

**UNIVERSITATEA TEHNICĂ “GHEORGHE
ASACHI” DIN IAȘI**

**Facultatea de Electronică, Telecomunicații și Tehnologia
Informației**



**CONTRIBUȚII ASUPRA METODELOR DE ANALIZĂ A
SEMNALULUI ELECTROENCEFALOGRAFIC ÎN EPILEPSIE**

- TEZĂ DE DOCTORAT -

Doctorand: Bioing. Mădălina-Giorgiana Murariu

Conducător de doctorat: Prof.univ.dr.ing. Daniela Tărniceriu

IAȘI, 2025

UNIVERSITATEA TEHNICĂ “GHEORGHE ASACHI” DIN IAȘI
R E C T O R A T U L

Către

Vă facem cunoscut că, în ziua de 16 Iunie 2025 la ora 10:00 în Aula Magna “Carmen Sylva” a Universității Tehnice „Gheorghe Asachi” din Iași, va avea loc susținerea publică a tezei de doctorat intitulată:

**“CONTRIBUȚII ASUPRA METODELOR DE ANALIZĂ A SEMNALULUI
ELECTROENCEFALOGRAFIC ÎN EPILEPSIE”**

elaborată de doamna Bioing. **Mădălina-Giorgiana MURARIU**, în vederea conferirii titlului științific de doctor.

Comisia de doctorat este alcătuită din:

- | | |
|---|------------------------|
| 1. Prof.univ.dr.ing. Bozomitu Radu Gabriel, Universitatea Tehnică "Gheorghe Asachi", Iași | președinte |
| 2. Prof.univ.dr.ing. Tărniceriu Daniela, Universitatea Tehnică "Gheorghe Asachi", Iași | conducător de doctorat |
| 3. Prof.univ.dr.ing. Burileanu Corneliu, Universitatea Națională de Știință și Tehnologie Politehnica București | - referent oficial |
| 4. Prof.univ.dr.ing. Rusu Corneliu Gheorghe, Universitatea Tehnică Cluj-Napoca | referent oficial |
| 5. Conf.univ.dr.ing. Cleju Nicolae, Universitatea Tehnică "Gheorghe Asachi", Iași | referent oficial |

Cu această ocazie vă invităm să participați la susținerea publică a tezei de doctorat.

RECTOR,

.....

Secretar universitate,

.....

Mulțumiri

Această lucrare nu ar fi fost posibilă fără sprijinul și îndrumarea unor oameni valoroși, cărora le sunt profund recunoscătoare.

În primul rând, doresc să îi mulțumesc doamnei prof. univ. dr. ing. Daniela Tărniceriu, conducătorul științific al acestei teze de doctorat, pentru încrederea acordată, pentru îndrumarea constantă, pentru răbdarea și pentru modul în care a știut să mă ghideze nu doar ca profesor, ci și ca om. Dedicarea, implicarea și rigoarea cu care m-a susținut, au făcut posibilă realizarea acestei teze de doctorat și, dincolo de orice, au contribuit la formarea mea profesională. Îi sunt profund recunoscătoare pentru încrederea pe care mi-a insuflat-o, mai ales în acele momente în care rezultatele nu păreau promițătoare.

De asemenea, adresez sincere mulțumiri doamnei prof. univ. dr. ing. Anca-Mihaela Lazăr, pentru sprijinul constant oferit pe întreaga durată a acestui parcurs academic. Îi sunt recunoscătoare nu doar pentru implicarea în perioada realizării tezei, ci mai ales pentru faptul că mi-a fost alături încă din timpul studiilor de master, când mi-a ghidat pașii spre cercetare, mi-a deschis perspective și m-a încurajat să urmez drumul doctoratului.

Îi mulțumesc cu recunoștință domnului dr. Bogdan Florea, pentru că a făcut posibilă desfășurarea acestei lucrări și i-a oferit o valoare științifică reală prin colaborarea constantă, disponibilitatea și sprijinul oferit în prelucrarea datelor clinice. Fără deschiderea, încurajările și răspunsurile domniei sale — dintre care primul răspuns la solicitările mele mi-a rămas profund întipărit: „Cu mare prețuire pentru cei curajoși” — această lucrare nu ar fi fost posibilă.

Mulțumiri deosebite adresez comisiei de îndrumare, domnului prof. univ. dr. ing. Radu Gabriel Bozomitu, domnului conf. dr. ing. Ciprian Comșa, domnului conf. dr. ing. Lucian-Vasile Trifina, pentru sprijinul acordat în etapele importante ale cercetării și pentru disponibilitatea de a analiza cu atenție parcursul lucrării mele. Recomandările și încurajările primite au avut un rol esențial în structurarea corectă a demersului științific.

De asemenea, mulțumesc comisiei de evaluare, domnului prof. univ. dr. ing. Burileanu Corneliu, domnului prof. univ. dr. ing. Rusu Corneliu Gheorghe, domnului conf.univ.dr.ing. Cleju Nicolae, pentru timpul, atenția și rigoarea cu care a analizat această lucrare. Mă onorează faptul că o comisie atât de valoroasă a acceptat să evalueze rezultatele muncii mele și să contribuie la validarea finală a acestei etape din parcursul academic.

În plan personal, le sunt profund recunoscătoare familiei mele, care mi-a fost alături cu răbdare, discreție și încredere.

În final, dau această lucrare mai departe ca o formă de recunoștință.

O dedic, cu profund respect, soțului meu, George-Adelin, care mi-a fost sprijin necondiționat în toți acești ani, și domnului dr. Bogdan Florea, al cărui profesionalism și ajutor au avut un rol important în parcursul acestei lucrări.

Cuprins

Capitolul 1.....	1
Introducere	1
1.1 Actualitatea și importanța temei	1
1.2 Scopul cercetării	1
1.3 Structura și conținutul tezei de doctorat	2
Capitolul 2.....	3
Baze teoretice	3
2.1 Introducere	3
2.2 Activitatea cerebrală în epilepsie și semnalele EEG	3
2.3 Metode de detecție a epilepsiei și de extragere de trăsături.....	6
2.4 Metode de clasificare a epilepsiei.....	6
2.5 Baza de date	7
2.6 Metodologie și metode	7
Capitolul 3.....	9
Clasificarea semnalelor EEG epileptice focale și non-focale utilizând metode bazate pe analiza spectrală de ordin superior	9
3.1 Introducere	9
3.2 Clasificarea semnalelor EEG cu abordarea HOSA I (bispectrul și bicoerența)	9
3.3 Clasificarea semnalelor EEG cu abordarea HOSA II (10% bispectru și 90% bicoerență)	10
3.4 Concluzii.....	10
Capitolul 4.....	11
Clasificarea semnalelor EEG epileptice focale, non-focale și generalizate utilizând metode bazate pe descompunerea empirică a semnalelor și combinații de mărimi statistice.....	11
4.1 Introducere	11
4.2 Metoda empirică de descompunere a semnalelor în combinație cu densitatea spectrală de putere	11
4.3 Metoda empirică de descompunere a semnalelor în combinație cu patru mărimi statistice	16
4.4 Concluzii.....	20
Capitolul 5.....	21

Clasificarea semnalelor EEG epileptice focale și generalizate utilizând metode bazate pe Transformata Empirică Wavelet și combinații de mărimi statistice	21
5.1 Introducere	21
5.2 Metoda EWT în combinație cu patru mărimi statistice	21
5.4 Metoda EWT în combinație cu șase mărimi statistice.....	24
5.5 Concluzii.....	26
Capitolul 6.....	27
Clasificarea semnalelor EEG epileptice focale și generalizate utilizând metode bazate pe tehnici empirice avansate de descompunerea a semnalelor	27
6.1 Introducere	27
6.2 Metoda empirică de descompunere a semnalului în moduri cu ansambluri (EEMD).....	27
6.3 Metoda empirică de descompunere completă a semnalului în moduri folosind ansambluri cu zgomot adaptiv (CEEMDAN)	29
6.4. Analiza comparativă a metodelor adaptive dezvoltate	31
6.5 Concluzii.....	32
Capitolul 7.....	33
Concluzii finale, contribuții proprii și direcții de cercetare viitoare	33
7.1 Concluzii finale.....	33
7.2 Contribuții proprii.....	34
7.3 Direcții viitoare de cercetare.....	35
Lista lucrărilor elaborate pe parcursul tezei.....	36
Bibliografie selectivă.....	38

Capitolul 1

Introducere

1.1 Actualitatea și importanța temei

Domeniul procesării semnalelor biomedicale a cunoscut o dezvoltare accelerată, susținută de avansul tehnologiilor de achiziție, creșterea capacității de procesare și extinderea aplicațiilor clinice. În mod special, analiza automată a semnalelor electroencefalografice (EEG) a devenit o direcție prioritară de cercetare, datorită potențialului său de a sprijini diagnosticul rapid și obiectiv în afecțiuni neurologice complexe, precum epilepsia.

Epilepsia reprezintă una dintre cele mai frecvente și complexe tulburări neurologice, afectând aproximativ 50 de milioane de persoane la nivel global, indiferent de vârstă, sex sau origine etnică. Manifestările clinice variate — de la convulsii și pierderi de conștiență până la simptome senzoriale și motorii atipice — sunt generate de descărcări electrice anormale la nivel cerebral, asociate adesea cu leziuni structurale, predispoziții genetice sau tulburări metabolice [1].

Diagnosticul epilepsiei se bazează în principal pe analiza activității cerebrale prin electroencefalografie. Cu toate acestea, metodele clinice tradiționale presupun procesări complexe și implică un grad ridicat de subiectivitate, putând duce la erori de diagnostic sau întârzieri în inițierea tratamentului [2].

În acest context, dezvoltarea unor metode automate de analiză a semnalelor EEG capătă o importanță majoră. Acestea oferă posibilitatea identificării rapide și precise a activității epileptice, facilitând diferențierea între formele de epilepsie. Cercetările recente în domeniu [3], subliniază potențialul acestor sisteme de a deveni instrumente standard în practica medicală, contribuind semnificativ la îmbunătățirea calității vieții pacienților și la eficientizarea intervențiilor clinice.

1.2 Scopul cercetării

Preocuparea pentru sprijinirea pacienților diagnosticați cu epilepsie, o afecțiune neurologică cu multiple forme de manifestare, a stat la baza dezvoltării acestei lucrări. Motivată de o curiozitate științifică robustă și de aspirația de a aduce valoare în domeniul procesării semnalelor biomedicale, am concentrat această cercetare pe analiza semnalelor EEG ale pacienților cu epilepsie, cu scopul de a dezvolta algoritmi automați capabili să clasifice și să identifice diferitele tipuri de epilepsie.

Metodele propuse vizează eficientizarea procesului de diagnosticare și reducerea timpului de interpretare, contribuind, astfel, la îmbunătățirea calității vieții pacienților.

Obiectivele acestei teze sunt reprezentate de:

- studierea epilepsiei prin prisma multiplelor sale forme de manifestare;
- constituirea unei baze de date EEG prin colaborare cu specialiști din domeniul medical;
- dezvoltarea de metode automate de identificare și de clasificare a tipului de epilepsie;
- prelucrarea bazelor de date EEG epileptice în scopul îmbunătățirii acurateței de diagnostic;
- optimizarea performanței sistemelor de diagnostic și sprijinirea deciziilor clinice obiective.

Prin aplicarea tehnicilor de analiză detaliată asupra semnalelor EEG, cercetarea a condus la crearea unor modele avansate de clasificare, cu potențial de implementare în practica medicală. Aceste soluții pot

contribui la reducerea incidenței și severității crizelor epileptice, precum și la integrarea într-un protocol de diagnostic modern, adaptat nevoilor reale ale pacienților.

1.3 Structura și conținutul tezei de doctorat

Teza de doctorat este structurată în șapte capitole și însumează un total de 167 de pagini.

Primul capitol oferă o introducere în domeniul de studiu, subliniind relevanța temei în contextul diagnosticării epilepsiei, sunt prezentate obiectivele cercetării și structura tezei.

În **capitolul al doilea** se prezintă metodele existente de detecție și clasificare a epilepsiei, evidențiindu-se necesitatea unor abordări automatizate pentru îmbunătățirea diagnosticului. În acest capitol sunt descrise bazele de date EEG utilizate în cercetare: baza publică Bern-Barcelona, cu înregistrări intracraniene de la pacienți cu epilepsie de lob temporal, și baza privată Cluj-Napoca, care conține semnale EEG neinvazive de la pacienți cu epilepsie focală și generalizată, înregistrate în stare de veghe și în timpul somnului.

În următoarele patru capitole sunt prezentate rezultatele obținute cu metodele dezvoltate și implementate pentru identificarea tipului de epilepsie.

În **capitolul al treilea** sunt implementate două metode de clasificare a semnalelor EEG epileptice în focale și non-focale, bazate pe analiza spectrală de ordin superior, utilizând bispectrul și bicoerența. Cercetarea a fost aplicată pe baza de date EEG Bern-Barcelona. Prima metodă se bazează pe patru indici cantitativi calculați pe baza bispectrului și a bicoerenței, iar clasificarea a fost realizată cu patru algoritmi, dintre care clasificatorul cel mai apropiat - vecin (K-nearest neighbour - KNN), a oferit cele mai bune rezultate. A doua metodă dezvoltată optimizează vectorul de trăsături din etapa de clasificare prin ajustarea ponderii între bispectru și bicoerență, cea mai eficientă combinație fiind 10% bispectru și 90% bicoerență. Rezultatele obținute cu cele două abordări propuse confirmă eficiența acestora și relevanța utilizării analizelor spectrale avansate pentru clasificarea semnalelor EEG epileptice.

În **capitolul al patrulea** este abordată clasificarea semnalelor EEG epileptice în trei categorii: focale, non-focale și generalizate, implementând două abordări bazate pe metoda empirică de descompunere a semnalelor (Empirical Mode Decomposition - EMD), în combinație cu diverse mărimi statistice. Prima abordare este aplicată pe ambele baze de date EEG, semnalele sunt descompuse în șase componente frecvențiale denumite funcții de mod intrinsec (Intrinsic Mode Function - IMF), iar pentru fiecare IMF se calculează densitatea spectrală de putere, utilizată ulterior în etapa de clasificare cu algoritmi KNN și Naïve Bayes (NB). Cea de-a doua abordare, este aplicată pe baza de date EEG Cluj-Napoca, pentru fiecare IMF s-au calculat patru mărimi statistice (mediana, skewness, kurtosis și indicele de fluctuație), iar clasificarea s-a realizat cu KNN. Ambele metode s-au dovedit eficiente, cu performanțe ridicate în special pentru semnalele înregistrate în timpul somnului.

În **capitolul al cincilea** sunt dezvoltate două noi metode de clasificare a semnalelor EEG focale și generalizate, utilizând Transformata Empirică Wavelet (Empirical Wavelet Transform - EWT), în combinație cu indicatori statistici și clasificatori. Metodele propuse sunt aplicate pe baza de date EEG Cluj-Napoca. Prima metodă utilizează EWT și patru mărimi statistice, iar semnalele EEG sunt clasificate folosind clasificatorii KNN și NB. Cea de-a doua abordare extinde analiza prin includerea a șase mărimi statistice și aplicarea metodei doar pe semnalele EEG înregistrate în timpul somnului pe canalele pre-frontale Fp1 - lobul stâng și Fp2 - lobul drept. După descompunerea semnalelor în cinci benzi de frecvență corespunzătoare ritmurilor cerebrale (delta, theta, alfa, beta și gamma), se compune vectorul de trăsături pentru fiecare bandă, iar semnalele sunt clasificate cu șase clasificatori, inclusiv clasificatorul cu suport vectorial (support vector machine - SVM) și arborele de decizie fină (Fine Decision Tree - Fine Tree). S-a

efectuat testul statistic Kruskal-Wallis, evidențiindu-se diferențe semnificative între activitatea epileptică focală și generalizată, cu performanțe superioare de clasificare pe canalul Fp1, în special în benzile delta, beta și gamma.

În *capitolul al șaselea* sunt implementate două metode avansate de clasificare a semnalelor EEG, bazate pe tehnici de descompunere empirică: metoda de descompunere empirică a semnalului în moduri cu ansambluri (Ensemble Empirical Mode Decomposition - EEMD) și metoda de descompunere completă a semnalului în moduri folosind ansambluri cu zgomot adaptiv (Complete Ensemble Empirical Mode Decomposition with Adaptive Noise - CEEMDAN). Acestea sunt aplicate pe semnalele EEG înregistrate în timpul somnului, din baza de date Cluj-Napoca. Pentru fiecare semnal sunt extrase cinci componente IMF, pentru care s-au calculat patru mărimi statistice. Clasificarea a fost realizată cu clasificatorii KNN și NB. Capitolul include și o comparație detaliată între toate metodele dezvoltate în cadrul tezei, aplicate pe aceleași date. Rezultatele au arătat că metoda CEEMDAN oferă cele mai bune performanțe în clasificarea epilepsiei, depășind performanțele de clasificare ale metodelor EMD, EWT și EEMD.

În *capitolul al șaptelea* sunt sintetizate concluziile finale, contribuțiile personale, diseminarea rezultatelor științifice obținute în cadrul stagiului de doctorat și propune direcții viitoare de cercetare. Acest capitol reprezintă o încheiere a lucrării de doctorat, consolidând relevanța și impactul metodelor dezvoltate în clasificarea semnalelor EEG pentru diagnosticarea epilepsiei.

Capitolul 2

Baze teoretice

2.1 Introducere

Epilepsia este o afecțiune neurologică manifestată prin crize necontrolate, cauzate de descărcări electrice anormale la nivelul creierului. Aceasta se clasifică în două forme principale: focală, în care focarele epileptice sunt localizate într-o zonă specifică a creierului, și generalizată, în cadrul căreia focarele sunt răspândite în ambele emisfere cerebrale [4].

Crizele pot varia de la episoade scurte de pierdere a conștienței până la convulsii severe, iar identificarea corectă a tipului de epilepsie este esențială pentru inițierea unui tratament adecvat. Intervenția terapeutică timpurie poate preveni agravarea manifestărilor clinice. În ciuda progreselor tehnologice, precum electroencefalografia, diagnosticul epilepsiei rămâne o provocare, motiv pentru care sunt necesare metode automate avansate care să sprijine deciziile clinice și să contribuie la îmbunătățirea calității vieții pacienților.

2.2 Activitatea cerebrală în epilepsie și semnalele EEG

Înregistrarea activității electrice a creierului reprezintă un aspect esențial în cercetarea neuroștiințifică și în diagnosticul afecțiunilor neurologice. Printre metodele utilizate în acest scop se numără electroencefalografia, magnetoencefalografia, tomografia computerizată cu emisie de foton unic, tomografia computerizată cu emisie de pozitroni și imagistica prin rezonanță magnetică funcțională. Aceste tehnici imagistice furnizează informații valoroase despre activitatea electrică și funcționarea globală a creierului, facilitând astfel diagnosticul afecțiunilor cerebrale [5].

Electroencefalografia presupune captarea semnalelor EEG cu ajutorul electrozilor cuplați la un dispozitiv medical numit electroencefalograf. Acești electrozi pot fi utilizați în două moduri: non-invaziv, prin plasarea lor pe scalpul pacientului, sau invaziv, prin implantarea directă la nivelul cortexului [5]. Electroencefalografii monitorizează activitatea electrică a creierului folosind cele două tipuri de electrozi, captând impulsurile neuronale generate de câmpul electromagnetic al creierului. Electroencefalograma este înregistrarea grafică a activității electrice a creierului, captată de electroencefalograf. Aceasta reflectă semnalele electrice generate de activitatea neuronală, măsurate în microvolți (μV) [6].

Activitatea electrică a creierului în timpul unei crize epileptice poate fi evaluată cu ajutorul înregistrărilor EEG, care oferă informații valoroase despre răspunsul cerebral și localizarea precisă a descărcărilor epileptice. Deși ideală în managementul pacienților, captarea EEG în timpul unei crize este dificil de realizat în practică. Astfel, diagnosticul epilepsiei se bazează frecvent pe înregistrări EEG interictale, unde pot fi identificate activități epileptiforme caracteristice, precum vârfuri și unde ascuțite, asociate puternic cu prezența epilepsiei [7]. Fiecare tip de activitate cerebrală este asociat cu ritmurile cerebrale utilizate în analiza componentelor EEG [8]. Ritmurile cerebrale sunt bine definite și includ benzi de frecvență specifice, recunoscute pentru asocierea lor cu diferite stări cognitive și activități cerebrale. De exemplu, undele de frecvență joasă (delta și theta) predomină în timpul somnului, în timp ce un semnal EEG obținut în timpul stărilor de veghe corespunde undelor de frecvență înaltă (alfa și beta). Analiza acestora este esențială pentru înțelegerea activității cerebrale și pentru diagnosticarea afecțiunilor neurologice. În continuare sunt prezentate succint bine cunoscutele ritmuri cerebrale.

Activitatea electrică cerebrală în timpul unei crize epileptice se caracterizează prin prezența unor modele specifice de unde EEG, precum spike-uri, polyspike-uri, unde ascuțite, complexe vârf-undă lentă și unde conturate cu tipar distinct.

- Spike-urile sunt descărcări bruște și sincrone ale neuronilor, cu durată de 20–70 ms, de regulă asimetrice și adesea urmate de unde lente. Un spike este de obicei asimetric (cu o pantă ascendentă mai abruptă decât cea descendentă, dar poate fi și invers).
- Undele sau vârfurile cu aspect ascuțit prezintă deflecții bruște și ascuțite ale undelor EEG, cu o durată de 70-200 ms, fiind mai lungi decât spike-urile, dar totuși diferite de activitatea de fond.
- Polyspike-urile constau în succesiuni rapide de două sau mai multe spike-uri cu durată totală sub 0.5 secunde.
- Undele ascuțite conturate combină o componentă ascuțită și una lentă, având durată de peste 200 ms și o structură mai complexă decât celelalte forme.

Prezența acestor tipare EEG este corelată cu formele clinice de epilepsie și cu localizarea focarelor epileptogene în creier. În plus, pot apărea și alte modele caracteristice, precum activitatea ritmică și sincronizată în benzile theta, delta sau alfa, în anumite regiuni cerebrale, în timpul crizelor. Analiza detaliată a acestor modele oferă clinicienilor informații esențiale pentru stabilirea tipului de epilepsie și identificarea zonelor implicate în generarea descărcărilor epileptice [9].

Diagnosticul de epilepsie se stabilește pe baza înregistrării EEG din starea de veghe, din timpul somnului de siestă sau din timpul somnului de noapte.

Activitatea EEG variază semnificativ între starea de veghe și cea din timpul somnului, prezentând oscilații electroencefalografice distincte în cazul persoanelor sănătoase. În starea de veghe, activitatea EEG este caracterizată de unde rapide și variate, în timp ce în somnul profund sunt observate unde lente, cu amplitudine mai mare. Analiza comparativă a activității EEG în starea de veghe și în timpul somnului este esențială pentru evaluarea completă a activității cerebrale la pacienții cu epilepsie [42], motiv pentru care

în cadrul acestei cercetări doctorale s-au utilizat înregistrări EEG epileptice atât din starea de veghe cât și din timpul somnului.

În cadrul acestei cercetări a fost utilizată o bază de date EEG privată, obținută prin colaborare cu Centrul de Epilepsie și Monitorizare EEG din Cluj-Napoca, România. Accesul la datele anonimizate a fost oferit cu aprobarea Comisiei de Etică și pe baza consimțământului informat al pacienților. Baza de date include înregistrări EEG de la pacienți diagnosticați cu epilepsie focală și generalizată. În scop ilustrativ, sunt prezentate două exemple de înregistrări EEG selectate din acest set, evidențiind diferențele de manifestare și de tipar electroencefalografic ale crizelor epileptice.



Figura 2.1 Traseul EEG - bufeu de complexe vârf-undă lentă generalizat – Subiect nr. 7 (Centrul de Epilepsie și Monitorizare EEG, Cluj-Napoca)

În înregistrarea EEG prezentată în Fig. 2.1, obținută în stare de veghe de la un pacient cu epilepsie generalizată, se observă încă de la debutul crizei un bufeu de complexe vârf-undă lentă, cu distribuție generalizată pe toate canalele. Activitatea are o durată de aproximativ 4 secunde și este mai accentuată pe derivațiile anterioare, aspect care susține încadrarea traseului EEG într-un tablou de epilepsie primar generalizată.

În înregistrarea EEG din Fig. 2.2, realizată în timpul somnului la un pacient cu epilepsie generalizată, se observă complexe vârf-undă lentă, inițial sub forma unor bufeuri scurte, cu durată de până la o secundă, urmate de secvențe ușor prelungite, de până la două secunde. Aspectul înregistrării susține diagnosticul de epilepsie primar generalizată.




Figura 2.2 Traseul EEG - bucă de complexe vârf-undă lentă – Subiect nr. 2 (Centrul de Epilepsie și Monitorizare EEG, Cluj-Napoca)

2.3 Metode de detecție a epilepsiei și de extragere de trăsături

Pentru un diagnostic precis al epilepsiei, cercetările recente s-au concentrat pe dezvoltarea unor metode automate capabile să clasifice cu acuratețe semnalele EEG. Datorită caracterului complex și nestăionar al acestor semnale, au fost propuse multiple abordări, de la metode temporale și spectrale până la tehnici avansate de analiză timp-frecvență și metode neliniare. Analiza spectrală tradițională, deși eficientă computațional, nu surprinde dinamica temporală a semnalelor, motiv pentru care au fost introduse metode precum, Transformata Fourier pe termen scurt, analiza pe componente principale (Principal Component Analysis - PCA) și Transformata Wavelet, capabile să ofere o localizare mai precisă a frecvențelor în timp.

Metodele moderne de procesare, cum ar fi EMD, decompunerea variațională a semnalului (Variational Mode decomposition - VMD), EEMD și CEEMDAN, [10,11] permit o descompunere adaptivă a semnalelor EEG, evidențiind componente relevante pentru detecția epilepsiei. În paralel, s-au dezvoltat tehnici de învățare automată care clasifică semnalele în funcție de tipul de activitate epileptică, pe baza trăsăturilor extrase: parametri statistici, entropii și măsuri neliniare. Combinarea acestor metode contribuie la îmbunătățirea semnificativă a acurateței diagnosticului și oferă perspective promițătoare pentru aplicarea practică în epilepsie [12].

2.4 Metode de clasificare a epilepsiei

Clasificarea tipului de epilepsie reprezintă un pas esențial în stabilirea unui diagnostic corect și a unei strategii terapeutice personalizate. Aceasta implică extragerea de trăsături relevante din semnalele EEG și utilizarea unor clasificatori capabili să diferențieze activitatea epileptică focală de cea generalizată. În acest context, cercetarea a integrat metode de prelucrare avansate, bazate pe caracteristici temporale, spectrale, neliniare și statistice, pentru a construi vectori de trăsături.

Au fost utilizate metode tradiționale de clasificare, precum Naïve Bayes, KNN, analiza discriminantă liniară (Linear Discriminant Analysis – LDA) [13], analiza discriminantă pătratică (Quadratic Discriminant Analysis - QDA) [14] și distanța Mahalanobis (Mahalanobis distance - MD), alături de algoritmi moderni de învățare automată, cum ar fi clasificatorul, rețelele neuronale artificiale (ANN) și arborii de decizie (Fine Tree) [15]. Aceste modele au fost aplicate în contexte supervizate și nesupervizate, cu scopul de a detecta tipare în datele EEG și de a optimiza performanța în clasificarea semnalelor epileptice.

2.5 Baza de date

O bază de date bine documentată și structurată este esențială în domeniul biomedical, reprezentând un element-cheie în dezvoltarea de metode fiabile de diagnostic. În această cercetare au fost utilizate două baze de date EEG care conțin înregistrări intracraniene și de pe scalp de la pacienți diagnosticați cu epilepsie, oferind suport validării metodelor propuse.

Baza de date Bern–Barcelona este recunoscută în literatura de specialitate [16], și conține 3750 de înregistrări EEG focale și 3750 non-focale, înregistrate intracranian de la cinci pacienți cu epilepsie de lob temporal. Semnalele au fost eșantionate la 512 Hz sau 1024 Hz, segmentate în intervale de 20 secunde și filtrate digital cu un filtru Butterworth (0.5–150 Hz). Fiecare pereche de semnale EEG include o înregistrare din zona focală sau non-focală, notată cu x și una de pe un canal adiacent, notată cu y , etichetarea fiind validată de cel puțin doi neurologi.

Baza de date Cluj-Napoca include semnale EEG neinvazive interictale de la 50 de pacienți (34 femei, 16 bărbați, cu vârste între 2 și 66 de ani), înregistrate în stare de veghe, somn de siestă și somn nocturn. Baza de date constă în 16 înregistrări din timpul somnului, 5 înregistrări din timpul somnului de siestă și 30 de înregistrări din starea de veghe, cu semnale focale și generalizate. Înregistrările au fost realizate cu sistemul Nicolet Natus, folosind protocolul internațional 10–20 și o frecvență de eșantionare de 1000 Hz. Canalele utilizate acoperă toate zonele majore ale cortexului cerebral. Pacienții au fost diagnosticați cu un anumit tip de epilepsie, epilepsie focală/parțială, epilepsie focală cu generalizare secundară sau epilepsie primar generalizată. Această bază de date a oferit suport esențial în dezvoltarea, testarea și validarea metodelor propuse, contribuind la asigurarea calității datelor și la relevanța clinică a rezultatelor. Colaborarea constantă cu specialiștii din centrul medical a permis evaluarea comparativă a metodelor și identificarea celor mai eficiente abordări de clasificare a epilepsiei.

2.6 Metodologie și metode

Această cercetare a urmat o metodologie structurată și sistematică, având ca scop analiza și clasificarea semnalelor EEG în vederea diagnosticării precise a epilepsiei. Metodologia propusă combină tehnici avansate de prelucrare a semnalelor, extragerea caracteristicilor și aplicarea diferiților clasificatori. Procesul de cercetare a fost realizat în următoarele etape:

1. *Achiziționarea semnalelor EEG*
2. *Preprocesarea semnalelor*
3. *Alegerea metodei și extragerea caracteristicilor*
4. *Construirea vectorului de trăsături*
5. *Alegerea clasificatorilor*
6. *Combinarea metodelor cu mărimi statistice și clasificatori*
7. *Identificarea tipului de epilepsie și validarea metodei*




Figura 2.3 Metodologia pentru analiza și clasificarea semnalelor EEG în diagnosticarea epilepsiei

Metodologia propusă în această teză a inclus dezvoltarea și aplicarea unor metode avansate de analiză și clasificare a semnalelor EEG epileptice, cu scopul identificării rapide și precise a tipului de epilepsie. Au fost concepute și implementate opt metode originale, rezultate din combinarea algoritmilor de descompunere a semnalelor, a unor seturi variate de mărimi statistice și a diversilor clasificatori.

1. **Analiza spectrală de ordin superior** a fost utilizată în două abordări:
 - în combinație cu bispectrul și bicoerența, utilizând clasificatorii LDA, QDA, MD și KNN;
 - în combinație cu bispectrul (10%) și bicoerența (90%), utilizând clasificatorul KNN.
2. **Metoda bazată pe descompunerea empirică a semnalului în moduri** a fost utilizată în două abordări:
 - în combinație cu densitatea spectrală de putere și cu clasificatorii KNN și NB;
 - în combinație cu mediana, skewness, kurtosis și indicele de fluctuație, și cu clasificatorul KNN.
3. **Metoda bazată pe Transformata Empirică Wavelet** a fost utilizată în două abordări:
 - în combinație cu mediana, skewness, kurtosis, indicele de fluctuație, și cu clasificatorii KNN și NB;
 - în combinație cu mediana, skewness, kurtosis, entropia estimării imparțiale a riscului lui Stein, entropia de prag și correntropia centrată, și cu clasificatorii Fine Tree, LDA, NB, KNN, Fine KNN, SVM liniar și SVM Kernel.
4. **Metoda bazată pe descompunerea empirică a semnalului în moduri cu ansambluri** este aplicată în combinație cu mediana, skewness, kurtosis și indicele de fluctuație, și cu clasificatorii KNN și NB.
5. **Metoda bazată pe descompunerea empirică a semnalului în ansambluri complete cu zgomot adaptiv** este aplicată în combinație cu mediana, skewness, kurtosis și indicele de fluctuație, iar clasificarea s-a realizat cu clasificatorii KNN și NB.

Capitolul 3

Clasificarea semnalelor EEG epileptice focale și non-focale utilizând metode bazate pe analiza spectrală de ordin superior

3.1 Introducere

Clasificarea semnalelor EEG epileptice constituie o provocare importantă atât în neurologie, cât și în domeniul procesării semnalelor biomedicale. Detectarea și încadrarea corectă a acestora sunt esențiale pentru stabilirea unui diagnostic precis și pentru aplicarea unui tratament adecvat în cazul epilepsiei.

În acest capitol sunt propuse două metode de analiză spectrală de ordin superior, HOSA I și HOSA II, concepute pentru a investiga în detaliu componentele de frecvență ale semnalelor EEG. Aceste metode au capacitatea de a surprinde variațiile subtile ale spectrului de putere asociate activității epileptice, oferind astfel un suport valoros pentru diferențierea semnalelor focale de cele non-focale.

Metodele propuse au fost dezvoltate în urma unei analize atente a literaturii de specialitate, unde eficiența abordărilor spectrale a fost frecvent confirmată prin rezultate remarcabile în clasificarea semnalelor epileptice [17]. În această cercetare, metodele au fost implementate în combinație cu patru clasificatori tradiționali, fiecare testat în contextul diferențierii semnalelor EEG focale și non-focale, pe baza caracteristicilor extrase.

Metodele au fost aplicate pe baza de date EEG Bern-Barcelona, iar în continuare sunt prezentate metodologia detaliată, rezultatele obținute, precum și avantajele și limitările fiecărei abordări. Aceste contribuții urmăresc îmbunătățirea preciziei clasificării și susținerea procesului de diagnostic în epilepsie.

Metodele propuse au fost aplicate pe baza de date Bern-Barcelona, s-a utilizat un set de date constând din 100 de semnale EEG focale și 100 de semnale EEG non-focale. Algoritmii dezvoltați au fost implementați în mediul de programare MATLAB. S-au utilizat doar semnalele EEG de pe canalul x . Spectrele de ordin superior, bispectrul și bicoerența au fost calculate pentru fiecare semnal EEG, pentru compunerea vectorului de trăsături necesar în etapa de clasificare a epilepsiei [18]. Pentru clasificarea semnalelor au fost utilizați patru clasificatori: LDA, QDA, MD și KNN, iar evaluarea performanței s-a făcut prin validare încrucișată cu 10 subseturi, folosind indicatori precum rata de clasificare, sensibilitate, specificitate, Scorul-F1, Coeficientul de corelație Matthews (Matthews Correlation Coefficient - MCC) și coeficientul Kappa.

3.2 Clasificarea semnalelor EEG cu abordarea HOSA I (bispectrul și bicoerența)

În prima abordare propusă (HOSA I), clasificarea semnalelor EEG focale și non-focale s-a realizat pe baza a patru indici cantitativi extrași în proporții egale din bispectru și bicoerență. Acești indicatori au fost calculați pentru zece regiuni de frecvență și utilizați pentru construirea vectorului de trăsături. Clasificarea s-a realizat folosind patru algoritmi: LDA, QDA, distanța Mahalanobis și KNN. În Tabelul 3.1 sunt prezentate rezultatele de clasificare obținute cu prima abordare HOSA.

Tabelul 3.1 Rezultate de clasificare – Abordare HOSA I

	LDA(%)			QDA(%)			MD(%)			KNN(%)		
	RC	Senz	Spec	RC	Senz	Spec	RC	Senz	Spec	RC	Senz	Spec
<i>Min</i>	40.95	22.21	19.47	37.22	41.37	34.02	45.70	51.24	16.73	57.35	37.77	54.32
<i>Max</i>	95.79	99.09	100	98	100	99.09	98	100	99.09	98.04	100	100
<i>Media</i>	74.87	71	79.62	77.01	84.27	70.20	77.27	85.96	68.94	80.75	77.83	83.96
<i>Mediana</i>	76.81	75.07	84.96	78.62	86.13	73.51	76.94	86.18	73.22	81.85	79.61	88.39

RC – reprezintă rata de clasificare, Senz – sensibilitatea și Spec – specificitatea.

Clasificatorul KNN a condus la obținerea celor mai bune rezultate în discriminarea semnalelor EEG focale și non-focale, cu valoarea mediană a ratei de clasificare de 81.85%.

Rezultatele au evidențiat performanța superioară și stabilă a clasificatorului KNN, care a obținut cele mai bune scoruri în termeni de acuratețe, sensibilitate, specificitate, Scor-F1, MCC și coeficient Kappa, demonstrând eficiența metodei propuse în discriminarea semnalelor EEG epileptice.

3.3 Clasificarea semnalelor EEG cu abordarea HOSA II (10% bispectru și 90% bicoerență)

Cea de-a doua abordare HOSA a avut ca obiectiv optimizarea vectorului de trăsături prin ajustarea proporțiilor dintre componentele bispectrului și bicoerenței. Dintre combinațiile testate, raportul 10% bispectru – 90% bicoerență a oferit cele mai bune rezultate și a fost utilizat pentru clasificarea semnalelor EEG focale și non-focale cu ajutorul algoritmului KNN. În Tabelul 3.2 sunt prezentate rezultatele de clasificare ale semnalelor focale și non-focale obținute cu cea de-a doua abordare HOSA propusă, utilizând clasificatorul KNN.

Tabelul 3.2 Rezultate de clasificare utilizând clasificatorul KNN – Abordare HOSA II

	RC (%)	Senz (%)	Spec (%)
<i>Min</i>	67.72	52.10	71.23
<i>Max</i>	99.55	100	99.09
<i>Media</i>	88.53	84.99	92.22
<i>Mediana</i>	89.67	88.36	94.30

Performanțele metodei au fost evaluate prin rata de clasificare, sensibilitate și specificitate, obținându-se valori mediane ridicate (peste 88%) și o îmbunătățire semnificativă față de abordarea HOSA I. Comparativ cu alte metode din literatură aplicate pe aceeași bază de date (Bern–Barcelona), metoda propusă a demonstrat o capacitate superioară de discriminare, cu potențial real de aplicabilitate clinică în diagnosticarea epilepsiei.

3.4 Concluzii

Metodele de clasificare a semnalelor EEG epileptice propuse în această cercetare au demonstrat o capacitate ridicată de a sprijini procesul de diagnosticare a epilepsiei. Abordările dezvoltate pe baza analizei spectrale de ordin superior, prin utilizarea bispectrului și a bicoerenței, au permis extragerea de caracteristici relevante pentru diferențierea semnalelor EEG focale și non-focale, obținând performanțe comparabile sau superioare față de metodele raportate în literatura de specialitate.

Contribuții proprii:

- A fost propusă și testată o metodă originală de extragere a trăsăturilor, bazată pe **combinarea ponderată a bispectrului și bicoerenței**.
- S-au testat multiple proporții între cele două mărimi, identificându-se **raportul optim 10% bispectru – 90% bicoerență**, care nu a fost raportat anterior în literatura de specialitate.

Capitolul 4

Clasificarea semnalelor EEG epileptice focale, non-focale și generalizate utilizând metode bazate pe descompunerea empirică a semnalelor și combinații de mărimi statistice

4.1 Introducere

Având în vedere complexitatea epilepsiei focale și riscul de generalizare a acesteia, dezvoltarea unor metode automate de clasificare EEG este esențială pentru un diagnostic rapid și precis. În acest capitol sunt propuse două abordări originale pentru clasificarea semnalelor EEG în focale, non-focale și generalizate, aplicate pe două baze de date: Bern–Barcelona și Cluj-Napoca. Metodele propuse se bazează pe descompunerea empirică a semnalelor EEG și pe extragerea de diferite caracteristici din fiecare componentă extrasă, pentru ca ulterior să fie aplicați o serie de clasificatori pentru a discrimina între tipurile de epilepsie.

Un avantaj major al acestor metode îl constituie **validarea clinică** realizată pe baza de date privată, cu diagnostice confirmate de medicul neurolog care a supravegheat înregistrările EEG, ceea ce subliniază relevanța practică și potențialul de implementare al soluțiilor propuse.

4.2 Metoda empirică de descompunere a semnalelor în combinație cu densitatea spectrală de putere

Prima abordare EMD constă în descompunerea semnalelor EEG în șase componente de frecvențe diferite, urmată de calculul densității spectrale de putere pentru fiecare componentă (IMF), caracteristicile extrase fiind utilizate în formarea vectorului de trăsături, necesar în etapa de clasificare a semnalelor. Metoda este aplicată pe două baze de date, baza de date Bern-Barcelona și baza de date Cluj-Napoca. Semnalele sunt clasificate cu clasificatorii KNN și NB. Pentru a efectua clasificarea datelor s-a utilizat o procedură de validare încrucișată în zece etape. Pentru clasificatorul KNN s-a utilizat metrica distanței euclidiene și s-a setat un număr de 5 vecini. Performanța metodei de clasificare dezvoltată a fost evaluată prin intermediul a șase parametri: rata de clasificare, sensibilitatea, specificitatea, Scorul F1, Coeficientul de Corelație Matthews și Coeficientul Kappa. În Fig. 4.1 este prezentată succint schema bloc a metodei EMD propuse.




Figura 4.1 Diagrama metodei EMD de clasificare a semnalelor EEG epileptice

Metoda offline EMD în combinație cu densitatea spectrală a fost aplicată pe un nr. de 1000 de înregistrări EEG focale și 1000 de înregistrări EEG non-focale din baza de date Bern-Barcelona. În Fig. 4.2 și 4.3 sunt afișate primele șase componente de mod intrinsec extrase dintr-un semnal EEG focal și unul non-focal. Semnale utilizate au fost extrase în mod aleatoriu din baza de date. Fiecare subgrafic reprezintă o componentă IMF, acestea sunt ordonate de la IMF1 la IMF6 pe baza conținutului său de frecvență.

Analiza componentelor IMF extrase prin EMD a evidențiat diferențe semnificative între semnalele EEG focale și non-focale. IMF1 din semnalul focal prezintă frecvențe ridicate, amplitudine redusă și fluctuații rapide, în timp ce IMF2 are oscilații mai pronunțate și amplitudine mai mare. În semnalele non-focale, IMF1 are o amplitudine mai mare și fluctuații mai evidente față de cel focal, iar IMF2 menține o amplitudine relativ constantă, dar cu variații semnificative ale oscilațiilor. Pentru IMF3 și IMF4, ambele tipuri de semnale prezintă oscilații complexe, iar IMF5 și IMF6 sunt dominate de oscilații lente și de amplitudine mare.




Figura 4.2 Componentele IMF extrase prin metoda EMD – semnal focal (Baza de date Bern–Barcelona)




Figura 4.3 Componentele IMF extrase prin metoda EMD – semnal non-focal (Baza de date Bern–Barcelona)

Rezultatele obținute prin abordarea EMD propusă sunt prezentate în Tabelul 4.1.

Tabelul 4.1 Rezultatele de clasificare obținute cu KNN și NB prin metoda EMD – baza de date Bern – Barcelona

	Rata de clasificare (%)		Senzitivitate (%)		Specificitate (%)	
	KNN	NB	KNN	NB	KNN	NB
<i>Min</i>	73.95	74.70	74.01	74.85	73.18	72.32
<i>Max</i>	99.90	99.80	100	100	100	100
<i>Media</i>	90.78	90.76	91.08	91.09	90.48	90.44
<i>Mediana</i>	91.57	91.40	91.85	91.81	91.45	91.23
<i>Nr. de situații clasificate cu valori > 90%</i>	597	609	605	576	592	576

Rezultatele obținute cu prima abordare EMD arată performanțe ridicate de clasificare ale ambilor clasificatori testați, cu valori mediane ale ratelor de clasificare și ale parametrilor de evaluare (senzitivitate, specificitate) situate în jurul valorii de 91%. Peste 57% dintre cazuri au înregistrat rate de clasificare, senzitivitate și specificitate mai mari de 90%, evidențiind astfel eficiența și stabilitatea metodei propuse în discriminarea semnalelor EEG focale, non-focale și generalizate.

Metoda EMD combinată cu densitatea spectrală de putere a fost aplicată și pe baza de date EEG Cluj-Napoca, utilizând 30 de înregistrări din starea de veghe și 16 din timpul somnului. Clasificarea semnalelor EEG focale și generalizate a generat un total de 216 situații de clasificat pentru starea de veghe și 48 de situații pentru somn, permițând evaluarea performanței metodei în funcție de starea fiziologică a pacientului.

În Fig. 4.4 sunt prezentate componentele IMF extrase dintr-un semnal EEG focal, iar în Fig. 4.5 sunt prezentate componentele IMF extrase dintr-un semnal EEG generalizat - Subiect 8.

Analiza componentelor IMF extrase prin EMD evidențiază diferențe semnificative între semnalele EEG focale și generalizate. Componentele IMF din semnalele focale prezintă fluctuații rapide și amplitudini ridicate, în special în primele componente (IMF1–IMF2), sugerând o activitate cerebrală localizată, intensă și variabilă. În schimb, componentele IMF din semnalele generalizate indică o activitate mai stabilă și mai uniformă, cu amplitudini mai reduse și variații frecvențiale mai puțin pronunțate. Aceste observații susțin ipoteza conform căreia activitatea epileptică focală produce variații regionale mai marcate în semnalul EEG, comparativ cu activitatea generalizată.




Figura 4.4 Componentele IMF extrase prin metoda EMD – epilepsie focală (Baza de date Cluj–Napoca)




Figura 4.5 Componentele IMF extrase prin metoda EMD – epilepsie generalizată (Baza de date Cluj–Napoca)

Rezultatele de clasificare obținute sunt prezentate în Tabelele 4.2 - 4.3.

Tabelul 4.2 Rezultatele de clasificare obținute cu clasificatorul KNN pentru discriminarea între epilepsia focală și cea generalizată – baza de date Cluj–Napoca

	Rata de clasificare (%)		Senzitivitate (%)		Specificitate (%)	
	Veghe	Somn	Veghe	Somn	Veghe	Somn
<i>Min</i>	85.64	89.14	85.74	88.95	85.54	89.33
<i>Max</i>	99.47	98	99.89	100	99.52	99.81
<i>Media</i>	96.03	95.79	96.38	95.29	95.70	96.29
<i>Mediana</i>	96.11	96.39	96.49	96.06	96.09	96.53
<i>Nr. de situații clasificate cu valori > 90%</i>	211	47	214	47	209	47

Tabelul 4.3 Rezultatele de clasificare obținute cu clasificatorul NB pentru discriminarea între epilepsia focală și cea generalizată – baza de date Cluj–Napoca

	Rata de clasificare (%)		Senzitivitate (%)		Specificitate (%)	
	Veghe	Somn	Veghe	Somn	Veghe	Somn
<i>Min</i>	83.30	87.95	76.47	87.95	72.55	88.33
<i>Max</i>	99.20	98.40	99.61	100	99.22	99.61
<i>Media</i>	95.96	95.83	96.23	95.14	95.67	96.51
<i>Mediana</i>	96	96.10	96.49	95.81	95.91	96.88
<i>Nr. de situații clasificate cu valori > 90%</i>	213	47	214	46	210	48

Rezumatul performanțelor de clasificare cu KNN și Naïve Bayes evidențiază rezultate ridicate și consistente pentru identificarea semnalelor EEG focale și non-focale. Ambii clasificatori au obținut valori mediane ale ratei de clasificare și ale parametrilor senzitivitate și specificitate de peste 91%, înregistrând performanțe ridicate în peste jumătate dintre cazurile analizate. Aceste rezultate susțin robustețea metodei propuse în discriminarea eficientă a tipurilor de semnale EEG.

4.3 Metoda empirică de descompunere a semnalelor în combinație cu patru mărimi statistice

A doua abordare EMD este aplicată pe același set de date din baza Cluj–Napoca utilizat și în prima abordare EMD. Metoda implică extragerea a patru mărimi statistice (mediana, skewness, kurtosis și indicele de fluctuație) din fiecare componentă IMF, urmată de clasificarea semnalelor cu KNN. Această combinație de metodă, set de caracteristici și clasificator nu a fost anterior raportată în literatura de specialitate. În Fig.4.6 este prezentată succint schema bloc a metodei EMD propuse.




Figura 4.6 Diagrama metodei de clasificare a semnalelor EEG epileptice bazată pe EMD și patru mărimi statistice

În Fig. 4.7 și 4.8 sunt prezentate reprezentările grafice ale componentelor IMF extrase pentru un semnal focal și unul generalizat, pentru înregistrări EEG din timpul stării de veghe.




Figura 4.7 Componentele IMF extrase prin metoda bazată pe EMD și 4 mărimi statistice – epilepsie focală – stare de veghe (Baza de date Cluj-Napoca)

Analiza componentelor IMF extrase din semnalele EEG înregistrate în stare de veghe a evidențiat diferențe clare între epilepsia focală și cea generalizată. În cazul semnalului focal, componentele cu

frecvență înaltă (IMF1–IMF2) prezintă oscilații rapide și amplitudini crescute, sugerând activitate epileptică intensă și variabilă. În schimb, semnalul generalizat se caracterizează prin oscilații mai regulate, amplitudini mai constante și fluctuații mai puțin pronunțate, sugerând afectarea activității cerebrale în ambele emisfere.




Figura 4.8 Componentele IMF extrase prin metoda bazată pe EMD și 4 mărimi statistice – epilepsie generalizată – stare de veghe (Baza de date Cluj–Napoca)

În etapa de compunere a vectorului de trăsături a metodei propuse, s-au calculat valorile skewness și kurtosis pentru fiecare componentă IMF extrasă din semnalele EEG. Distribuțiile acestor mărimi, prezentate în Fig. 4.9, ilustrează frecvența relativă a valorilor înregistrate în semnalele epileptice focale și generalizate, evidențiind diferențe semnificative în forma și simetria distribuțiilor asociate fiecărui tip de activitate cerebrală.

Distribuțiile skewness ale semnalelor focale prezintă o ușoară asimetrie negativă, în timp ce semnalele generalizate au o distribuție mai concentrată și mai simetrică, indicând un comportament oscilatoriu mai uniform. În ceea ce privește kurtosis, semnalele focale prezintă valori în general scăzute, dar cu prezența unor spike-uri izolate, în timp ce semnalele generalizate prezintă valori mai mari și mai răspândite, sugerând o activitate cerebrală mai neregulată, cu tendință spre extreme.




Figura 4.9 Distribuția skewness și kurtosis pentru componentele IMF extrase din semnalele EEG epileptice focale și generalizate – stare de veghe (Baza de date Cluj–Napoca)

Rezultatele obținute cu metoda propusă sunt prezentate în Fig. 4.10.




Figura 4.10 Performanțele metodei EMD în combinație cu patru mărimi statistice pentru discriminarea între epilepsia focală și generalizată cu clasificatorul KNN

Pentru datele înregistrate în timpul somnului, metoda a atins o rată maximă de clasificare de 86.33% și o mediana de 74.21%, cu performanțe mai ridicate în identificarea semnalelor generalizate. Pe semnalele din starea de veghe, rata maximă de clasificare a fost de 88.03%, cu o mediana de 72.27%. În ambele cazuri, peste 70% dintre situațiile de clasificare au depășit pragul de 70% pentru acuratețe, senzitivitate și specificitate. Rezultatele confirmă potențialul metodei în detectarea epilepsiei, cu o eficiență mai mare în cazul semnalelor EEG generalizate.

4.4 Concluzii

Metoda EMD în combinație cu densitatea spectrală de putere s-a dovedit eficientă în clasificarea semnalelor EEG focale, non-focale și generalizate, evidențiind diferențele de conținut spectral între tipurile de activitate cerebrală. Rezultatele au demonstrat o capacitate ridicată de discriminare, confirmând utilitatea acestei abordări în identificarea zonelor epileptogene și în susținerea procesului de diagnostic al epilepsiei.

Aplicarea metodei dezvoltate pe cele două baze de date, una publică și una privată, oferă un instrument valoros pentru neurologi în identificarea tipului de epilepsie,

Rezultatele experimentale obținute cu metoda EMD și patru mărimi statistice demonstrează o capacitate ridicată de discriminare între semnalele EEG focale și generalizate .

Validarea clinică a metodelor EMD aplicate pe baza de date Cluj-Napoca confirmă aplicabilitatea abordării propuse, metoda propusă nu doar îmbunătățește diagnosticarea, dar și oferă un model de referință pentru comparații ulterioare în literatura de specialitate.

Contribuții proprii:

- O contribuție semnificativă a cercetării constă în originalitatea metodelor propuse, bazate pe metoda EMD.
- Au fost dezvoltate două abordări unice:
 - EMD în combinație cu densitatea spectrală de putere;
 - EMD în combinație cu patru mărimi statistice
- Metodele propuse au fost validate pe un set de date privat, confirmând potențialul lor de aplicabilitate clinică.

Capitolul 5

Clasificarea semnalelor EEG epileptice focale și generalizate utilizând metode bazate pe Transformata Empirică Wavelet și combinații de mărimi statistice

5.1 Introducere

În acest capitol sunt propuse două metode de clasificare a semnalelor EEG epileptice, dezvoltate pe baza algoritmului Empirical Wavelet Transform, ca o continuare și îmbunătățire a performanțelor obținute anterior cu metoda EMD combinată cu mărimi statistice.

5.2 Metoda EWT în combinație cu patru mărimi statistice

Prima metodă EWT propusă utilizează EWT în combinație cu patru mărimi statistice (mediana, skewness, kurtosis și indicele de fluctuație). Semnalele EEG din baza de date Cluj-Napoca, înregistrate în starea de veghe și în timpul somnului, sunt descompuse în cinci componente EWT, pentru care se extrag trăsăturile utilizate ulterior în clasificarea semnalelor ca focale sau generalizate, folosind KNN, Naïve Bayes și SVM. În Fig. 5.1 este prezentată schema bloc a metodei dezvoltate, bazată pe algoritmul EWT și cele patru mărimi statistice.




Figura 5.1 Schema bloc a metodei EWT în combinație cu patru mărimi statistice

Componentele EWT extrase din semnalele EEG înregistrate în timpul somnului (Fig. 5.2 și 5.3) evidențiază diferențe între activitatea epileptică focală și generalizată. În cazul semnalului focal, componentele EWT1–EWT5 surprind frecvențe distincte, cu EWT1 caracterizată prin oscilații rapide și variate, asociate frecvențelor înalte. Fluctuațiile sincronizate observate și în componentele inferioare pot indica prezența unor spike-uri epileptice, specifice activității focale. În contrast, semnalul generalizat este caracterizat de o amplitudine mai mică și un traseu mai uniform, cu oscilații lente în componentele EWT2–

EWT5, reflectând natura difuză a activității epileptice. Aceste rezultate confirmă capacitatea algoritmului EWT de a decompune eficient semnalele EEG și de a evidenția trăsături relevante pentru discriminarea tipurilor de epilepsie.

Rezultatele clasificării semnalelor EEG epileptice în focale și generalizate utilizând metoda EWT în combinație cu cele patru mărimi statistice și clasificatorii KNN, SVM și NB sunt prezentate în Fig. 5.1 - 5.2.




Figura 5.2 Componentele de frecvență extrase prin metoda bazată pe EWT și patru mărimi statistice – epilepsie focală (Baza de date Cluj–Napoca)

Rezultatele clasificării semnalelor EEG epileptice în focale și generalizate utilizând metoda EWT în combinație cu cele patru mărimi statistice și clasificatorii KNN, SVM și NB sunt prezentate în Fig. 5.4 - 5.5.




Figura 5.3 Componentele de frecvență extrase prin metoda bazată pe EWT și patru mărimi statistice – epilepsie generalizată (Baza de date Cluj–Napoca)




Figura 5.4 Performanțele de clasificare ale metodei bazate pe EWT și patru mărimi statistice – semnale EEG înregistrate în starea de veghe




Figura 5.5 Performanțele de clasificare ale metodei bazate pe EWT și patru mărimi statistice – semnale EEG înregistrate în timpul somnului

Metoda propusă, bazată pe Transformata Empirică Wavelet (EWT), a fost aplicată pentru clasificarea semnalelor EEG focale și generalizate, înregistrate în starea de veghe și în timpul somnului. Pe ambele seturi de date, clasificatorii KNN, Naïve Bayes (NB) și SVM au obținut performanțe comparabile, cu valori mediane ale ratelor de clasificare în jurul a 70%.

Pentru semnalele din starea de veghe, clasificatorul KNN a oferit cele mai bune rezultate generale, în timp ce SVM a excelat în identificarea semnalelor focale (senzitivitate mediană 76.88%). Semnalele generalizate au fost mai dificil de identificat, în special cu SVM, care a avut valori scăzute ale specificității.

Pentru semnalele din timpul somnului, performanțele celor trei clasificatori au fost echilibrate, cu valori maxime ale ratelor de clasificare de peste 77% și mediane apropiate de 70%. SVM a continuat să fie cel mai performant pentru semnalele focale, în timp ce KNN și NB au avut specificitate mai bună pentru semnalele generalizate.

5.4 Metoda EWT în combinație cu șase mărimi statistice

A doua metodă dezvoltată constă în algoritmul EWT și combinații de șase mărimi statistice: skewness, kurtosis, mediana, entropia estimării imparțiale a riscului lui Stein (Stein's Unbiased Risk Estimation Entropy - SURE), entropia de prag și correntropia centrată, aplicată pe semnalele EEG din timpul somnului, înregistrate pe canalele Fp1 și Fp2 din baza de date Cluj-Napoca.

Metoda vizează identificarea benzii de frecvență, corespunzătoare ritmurilor cerebrale: delta, theta, alfa, beta și gamma, în care diferențierea dintre activitatea epileptică focală și generalizată este cea mai precisă. După descompunerea semnalelor în cinci benzi de frecvență, sunt extrase caracteristicile statistice, iar semnificația diferențelor este evaluată prin testul Kruskal-Wallis. Clasificarea se realizează cu șase algoritmi: Fine Tree, Naïve Bayes, LDA, SVM liniar și de tip Kernel, și Fine – KNN. În Fig. 5.6 este prezentată schema bloc a metodei bazate pe EWT și șase mărimi statistice.

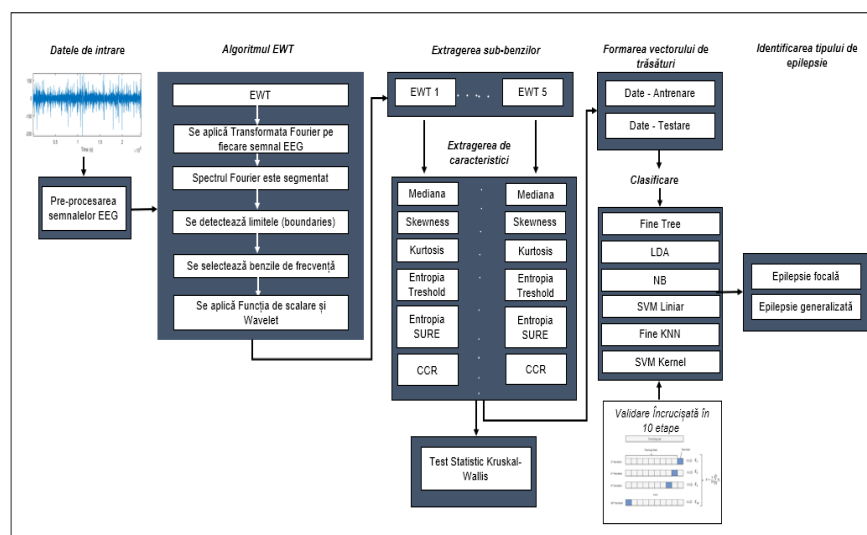


Figura 5.6 Schema bloc a metodei de clasificare EWT în combinație cu șase parametri statistici

Tabelul 5.1 conține rezultatele testului Kruskal-Wallis aplicat pe sub-benzile extrase din semnalele EEG. Rezultatele sunt afișate pentru fiecare canal, Fp1 și Fp2.

Tabelul 5.1 Rezultatele testului Kruskal–Wallis aplicat pe sub-benzile EEG pentru canalele Fp1 și Fp2

	Test statistic Kruskal-Wallis									
	Banda delta		Banda theta		Banda alfa		Banda beta		Banda gamma	
	Fp1	Fp2	Fp1	Fp2	Fp1	Fp2	Fp1	Fp2	Fp1	Fp2
Mediana (p)	0.045	0.047	0.016	0.032	0.041	0.019	0.018	0.024	0.015	0.015

Analiza comparativă între canalele Fp1 și Fp2, pe baza testului Kruskal-Wallis, a evidențiat un număr mai mare de diferențe semnificative ($p < 0.05$) pentru datele înregistrate pe canalul Fp1, sugerând o sensibilitate crescută a acestuia în discriminarea tipurilor de epilepsie. De asemenea, benzile beta și gamma au prezentat cele mai multe diferențe semnificative între semnalele focale și generalizate, pe ambele canale, indicând relevanța acestor benzi de frecvență în procesul de clasificare EEG.

Rezultatele obținute pentru clasificarea semnalelor de pe canalul Fp1 și Fp2 sunt prezentate în continuare în Tabelele 5.2 – 5.3, fiind raportate valorile mediane obținute cu cei șase clasificatori.

Tabelul 5.2 Performanțele de clasificare – canalul Fp1

Banda	Rata de clasificare (%)					
	Fine Tree	LDA	NB	SVM liniar	KNN Fine	SVM Kernel
Delta	81.25	80	73.75	81.25	80	77.50
Theta	77.50	67.50	71.25	78.75	71.25	73.75
Alfa	76.25	71.25	71.25	77.50	73.75	75
Beta	87.50	80	80	86.25	82.50	81.25
Gamma	93.75	91.25	92.50	93.75	92.50	95

Concluzia acestor rezultate obținute pentru datele de pe canalul Fp1 este că metoda bazată pe EWT și parametrii statistici utilizați a demonstrat o capacitate ridicată de a clasifica tipurile de epilepsie focală și generalizată, în special în benzile de frecvență delta, beta și gamma, pentru care ratele de clasificare au fost ridicate, iar cu clasificatorii SVM liniar, Fine Tree și KNN Fine s-au obținut cele mai bune performanțe de clasificare. Rezultatele de clasificare obținute sunt susținute și de rezultatele testului statistic Kruskal-Wallis.

Tabelul 5.2 Performanțele de clasificare – canalul Fp2

Banda	Rata de clasificare (%)					
	Fine Tree	LDA	NB	SVM liniar	KNN Fine	SVM Kernel
Delta	66.25	74.38	65.63	73.13	72.50	65.63
Theta	66.25	62.50	63.13	70	66.88	64.38
Alfa	79.38	70.63	76.25	80.63	77.50	76.25
Beta	87.50	75	76.25	88.75	82.50	83.75
Gamma	90.63	86.25	90.63	90.63	91.88	88.13

Cele mai bune rezultate de clasificare au fost obținute în benzile beta și gamma, valorile mediane ale ratelor de clasificare au depășit 90% pentru mai mulți clasificatori, în special Fine Tree, SVM liniar, KNN Fine și Naïve Bayes. Aceste performanțe sunt susținute și de testul Kruskal-Wallis, care a indicat diferențe

semnificative în aceste sub-benzi. În benzile delta, theta și alfa, SVM liniar, Fine Tree și KNN Fine au obținut constant cele mai bune rezultate, cu valori mediane ale ratelor de clasificare de peste 70% în majoritatea cazurilor. Activitatea EEG din banda gamma, adesea asociată cu hiperexcitabilitatea neuronală, a contribuit semnificativ la diferențierea semnalelor epileptice.

5.5 Concluzii

Metoda EWT în combinație cu patru și respectiv șase mărimi statistice a demonstrat o capacitate ridicată de discriminare a semnalelor EEG epileptice focale și generalizate, obținând performanțe superioare pentru semnalele din starea de veghe comparativ cu cele înregistrate în timpul somnului.

Prima abordare EWT, a evidențiat un echilibru optim între acuratețea clasificării și eficiența computațională, în special pentru semnalele EEG din starea de veghe. A doua abordare EWT, a condus la o îmbunătățire a preciziei clasificării în sub-benzile de frecvență, în special în benzile beta și gamma, aspect confirmat și de testul statistic Kruskal-Wallis.

Clasificarea semnalelor provenite de pe canalul Fp1 a oferit rezultate superioare față de canalul Fp2, sugerând o mai mare relevanță a acestui canal în detectarea activității epileptice.

Clasificatorii Fine Tree, SVM liniar și KNN Fine s-au remarcat prin performanțe constante în toate benzile analizate, demonstrând un potențial ridicat pentru aplicații extinse în analiza EEG.

Validarea metodei pe o bază de date EEG obținută în condiții clinice reale confirmă aplicabilitatea practică a algoritmilor EWT propuși, oferind un suport valoros pentru diagnosticarea epilepsiei în context medical.

Contribuții proprii:

- O contribuție proprie este dată de combinarea originală a metodei EWT cu mărimile statistice pentru extragerea caracteristicilor semnalelor EEG epileptice
- O altă contribuție este dată de integrarea originală a metodei EWT cu clasificatorii aleși (SVM liniar, Fine Tree, KNN Fine, SVM liniar, SVM Kernel, LDA, NB), ceea ce a permis obținerea unor performanțe superioare în clasificarea semnalelor epileptice.
- Utilizarea unei baze de date private pentru validarea metodei propuse, a oferit o contribuție practică a rezultatelor obținute.

Capitolul 6

Clasificarea semnalelor EEG epileptice focale și generalizate utilizând metode bazate pe tehnici empirice avansate de descompunerea a semnalelor

6.1 Introducere

În contextul creșterii prevalenței epilepsiei, este necesară dezvoltarea unor metode automate capabile să ofere un diagnostic rapid și precis, în special pentru diferențierea între epilepsia focală și cea generalizată. Acest capitol propune două metode noi de clasificare a semnalelor EEG, bazate pe tehnici empirice avansate: descompunerea empirică a semnalului în moduri cu ansambluri și descompunerea empirică completă a semnalului în moduri folosind ansambluri cu zgomot adaptiv. Ambele metode au fost aplicate pe semnalele EEG înregistrate în timpul somnului, provenite din baza de date Cluj-Napoca. Semnalele au fost descompuse în componente IMF, din care au fost extrase patru caracteristici statistice (mediana, skewness, kurtosis și indicele de fluctuație). Clasificarea semnalelor a fost realizată utilizând algoritmi KNN și Naïve Bayes.

În Fig. 6.5 este ilustrată schema bloc a celor două metode adaptive.




Figura 6.1 Schema bloc a metodelor adaptive de clasificare: EEMD și CEEMDAN

6.2 Metoda empirică de descompunere a semnalului în moduri cu ansambluri (EEMD)

Metoda EEMD este introdusă ca o extensie a algoritmului EMD, având ca scop depășirea limitării legate de amestecarea modurilor. Spre deosebire de EMD, EEMD adaugă zgomot alb gaussian și aplică decompunerea în moduri pe multiple iterații, rezultatul fiind obținut prin medierea componentelor extrase [10]. Acest proces reduce interferențele între frecvențe și permite o separare mai clară a componentelor spectrale.

Pentru a analiza comportamentul statistic al componentelor IMF extrase prin metoda EEMD, au fost selectate aleatoriu două semnale EEG aparținând unor pacienți diagnosticați cu epilepsie focală și generalizată. În Fig. 6.2 sunt ilustrate distribuțiile valorilor skewness și kurtosis corespunzătoare componentelor IMF, oferind o perspectivă asupra diferențelor de simetrie și dispersie între cele două tipuri de activitate epileptică.

Analiza distribuțiilor skewness și kurtosis pentru componentele IMF extrase prin EEMD evidențiază diferențe semnificative între semnalele EEG focale și generalizate. Semnalul focal prezintă o asimetrie accentuată spre dreapta și o distribuție leptocurtică, cu valori ridicate de kurtosis și prezența unor outlieri, indicând vârfuri bruște specifice activității epileptice focale. În contrast, semnalul generalizat are o distribuție aproape simetrică și predominant platycurtică, cu o variabilitate mai omogenă și o absență a valorilor extreme, ceea ce reflectă natura mai difuză și echilibrată a descărcărilor epileptice generalizate.




Figura 6.2 Distribuția skewness și kurtosis pentru componentele IMF extrase din semnalele EEG epileptice focale și generalizate – din timpul somnului (Baza de date Cluj-Napoca) – EEMD

Performanțele de clasificare a semnalelor EEG cu metoda bazată pe EEMD sunt prezentate în Fig. 6.3.




Figura 6.3 Performanțele de clasificare ale metodei EEMD

Semnalele EEG ale pacienților cu epilepsie focală și generalizată din baza de date Cluj–Napoca au fost clasificate cu succes utilizând metoda propusă bazată pe EEMD. Clasificatorii KNN și Naïve Bayes au evidențiat performanțe solide, cu valori ale ratei de clasificare, sensibilității și specificității ridicate în majoritatea combinațiilor analizate. KNN a oferit performanțe superioare în identificarea semnalelor epileptice, atât focale cât și generalizate, cu o capacitate mai bună de generalizare comparativ cu NB. Rezultatele susțin robustețea metodei EEMD în discriminarea tipurilor de epilepsie pe baza trăsăturilor statistice extrase din componentele IMF.

6.3 Metoda empirică de descompunere completă a semnalului în moduri folosind ansambluri cu zgomot adaptiv (CEEMDAN)

Deși metoda EEMD abordează eficient problema amestecării modurilor din metoda EMD, ea este încă susceptibilă la alte limitări, reprezentate de prezența zgomotului rezidual în semnalul reconstruit și de numărul variabil de moduri obținut în diferitele realizări.

Metoda empirică de descompunere a semnalului EEG în moduri folosind ansamblul complet cu zgomot adaptiv, reprezintă o îmbunătățire semnificativă față de tehnicile EMD și EEMD [10].

Distribuțiile skewness și kurtosis obținute prin aplicarea metodei CEEMDAN evidențiază diferențe clare între semnalele EEG focale și generalizate. Semnalele focale prezintă o asimetrie pozitivă și valori ridicate de kurtosis, indicând vârfuri accentuate și cozi lungi în distribuție, caracteristice activității epileptice localizate. În schimb, semnalele generalizate au o distribuție mai simetrică și mai uniformă, cu valori de kurtosis moderate, reflectând o activitate cerebrală mai stabilă. Aceste diferențe confirmă capacitatea metodei CEEMDAN de a distinge eficient între cele două tipuri de semnale.




Figura 6.4 Distribuția skewness și kurtosis pentru semnalele EEG epileptice focale și generalizate – din timpul somnului (Baza de date Cluj-Napoca) – CEEMDAN

Performanțele de clasificare a semnalelor cu metoda bazată pe CEEMDAN sunt prezentate în Fig. 6.5.




Figura 6.5 Performanțele de clasificare ale metodei CEEMDAN

Metoda CEEMDAN, aplicată în combinație cu patru mărimi statistice și clasificatorii KNN și Naïve Bayes, a demonstrat performanțe superioare în clasificarea semnalelor EEG epileptice în focale și generalizate. Atât rata de clasificare, cât și valorile sensibilității și specificității au fost ridicate în majoritatea situațiilor analizate, evidențiind robustețea și eficiența metodei.

Comparativ cu metoda EEMD, CEEMDAN a oferit rezultate mai stabile și o capacitate mai bună de discriminare, susținând aplicarea sa ca instrument valoros pentru diagnosticarea automată a epilepsiei.

6.4. Analiza comparativă a metodelor adaptive dezvoltate

Algoritmii propuși sunt dezvoltați într-un mod original, fiind aplicați baza de date privată, în combinații de algoritmi și metode tehnice ce nu au mai fost testate în literatura, iar rezultatele au fost validate și publicate în jurnale științifice. Compararea s-a realizat pentru semnalele înregistrate în timpul somnului, fiind raportate valorile mediane.

Tabelul 6.1 Comparații între metodele dezvoltate și aplicate pe baza de date EEG Cluj–Napoca

Referința	Metoda/ Mărimi extrase	Clasificatori	Rezultate (%)
<i>Murariu, M.-G., et al., [19]</i>	EMD și densitate spectrală de putere	KNN NB	Rata de clasificare: 96.39–KNN/ 96.10–NB Senzitivitate: 96.06–KNN/ 95.81–NB Specificitate: 96.53–KNN/ 96.88–NB Scorul – F1: 0.70–KNN / 0.70–NB
<i>Murariu, M.-G., et al., [20]</i>	EMD și patru mărimi: mediana, skewness, kurtosis și indicele de fluctuație	KNN	Rata de clasificare: 74.21 Senzitivitate: 73.77 Specificitate: 77 Score–F1: 0.70
<i>Murariu, M.-G., et al., [21]</i>	EWT și patru mărimi: mediana, skewness, kurtosis și indicele de fluctuație	KNN NB SVM	Rata de clasificare: 69.33–KNN/ 70.30–NB/ 69.06–SVM Senzitivitate: 69.50–KNN/68.75 –NB/ 76.88–SVM Specificitate: 70.22–KNN/70.63 – NB/ 60.94–SVM Scorul – F1: 0.70–KNN /NB/SVM
<i>Murariu, M.-G et al., [22]</i>	EWT și șase mărimi: mediana, skewness, kurtosis, SURE, TH, correntropia centrată aplicate separat pe 2 canale: Fp1 și Fp2	Fine Tree, LDA, NB, SVM Liniar, Fine KNN, SVM Kernel	Rata de clasificare banda delta Fp1: 81.25-Fine Tree, 80-LDA, 73.75-NB, 81.25-SVM Liniar, 80-Fine KNN, 77.50-SVM Kernel Rata de clasificare banda delta Fp2: 66.25-Fine Tree, 74.38-LDA, 65.63-NB, 73.13-SVM Liniar, 72.50-Fine KNN, 65.63-SVM Kernel

			Rata de clasificare banda beta Fp1: 87.50 -Fine Tree, 80-LDA, 80-NB, 86.25-SVM Liniar, 82.50-Fine KNN, 81.25-SVM Kernel Rata de clasificare banda beta Fp2: 87.50 -Fine Tree, 76-LDA, 76.25-NB, 88.75-SVM Liniar, 82.50-Fine KNN, 83.75-SVM Kernel Rata de clasificare banda gamma Fp1: 93.75 -Fine Tree, 91.25 -LDA, 92.50-NB, 93.75-SVM Liniar, 92.50-Fine KNN, 95-SVM Kernel Rata de clasificare banda gamma Fp2: 90.63-Fine Tree, 86.25-LDA, 90.63-NB, 90.63-SVM Liniar, 91.88-Fine KNN, 88.13-SVM Kernel
<i>Murariu. M et al., [23]</i>	EEMD și patru mărimi: mediana, skewness, kurtosis și indicele de fluctuație	KNN NB	Rată de clasificare: 80.01–KNN/ 75.90–NB Senzitivitate: 79.06–KNN/ 75.63–NB Specificitate: 80.16– KNN/ 74.38– NB Scorul – F1: 0.70–KNN / 0.60–NB
	CEEMDAN și patru mărimi: mediana, skewness, kurtosis și indicele de fluctuație		Rată de clasificare: 85.15–KNN/ 80.60–NB Senzitivitate: 81.96–KNN/ 77.50–NB Specificitate: 87.19– KNN/ 84.38– NB Scorul – F1: 0.70–KNN / 0.60–NB

În toate scenariile de clasificare, metodele propuse au estimat corect diagnosticul de epilepsie, aliniindu-se îndeaproape cu evaluările furnizate de către medicul neurolog. Această concordanță validează în continuare fiabilitatea și eficacitatea metodelor propuse în clasificarea cazurilor de epilepsie.

Dezvoltarea metodelor de clasificare și-a atins scopul prin implementarea metodelor EMD, EWT, EEMD și CEEMDAN, care au dus la rezultate de clasificare ridicate, cu concluzii diferite pentru fiecare abordare.

6.5 Concluzii

Aplicarea metodelor empirice de descompunere adaptivă în clasificarea semnalelor EEG focale și generalizate a condus la performanțe superioare față de metodele clasice raportate în literatură. Metoda EEMD, a demonstrat o capacitate ridicată de discriminare a semnalelor epileptice, iar distribuțiile skewness și kurtosis au confirmat relevanța caracteristicilor extrase. Totuși, limitările legate de contaminarea cu zgomot și amestecul de moduri au fost evidente în unele situații.

Aceste limitări au fost depășite prin metoda CEEMDAN, care a încorporat un mecanism adaptiv de reducere a zgomotului, permițând o descompunere mai stabilă și o separare mai clară a componentelor

semnalului. Rezultatele experimentale au confirmat superioritatea metodei CEEMDAN în extragerea trăsăturilor relevante, ceea ce a condus la o clasificare robustă a semnalelor EEG epileptice.

Contribuții proprii:

- O contribuție originală a acestei lucrări constă în combinarea metodologică inovatoare a algoritmilor de descompunere adaptivă EEMD și CEEMDAN cu patru mărimi statistice esențiale (mediana, skewness, kurtosis și indicii de fluctuație) pentru extragerea caracteristicilor semnalelor EEG epileptice.
- Originalitatea acestor combinații de metode și clasificatori constă în faptul că nu au fost raportate anterior în literatura de specialitate, subliniind caracterul inovator și contribuția științifică adusă de această cercetare în domeniul procesării semnalelor biomedicale.
- De asemenea, un aport tehnic important îl reprezintă implementarea completă a metodelor propuse în mediul Matlab, asigurând reproducibilitatea și aplicabilitatea practică a soluțiilor dezvoltate.

Capitolul 7

Concluzii finale, contribuții proprii și direcții de cercetare viitoare

Lucrarea de doctorat s-a concentrat pe dezvoltarea de metode avansate de clasificare a semnalelor EEG pentru diagnosticarea epilepsiei, prin integrarea unor tehnici moderne de procesare a semnalului, precum descompunerea empirică (EMD, EEMD, CEEMDAN), analiza spectrală de ordin superior (HOSA) și Transformata Empirică Wavelet. Aceste metode au fost combinate cu extragerea de trăsături statistice complexe și cu clasificatori performanți pentru diferențierea între epilepsia focală și cea generalizată.

Metodele propuse au fost aplicate pe două baze de date EEG: Cluj-Napoca și Bern-Barcelona, ceea ce a permis evaluarea riguroasă a metodelor dezvoltate și compararea obiectivă a performanțelor obținute, asigurând relevanța practică și științifică a rezultatelor.

7.1 Concluzii finale

Principalele concluzii ale lucrării sunt următoarele:

- **Abordările bazate pe metoda HOSA** au evidențiat o îmbunătățire semnificativă a performanțelor de clasificare, în special atunci când vectorul de trăsături a fost format dintr-un raport de 90% bicoerență și 10% bispectru, obținându-se valoarea mediană a ratei de clasificare de 89.67% cu clasificatorul KNN.
- **Metoda EMD combinată cu densitatea spectrală de putere** a condus la o clasificare robustă a semnalelor EEG focale, non-focale și generalizate, cu rate mediane de clasificare de 96% (KNN, NB) pentru semnalele din baza de date Cluj-Napoca și de peste 90% pentru semnalele din baza de date Bern-Barcelona.

- **Metoda EMD combinată cu patru mărimi statistice** a permis extragerea de informații relevante legate de forma, distribuția și variația semnalului EEG, evidențiind o performanță mai ridicată în clasificarea semnalelor înregistrate în timpul somnului, comparativ cu cele înregistrate în starea de veghe. Valorile mediane ale ratelor de clasificare fiind de 72.27% pentru semnalele EEG achiziționate în starea de veghe și 74.21% pentru semnalele EEG achiziționate în timpul somnului la aplicarea clasificatorului KNN.
- **Metoda EWT combinată cu patru mărimi statistice** a permis discriminarea semnalelor EEG în focale și generalizate, cele mai bune rezultate de clasificare fiind obținute cu clasificatorii KNN și NB.
- **EWT combinată cu șase mărimi statistice** a permis o discriminare detaliată a semnalelor în benzile delta, beta și gamma, cu rezultate semnificativ mai bune pe canalul Fp1, față de canalul Fp2, subliniind relevanța topografică în analiza EEG și oferind perspective suplimentare asupra sincronizării și caracteristicilor activității cerebrale.
- **Metodele EEMD și CEEMDAN**, introduse pentru a corecta limitările EMD, au oferit o separare mai clară a componentelor semnalului și o reducere a zgomotului. CEEMDAN, în special, s-a remarcat printr-o performanță robustă și superioară în clasificare, datorită utilizării zgomotului adaptiv și a ansamblurilor complete. Valorile mediane ale ratei de clasificare obținute cu abordările propuse au fost de 80.01% cu metoda EEMD și de 85.15% cu metoda CEEMDAN, în combinație cu clasificatorul KNN în ambele situații.

7.2 Contribuții proprii

Contribuțiile personale sunt structurate pentru a evidenția originalitatea abordărilor propuse și impactul acestora asupra diagnosticării epilepsiei. Principalele contribuții includ:

1. **Obținerea accesului la date EEG private:** realizarea unei baze de date private prin colaborarea cu clinica de neurologie Cluj-Napoca.
2. **Optimizarea vectorilor de trăsături:** propunerea și integrarea mărimilor statistice în diferite combinații: mediana, skewness, kurtosis, indicele de fluctuație, entropia estimării imparțiale a riscului lui Stein, entropia de prag și correntropia centrată, bispectrul, bicoerența, densitatea spectrală de putere.
3. **Integrarea clasificatorilor:** propunerea și dezvoltarea componentei software în MATLAB pentru integrarea clasificatorilor avansați (KNN, NB, SVM, Fine Tree, SVM Kernel, SVM Liniar, Fine KNN, LDA, QDA, MD), cu metodele dezvoltate; testarea clasificatorilor pe multiple seturi de date cu implicarea medicilor în validarea clinică a rezultatelor.
4. **Propunerea și validarea mai multor metode originale:**
 - **HOSA:** utilizarea unui vector de trăsături optimizat (90% bicoerență, 10% bispectru) aplicat pe baza Bern–Barcelona;
 - **EMD:** două abordări distincte cu trăsături spectrale și statistice, testate pe ambele baze de date;
 - **EWT:** dezvoltarea a două metode, una cu patru și una cu șase mărimi statistice, aplicate pe date EEG Cluj-Napoca, captate în starea de veghe și în somn;
 - **EEMD și CEEMDAN:** propunerea și validarea a două metode empirice avansate, demonstrând superioritate în reducerea zgomotului și evitarea amestecului de moduri.

5. Analiză comparativă extinsă:

- Evaluarea performanțelor relative ale metodelor propuse în funcție de clasificatori, trăsături și starea fiziologică (somn/veghe);
- Compararea cu metode similare din literatură pentru evidențierea și validarea abordărilor dezvoltate.

7.3 Direcții viitoare de cercetare

În continuarea acestei lucrări, direcțiile viitoare de cercetare vor urmări aprofundarea și extinderea metodelor propuse prin:

- extinderea studiilor pe baze de date EEG internaționale, care includ pacienți diagnosticați cu alte forme de epilepsie, pentru a evalua robustețea metodelor dezvoltate în contexte mai diverse;
- analiza sincronizării inter-canal între diferite regiuni cerebrale, cu scopul de a îmbunătăți detecția episoadelor epileptice și de a înțelege mai bine propagarea activității epileptiforme;
- consolidarea colaborării cu instituții medicale, pentru accesul la baze de date clinice și validarea metodelor în scenarii reale, cu implicații directe în practica neurologică;
- explorarea și integrarea unor algoritmi avansați de învățare automată, precum rețele neuronale profunde (deep learning), rețele neuronale convoluționale (CNN) sau modele hibride, aplicate pe vectorii de trăsături propuși în această cercetare.

Lista lucrărilor elaborate pe parcursul tezei

Rezultatele cercetării au fost diseminate prin publicarea unui număr de 12 lucrări științifice, dintre care 7 în calitate de prim autor și 4 ca al doilea autor. Dintre acestea:

- 5 articole sunt indexate în Web of Science (WoS),
- 6 articole au fost publicate în cadrul conferințelor IEEE,
- 1 articol este indexat într-o bază de date internațională recunoscută (BDI).

Această activitate de publicare reflectă recunoașterea contribuțiilor aduse în domeniul procesării semnalelor EEG și al clasificării epilepsiei în comunitatea științifică internațională.

1. **Murariu, M.-G.;** Dorobanțu, F.-R.; Tărniceriu, D. A Novel Automated Empirical Mode Decomposition (EMD) Based Method and Spectral Feature Extraction for Epilepsy EEG Signals Classification. *Electronics* 2023, 12, 1958, doi:10.3390/electronics12091958, WOS:000986895900001.
2. **Murariu, M.-G.;** Dorobanțu, F.-R.; Tărniceriu, D. Enhanced Classification of Focal and Generalized Epilepsy Using EEMD and CEEMDAN Methods. *Traitement du Signal*, 2024, 41, 1315–1322, IF:1.2, DOI: 10.18280/ts.410320, WOS:001260365800020.
3. **Murariu, M.-G.;** Gavrilă, M.; Dorobanțu, F.-R.; Tărniceriu, D. Epilepsy Detection Through EEG Sub-band Classification Using Empirical Wavelet Transform and Statistical Features. In the 12th International Conference on E-Health and Bioengineering - EHB 2024; November 14-15, 2024, Iasi, ROMANIA, DOI:10.1109/EHB64556.2024.10805732, WOS:001413708800021.
4. **Murariu, M.-G.;** Gavrilă, M.; Tărniceriu, D. Empirical Wavelet Transform in Epilepsy Diagnosis: A Multi-Features Approach to EEG Focal and Generalized Signal Classification. In Proceedings of the 2024 16th International Conference on Electronics, Computers and Artificial Intelligence (ECAI); June 2024; pp. 1–6, DOI: 10.1109/ECAI61503.2024.10607402.
5. **Murariu, M.-G.;** Tărniceriu, D.; Hrișcă-Eva, O.D. Classification of Focal and Generalized Epilepsy Using Multi-Features and Empirical Mode Decomposition Method.; International Symposium on Signals, Circuits & Systems: Iasi. Romania, July 13 2023, INSPEC:23488280, DOI: 10.1109/ISSCS58449.2023.10190929.
6. **Murariu, M.G.;** Tărniceriu, D.; Hrișcă-Eva, O.D.; Lazăr, A.M. An Approach to Identify Different Types of EEG Epileptic Signals Based on Higher-Order Spectra (HOS) Features. In Proceedings of the 2022 14th International Conference on Electronics, Computers and Artificial Intelligence (ECAI); June 2022; pp. 1–5, DOI: 10.1109/ECAI54874.2022.9847451.
7. **Murariu, M.-G.;** Tărniceriu, D. Discrimination of Focal and Non-Focal Epileptic EEG Signals Using Different Types of Classifiers. *Bulletin of the Polytechnic Institute of Iași. Electrical Engineering, Power Engineering, Electronics Section* 2022, 68, 61–79, DOI:10.2478/bipie-2022-0011.
8. Gavrilă, M.; **Murariu, M.G.;** Ambrozie, R.E.; Tărniceriu, D.; Monitoring Health Traffic Participants Using a IoT Smart Band Integrated with a Data Collection Platform secured with Blockchain. In Proceedings of the 12th International Conference on E-Health and Bioengineering - EHB 2024, Grigore T. Popa University of Medicine and Pharmacy Iasi, November 14-15, 2024, Iasi, ROMANIA, DOI: 10.1109/EHB64556.2024.10805551, WOS:001413708800022.

9. Hrisca-Eva, O.-D.; **Murariu, M.-G.**; Lazar, A.M. Higher Order Statistics and Phase Synchronization as Features in a Motor Imagery Paradigm. *International Journal of Advanced Computer Science and Applications* **2021**, *12*, [WOS:000693682500015](#).
10. Gavrilă M., Fotache M., Bărbuță, D.E, Alexandrescu A., **Murariu, M.-G**, Ambrozie R.E., Tărniceriu D., Sensor Data Analysis in a Real-Time IoT and Blockchain-Based System for Monitoring Driver Alcohol Levels, 2024 International Symposium on Electronics and Telecommunications (ISETC), Timisoara, Romania, 2024, pp. 1-6, DOI: 10.1109/ISETC63109.2024.10797237.
11. Gavrilă, M.; **Murariu, M.G.**; Bărbuță, D.E.; Tărniceriu, D. Development of a Modular Sensor Battery Integrated with a Data Collection Platform for Alcohol Level Detection and Driver Geolocation. In Proceedings of the 2024, 15th International Conference on Communications (COMM); October 2024; 10.1109/COMM62355.2024.10741399.
12. Gavrilă, M.; **Murariu, M.G.**; Bărbuță, D.E.; Mihăilescu, E.; Tărniceriu, D. Enhancing Driver Safety through a Data Collection Platform. In Proceedings of the 2024 16th International Conference on Electronics, Computers and Artificial Intelligence (ECAI); IEEE, 2024, pp. 1–8, DOI: 10.1109/ECAI61503.2024.10607493.

Bibliografie selectivă

1. Chen, Z.; Brodie, M.J.; Ding, D.; Kwan, P. Editorial: Epidemiology of Epilepsy and Seizures. *Front. Epidemiol.* **2023**, *3*, doi:10.3389/fepid.2023.1273163.
2. Harris, L.; Angus-Leppan, H. Epilepsy: Diagnosis, Classification and Management. *Medicine* **2020**, *48*, 522–528, doi:10.1016/j.mpmed.2020.05.001.
3. Han, K.; Liu, C.; Friedman, D. Artificial Intelligence/Machine Learning for Epilepsy and Seizure Diagnosis. *Epilepsy & Behavior* **2024**, *155*, 109736, doi:10.1016/j.yebeh.2024.109736.
4. Fiest, K.M.; Sauro, K.M.; Wiebe, S.; Patten, S.B.; Kwon, C.-S.; Dykeman, J.; Pringsheim, T.; Lorenzetti, D.L.; Jetté, N. Prevalence and Incidence of Epilepsy. *Neurology* **2017**, *88*, 296–303, doi:10.1212/WNL.0000000000003509.
5. Vartanov, A.V. A New Method of Localizing Brain Activity Using the Scalp EEG Data. *Procedia Computer Science* **2022**, *213*, 41–48, doi:10.1016/j.procs.2022.11.036.
6. Yi, Y.; Billor, N.; Liang, M.; Cao, X.; Ekstrom, A.; Zheng, J. Classification of EEG Signals: An Interpretable Approach Using Functional Data Analysis. *Journal of Neuroscience Methods* **2022**, *376*, 109609, doi:10.1016/j.jneumeth.2022.109609.
7. İnce, R.; Adanır, S.S.; Sevmez, F. The Inventor of Electroencephalography (EEG): Hans Berger (1873–1941). *Childs Nerv Syst* **2021**, *37*, 2723–2724, doi:10.1007/s00381-020-04564-z.
8. Buzsáki, G.; Watson, B.O. Brain Rhythms and Neural Syntax: Implications for Efficient Coding of Cognitive Content and Neuropsychiatric Disease. *Dialogues Clin Neurosci* **2012**, *14*, 345–367.
9. Hirsch, L.J.; Fong, M.W.K.; Leitinger, M.; LaRoche, S.M.; Beniczky, S.; Abend, N.S.; Lee, J.W.; Wusthoff, C.J.; Hahn, C.D.; Westover, M.B.; et al. American Clinical Neurophysiology Society's Standardized Critical Care EEG Terminology: 2021 Version. *J Clin Neurophysiol* **2021**, *38*, 1–29, doi:10.1097/WNP.0000000000000806.
10. Carvalho, V.R.; Moraes, M.F.D.; Braga, A.P.; Mendes, E.M.A.M. Evaluating Five Different Adaptive Decomposition Methods for EEG Signal Seizure Detection and Classification. *Biomedical Signal Processing and Control* **2020**, *62*, 102073, doi:10.1016/j.bspc.2020.102073.
11. Gilles, J. Empirical Wavelet Transform. *IEEE Trans. Signal Process.* **2013**, *61*, 3999–4010, doi:10.1109/TSP.2013.2265222.
12. Oliva, J.T.; Rosa, J.L.G. Binary and Multiclass Classifiers Based on Multitaper Spectral Features for Epilepsy Detection. *Biomedical Signal Processing and Control* **2021**, *66*, 102469, doi:10.1016/j.bspc.2021.102469.
13. Balakrishnama, S.; Ganapathiraju, A. LINEAR DISCRIMINANT ANALYSIS - A BRIEF TUTORIAL.
14. Bose, S.; Pal, A.; SahaRay, R.; Nayak, J. Generalized Quadratic Discriminant Analysis. *Pattern Recognition* **2015**, *48*, 2676–2684, doi:10.1016/j.patcog.2015.02.016.
15. Rahouma, K.; Mostafa, A. Location Estimation of Multiple Emitting RF Sources Using Supervised Machine Learning Technique. *International Journal of Engineering Trends and Technology* **2022**, *70*, 428–437, doi:10.14445/22315381/IJETT-V70I10P242.
16. The Bern-Barcelona EEG Database - Nonlinear Time Series Analysis (UPF) Available online: https://www.upf.edu/web/ntsa/downloads/-/asset_publisher/xvT6E4pczrBw/content/2012-nonrandomness-nonlinear-dependence-and-nonstationarity-of-electroencephalographic-recordings-from-epilepsy-patients (accessed on 24 February 2023).
17. Tzallas, A.T.; Tsipouras, M.G.; Fotiadis, D.I. Epileptic Seizure Detection in EEGs Using Time–Frequency Analysis. *IEEE Transactions on Information Technology in Biomedicine* **2009**, *13*, 703–710, doi:10.1109/TITB.2009.2017939.
18. Swami, A.; Mendel, J.M. Higher-Order Spectral Analysis Toolbox.
19. Murariu, M.-G.; Dorobanțu, F.-R.; Tărniceriu, D. A Novel Automated Empirical Mode Decomposition (EMD) Based Method and Spectral Feature Extraction for Epilepsy EEG Signals Classification. *Electronics* **2023**, *12*, 1958, doi:10.3390/electronics12091958.

20. Murariu, M.-G.; Tărniceriu, D.; Hrișcă-Eva, O.D. Classification of Focal and Generalized Epilepsy Using Multi-Features and Empirical Mode Decomposition Method.; International Symposium on Signals, Circuits & Systems: Iasi. Romania, July 13 2023.
21. Murariu, M.-G.; Gavrilă, M.; Tărniceriu, D. Empirical Wavelet Transform in Epilepsy Diagnosis: A Multi-Features Approach to EEG Focal and Generalized Signal Classification. In Proceedings of the 2024 16th International Conference on Electronics, Computers and Artificial Intelligence (ECAI); June 2024; pp. 1–6.
22. Murariu, M.-G.; Gavrilă, M.; Dorobanțu, R.-F.; Tărniceriu, D. Epilepsy Detection Through EEG Sub-Band Classification Using Empirical Wavelet Transform and Statistical Features. In Proceedings of the 2024 E-Health and Bioengineering Conference (EHB); November 2024; pp. 1–4.
23. Murariu, M.-G.; Dorobanțu, F.-R.; Tărniceriu, D. Enhanced Classification of Focal and Generalized Epilepsy Using EEMD and CEEMDAN Methods. *TS* **2024**, *41*, 1315–1322, doi:10.18280/ts.410320.