



**UNIVERSITATEA POLITEHNICA
DIN BUCUREȘTI**



**Școala Doctorală de Electronică, Telecomunicații
și Tehnologia Informației**

Decizie nr. ____ din __-__-__

REZUMAT TEZĂ DE DOCTORAT

Ing Alexe Ciurea

**TEHNICI BAZATE PE REȚELE NEURONALE ADÂNCI
PENTRU DETECȚIA ȘI MONITORIZAREA CRIZELOR DE
EPILEPSIE**

**DEEP NEURAL NETWORK-BASED TECHNIQUES FOR THE
DETECTION AND MONITORING OF EPILEPTIC SEIZURES**

THESIS COMMITTEE

Prof. Dr. Ing. Mihai CIUC Univ. Politehnica din București	Președinte
Prof. Dr. Ing. Ionescu BOGDAN Univ. Politehnica din București	Conducător de doctorat
Prof. Dr. Ing. Bogdan FLOREA Univ. Politehnica din București	Referent
Prof. Dr. Ing. Ruxandra ȚAPU Univ. Politehnica din București	Referent
Prof. Dr. Ing. Dragoș ȚARALUNGĂ Univ. Politehnica din București	Referent

BUCHAREST 2025

Cuprins

Cuprins	iii
Capitolul 1 Introducere	1
1.1 Prezentarea domeniului tezei de doctorat	1
1.2 Scopul tezei de doctorat	2
1.3 Conținutul tezei de doctorat	2
Capitolul 2 Starea actuală a tehnicii în recunoașterea și predicția crizelor epileptice.....	5
2.1 Introducere	5
2.1.1 Care sunt metodele cheie de detectare a crizelor în medicină?.....	5
2.1.2 Cum ar ajuta un algoritm de deep learning?	5
2.1.3 Arhitectura algoritmului de învățare automată	6
2.1.4 Performanța unui algoritm de învățare.....	6
2.2 Seturi de date	7
2.3 Detectarea crizelor	7
2.3.1 Setul de date CHB-MIT	7
2.3.2 Baza de date a Universității din Bonn.....	7
2.3.3 Baza de date a Universității din Freiburg.....	8
2.4 Predicția crizelor	8
2.4.1 Setul de date CHB-MIT	8
2.4.2 Baza de date a Universității din Bonn.....	8
2.4.3 Baza de date a Universității din Freiburg.....	9
2.4.4 Baza de date a provocărilor de predicție a crizelor AES	9
2.5 Discuție	9
2.5.1 Atenuarea limitărilor seturilor de date existente	9
2.5.2 Depășirea provocărilor legate de detectarea crizelor	10
2.5.3 Predicția crizelor	10
2.6 Conclusions and Future Direction	10
Capitolul 3 Detectarea automată a crizelor epileptice cu latență redusă: abordări individualizate vs. globale	11
3.1 Introducere	11

3.2 Abordarea propusă	11
3.2.1 Prezentare generală.....	11
3.2.2 Preprocesarea datelor.....	12
3.2.3 Extragerea caracteristicilor	12
3.2.4 Structura rețelei neuronale.....	13
3.3 Rezultate experimentale	13
3.3.1 Seturi de date	13
3.3.2 Metrice	13
3.3.3 Reglarea parametrilor	14
3.3.4 Rezultate comparative	14
3.4 Concluzii	15
Capitolul 4 Smart-EEG – Un cadru complet de învățare profundă pentru analiza și predicția semnalelor EEG.....	17
4.1 Introducere	17
4.2 Motivare	17
4.3 Prezentare generală a literaturii de specialitate	17
4.3.1 Cadre EEG existente.....	17
4.4 Arhitectura cadrului smartEEG	18
4.4.1 Obiectivele de proiectare a cadrului de lucru	18
4.4.2 Modulul principal	18
4.4.3 Parametri de configurare	19
4.4.4 Modulul generator de matrice de adrese și etichete pentru înregistrare.....	19
4.4.5 Generator de adrese pentru clipuri și etichete EEG.....	19
4.4.6 Modul generator de matrice de clipuri EEG.....	19
4.4.7 Modulul de procesare a datelor EEG și de eliminare a zgomotului ..	20
4.4.8 Biblioteca de modele și modulul Builder	20
4.4.9 Exemple de modele în bibliotecă.....	20
4.4.10 Antrenarea modelului	20
4.4.11 Modulul de rulare în loturi.....	20
4.4.12 Modul de plotare.....	20
4.5 Rezultatele aplicațiilor experimentale	21
4.6 Concluzii	22
4.7 smartMRI: derivat al cadrului smartEEG aplicat pe imagini RMN.....	22

4.7.1 Introducere	22
4.7.2 Prezentare generală a cadrului smartMRI	22
4.7.3 Set de date	22
4.7.4 Configurarea instruirii și indicatorii de evaluare	22
4.7.5 Rezultate ale rețelelor neuronale convoluționale	23
4.7.6 Discuție	23
Capitolul 5 Detectarea și predicția crizelor bazate pe EEG: CNN hibrid, eliminarea zgomotului și abordări comparative de învățare profundă....	25
5.1 Introducere	25
5.2 Clasificarea EEG utilizând o rețea neuronală convoluțională hibridă cu mecanism de atenție.....	25
5.2.1 Introducere	25
5.2.2 Abordarea propusă	25
5.2.3 Rezultate experimentale	26
5.2.4 Concluzii	27
5.3 Reducerea zgomotului EEG cu metode de selecție a canalelor.....	28
5.3.1 Introducere	28
5.3.2 Metode	28
5.3.3 Rezultate experimentale	28
5.3.4 Concluzii	30
5.4 Studiu comparativ al tehnicilor de procesare a semnalului EEG pentru detectarea și predicția crizelor folosind învățarea profundă.....	30
5.4.1 Introducere	30
5.4.2 Metode	31
5.4.3 Rezultate experimentale	31
5.5 Direcții viitoare	32
Capitolul 6 Concluzii	33
6.1 Rezultate obținute	33
6.2 Contribuții originale.....	34
6.3 Lista lucrărilor originale	35
6.4 Perspective de dezvoltare ulterioară	35
Bibliografie	37

Capitolul 1

Introducere

Această teză examinează aplicarea rețelelor neuronale profunde ca metodă de monitorizare a crizelor epileptice captate de semnalele electroencefalografice. Există numeroase beneficii pe care acest lucru le poate aduce pacienților cu epilepsie, cum ar fi o îmbunătățire a calității vieții și o durată redusă a tratamentului. De asemenea, este benefic pentru medici și cercetători, permițându-le să economisească timp într-un mediu clinic, unde sarcinile repetitive, cum ar fi adnotarea manuală a crizelor în scopuri de diagnostic și tratament, pot fi automatizate.

Cu toate acestea, există provocări semnificative în realizarea monitorizării automate a crizelor de electroencefalogramă (EEG), în principal din cauza variabilității pacienților, zgomotului de fundal, mișcărilor oculare și musculare, etichetării incorecte de către medici, diferențelor de echipament și chiar a echipamentelor defecte care pot crește nivelul de zgomot din date. Înregistrările EEG sunt lungi, ocupând o memorie substanțială și de obicei denaturate, cu crize subreprezentate, ceea ce duce la date dezechilibrate.

Deși multe studii pe această temă se concentrează pe sisteme expert și învățare automată pentru un subset de pacienți dintr-un set de date pre-curățat, acestea pot să nu reprezinte întotdeauna înregistrări EEG tipice și nevoi de interpretare.

Lucrarea face progrese în domeniu prin intermediul unor noi canale de învățare profundă și a unui cadru care permite o abordare consistentă și permite o creștere semnificativă a rezultatelor cercetării. Cadru automatizează extragerea extinsă a datelor EEG, antrenarea modelelor și colectarea rezultatelor.

1.1 Prezentarea domeniului tezei de doctorat

Medicii utilizează înregistrări EEG în mediile clinice pentru a monitoriza, detecta și diagnostica epilepsia. Procesul de automatizare a acestor sarcini va reduce volumul de muncă repetitiv al personalului, ajutându-i în același timp să aloce mai mult timp pentru interpretarea rezultatelor și tratarea pacienților. Monitorizarea automată a semnalului EEG este benefică și pentru pacienții cu forme severe ale bolii, care necesită supravegherea și atenția constantă a personalului medical.

Aplicațiile din lumea reală includ:

1. Unități de monitorizare a epilepsiei, unde neurologii evaluează pacienții pe perioade lungi de timp cu forme de epilepsie dificil de diagnosticat și tratat. Automatizarea procesului de monitorizare poate contribui la îmbunătățirea preciziei tratamentului,

deoarece datele esențiale, cum ar fi momentul și frecvența debutului crizelor, pot fi colectate mai eficient de către personalul medical.

2. Aplicații în domeniul siguranței pacienților și al calității vieții, unde dispozitivele portabile pot alerta personalul medical, îngrijitorii sau rudele. Beneficiile sunt în principal pentru pacienții care suferă de forme severe, refractare la tratament, care duc la pierderea conștienței și prezintă un risc crescut de vătămări accidentale.
3. Intervenție preventivă, în care dispozitivele de detectare automată pot declanșa tratament pe loc, cum ar fi stimularea cerebrală profundă, pentru a atenua severitatea crizelor de epilepsie.
4. Cercetare, în care analiza big data și automatizarea adnotărilor vor contribui la progresul și îmbunătățirea tratamentului pacienților cu epilepsie.

Învățarea automată clasică a fost utilizată pe scară largă pentru sarcini de clasificare și predicție, în special cu seturi de date mai mici și necesitând de obicei mai puțin timp și resurse de antrenament.

Cu toate acestea, se bazează pe ingineria manuală a caracteristicilor. În schimb, algoritmi de Deep Learning (DL) extrag automat caracteristicile din datele brute și au succes cu seturi de date mai mari, chiar și cu cele zgomotoase, și necesită o preprocesare minimă. Au o putere de generalizare mai bună; cu toate acestea, necesită mai mult timp de antrenament și o configurare atentă.

Cheia pentru a permite Deep Learning în domeniul medical este dezvoltarea unei metode de cercetare a soluțiilor într-un ritm accelerat. Deși este disponibilă o varietate de aplicații și cadre în procesarea semnalelor EEG, acestea duc adesea lipsă de automatizare. DL este potrivită pentru procesarea EEG, dar procesul de cercetare trebuie să permită iterații rapide între diferite seturi de date, construirea de modele și evaluarea performanței pentru a identifica cea mai potrivită conductă de procesare.

1.2 Scopul tezei de doctorat

Scopul tezei de doctorat este de a monitoriza semnalele EEG pentru detectarea și prezicerea crizelor epileptice utilizând un algoritm general de clasificare independent de variabilitatea de la pacient la pacient, diferențele de echipament și zgomot, oferind astfel un rezultat fiabil. Metoda implică dezvoltarea unui cadru de învățare profundă pentru iterare rapidă și evaluarea celor mai eficiente conducte de învățare profundă pentru a oferi o imagine obiectivă asupra peisajului soluțiilor.

1.3 Conținutul tezei de doctorat

Următoarele capitole ale tezei de doctorat sunt organizate după cum urmează: (i) Capitolul 2 descrie conceptele teoretice și o evaluare detaliată a stării actuale a domeniului, pregătind terenul pentru cercetarea ulterioară; (ii) Capitolul 3 propune o rețea cu caracteristici proiectate manual și un model de rețea neuronală de complexitate redusă pentru clasificarea crizelor cu latență redusă, validată pe seturi multiple de date; (iii) Capitolul 4 descrie un nou cadru de învățare automată pentru automatizarea procesului

de cercetare în dezvoltarea modelelor DL și EEG ca big data. În plus, sunt discutate derivatele cadrului în domeniul segmentării imaginilor prin rezonanță magnetică; (iv) Capitolul 5 continuă evaluarea aplicațiilor îmbunătățite ale cadrului de învățare automată, prin îmbunătățirea performanței canalelor propuse. În final, Capitolul 6 prezintă un rezumat al concluziilor și propune direcții de cercetare pentru dezvoltări viitoare

Capitolul 2

Starea actuală a tehnicii în recunoașterea și predicția crizelor epileptice

2.1 Introducere

Organizația Mondială a Sănătății (OMS) descrie epilepsia ca fiind o boală a creierului care afectează aproximativ 50 de milioane de oameni din întreaga lume. Simptomele includ mișcări involuntare ale corpului și pierderea controlului vezicii urinare, printre altele. Crizele sunt cauzate de activitatea electrică anormală a unui grup de celule neuronale, caracterizată prin descărcări sincrone și necontrolate ale celulelor creierului [1].

Motivația acestei lucrări este de a dezvolta detectarea și predicția automată a crizelor, necesare pentru îmbunătățirea metodelor de diagnostic, prevenirea morții subite în timpul crizelor și îmbunătățirea calității vieții pacientului.

2.1.1 Care sunt metodele cheie de detectare a crizelor în medicină?

Evaluarea diagnostică tipică implică examinarea neurologică de către un medic și căutarea unor caracteristici focale, inclusiv semne premonitorii, cum ar fi aura. Apoi, neurologul va încerca să evalueze localizarea patologiei cerebrale care ar putea fi responsabilă pentru declanșarea evenimentelor ictale.

Principalul instrument utilizat pentru detectare este electroencefalografia, unde un aparat sensibil va înregistra activitatea electrică a creierului, de obicei măsurată în μV , prin plasarea de electrozi fie pe scalpul pacientului, fie prin implantarea lor în interiorul creierului. Aparatul înregistrează măsurătorile sub formă de electroencefalograme (EEG), unde fiecărui electrod i se atribuie un canal, pe o perioadă specifică de timp determinată de medic. Neurologul va evalua înregistrarea pentru a determina dacă criza a avut loc sau nu.

2.1.2 Cum ar ajuta un algoritm de deep learning?

O lucrare de Christoph Baumgartner și colab. [2] descrie necesitatea unor

dispozitive automate de avertizare și detectare a crizelor epileptice.

Dispozitivele de detectare a crizelor îmbunătățesc tratamentul prin eliminarea necesității monitorizării prelungite în spital, în special pentru pacienții cu frecvență scăzută a crizelor. Un alt motiv pentru detectarea crizelor de epilepsie este reducerea la minimum a morții subite și neașteptate în epilepsie (SUDEP), ceea ce permite o intervenție medicală în timp util.

Algoritmii de clasificare permit înregistrarea și extragerea automată a datelor pacienților, îmbunătățind înțelegerea și tratamentul, precum și permițând potențial tratamente automate precum simularea creierului profund. Dispozitivele de prognoză a crizelor pot ajuta la prevenirea accidentelor și a leziunilor cauzate de pierderea corpului sau a conștienței. Atât dispozitivele de avertizare, cât și cele de detectare a crizelor promit să îmbunătățească monitorizarea și tratamentul pacienților, îmbunătățind îngrijirea acestora.

2.1.3 Arhitectura algoritmului de învățare automată

Această secțiune descrie pe scurt principiile de bază ale unui algoritm de învățare automată. Obiectivul algoritmului este de a se antrena pentru a prezice un rezultat pe baza unor exemple de învățare. De exemplu, datele de intrare ale unui algoritm de învățare includ date precum pixeli, unde sonore sau rezultatul unui alt algoritm.

În timpul antrenamentului, modelul învață prin ajustarea ponderilor sale pe baza diferenței dintre rezultat și rezultatul așteptat, așa cum se arată în Figura 2.4. Odată ce antrenamentul algoritmului este complet, acesta poate fi utilizat pentru a prezice rezultatele pentru noi intrări.




Figura 2.4 Algoritm de învățare automată în antrenament, având în vedere un set de date de antrenament

De obicei, există trei clase de algoritmi de învățare: supravegheați, nesupravegheați și semi-supravegheați.

Cea mai mare parte a lucrărilor realizate până în prezent în domeniul predicției crizelor epileptice s-a bazat pe învățarea supravegheată.

2.1.4 Performanța unui algoritm de învățare

Pentru sarcinile de detectare și clasificare, identificarea vizuală de către clinicienii umani este considerată standardul de aur. Cu toate acestea, pentru algoritmii de avertizare, nu există echivalente umane, cu excepția autoavertismentului prin aure. Pentru a măsura performanța, se poate utiliza un număr mare de indicatori cheie, cum ar fi Adevărat Pozitiv (TP), Adevărat Negativ (VN), Fals Negativ (FN), Fals Pozitiv (FP), Sensibilitate, Specificitate, Precizie, Aria de Sub Curba de Operare a Receptorului (AUROC) și așa

mai departe.

O provocare cheie este standardizarea indicatorilor de performanță pentru algoritmi. Echivalența dintre valorile AUROC, Sensibilitate și Specificare poate fi realizată presupunând că acestea din urmă sunt definite într-un punct de pe curbă cu cele mai bune rezultate.

2.2 Seturi de date

Această secțiune prezintă seturi de date EEG publice care conțin etichete de crize epileptice.

Sarcina de clasificare a crizelor este de obicei împărțită în două categorii: (1) detectarea crizelor și (2) predicția crizelor. Pentru sarcinile de detectare a crizelor, modelele sunt concepute pentru a diferenția între datele ictale (de exemplu, în timpul unei crize) și cele non-ictale, care sunt de obicei adnotate împreună cu setul de date EEG. În schimb, clasificarea datelor pre-criză nu este de obicei adnotată. Există numeroase seturi de date despre EEG pe care cercetătorii le utilizează pentru explorarea și dezvoltarea ulterioară a unor noi metode, iar unele dintre ele sunt: Setul de date gratuit al Spitalului de Copii din Boston, creat în parteneriat cu Institutul de Tehnologie din Massachusetts (CHB-MIT) [3],[4], Universitatea din Bonn [5], Kaggle [6], Universitatea din Pennsylvania (UPenn) și Clinica Mayo [7] [8], și Spitalul Universitar Temple (TUSZ) Corpus EEG [9] .

2.3 Detectarea crizelor

2.3.1 Setul de date CHB-MIT

Alotaiby și colab. [10] selectat 5 pacienți din 24 aparținând setului de date CHB-MIT. Au folosit ca caracteristici amplitudinea semnalului EEG, derivata, media locală, varianța locală, mediana și selecția canalului cu histogramă(e) de canal(e) și interval(e). Fereastra lor corespunzătoare are o durată de 10 secunde pe fiecare canal. Datele sunt introduse într-un algoritm de procesare a pragului pentru a clasifica pacientul în clase ictale și non-ictale. Cu validare încrucișată de tip „leave-one-out”, au obținut o precizie medie de 97,86%, o sensibilitate medie de 97,14% și o specificitate medie de 95,58%. Lucrarea explică clar ce ar trebui să detecteze fiecare caracteristică, cu toate acestea, nu este clar cum au fost selectate canalele și de ce antrenamentul a fost efectuat doar pe cinci pacienți, deoarece setul de date constă dintr-o selecție largă de 24 de pacienți.

2.3.2 Baza de date a Universității din Bonn

Türk și colab. [11] au implementat învățarea profundă pe setul de date al Universității din Bonn. Datele sunt transformate folosind transformarea wavelet continuă în scalograme timp-frecvență. Antrenamentul se face în diferite combinații de clase: A-E, A-D, D-E, A-D-E și A-B-C-D-E, și nu este specific pacientului, ceea ce face ca acesta să fie un algoritm global. Se utilizează o rețea CNN cu 6 straturi, iar divizarea validării

este de 80% antrenament și 20% testare cu validare încrucișată de 10 ori. Media maximă este de până la 100% pentru A-D, dar mai semnificativă de 93,6% pentru A-B-C-D-E. Lucrarea demonstrează că modelele de învățare profundă sunt un algoritm de generalizare fezabil pentru clasificarea EEG.

2.3.3 Baza de date a Universității din Freiburg

Donos și colab. [12] au dezvoltat un algoritm de detectare a crizelor bazat pe date de la Universitatea din Freiburg. Caracteristicile sunt calculate din ferestre de o secundă, nesuprapuse, ale unor canale EEG individuale în domeniile timp și frecvență. Următoarele caracteristici sunt utilizate pentru domeniul timp: media, deviația absolută medie, asimetria, kurtoza, autocorelația și lungimea liniei. În domeniul frecvență, autorii utilizează: puterea în benzile infra-lente (0,1-0,5 Hz), beta (13-30 Hz) și gamma (30-128 Hz) și, în final, raporturile de putere dintre benzile alfa (7-13 Hz), beta și gamma. Apoi, caracteristicile sunt selectate, pentru fiecare pacient, pe baza indicelui Gini. Clasificatorul selectat este Random Forest. Autorii au obținut o sensibilitate medie de 93,84%, cu o specificitate de 0,33 FP/h și o latență medie de 5,47s.

2.4 Predicția crizelor

2.4.1 Setul de date CHB-MIT

Usman și colab. [13] au împărțit înregistrările EEG din setul de date CHB-MIT în clipuri de 30 de secunde, care nu se suprapun, după aplicarea unui filtru trece-bandă pentru a elimina zgomotul liniar și zgomotul de bază EEG. Autorii susțin că au folosit date de la toți cei 24 de pacienți; cu toate acestea, nu este clar dacă antrenamentul este efectuat per pacient sau global. Apoi, clipurilor li se aplică o Transformată Fourier de Timp Scurt (STFT) pentru a converti semnalele din domeniul timp în semnale din domeniul frecvență. Este propus un model CNN cu 5 straturi pentru a extrage automat caracteristici care sunt apoi transmise către o mașină vectorială de suport liniar (SVM). În cele din urmă, este identificată una dintre cele două clase: preictal și ictal și se efectuează validarea „leave-one-out”. Cu un timp mediu de anticipare de 21 de minute, autorii au obținut o sensibilitate medie de 92,7% și o specificitate medie de 90,8%. Nici metoda de validare nu este specificată, așa că nu este clar dacă datele afișate rezultă din antrenament, validare sau testare.

2.4.2 Baza de date a Universității din Bonn

Acharya și colab. [14] una dintre primele lucrări care aplică algoritmi de deep learning setului de date Bonn. Datele sunt normalizate folosind normalizarea scorului Z. Semnalele sunt clasificate în trei clase: ictale, preictale și nonictale. Etichetarea semnalelor preictale nu provine din setul de date EEG. Caracteristicile nu sunt extrase explicit și se utilizează o rețea neuronală convoluțională profundă de 13 straturi. Supraadaptarea este abordată utilizând 70% din date pentru antrenament, 30% pentru

validare și 10% pentru testare. Modelul atinge o precizie de 88,65% prin validare încrucișată de 10 ori. Lucrarea descrie aplicarea unui algoritm de bagging pentru îmbunătățirea performanței.

2.4.3 Baza de date a Universității din Freiburg

Yang și colab. [15] și-au evaluat modelul pe date specifice pacienților de la Universitatea din Freiburg, selectând 19 din 21 de pacienți cu cel puțin 2 crize. Datele au fost filtrate folosind un filtru trece-bandă, iar caracteristicile au fost generate pe baza Entropiei de Permutare Shannon (PE) într-un clip de fereastră glisantă de 5 secunde, fără suprapunere. Apoi, un clasificator SVM este utilizat pentru a discrimina între stările preictale și interictale, utilizând validare încrucișată de 6 ori. O conductă de post-procesare utilizează o fereastră de 2 minute, încorporată într-o fereastră mai lungă de 6 minute, numită putere de tragere în 2 pași, pentru a evita FP. Parametrii puterii de tragere sunt proiectați manual și nu sunt testați sau validați în alt mod. Studiul definește unele metrice relevante, dar îi lipsesc metrice de performanță comune, cum ar fi precizia și AUROC, iar algoritmul nu este evaluat temeinic.

2.4.4 Baza de date a provocărilor de predicție a crizelor AES

Câștigătorul competiției de predicție a crizelor organizate de Societatea Americană de Epilepsie (AES) (Kaggle), echipa Medial Research NK [16] au eșantionat datele la intervale de 1 minut și au utilizat ferestre de 8 secunde cu o suprapunere de 97%. Apoi, au dezvoltat un set de caracteristici în domeniul timpului care implică: (1) media energiei și deviația standard a energiei în timp (în benzi de 15 secunde), pentru fiecare canal; (2) transformata Fourier rapidă (FFT), logaritmul energiei în diferite benzi de frecvență pentru fiecare canal; (3) FFT, logaritmul energiei și energia totală (fără logaritm) în diferite benzi de frecvență pentru media tuturor canalelor; (4) corelarea energiei în benzile de frecvență între canale și (5) rădăcina pătrată sau puterea pentru fiecare caracteristică, pentru a exploata comportamentul neliniar al fiecărei caracteristici. Modelul utilizat a fost un model iterativ de ansamblu cu cele mai mici pătrate, cu un AUROC rezultat de 0,871. Au necesitat un model cu regularizare ridicată. Autorii sugerează că modelul lor nu poate fi utilizat pentru dispozitive de detectare din viața reală.

2.5 Discuție

2.5.1 Atenuarea limitărilor seturilor de date existente

Setul de date Bonn pare să favorizeze cele mai bune rezultate. Acest lucru ar putea fi legat de abordarea eliminării manuale a artefactelor.

Setul de date Freiburg nu mai este accesibil public, prin urmare, noile modele nu îl pot utiliza pentru informații comparative. Un set de date care include setul de date Freiburg poate fi accesat prin plata unei taxe, ceea ce face mai dificilă dezvoltarea de noi algoritmi și compararea cu cercetările anterioare.

Seturile de date Kaggle, atât pentru detectare, cât și pentru predicție, oferă înregistrări ale crizelor epileptice care includ artefacte, fiind cu un pas mai aproape de a permite antrenamentul pentru aplicații din lumea reală.

În cele din urmă, seturile de date private sau auto-înregistrate nu permit cercetătorilor să reproducă cu ușurință rezultatele, prin urmare, lucrările bazate pe seturi de date private nu au fost luate în considerare în această lucrare.

Cu câteva excepții, majoritatea lucrărilor își antrenează algoritmul pe un singur set de date. Marea majoritate a lucrărilor arată rezultate foarte bune pentru antrenamentul specific pacientului.

2.5.2 Depășirea provocărilor legate de detectarea crizelor

Analizând numărul de pacienți incluși în studiile prezentate, se constată că Universitatea din Bonn are date doar de la cinci pacienți, în timp ce CHB-MIT va furniza date de la 24. Totuși, acest lucru nu înseamnă că toate lucrările vor utiliza setul complet de date. Printre lucrările CHB-MIT, un număr mai mic de pacienți dă rezultate mai bune. În cele din urmă, analizând lungimea clipului utilizat în scopuri de detectare, în general, o lungime mai mare a clipului poate însemna un rezultat mai bun, cu condiția ca datele disponibile să fie suficiente.

2.5.3 Predicția crizelor

Cea mai mare performanță se obține pentru sarcinile de predicție care utilizează modele de deep learning, în special CNN-uri, având un comportament similar cu sarcina de detecție. Acestea sunt mai eficiente în extragerea automată a caracteristicilor, spre deosebire de caracteristicile proiectate manual pe baza intuiției umane. În era învățării profunde, modelele de predicție utilizează transferul de învățare din modelele de detecție.

2.6 Conclusions and Future Direction

Algoritmii de clasificare a crizelor epileptice de generație următoare vor beneficia foarte probabil de implementarea învățării profunde. Antrenamentul pe mai multe seturi de date poate dezvălui o cartografiere foarte robustă a semnalelor crizelor EEG. Scopul este de a dezvolta un set de date și un model scalabil, independent de pacient, care poate fi utilizat pentru a clasifica semnalele EEG pentru clase pre-ictale, ictale, inter-ictale și normale. Selecția canalelor se va dovedi importantă pentru acest rol și va permite dezvoltarea unei arhitecturi scalabile pentru diferite aplicații, cum ar fi monitoare EEG spitalicești, dispozitive de avertizare implantabile și stimulatoare cerebrale profunde.

Capitolul 3

Detectarea automată a crizelor epileptice cu latență redusă: abordări individualizate vs. globale

3.1 Introducere

Acest capitol propune un algoritm cu răspuns rapid care utilizează caracteristici proiectate manual. Pentru a minimiza complexitatea computațională, accentul se pune exclusiv pe caracteristicile domeniului timp, care sunt apoi introduse într-o rețea neuronală complet conectată, concepută pentru a clasifica înregistrările EEG ca fiind ictale timpurii, ictale netimpurii sau interictale. Conținutul acestui capitol se bazează pe lucrarea publicată anterior [17].




Figura 3.1 Algoritm Retea: Stratul superior convertește formatul CHB-MIT în format Upenn și Mayo Clinic cu clipuri de 1 secundă. Stratul inferior include secțiunea principală de extragere și clasificare a caracteristicilor.

3.2 Abordarea propusă

3.2.1 Prezentare generală

Mai întâi, datele CHB-MIT sunt convertite în formatul Clinicii Upenn-Mayo, constând în clipuri de o secundă. Apoi, datele din ambele seturi de date sunt filtrate și echilibrate. După aceea, caracteristicile sunt extrase folosind tehnici proiectate manual. Clasificarea finală se realizează folosind o rețea neuronală, așa cum se arată în Figura 3.1.

Evaluarea se realizează atât pe baza datelor specifice pacientului, cât și pe cea globală.

3.2.2 Preprocesarea datelor

Pentru înregistrările CHB-MIT, conducta de preprocesare ajustează numărul de canale fie prin eliminarea canalelor suplimentare, fie prin umplutura cu cele lipsă, așa cum se ilustrează în stratul superior al Figurii 3.1. Datele sunt mai întâi organizate în matrici continue 1-D pentru fiecare clip și apoi filtrate folosind un filtru trece-bandă de 1-47 Hz [18]. Deoarece se utilizează o rețea neuronală cu o țintă de performanță a erorii medii pătratice, datele sunt echilibrate pentru a asigura o reprezentare egală a clipurilor ictale și interictale prin eliminarea aleatorie a segmentelor interictale suplimentare.

3.2.3 Extragerea caracteristicilor

Următoarele caracteristici sunt extrase din fiecare canal EEG:

Energie medie a semnalului per clip: Aceasta se calculează din numărul total de eșantioane discrete pe toate canalele din clipul x . Această funcție este eficientă în detectarea evenimentelor ictale semnificative care se întind pe mai multe canale cu amplitudine mare.

Energie minimă a canalului per clip: este utilă pentru identificarea înregistrărilor cu energie de semnal scăzută per canal, care sunt mai susceptibile de a fi de natură interictal.

Energie minimă a epocii per clip: ajută la identificarea clipurilor interictale care au o energie de semnal foarte scăzută. Dimensiunea epocii este definită ca o zecime din rata de eșantionare a semnalului.

Lungime totală a liniei per clip: Această funcție măsoară lungimile liniilor tuturor canalelor pe un clip și se calculează după cum urmează. Valorile mai mari indică o probabilitate mai mare de activitate critică.

Corelație încrucișată maximă a ferestrei mobile: Această funcție indică cea mai bună corelație încrucișată cu întârziere zero pentru o epocă care conține eșantioane pe două canale adiacente.

Corelație încrucișată maximă pe o fereastră mobilă: Această funcție oferă corelația încrucișată brută maximă, calculată în același mod ca și corelația încrucișată maximă a ferestrei mobile.

Număr de treceri prin zero per clip normalizat: Fiecare clip este normalizat astfel încât valoarea maximă să fie 0,5, iar valoarea minimă să fie -0,5.

Număr de vârfuri per înregistrare: Această funcție calculează numărul total de vârfuri cu o proeminență de 0,3, care este ales empiric pe baza înregistrărilor. Scopul este de a detecta crizele de înaltă frecvență și amplitudine mare.

Valori proprii ale clipurilor: Funcția matricei de corelație este de a prezice sincronizarea pe toate canalele. Cu toate acestea, pentru a utiliza eficient această funcție, aceasta trebuie transformată într-un vector propriu a cărui dimensiune corespunde numărului de canale.

Valori proprii derivate ale clipurilor: Această funcție detectează modificările sincronizate pe canale și nu depinde de amplitudinea brută, concentrându-se în schimb pe rata de modificare. Minimizaază eficient diferențele de amplitudine dintre canale.

3.2.4 Structura rețelei neuronale

Tabelul 3.1 Structuri de straturi ascunse ale rețelelor neuronale (NN)

Rețea neuronală	Numărul de neuroni pe strat ascuns (HL)			
	HL1	HL2	HL3	HL4
NN11	1	-	-	-
NN12	25	-	-	-
NN13	50	-	-	-
NN21	10	5	-	-
NN22	20	10	-	-
NN23	50	20	-	-
NN31	10	5	2	-
NN32	20	10	4	-
NN33	40	20	8	-
NN41	16	12	3	2
NN42	32	24	6	3
NN43	64	48	12	6

Modelul de predicție utilizează o rețea neuronală cu următoarele caracteristici:

- Strat de intrare: variabil, în funcție de numărul de canale pentru fiecare clip.
- Straturi ascunse: până la patru straturi, așa cum este ilustrat în Tabelul 3.1.
- Strat de ieșire: doi neuroni pentru a prezice probabilitatea unei crize epileptice și probabilitatea unei crize epileptice timpurii.

3.3 Rezultate experimentale

3.3.1 Seturi de date

Algoritmul a fost dezvoltat folosind setul de date UPenn și Mayo Clinic Seizure Detection Challenge și a fost îmbunătățit în continuare pe baza setului de date CHB-MIT. CHB-MIT este format din 24 de pacienți cu o rată de eșantionare de 256 Hz, în timp ce UPenn vine cu o rată de eșantionare între 400 Hz și 5000 Hz. Sunt utilizate toate datele disponibile public din ambele seturi de date.

3.3.2 Metrici

Pentru a evalua performanța, propunerea respectă cele mai bune practici pentru seturile de date selectate și utilizează AUROC pentru a evalua capacitatea de detectare a crizelor.

3.3.3 Reglarea parametrilor

Reglarea parametrilor a fost efectuată exclusiv pe setul de date al Clinicii Upenn-Mayo. Performanța fiecărei configurații de rețea enumerate în Tabelul 3.1 a fost evaluată utilizând parametrul de crize AUROC ca și criteriu de evaluare. Se observă că un număr mai mare de neuroni și straturi duce la rezultate mai bune, cel puțin până la un anumit punct de inflexiune. În acest studiu, s-a decis să se continue cu rețeaua N23 cu cea mai bună performanță.

3.3.4 Rezultate comparative

Rezultatele din setul de date al Clinicii Upenn-Mayo demonstrează performanțe individuale și globale comparabile. A fost utilizată o metodă de validare k-fold cu k=10. Pentru evaluarea globală, lucrarea s-a concentrat exclusiv pe datele câinilor care aveau un număr egal de canale. În schimb, setul de date CHB-MIT a prezentat o variație mai mare, rezultând o performanță individuală ușor mai mică decât setul de date al Clinicii Upenn-Mayo, ceea ce poate fi atribuit naturii mai mari și mai diverse a setului de date. În plus, performanța globală a fost, de asemenea, mai mică în comparație cu performanța individuală.




Figura 3.7 Stânga: Performanța medie a N23 în seturile de date Upenn-Mayo Clinic și CHB-MIT. Dreapta: Comparație între N23 și arhitecturile de deep learning semi-supervizate CNN+FC și SAE2 prezentate de Tautan și colab.[19] .

Tabelul 3.2 . Rezultatele competiției Kaggle pe media AUROC

Rețea	Media AUROC
[12] – Random Forest	0.9749
[11] – Rețelelor Neuronale	0.9566
N23 – validare K-fold	0.9494
N23 – validare K-fold - global	0.9511
N23 – 80/10/10 validare	0.9967
N23 – 80/10/10 validare - global	0.9872

Când se compară performanța utilizând ferestre de o secundă cu abordarea propusă de Tautan și colab. [19], se pot observa îmbunătățiri în Figura 3.7 (secțiunea din dreapta) și Tabelul 3.2. Performanța individuală în cadrul seturilor de date este comparabilă și arată o îmbunătățire față de algoritmul de învățare profundă.

În experimentul final, Tabelul 3.2 compară performanța N23 cu înscrierile din Competiția Kaggle [7]. Rezultatele demonstrează performanța teoretică maximă obținută

cu 300 de iterații și 10.000 de epoci, împărțită în 80% antrenament, 10% validare și 10% testare. Performanța obținută a depășit pragul stabilit de [20], indicând faptul că pipeline-ul poate atinge performanțe comparabile cu alți algoritmi.

3.4 Concluzii

Acest capitol a introdus un algoritm cu răspuns rapid pentru detectarea automată a crizelor epileptice, optimizat pentru ferestre EEG de 1 secundă. Deși detectarea crizelor din clipuri foarte scurte este o provocare pentru oameni, această propunere demonstrează că acest lucru poate fi realizat eficient. Această capacitate de detectare rapidă este deosebit de benefică pentru dispozitivele în timp real, cum ar fi stimulatorii cerebrali profundi implantabili.

Folosind un set de caracteristici proiectate manual și o rețea neuronală simplă cu 3 straturi (N23), pipeline-ul a obținut în mod constant performanțe puternice în două seturi de date diferite, utilizând validarea încrucișată k-Fold ($k=10$) și o divizare 80/10/10 pentru validare. Acest lucru a fost aplicabil atât pentru subiecții individuali, cât și pentru seturile de date în ansamblu. Cu toate acestea, algoritmul are limitări legate de antrenamentul global; se pot utiliza doar clipuri cu același număr de canale. Această restricție ne permite să utilizăm întregul set de date CHB-MIT, dar ne limitează doar la o porțiune din setul de date al Clinicii Upenn-Mayo. În ciuda acestui fapt, este de așteptat ca rezultatele să se generalizeze bine la seturi de date mai mari.

Pentru lucrări viitoare, se propune explorarea arhitecturilor de deep learning care pot fi antrenate pe seturi multiple de date cu diferite tipuri de EEG, configurații de canale și rate de eșantionare. O abordare de deep learning ar putea beneficia semnificativ de această diversitate a datelor și ar putea duce la îmbunătățirea performanței în dezvoltarea unui algoritm de detecție mai generalizat.

Capitolul 4

Smart-EEG – Un cadru complet de învățare profundă pentru analiza și predicția semnalelor EEG

4.1 Introducere

De cele mai multe ori, cercetătorii s-au bazat pe o combinație de inginerie manuală a caracteristicilor și metode clasice de învățare automată pentru analiza EEG și dezvoltarea modelelor [21]. De exemplu, cercetătorii proiectează caracteristici, extrag segmente relevante și apoi aplică diferiți algoritmi, cum ar fi Mașinile cu Vectori de Suport, algoritmi Bayes naivi [22] și așa mai departe, pentru a distinge activitățile cerebrale, ceea ce consumă mult timp și nu reușește să scaleze seturi mari de date.

Capitolul prezintă smartEEG, un framework complet dezvoltat pentru a rezolva această discrepanță functionand într-un mod eficient cu resurse hardware limitate folosind diferite arhitecturi neuronale și rulând automat peste noapte.

4.2 Motivare

Motivația construirii smartEEG este mai întâi de a accelera cercetarea DL EEG prin automatizarea sarcinilor esențiale precum colectarea datelor, preprocesarea, etichetarea și configurarea modelului folosind antrenamentul accelerat de Unitatea de Procesare Grafică (GPU). Cadrul este conceput pentru a permite experimentarea la scară largă, utilizând două seturi de date CHB-MIT [4] și TUSZ [9] care conțin mii de ore de înregistrări la sute de pacienți, cu accent pe detecție și pe sarcini de detectare plus predicție.

4.3 Prezentare generală a literaturii de specialitate

4.3.1 Cadre EEG existente

Au fost dezvoltate mai multe framework-uri EEG, fiecare având propriile capabilități. Unele dintre framework-uri, cum ar fi pySPACE [22], MNE-Python [23],

BciPy [24], EEGLAB [25] și multe altele, se concentrează pe preprocesarea și vizualizarea semnalelor, învățarea automată clasică și altele încorporează învățarea profundă în contextul lor. Cu toate acestea, niciunul dintre cadrele (framework-urile) existente nu oferă o soluție complet integrată, end-to-end, capabilă să evalueze automat noile conducte pe baza unor setări predefinite.

4.4 Arhitectura cadrului smartEEG

4.4.1 Obiectivele de proiectare a cadrului de lucru

SmartEEG este un framework de deep learning end-to-end bazat pe Python, care minimizează utilizarea resurselor hardware, maximizând în același timp performanța și viteza de iterație. Această pipeline permite antrenamentul și validarea eficientă pe seturi de date la scară largă, inclusiv mii de pacienți și sute de mii de clipuri EEG, fără a epuiza resursele sistemului.




Figura 4.1 Prezentare a modului principal al cadrului smartEEG [26].

4.4.2 Modulul principal

Canalul smartEEG este rulat din modulul principal și constă din toate modulele necesare pentru rularea cadrului. În primul rând, există modulul de rulare în lot, care permite canalului să ruleze fie utilizând configurații multiple într-o buclă, fie rulând pe configurația implicită. Se selectează unul dintre cele două seturi de date. Apoi, se definesc și se selectează parametrii de date și de antrenament, care fac parte din modulul principal.

Modulul generator de adrese de înregistrare și matrice de etichete este apelat în modulul principal pentru a genera aceste date, care se bazează, de asemenea, pe biblioteca de date. Prin urmare, există două module distincte generatoare de adrese și etichete de clipuri EEG, create pentru fiecare set de date, care sunt utilizate pentru a colecta toate informațiile necesare.

Modulul generator de matrice de clipuri EEG și etichete generează matricea de date de intrare (Date X) și matricea de etichete (Date Y). Modulul de procesare a datelor EEG și de eliminare a zgomotului poate fi utilizat pentru a activa diferite metode de eliminare a zgomotului prezentate în secțiunile următoare. După ce matricea de clipuri EEG și etichetele sunt generate, acestea sunt apoi introduse în modulul de antrenament al modelului, unde antrenamentul este efectuat pe baza setului de configurații.

4.4.3 Parametri de configurare

Parametrii de configurare oferă o serie de chei de parametri pentru fiecare categorie, parametri de date și parametri de antrenament, cum ar fi lungimea clipului, modelul și altele.

4.4.4 Modulul generator de matrice de adrese și etichete pentru înregistrare

Acest modul primește ca intrări datele și configurațiile de antrenament, precum și setul de date selectat. Este utilizat pentru a genera o matrice de adrese de înregistrare în format standard, care conține codul pacientului, căile fișierelor, frecvența de eșantionare, numărul de canale, începutul și sfârșitul unei crize epileptice. Apoi generează ca ieșire matricea de adrese de înregistrare în format standard.

4.4.5 Generator de adrese pentru clipuri și etichete EEG

Obiectivul principal al modulului de adrese de clipuri și etichete EEG este de a genera o matrice echilibrată și randomizată de adrese de clipuri EEG de lungimi identice și etichetele corespunzătoare acestora. Modulul îndeplinește o serie de funcții pentru a realiza acest lucru, cum ar fi crearea unui set de referințe (sau adrese) de clipuri EEG cu 4 etichete implicite, echilibrarea și randomizarea pentru a construi în final o matrice de adrese de clipuri EEG și etichetele acesteia.

4.4.6 Modul generator de matrice de clipuri EEG

Modulul Generator de Matrice de Clipuri este propus pentru a oferi următoarele funcționalități: (i) clipurile EEG adresează gruparea pe baza locației lor în fiecare fișier al pacientului, (ii) citirea fișierului EDF, (iii) reeșantionarea în domeniul timpului la o rată de eșantionare comună, (iv) normalizarea datelor semnalului, (v) umplutura canalelor, (vi) stocare pe disc pentru matrice de clipuri foarte mari și (vii) vectorizarea etichetelor la codificare one-hot, astfel încât datele X și Y să poată fi create.

4.4.7 Modulul de procesare a datelor EEG și de eliminare a zgomotului

Deoarece EEG-ul poate fi zgomotos, unele canale pot fi defecte în timpul înregistrării. Pentru a atenua acest lucru, este introdus Modulul de Procesare a Datelor și Dezgomotare EEG, care constă în diverse metode, inclusiv clasificarea canalelor folosind LassoCV, RFE și SelectKBest. În plus, sunt utilizate metode precum transformata Hilbert, derivatele și filtrele trece-bandă.

4.4.8 Biblioteca de modele și modulul Builder

Acest modul este locul unde modelele pot fi construite și selectate. Prin urmare, accentul în acest studiu se pune pe o varietate de rețele neuronale profunde, începând de la rețele complet conectate (NN) și continuând cu CNN unidimensionale și bidimensionale (C1D, C2D), precum și RNN-Elman (RNE), RNN-GRU (RNG) și RNN-LSTM (RNL) care au fost construite și testate în curs de dezvoltare. În codul modelului, a doua cifră reprezintă numărul de straturi ascunse.

4.4.9 Exemple de modele în bibliotecă

Toate arhitecturile modelelor sunt proiectate cu un număr diferit de straturi și parametri. De exemplu, un model C1D1H-2 se referă la o rețea CNN unidimensională cu o dimensiune a nucleului de 64 și 50 de caracteristici. Desigur, există și combinații ale aceleiași rețele, dar cu configurații diferite, cum ar fi dimensiunea nucleului, numărul de straturi ascunse sau chiar numărul de straturi de clasificare utilizate.

4.4.10 Antrenarea modelului

Antrenamentul modelului se face luând în considerare diferiți pași, cum ar fi divizările de antrenament și validare, setarea hiperparametrilor de antrenament, crearea de mini-loturi, încărcarea modelului selectat și a mini-loturilor în memoria RAM a GPU-ului, efectuarea retropropagării, capturarea metricilor de performanță și stocarea parametrilor și performanței modelului.

4.4.11 Modulul de rulare în loturi

Executarea în lot este activată atunci când trebuie efectuate experimente cu diferite configurații ale datelor și parametrilor de antrenament listați în configurator. Acest lucru se face pentru a economisi timp în timpul cercetării, permițând utilizatorului, de exemplu, să efectueze mai multe experimente peste noapte.

4.4.12 Modul de plotare

Pentru a permite vizualizarea datelor, a fost dezvoltat un modul de reprezentare grafică care poate efectua reprezentarea grafică a următoarelor elemente: (i) date de performanță, cum ar fi curbe de precizie și pierdere și matrici de confuzie, (ii) date statistice, cum ar fi diagrame de tip box plot pentru validarea k-fold și grafice ale

semnalelor EEG.

4.5 Rezultatele aplicațiilor experimentale

Această secțiune prezintă performanța modelului obținută utilizând conducta smartEEG la diverse configurații, așa cum este prezentată în lucrarea publicată [26]. Prin urmare, Figura 4.34 din stânga afișează căutarea în rețea efectuată cu o lungime a clipului de 1 secundă și fără augmentarea datelor CHB-MIT utilizate pentru antrenament. Se utilizează cele două clase, ictal și interictal, iar ajustarea a fost efectuată global, folosind 80% din întregul set de date pentru antrenament și 20% pentru o divizare aleatorie pentru validare, iar antrenamentul a fost realizat pe 50 de epoci pentru fiecare model.

Figura 4.34 prezintă comparația sensibilității modelului la diferite lungimi de clipuri EEG utilizând tehnica de regularizare a opririi timpurii, care a fost implementată cu o răbdare de 5 epoci pe setul de date CHB-MIT utilizând rețeaua C1D1H-2.

Tabelul 4.6 Comparație cu lucrările anterioare

CHB, 1 s, global, valid. 10-fold	Media		
	Senzitivitate	Specificitate	Acuratețe
Ciurea și colab. [17]	0.8164	0.8031	0.809
C1D1H-2	0.925	0.938	0.931




Figura 4.34 Stânga: Prezentare generală a căutării modelului în cele 36 de rețele definite în tabelul Arhitectură model din setul de date CHB-MIT. Legenda plasată sub axa orizontală indică ultimele caractere ale codului modelului; Dreapta: Efectul lungimii clipului și al regularizării opririi timpurii pentru antrenamentul global pe setul de date CHB-MIT. Numărul Exxx (de exemplu, E187) indică cea mai bună epocă în care validarea se face pe 80/20% din date.

Antrenamentul și validarea sunt aceleași, cu excepția implementării opririi timpurii.

Întrucât acest capitol se concentrează pe întreaga configurație a conduitei smartEEG, performanța modelului este comparată cu cea a lucrărilor anterioare și este prezentată în Tabelul 4.6. Antrenamentul este efectuat pe un clip CHB-MIT de 1 secundă pentru detectarea crizelor epileptice și se aplică o tehnică de validare în zece moduri. Nu

este activată oprirea sau augmentarea timpurie.

4.6 Concluzii

Pentru a evalua detectarea și predicția crizelor epileptice, pipeline-ul smartEEG este conceput să suporte diferite configurații. În primul rând, facilitează extragerea datelor, facilitând integrarea de către cercetători a unor seturi de date suplimentare, după cum este necesar. După antrenament, pipeline-ul generează ponderi și rezultate ale modelului, sporind atât eficiența, cât și reutilizabilitatea. Secțiunea cu rezultate experimentale prezintă o varietate de arhitecturi de model, CNN-urile fiind cele mai potrivite pentru sarcinile de detectare atunci când extractorul de caracteristici este limitat la două straturi, iar antrenamentul este efectuat pe setul de date global.

Compararea rezultatelor cu lucrările anterioare arată că rețelele de învățare profundă pot depăși performanța învățării automate clasice.

4.7 smartMRI: derivat al cadrului smartEEG aplicat pe imagini RMN

Bazându-se pe pipeline-ul smartEEG, dezvoltat inițial pentru detectarea și predicția EEG, metodologia sa a fost extinsă la imaginile prin rezonanță magnetică (RMN). Acest cadru adaptat este denumit smartMRI, introdus în lucrarea anterioară [27].

4.7.1 Introducere

RMN-ul este o tehnică de imagistică medicală pentru planificarea diagnosticului. Acesta oferă imagini detaliate și de înaltă calitate ale structurilor interne, care pot ajuta la detectarea și localizarea anomaliilor.

4.7.2 Prezentare generală a cadrului smartMRI

Pentru a face față acestor provocări și a accelera procesul computațional, este introdus cadrul smartMRI, similar cu cadrul smartEEG, pentru a automatiza mai multe modele de deep learning. Structura framework-ului RMN constă din module similare cu smartEEG, așa cum a fost prezentat anterior, dar modul în care datele sunt citite și procesate diferă pentru imaginile medicale.

4.7.3 Set de date

Setul de date RMN a fost obținut de la [28], care a fost disponibilă publicului și constă din 60 de imagini RMN de antrenament și 40 de imagini RMN de validare de la pacienți. Etichetele au fost furnizate de medici care au segmentat manual masca multi-clasă pentru fiecare secțiune de articulație a genunchiului din imaginea RMN.

4.7.4 Configurarea instruirii și indicatorii de evaluare

Datele au fost antrenate pe un singur plan anatomic. Optimizatorul utilizat în acest

studiu este același cu cel utilizat în pipeline-ul smartEEG, și anume Adam. Comparativ cu smartEEG-ul din acest studiu, sunt evaluate diferite metrice, cum ar fi distanța medie simetrică la suprafață (ASSD), distanța medie pătratică (RMSD) și coeficientul de similaritate a dicelor (DSC).

4.7.5 Rezultate ale rețelelor neuronale convoluționale

Cea mai bună performanță a modelului pentru ASSD și RMSD este comparată între cele de top, împreună cu o lucrare suplimentară de ultimă generație. Rezultatele sunt prezentate în Tabelul 4.8, unde cu cât abaterea standard este mai mică, cu atât predicția a fost detectată mai bine.

Tabelul 4.8 Compararea metricilor distanței la suprafață

Metode 60 antrenament/ 40 validare	Medie			
	Femur ASSD	Tibie ASSD	Femur RMSD	Tibie RMSD
Lee și colab [29]	0.58 (0.45)	0.47 (0.32)	1.73 (0.85)	1.53 (1.05)
P3D U-Net128	0.35 (0.20)	0.46 (0.37)	0.87 (0.82)	1.32 (1.21)
P3D GU-Net128	0.34 (0.18)	0.47 (0.31)	0.85 (0.64)	1.33 (1.18)
P3D GU-Net868	0.30 (0.16)	0.37 (0.30)	0.72 (0.58)	0.90 (1.01)

4.7.6 Discuție

Cadrul smartMRI, dezvoltat pe baza cadrului smartEEG, a demonstrat eficacitate și în alte aplicații prin generarea de rezultate utilizând mai multe modele de deep learning, făcând ca pipeline-ul de bază să fie eficient pentru o gamă mai largă de aplicații și facilitând găsirea celei mai bune performanțe a modelului într-o varietate de modele.

Capitolul 5

Detectarea și predicția crizelor bazate pe EEG: CNN hibrid, eliminarea zgomotului și abordări comparative de învățare profundă

5.1 Introducere

Semnalele EEG sunt predispuse la zgomot și variază în funcție de pacient.

Pentru a aborda aceste provocări, acest capitol propune trei abordări, dezvoltate folosind cadrul smartEEG [26]: o rețea hibridă, o tehnică de eliminare a zgomotului folosind selecția canalului și diverse tehnici de procesare.

5.2 Clasificarea EEG utilizând o rețea neuronală convoluțională hibridă cu mecanism de atenție

5.2.1 Introducere

Majoritatea abordărilor actuale vizează îmbunătățirea algoritmilor EEG prin diverse metode care utilizează învățarea profundă. De exemplu, Gia și colab. [30], o lucrare din 2023 [31], Ru și colab. [32] au utilizat un mecanism de atenție cu mai multe capete cu învățare profundă. În plus, Shoka și colab. [33] au combinat criptarea spectrogramelor cu învățarea profundă pentru EEG, iar Cisotto și colab. [34] s-au concentrat, de asemenea, pe mecanisme de atenție diferite, dar folosind setul de date TUSZ. Cu toate acestea, niciunul dintre ei nu s-a concentrat pe lungimi mai scurte ale clipurilor, cum ar fi 1 secundă.

5.2.2 Abordarea propusă

În acest studiu, performanța modelului este verificată folosind cadrul smartEEG și date provenite din două seturi de date, CHB-MIT și TUSZ, atât pentru detectarea, cât și pentru predicția crizelor epileptice.

Modelul de bază este modelul C1D1H-2 validat în Capitolul 3. Acesta este

îmbunătățit prin adăugarea unui modul Simple Attention 1-D (S-Attn1D) care stabilește o importanță canalelor din model. Acest bloc de atenție constă dintr-o pereche de CNN 1-D, iar la final ponderile atenției sunt multiplicare element cu datele de intrare. Ulterior, este propusă o nouă rețea convoluțională hibridă pentru a capta dependențele temporale alături de dependențele spațiale, așa cum se arată mai jos în Figura 5.1 c.




Figura 5.1 a) Bloc 1D Atenție simplă. b) Arhitectură de rețea C1D1H-2 cu modul Atenție (C1D1H-2+Atenție). c) Arhitectură de rețea convoluțională hibridă pentru modele Lite și Large [35].

Arhitectura modelului este proiectată cu o lungime a clipului de 1 secundă și integrează rețele neuronale convoluționale paralele, în special CNN 1-D și 2-D, pentru a îmbunătăți capacitatea modelului de a se concentra pe cele mai importante segmente ale semnalului. Rezultatul este modelat în funcție de numărul de categorii de clasificare.

Această arhitectură hibridă servește drept bază pentru două modele: un HybridConv Lite și un HybridConv Large. Diferența dintre acestea două constă în modul în care sunt setate dimensiunea nucleului și numărul de caracteristici. Un model mai mare constă din mai multe caracteristici și o dimensiune mai mare a nucleului.

5.2.3 Rezultate experimentale

Pentru acest experiment, sunt utilizate atât seturi de date CHB-MIT, cât și TUSZ, însă pentru cel din urmă sunt luați în considerare doar 20 de pacienți în scopuri de verificare. Pentru acest studiu, au fost utilizate clipuri cu lungimi de 1 secundă, 2 secunde, 3 secunde și 5 secunde atât pentru sarcini de detectare, cât și pentru cele de predicție, utilizând diferite tehnici de normalizare, cum ar fi $[-1,1]$, $[0,1]$ și împărțirea la 10000.

Variația intervalelor clipurilor nu numai că a ajustat granularitatea temporală a datelor de intrare, dar a afectat direct și numărul total de clipuri disponibile pentru antrenament.

Tabelul 5.1 Compararea diferitelor rețele

Model	Pacient		Global	
	Detect	Detect & predict	Detect	Detect & predict
C1D1H-2	0.922	0.704	0.891	0.668
C1D1H-2+Attn	0.939	0.825	0.930	0.743
Hybrid Conv Lite	0.953	0.876	0.946	0.777
Hybrid Conv Large	0.678	0.679	0.968	0.852

În plus, s-a aplicat o tehnică de fereastră glisantă clipurilor EEG de 1 secundă, utilizând o suprapunere de 50% pentru a îmbunătăți performanța modelului TUSZ, ceea ce a arătat o creștere a performanței.

Tabelul 5.1 prezintă progresele comparativ cu valoarea inițială, atât în ceea ce privește indicatorii de performanță specifici pacientului, cât și cei globali, toate acestea fiind validate folosind o metodă de divizare 80/20. În special, HybridConv Lite demonstrează rezultate îmbunătățite la nivel individual de pacient, dar are performanțe sub așteptări într-un context global mai larg. În schimb, HybridConv Large tinde să aibă performanțe mai bune la scară globală, dar este insuficient în ceea ce privește rezultatul individual al pacientului.

Performanța celor două modele hibride a fost comparată cu alte rețele de ultimă generație bazate pe atenție, așa cum este ilustrat în Tabelul 5.2. S-a utilizat o validare k-fold, cu k setat la 10, pentru a verifica toate rezultatele. Rezultatele sunt comparate cu literatura existentă. În special, utilizarea unei funcții de fereastră glisantă dă rezultate mai bune, ceea ce se aliniază cu așteptările.

Tabel 5.2 *Comparație cu alte studii*

	Model	Lungime clip (s)	Detect	Detect & predict
CHB	[30]	23.6	0.740	0.510
	[33]	10	0.889	-
	[31]	5	0.964	-
	[32]	30	0.928	-
	C1D1H-2 [26]	1	0.931	0.720
	Hybrid Conv Large, validare k-fold, k = 10	1	0.963	0.851
		3	0.977	0.875
		5	0.979	0.854
TUSZ	CNN+Attn. [34]	2	0.969	-
	HybridConv Large, validare k-fold, k=10, suprap. 50%	2	0.981	0.943

5.2.4 Concluzii

Modelele hibride dezvoltate încorporează atât caracteristici temporale, cât și spațiale, ceea ce duce la o performanță îmbunătățită a modelelor datorită arhitecturii lor simplificate. Utilizarea unor tehnici precum suprapunerea și ferestrele glisante pentru augmentarea datelor ridică unele îngrijorări. Una dintre problemele majore este că segmentele EEG identice pot duce la scurgeri de date, astfel încât acestea pot apărea atât în seturile de date de antrenament, cât și în cele de validare, ceea ce poate duce la o evaluare nerealistă a modelului și poate afecta aplicabilitatea acestuia pentru date din lumea reală sau nevăzute. Pentru a aborda această problemă, explorarea altor strategii alternative la tehnica suprapunerii poate fi benefică pentru a îmbunătăți performanța modelului, cum ar fi reducerea zgomotului pe canal sau tehnicile de preprocesare a semnalului EEG.

5.3 Reducerea zgomotului EEG cu metode de selecție a canalelor

5.3.1 Introducere

Selectarea canalelor poate ajuta la atenuarea problemelor asociate cu canalele irelevante sau zgomotoase, care pot fi inutile și pot avea un impact negativ asupra preciziei clasificării.

Au fost utilizate mai multe tehnici pentru a atenua acest lucru. De exemplu, Jigswal și colab. [36] au redus numărul de canale EEG înainte de a le introduce într-un clasificator, ceea ce le-a permis să obțină o precizie de 0,99. Un alt studiu realizat de Tran și colab. [37] unde s-au concentrat pe un singur canal pentru a accelera procesul de clasificare; Cu toate acestea, această abordare nu reflectă cu acuratețe datele din lumea reală.

5.3.2 Metode

Selectarea canalelor este utilizată pentru a îmbunătăți clasificarea EEG prin reducerea numărului de canale EEG (caracteristici de intrare: medie, deviație standard, minim, maxim, energie, energie minimă, număr de vârfuri și fereastră mobilă maximă), îmbunătățind în același timp performanța modelului. În această lucrare, sunt utilizate trei tehnici de selecție a caracteristicilor: LassoCV, RFE și SelectKBest. LassoCV este o metodă de regresie care utilizează validarea încrucișată și poate fi utilizată pentru selecția și regularizarea caracteristicilor prin reducerea coeficienților la zero. Această metodă poate reduce numărul de caracteristici selectate pe baza coeficienților modelului. RFE, pe de altă parte, este o abordare iterativă care elimină recursiv cele mai puțin importante caracteristici pe baza coeficienților estimatorului sau a scorurilor de importanță, până când se atinge numărul așteptat de caracteristici. SelectKBest clasifică caracteristicile în funcție de importanța lor în prezicerea variabilei țintă folosind un test statistic, iar primele K caracteristici sunt selectate. Aceste metode sunt aplicate înainte de antrenamentul pe cadrul smartEEG, iar scopul este de a elimina zgomotul din date prin identificarea celor mai relevante canale EEG pentru detectarea și predicția crizelor epileptice, îmbunătățind astfel performanța modelului, reducând în același timp costurile de calcul și accelerând antrenamentul și validarea modelului.

Modelul utilizat pentru acest studiu este evidențiat în lucrările anterioare prezentate în Capitolul 3. Flexibilitatea algoritmului permite selectarea unui număr predefinit de canale de top (de exemplu, 8, 15 sau 18), astfel încât performanța poate fi comparată între modelele Lite și Large.

5.3.3 Rezultate experimentale

Pentru acest studiu, a fost utilizat doar CHB-MIT, examinând atât clipuri EEG de 1 secundă, cât și de 5 secunde.

Evaluarea performanței de detectare a crizelor EEG a fost evaluată pe baza tuturor celor trei metode de selecție a caracteristicilor prezentate: LassoCV, RFE și SelectKBest.




Figura 5.9 Compararea performanței modelului între seturi de date specifice pacientului și globale folosind clipuri de 1 secundă, evaluate pe un subset de canale 18, 15 și 8. Se utilizează LassoCV, RFE și SelectKBest. .

Figura 5.9 se concentrează pe două aspecte cheie: detectarea și detectarea plus predicția crizelor epileptice la o durată a clipului de 1 secundă. Se poate observa că LassoCV și SelectKBest demonstrează în mod constant performanțe ușor mai mari în cele trei configurații de canale pentru date specifice pacientului atunci când se utilizează modelul Lite, depășind precizia RFE.

Caracteristicile de intrare utilizate în toate cele trei metode au în comun cele mai multe caracteristici, care sunt energia medie și lungimea liniei. Tabelul 5.3 prezintă performanța de validare în cel mai bun caz pentru toate metodele de selecție a caracteristicilor și numărul de canale selectate pentru eliminarea zgomotului, comparând modelele Lite și Large cu valorile de referință din lucrările anterioare, așa cum este evidențiat în Secțiunea 5.2.2, atât pentru datele specifice pacientului, cât și pentru cele globale.

Tabelul 5.3 Rata de îmbunătățire față de munca anterioară

Model	Lungime clip (s)	Pacient		Global	
		Detect	Detect & predict	Detect	Detect & predict
Lite	1	0.965	0.848	0.941	0.731
		0.43%	1.68%	4.8%	8.36%
	5	0.811	0.778	0.960	0.830
Large	1	0.703	0.807	0.959	0.844
		3.65%	18.80%	-0.37%	-0.85%
	5	0.582	0.465	0.973	0.864
		4.48%	12.67%	-0.64%	1.17%

Mai exact, cu date globale, modelul Lite demonstrează îmbunătățiri, în special la o lungime a clipului de 1 secundă, atât pentru detectare, cât și pentru detectare plus predicție. De exemplu, se observă o îmbunătățire mai mare în datele globale pentru sarcina de detectare, unde se obține o rată de îmbunătățire de 10,88% la o lungime a clipului de 5 secunde utilizând modelul Lite. Cu toate acestea, se observă o rată de îmbunătățire mai semnificativă la o lungime a clipului de 1 secundă, unde modelul Large îmbunătățește performanța cu 18,80%.

5.3.4 Concluzii

Au fost prezentate trei metode de selecție a caracteristicilor, LassoCV, SelectKBest și RFE, care ajută la suprimarea zgomotului prin clasificarea canalelor și selecția bazată pe caracteristici proiectate manual. Proiectul a arătat îmbunătățiri generale pentru modelul Light în sarcina de clasificare globală și pentru modelul Large în sarcina specifică pacientului, confirmând că acțiunea de eliminare a zgomotului a fost eficientă.

5.4 Studiu comparativ al tehnicilor de procesare a semnalului EEG pentru detectarea și predicția crizelor folosind învățarea profundă

5.4.1 Introducere

Pentru a aborda zgomotul și a îmbunătăți performanța modelului, în acest studiu sunt propuse diverse tehnici bazate pe anvelopă. De exemplu, anvelopa bazată pe Transformata Hilbert [38] este utilizată pentru puterea sa de a reprezenta modulațiile de amplitudine și de a reduce zgomotul de fază al semnalului. Următorul paragraf este o scurtă trecere în revistă a literaturii de specialitate privind tehnicile de procesare utilizate cu CHB-MIT și TUSZ.

Cao și colab. [38] au utilizat o metodologie de fuziune a caracteristicilor pentru a descompune semnalele EEG brute și au aplicat un filtru trece-bandă, obținând o precizie de 98,43%. Shen și colab. [40] au aplicat, de asemenea, filtrarea trece-bandă pentru o rețea în care extragerea și clasificarea caracteristicilor au fost efectuate de GoogleNet CNN pentru detectarea crizelor epileptice în timp real. Aceștia au obținut o precizie de 97,74%.

Deng și colab. [39] au aplicat suprapunerea la diferite ferestre. În fluxul lor de lucru, au folosit, de asemenea, un filtru trece-bandă, iar clasificarea a fost efectuată cu ajutorul unui transformator Deepwalk. Au obținut o precizie de 99,54%. O altă lucrare care utilizează filtrarea trece-bandă între 0 și 128 Hz este cea a lui Rukhsar și colab. [40]. Autorii au folosit un transformator convoluțional ușor (LCT) și au obținut o precizie de 96,31% pentru un clip de 0,5 secunde și de 95,97% pentru un clip de 1 secundă.

Chung și colab. [41] a utilizat un filtru trece-bandă cuprins între 1 și 30 Hz, acoperind benzile de frecvență alfa (1-4 Hz) și beta (13-30 Hz) ca tehnici de preprocesare. Un clasificator CNN compact a oferit o precizie de 98,47%.

Xiang și colab. [42] u utilizat 18 canale EEG în care componentele de frecvență la 0 Hz și cele cuprinse între 57 și 63 Hz au fost eliminate. Autorii au folosit suprapunerea și o rețea de atenție spațio-temporală grafică, obținând o precizie de 94,76% pentru o fereastră de 1 secundă și de 98,20% pentru o fereastră de 5 secunde.

5.4.2 Metode

Următoarele tehnici de procesare au fost evaluate pe framework-ul smartEEG: (i) anvelopa Hilbert, destinată calculării magnitudinii semnalului analitic; (ii) anvelopa medie pătratică (RMS), utilizată pentru a echilibra precizia temporală și netezire; (iii) anvelopa puterii logaritmice, calculată pentru a evidenția caracteristicile prin aplicarea transformării logaritmice la valorile pătratice; (iv) derivata temporală, calculată pentru a accentua caracteristicile dinamice pe măsură ce se schimbă panta și se utilizează derivate primare, secundare și a treia; (v) filtrare trece-bandă utilizată pentru a elimina atât frecvențele joase, cât și cele înalte și (vi) filtrare trece-bandă cu derivată temporală, unde ieșirea filtrării trece-bandă este adăugată cu derivata de ordinul întâi pentru a crea noul semnal.

5.4.3 Rezultate experimentale

Figura 5.14 ilustrează performanța comparativă a diferitelor tehnici de procesare. Se poate observa în mod clar că anvelopele Hilbert, RMS și LogPower nu numai că degradează performanța finală, dar și modifică curbele de învățare, făcând astfel modelul mai puțin stabil.




Figura 5.2 Compararea preciziei de validare a clasificării între diferite tehnici de procesare EEG: anvelopă Hilbert, anvelopă RMS, anvelopă log-power, semnal EEG brut normalizat și derivată temporală de ordinul întâi. Toate metodele sunt evaluate folosind configurația globală, cu clipuri de 1 secundă în sarcina de detectare a crizelor epileptice.

Tabelul 5.4 Compararea preciziei cu alte studii privind clasificarea crizelor EEG specifice pacientului CHB-MIT

Detectare	# pacient	Lungime clip (s)	Fereastră suprapusă	Acuratețe
Cao și colab. [38]	Nespecificat			0.984
Shen și colab. [43]	16	1.35	Da (1s)	0.977
Deng și colab. [39]	23	0.5 și 1	Da, pas necunoscut	0.995
Rukhsar și colab. [40]	23	0.5 și 1	Yes (25%)	0.963 (0.5s), 0.959 (1s)
Chung și colab. [41]	13	4	Yes (4s)	0.984
Prediction Task				
Xiang și colab. [42]	19	1 și 5	Alunecare	0.947 (1s), 0.982 (5s)
Propunerea (Detect & Predict)	24 (toți)	1	No	0.971 (Det.), 0.890 (Det. & Pred.)

În schimb, derivata de ordinul întâi, filtrarea trece-bandă și filtrarea trece-bandă prezintă în mod clar o îmbunătățire mai bună. Compararea cu alte lucrări este prezentată în Tabelul 5.7 și se observă că precizia ridicată obținută de alții se datorează tehnicii de suprapunere, ceea ce face ca metricile să nu fie reprezentative pentru datele din lumea reală..

5.5 Direcții viitoare

Acest capitol prezintă trei aplicații ale cadrului smartEEG. Prima este o arhitectură de rețea neuronală convoluțională hibridă, care constă din două rețele neuronale convoluționale paralele (1-D și 2-D). Se observă că combinarea caracteristicilor temporale și spațiale îmbunătățește performanța canalului.

În al doilea rând, se discută despre reducerea zgomotului EEG folosind selecția canalului pe baza clasamentului. Au fost evaluate trei metode pentru selecția caracteristicilor și clasamentul canalelor: LassoCV, RFE și SelectKBest.

Efectul de reducere a zgomotului a fost demonstrat prin îmbunătățirea rețelei Lite în sarcina globală și a rețelei mari în sarcina la nivel de pacient. De asemenea, a fost demonstrată o îmbunătățire generală.

În cele din urmă, s-a discutat despre tehnica de procesare EEG pentru suprimarea zgomotului prin tehnici de anvelopă și filtrare. Aplicarea unei derivate și a filtrării semnalului a fost cea mai bună metodă de reducere a zgomotului din datele EEG. Aceasta a arătat nu numai o performanță îmbunătățită în ceea ce privește acuratețea validării, dar și curbele de antrenament/validare au fost mai stabile.

Capitolul 6

Concluzii

În primul rând, a fost evaluată dezvoltarea unui clasificator de rețea neuronală ușoară, capabil să detecteze crizele epileptice cu un set mic de caracteristici proiectate manual. În al doilea rând, a fost dezvoltat un cadru inteligent de Deep Learning (smartEEG) capabil să iterateze rapid printr-o varietate de modele de deep learning. Acest lucru este esențial pentru accelerarea timpului de calcul, chiar și peste noapte, și ajută cercetătorii să analizeze rapid și mai detaliat matricile de performanță dintre diverse modele. În al treilea rând, pentru a îmbunătăți și mai mult performanța modelului, a fost demonstrată o rețea hibridă care valorifică atât dependențele temporale, cât și cele spațiale din date. În cele din urmă, au fost utilizate diverse tehnici pentru a reduce zgomotul de semnal din date pentru a maximiza performanța modelului.

6.1 Rezultate obținute

Această secțiune începe cu un rezumat al rezultatelor obținute din Capitolul 2 încoace.

Prin urmare, Capitolul 2 prezintă stadiul actual al tehnicii în detectarea și predicția crizelor epileptice utilizând diverse seturi de date, cum ar fi CHB-MIT, Universitatea din Bonn și Universitatea din Freiburg. Rezultatul este un studiu comparativ al stadiului actual al tehnicii și stabilește baza pentru cercetări ulterioare în capitolele următoare, unde utilizarea tehnicilor de învățare profundă este principala direcție de cercetare.

Capitolul 3 explorează diferite rețele neuronale. Introduce un algoritm cu răspuns rapid cu caracteristici proiectate manual pentru detectarea automată a crizelor epileptice, optimizat pentru clipuri foarte scurte. Canalul de lucru a fost evaluat pe seturile de date CHB-MIT și UPenn, atât la nivel de pacient, cât și global. Rețeaua cu două straturi, cu 50 și, respectiv, 20 de neuroni, a oferit cea mai bună performanță. Cu toate acestea, pentru date mai complexe, se sugerează explorarea în continuare a învățării profunde.

Capitolul 4 prezintă o dezvoltare pas cu pas a cadrului smartEEG pentru automatizarea lucrărilor de cercetare care implică dezvoltarea de canale de învățare profundă pentru a evalua detectarea și predicția crizelor epileptice. Acesta demonstrează modul în care este proiectată conducta de procesare pentru a suporta diverse configurații, de la extragerea și procesarea datelor la integrarea datelor și a modelelor, antrenament, validare și generarea de grafice, permițând cercetătorilor să ruleze și să analizeze

performanța modelului cu ușurință și să iterateze rapid. În plus, a fost dezvoltat un set de conducte de învățare profundă care au demonstrat performanțe îmbunătățite în comparație cu propunerea anterioară din Capitolul 3.

Capitolul 5 discută conductele cu performanțe îmbunătățite dezvoltate pe smartEEG. Acest lucru a fost realizat prin utilizarea (i) unui nou CNN hibrid, (ii) unei noi clasificări și selecții a canalelor de reducere a zgomotului și (iii) a procesării semnalului EEG folosind derivate și filtrare pentru a suprima și mai mult zgomotul. Fiecare metodă prezintă o îmbunătățire incrementală a performanței în comparație cu Capitolul 4.

6.2 Contribuții originale

Contribuțiile originale sunt detaliate mai jos, unde P1 – P6 se referă la articolele științifice din lista publicațiilor originale, în secțiunea următoare:

În P1, o rețea neuronală simplă nouă, alimentată cu caracteristici proiectate manual, este evaluată pe segmente de clipuri EEG foarte scurte de 1 secundă, atât pentru date specifice pacientului, cât și pentru date globale, cu performanțe care depășesc cele ale abordărilor comparabile. Limitarea acestei abordări este că viteza de iterație este redusă, deoarece noi conducte de date sunt create manual de fiecare dată. În plus, au putut fi utilizate clipuri cu același număr de canale; Prin urmare, a fost evaluată doar o parte din setul de date UPenn și Mayo.

P2 și P3 descriu în detaliu noi cadre de învățare profundă pentru clasificarea semnalelor EEG și segmentarea imaginilor RMN, pentru a automatiza și accelera procesul de cercetare. Cadrul de învățare profundă EEG smartEEG a permis evaluarea unui număr mare de rețele complexe de învățare profundă în raport cu date de la 1447 de pacienți proveniți din două seturi de date distincte, identificând obiectiv modelul cel mai potrivit, care depășește semnificativ performanța propunerii anterioare.

Noi modele hibride de învățare profundă care valorifică atât caracteristicile datelor temporale, cât și cele spațiale au fost evaluate în P3. Importanța echilibrării datelor și a calității datelor a fost subliniată la analizarea pacienților individuali și a datelor disponibile pentru învățare. Abordarea a îmbunătățit și mai mult rezultatele performanței față de lucrările anterioare.

P5 propune îmbunătățiri suplimentare ale modului în care se efectuează preprocesarea datelor prin implementarea unei funcții de clasificare a importanței canalelor. Este demn de remarcat faptul că clasificarea canalelor este valabilă în cazurile în care datele sunt deja disponibile pentru fiecare pacient și poate ajuta un model să se concentreze pe datele relevante. Îmbunătățiri notabile se observă în cazul clipurilor scurte de date EEG.

În cele din urmă, P6 demonstrează tehnici de procesare a semnalului, unde cele mai eficiente sunt filtrarea derivată și filtrarea trece-bandă, pentru a elimina zgomotul și a îmbunătăți calitatea datelor. Este prezentată o analiză detaliată a acestor tehnici în conjuncție cu cele mai performante modele de învățare profundă dezvoltate, unde sunt discutate caracteristici precum stabilitatea rețelei.

6.3 Lista lucrărilor originale

Această secțiune listează toate lucrările publicate sau în curs de evaluare legate de această teză:

- P 1. **A. Ciurea**, C. P. Manoila, A. M. Tautan, and B. Ionescu, “Low latency automated epileptic seizure detection: Individualized vs. Global approaches,” *2020 8th E-Health and Bioengineering Conference, EHB 2020*, pp. 8–11, 2020, doi: 10.1109/EHB50910.2020.9280267.
- P 2. **A. Ciurea**, C.-P. Manoila, and B. Ionescu, “SmartEEG: An End-to-End Framework for the Analysis and Classification of EEG signals,” in *2021 International Conference on e-Health and Bioengineering (EHB) 2021*, pp. 1–4.
- P 3. C.P. Manoila, **A. Ciurea**, and F. Albu, “SmartMRI Framework for Segmentation of MR Images Using Multiple Deep Learning Methods,” in *2022 10th E-Health and Bioengineering Conference, EHB 2022*, 2022. doi: 10.1109/EHB55594.2022.9991496.
- P 4. **A. Ciurea**, C.-P. Manoila, and B. Ionescu, “EEG Classification Using Hybrid Convolutional Neural Network with Attention Mechanism,” in *International Conference on e-Health and Bioengineering*, 2023, pp. 783–791.
- P 5. **A. Ciurea**, C.-P. Manoila, and B. Ionescu, “EEG Denoising with Channel Ranking and Selection,” in *2024 E-Health and Bioengineering Conference (EHB)*, 2024, pp. 1–4.
- P 6. **A. Ciurea**, C.-P. Manoila, and B. Ionescu, “A comparative Study of eeg signal processing techniques for seizure detection and prediction using deep learning,” *Series C Electrical Engineering and Computer Science*, 2025”, 2025 (under review)

6.4 Perspective de dezvoltare ulterioară

Cercetările viitoare ar putea lua în considerare dezvoltarea continuă a cadrelor de Deep Learning pentru a extinde domeniul de aplicare al clasificării semnalelor EEG la tipuri mai variate de crize epileptice, îmbunătățind astfel capacitatea de diagnosticare automată. Inteligența artificială generativă poate ajuta la dezvoltarea unei noi conduite de date care poate fi testată rapid pe cadrul smartEEG. smartEEG poate fi extins în continuare pentru a explora diferite tipuri de evenimente EEG și ar putea fi aplicat în domenii precum interfața creier-computer. În cele din urmă, o implementare hardware sub forma unui dispozitiv portabil pentru o conductă de date cu latență redusă ar putea ajuta în continuare pacienții cu epilepsie.

Bibliografie

- [1] World Health Organisation, “Epilepsy (WHO),” <https://www.who.int/news-room/fact-sheets/detail/epilepsy>. Accessed: Jul. 16, 2025. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/epilepsy>
- [2] C. Baumgartner, J. P. Koren, and M. Rothmayer, “Automatic computer-based detection of epileptic seizures,” *Front Neurol*, vol. 9, no. AUG, pp. 1–9, 2018, doi: 10.3389/fneur.2018.00639.
- [3] Ali Hossam Shoeb, “Application of machine learning to epileptic seizure onset detection and treatment,” *Massachusetts Institute of Technology*, 2009.
- [4] “CHB-MIT Scalp EEG Database v1.0.0.” Accessed: Jul. 24, 2025. [Online]. Available: <https://physionet.org/content/chbmit/1.0.0/>
- [5] R. G. Andrzejak, K. Lehnertz, F. Mormann, C. Rieke, P. David, and C. E. Elger, “Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state,” *Phys Rev E Stat Phys Plasmas Fluids Relat Interdiscip Topics*, vol. 64, no. 6, 2001, doi: 10.1103/PhysRevE.64.061907.
- [6] “Kaggle: Your Machine Learning and Data Science Community.” Accessed: Jul. 25, 2025. [Online]. Available: <https://www.kaggle.com/>
- [7] bbrinkm, sbaldassano, and Will Cukierski, “UPenn and Mayo Clinic’s Seizure Detection Challenge,” Kaggle. Accessed: Jul. 25, 2025. [Online]. Available: <https://www.kaggle.com/c/seizure-detection>
- [8] S. N. Baldassano *et al.*, “Crowdsourcing seizure detection: algorithm development and validation on human implanted device recordings,” *Brain*, vol. 140, no. 6, p. 1680, Jun. 2017, doi: 10.1093/BRAIN/AWX098.
- [9] A. Harati, S. López, I. Obeid, J. Picone, M. P. Jacobson, and S. Tobochnik, “The TUH EEG CORPUS: A big data resource for automated EEG interpretation,” in *2014 IEEE Signal Processing in Medicine and Biology Symposium (SPMB)*, 2014, pp. 1–5. doi: 10.1109/SPMB.2014.7002953.
- [10] T. N. Alotaiby, S. A. Alshebeili, F. E. A. El-Samie, A. Alabdulrazak, and E. Alkhnaian, “Channel selection and seizure detection using a statistical approach,” *International Conference on Electronic Devices, Systems, and Applications*, pp. 1–4, 2017, doi: 10.1109/ICEDSA.2016.7818505.
- [11] Ö. Türk and M. S. Özerdem, “Epilepsy detection by using scalogram based convolutional neural network from eeg signals,” *Brain Sci*, vol. 9, no. 5, 2019, doi: 10.3390/brainsci9050115.
- [12] C. Donos, M. Dümpelmann, and A. Schulze-Bonhage, “Early Seizure Detection Algorithm Based on Intracranial EEG and Random Forest Classification,” *Int J Neural Syst*, vol. 25, no. 5, pp. 1–11, 2015, doi: 10.1142/S0129065715500239.
- [13] S. Muhammad Usman, S. Khalid, and M. H. Aslam, “Epileptic Seizures Prediction

- Using Deep Learning Techniques,” *IEEE Access*, vol. 8, pp. 39998–40007, 2020, doi: 10.1109/ACCESS.2020.2976866.
- [14] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, and H. Adeli, “Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals,” *Comput Biol Med*, vol. 100, no. September, pp. 270–278, 2018, doi: 10.1016/j.compbimed.2017.09.017.
- [15] Y. Yang *et al.*, “Epileptic seizure prediction based on permutation entropy,” *Front Comput Neurosci*, vol. 12, 2018, doi: 10.3389/fncom.2018.00055.
- [16] S. N. Baldassano *et al.*, “Crowdsourcing seizure detection: Algorithm development and validation on human implanted device recordings,” *Brain*, vol. 140, no. 6, 2017, doi: 10.1093/brain/awx098.
- [17] A. Ciurea, C. P. Manoilă, A. M. Tautan, and B. Ionescu, “Low latency automated epileptic seizure detection: Individualized vs. Global approaches,” *2020 8th E-Health and Bioengineering Conference, EHB 2020*, pp. 8–11, 2020, doi: 10.1109/EHB50910.2020.9280267.
- [18] A. Baldominos and C. Ramon-Lozano, “Optimizing EEG energy-based seizure detection using genetic algorithms,” *2017 IEEE Congress on Evolutionary Computation, CEC 2017 - Proceedings*, pp. 2338–2345, 2017, doi: 10.1109/CEC.2017.7969588.
- [19] A. M. Tautan, M. Dogariu, and B. Ionescu, “Detection of Epileptic Seizures using Unsupervised Learning Techniques for Feature Extraction,” *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 2377–2381, 2019, doi: 10.1109/EMBC.2019.8856315.
- [20] M. Hills, “Seizure detection using FFT, temporal and spectral correlation coefficients, eigenvalues and Random Forest,” *Github, San Francisco, CA, USA, Tech. Rep*, pp. 1–10, 2014.
- [21] H. Zhang and H. Li, “Transformer-based EEG Decoding: A Survey,” *arXiv preprint arXiv:2507.02320*, 2025.
- [22] M. M. Krell *et al.*, “PySPACE - A signal processing and classification environment in python,” *Front Neuroinform*, vol. 7, no. DEC, pp. 1–11, 2013, doi: 10.3389/fninf.2013.00040.
- [23] A. Gramfort *et al.*, “MEG and EEG data analysis with MNE-Python,” *Front Neurosci*, vol. 7, no. 7 DEC, pp. 1–13, 2013, doi: 10.3389/fnins.2013.00267.
- [24] B. Memmott, T., Kocanaogullari, A., Erdogmus, D., Bedrick, S., Peters, B., Fried-Oken, M. & Oken, “BciPy: A Python Framework for Brain-Computer Interface Research,” in *7th International BCI meeting 2018 in Asilomar, CA*, 2018, p. 1.
- [25] A. Delorme and S. Makeig, “EEGLAB: An open source toolbox for analysis of single-trial EEG dynamics including independent component analysis,” *J Neurosci Methods*, vol. 134, no. 1, pp. 9–21, 2004, doi: 10.1016/j.jneumeth.2003.10.009.
- [26] A. Ciurea, C.-P. Manoilă, and B. Ionescu, “SmartEEG: An End-to-End Framework for the Analysis and Classification of EEG signals,” in *2021 International*

- Conference on e-Health and Bioengineering (EHB)*, 2021, pp. 1–4.
- [27] C. P. Manoila, A. Ciurea, and F. Albu, “SmartMRI Framework for Segmentation of MR Images Using Multiple Deep Learning Methods,” in *2022 10th E-Health and Bioengineering Conference, EHB 2022*, 2022. doi: 10.1109/EHB55594.2022.9991496.
 - [28] “Home - SKI10 - Grand Challenge.” Accessed: Sep. 24, 2025. [Online]. Available: <https://ski10.grand-challenge.org/>
 - [29] H. Lee, H. Hong, and J. Kim, “BCD-NET: A novel method for cartilage segmentation of knee MRI via deep segmentation networks with bone-cartilage-complex modeling,” in *Proceedings - International Symposium on Biomedical Imaging*, 2018. doi: 10.1109/ISBI.2018.8363866.
 - [30] T. N. Gia, Z. Wang, and T. Westerlund, “Detection of Epilepsy Seizures Based on Deep Learning with Attention Mechanism,” in *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST*, 2022. doi: 10.1007/978-3-031-06368-8_5.
 - [31] A. Baghdadi *et al.*, “A channel-wise attention-based representation learning method for epileptic seizure detection and type classification,” *J Ambient Intell Humaniz Comput*, vol. 14, no. 7, 2023, doi: 10.1007/s12652-023-04609-6.
 - [32] Y. Ru, G. An, Z. Wei, and H. Chen, “Epilepsy detection based on multi-head self-attention mechanism,” *PLoS One*, vol. 19, no. 6, p. e0305166, 2024.
 - [33] A. A. Ein Shoka, M. M. Dessouky, A. El-Sayed, and E. El-Din Hemdan, “An efficient CNN based epileptic seizures detection framework using encrypted EEG signals for secure telemedicine applications,” *Alexandria Engineering Journal*, vol. 65, 2023, doi: 10.1016/j.aej.2022.10.014.
 - [34] G. Cisotto, A. Zanga, J. Chlebus, I. Zoppis, S. Manzoni, and U. Markowska-Kaczmar, “Comparison of attention-based deep learning models for EEG classification. arXiv 2020,” *arXiv preprint arXiv:2012.01074*.
 - [35] A. Ciurea, C.-P. Manoila, and B. Ionescu, “EEG Classification Using Hybrid Convolutional Neural Network with Attention Mechanism,” in *International Conference on e-Health and Bioengineering*, 2023, pp. 783–791.
 - [36] A. K. Jaiswal and H. Banka, “Local pattern transformation based feature extraction techniques for classification of epileptic EEG signals,” *Biomed Signal Process Control*, vol. 34, 2017, doi: 10.1016/j.bspc.2017.01.005.
 - [37] L. V. Tran, H. M. Tran, T. M. Le, T. T. M. Huynh, H. T. Tran, and S. V. T. Dao, “Application of Machine Learning in Epileptic Seizure Detection,” *Diagnostics*, vol. 12, no. 11, 2022, doi: 10.3390/diagnostics12112879.
 - [38] Z. M. Hussain and B. Boashash, “Hilbert transformer and time delay: Statistical comparison in the presence of Gaussian noise,” *IEEE Transactions on Signal Processing*, vol. 50, no. 3, 2002, doi: 10.1109/78.984723.
 - [39] X. Cao, S. Zheng, J. Zhang, W. Chen, and G. Du, “A hybrid CNN-Bi-LSTM model with feature fusion for accurate epilepsy seizure detection,” *BMC Med Inform Decis Mak*, vol. 25, no. 1, p. 6, 2025.

- [40] M. Shen, F. Yang, P. Wen, B. Song, and Y. Li, “A real-time epilepsy seizure detection approach based on EEG using short-time Fourier transform and Google-Net convolutional neural network,” *Heliyon*, vol. 10, no. 11, 2024.
- [41] X. Deng, “A novel dual-branch network for comprehensive spatiotemporal information integration for EEG-based epileptic seizure detection,” *PLoS One*, vol. 20, no. 6, p. e0321942, 2025.
- [42] S. Rukhsar and A. K. Tiwari, “Lightweight convolution transformer for cross-patient seizure detection in multi-channel EEG signals,” *Comput Methods Programs Biomed*, vol. 242, 2023, doi: 10.1016/j.cmpb.2023.107856.
- [43] Y. G. Chung, A. Cho, H. Kim, and K. J. Kim, “Single-channel seizure detection with clinical confirmation of seizure locations using CHB-MIT dataset,” *Front Neurol*, vol. 15, p. 1389731, 2024.
- [44] J. Xiang, Y. Li, X. Wu, Y. Dong, X. Wen, and Y. Niu, “Synchronization-based graph spatio-temporal attention network for seizure prediction,” *Sci Rep*, vol. 15, no. 1, p. 4080, 2025.