



جامعة بجاية
Tasdawit n Bgayet
Université de Béjaïa

Université A/Mira de Béjaïa
Faculté des Sciences Exactes
Département d'Informatique

Mémoire de fin de Cycle

*En vue de l'obtention du diplôme de Master professionnel
en Informatique*

Option : Génie Logiciel

Thème

Détection et distinction intelligente et
automatique de crises épileptiques
convulsives et crises psychogènes non
épileptiques à partir des signaux EEG

Présenté par : M. HOCINE Ali
M. KHELIFA Ali

Devant le jury composé de :

Présidente	S. Ait HACENE	Maître Assist. A	U. A/Mira Béjaïa.
Examinatrice	Dr S. CHIBANI	Maître de Conf. A	U. A/Mira Béjaïa.
Examinatrice	Dr K. OUAZINE	Maître de Conf. B	ESTIN Amizour Béjaïa.
Encadrant	Dr M. MOHAMMEDI	Maître de Conf. A	U. A/Mira Béjaïa.
CoEncadrante	Dr L. HAMZA	Maître de Conf. A	U. A/Mira Béjaïa.

※ *Remerciements* ※

Nous remercions Allah le tout Puissant qui nous a donné la force et la volonté d'accomplir ce travail.

Nous tenons tout d'abord à remercier docteur Mohamed MOHAMMEDI et docteur Lamia HAMZA, pour l'honneur qu'ils nous a fait en acceptant de nous encadrer. Leurs conseils précieux nous ont permis une bonne orientation dans la réalisation de ce travail.

Nos vifs remerciements vont également au président et aux membres de jury d'avoir accepté d'évaluer notre travail.

Nous remercions tous ceux qui ont contribué de près ou de loin à la réalisation de ce travail.

Nos très sincères remerciements vont aussi à tous les enseignants et enseignantes qui ont contribué à notre formation durant notre cursus.

Merci à nos parents et nos familles qui nous ont toujours soutenus tout au long de notre cursus.

※ *Dédicaces* ※

Je dédie ce modeste travail :

À mes chers parents pour leur soutien inconditionnel,
leur tolérance durant toutes mes années d'études,

À nos encadrants Docteur MOHAMMEDI Mohamed et Docteur HAMZA Lamia qui nous ont
vraiment motivé et guidé tout au long de notre travail,

À tous mes ami(e)s et toute la promotion Génie Logiciel.

M. KHELIFA Ali

※ *Dédicaces* ※

Je dédie ce modeste travail :

À mes très chers parents qui m'ont soutenu durant toutes mes études, qui ont fait de moi ce que je suis aujourd'hui je leurs serais éternellement reconnaissant,

À nos encadrants Docteur MOHAMMEDI Mohamed et Docteur HEMZA Lamia qui nous ont vraiment motivé et guidé tout au long de notre travail,

À mes soeurs, à mon frère

À tous mes ami(e)s et à tous ceux qui m'ont aidé de près ou de loin,

À tous mes ami(e)s et toute la promotion Génie Logiciel.

M. *HOCINE Ali*

TABLE DES MATIÈRES

Table des Matières	i
Liste des tableaux	iii
Liste des figures	iv
Liste des acronymes	v
Introduction générale	1
1 Généralités sur les épilepsies et les signaux EEG	3
1.1 Introduction	3
1.2 Crises épileptiques	4
1.2.1 Définition	4
1.2.2 Types de crises	4
1.2.3 Causes et symptômes	6
1.2.4 Traitement	6
1.3 L'épilepsie chez les adultes	7
1.4 Crises psychogènes non épileptiques	7
1.4.1 Symptômes	8
1.4.2 Causes	8
1.4.3 Diagnostic	8
1.4.4 Traitement	9
1.5 L'EEG de surface et les crises d'épilepsie	9
1.5.1 Modalité d'enregistrement	10
1.5.2 Type des montages	12
1.5.3 Bandes de fréquences principales des signaux EEG	13
1.5.4 Activités paroxystiques élémentaires	14
1.5.5 Les perturbations de l'EEG	15
1.6 Système automatique pour prédire l'arrivée des crises d'épilepsie	15
1.7 Conclusion	16

2	ÉTAT DE L'ART SUR LES SYSTÈMES DE DÉTECTION DES CRISES D'ÉPI-LEPSIE ET DE DISTINCTION DES CNEP'S	17
2.1	Introduction	17
2.2	Critères d'évaluation des approches existantes	18
2.2.1	La Sensibilité	18
2.2.2	La Latence	18
2.2.3	La Spécificité	18
2.2.4	Taux de faux négatif	19
2.2.5	Taux de faux positif	19
2.2.6	Exactitude	19
2.3	Taxonomie des travaux examinés	19
2.4	Travaux antérieurs	20
2.4.1	Solutions basées sur deep Learning (DL)	20
2.4.2	Solutions basées sur le traitement d'image	21
2.4.3	Solutions basées sur la machine de Learning (ML)	22
2.4.4	Improved Detection and Classification of Convulsive Epileptic and Psychogenic Non-epileptic Seizures Using FLDA and Bayesian Inference	24
2.5	Étude comparative	24
2.6	Synthèse	26
2.7	Conclusion	27
3	Une méthode d'entropie approximative par ondelettes pour détecter et distinguer les crises épileptiques et les crises psychogènes non épileptiques à partir de l'EEG et ses sous-bandes	28
3.1	Introduction	28
3.2	Motivation	29
3.3	Schéma fonctionnel de l'architecture proposée	30
3.4	Le système de détection des crises proposé	30
3.4.1	Prétraitement	30
3.4.2	Transformée en ondelettes discrète (DWT, Discrete Wavelet Transform)	31
3.4.3	Extraction de caractéristiques	33
3.4.4	Classification	34
3.5	Conclusion	35
4	Simulation et évaluation de performances	36
4.1	Introduction	36
4.2	Protocole expérimental et description de l'ensemble de données	36
4.3	Acquisition EEG	37
4.4	Environnement de simulation	37
4.4.1	Paramètres de simulation	37
4.4.2	Résultats et Discussion	38
4.5	Conclusion	41
	Conclusion générale et perspectives	42
	Bibliographie	43

LISTE DES TABLEAUX

1.1	Principaux rythmes dun EEG[24].	13
2.1	Étude comparative des différents système analysés	25
4.1	La moyenne des valeurs ApEn pour chaque sous-ensemble de segments EEG et leurs sous-bandes.	39
4.2	L'écartype des valeurs ApEn pour chaque sous-ensemble de segments EEG et leurs sous-bandes.	39
4.3	Le P-valeur et la probabilité de séparation de chaque paire de sous-ensemble de segments EEG et leurs sous-bandes.	40

TABLE DES FIGURES

1.1	Crise épilepsie [11].	4
1.2	Classification Des Crises Épileptique [38]	5
1.3	Montage 10/20 [6].	10
1.4	Video EEG [7].	11
1.5	Équipement Holter EEG [10].	11
1.6	Montage à Référence Commune [49].	12
1.7	Montage à Référence Moyenne [49].	12
1.8	Montage Bipolaire [55].	13
1.9	Quelque Activités Paroxystiques [55].	14
1.10	Système IA pour la détection des crises [17].	16
2.1	Classification de systèmes de détection des crises épileptiques et de distinction des CNEP's étudiées.	19
3.1	Détection des crises en temps réel pour une réponse rapide.	29
3.2	Décomposition de la séquence EEG avec transformée en ondelettes discrètes et extraction de cinq sous-bandes physiologiques	32
3.3	Schéma fonctionnel de la méthode globale pour l'extraction des caractéristiques EEG.	34
4.1	Les valeurs ApEn de signal EEG de tous les segments de chaque sous-ensembles.	38
4.2	Les valeurs ApEn de la sous-bande Bêta de tous les segments de chaque sous-ensembles.	38
4.3	Les valeurs ApEn de la sous-bande Alpha de tous les segments de chaque sous-ensembles.	38
4.4	Les valeurs ApEn de la sous-bande Thêta de tous les segments de chaque sous-ensembles.	38

LISTE DES ACRONYMES

A	AAR	Adaptatifs Auto-régressifs.
	ANN	Artificial Neural Network.
	ApEn	Approximation Entropy.
B	Bi-LSTM	Bidirectional Long Short-Term Memory
C	CAR	Commun Average Référencement.
	CNEP	Crises non épileptiques psychogènes
	CNN	Convolutional Neuron Networks
	CNGP	Closed Neighbourhood Gradient Pattern
	CTP	combined texture pattern
D	DCNN	Deep Convolutional Neural Network
	DCAE	Deep Convolutional Autoencoder architecture
	DT	Decision Tree
	DL	Deep Learning
	DWT	Discrete Wavelet Transforms
	DF	Degree of Freedom
E	EEG	Electroencéphalogramme.
	ES	Epileptic Seizures.
F	FPGA	Field Programmable Gate Array.
	FPR	False Positive Rate.
H	Hz	Hertz.
I	IRMf	Imagerie par Résonance Magnétique Fonctionnelle.
	IRM	Imagerie par Résonance Magnétique.
	IoT	Internet of Things.
	IC	Independent Component
	IoMT	Internet of Medical Things

K	KNN	K-Nearest neighbors.
L	LS-SVM	Least-Squares Support-Vector Machines.
M	MLP	Multi-layer Perceptron.
	MMV	Mean Magnitude Value.
	ML	Machine Learning.
P	PDD	patient-dependent design
	PID	Patient-independent design
R	RF	Random Forest.
	ROC	Receiver Operating Characteristics.
S	SVM	Support Vector Machine.
	STD	Ecartype.
T	TDM	Tomodensitométrie.
	TF	Time-Frequency
X	XGBoost	eXtreme Gradient Boosting.

INTRODUCTION GÉNÉRALE

Aujourd'hui, l'épilepsie touche environ 50 millions de personnes dans le monde et plus de 150 000 personnes en Algérie. Elle se caractérise par des crises récurrentes dites épileptiques, qui sont de courts épisodes de tremblements involontaires qui affectent une partie du corps (crises partielles) ou tout le corps (crises généralisées). Ils s'accompagnent parfois d'une perte de conscience et d'une perte de contrôle de la vessie et des intestins [20]. Ce trouble n'a cessé d'être l'objet de recherches dans tous les domaines, aussi bien médicaux que dans le domaine de la statistique et des mathématiques, et plus récemment dans le domaine informatique.

Selon les statistiques, 30% des patients référés pour une épilepsie résistante aux médicaments sont en réalité touchés par des crises psychogènes non épileptiques (CNEP) vu que les crises d'épilepsie et les CNEP's sont des événements paroxystiques qui se ressemblent du fait de leur contenu comportemental ou expérientiel avec la différence que les CNEP's sont d'origine psychogène [33]. Le diagnostic le plus idéal pour cette pathologie est apporté par l'enregistrement vidéo-électroencéphalographie (EEG) des manifestations cliniques, où le médecin ne trouvera aucune anomalie électrique habituelle de l'épilepsie. La cause de CNEP n'est pas connue exactement, de nombreux facteurs psychosociaux et mécanismes psychologiques tels que le traumatisme, le trouble de somatisation, les facteurs ou les troubles de la personnalité, la comorbidité psychiatrique (dépression, trouble panique, anxiété chronique), facteurs d'âge, changement de comportement et le sexe de la personne peuvent être liés à ce trouble. De nombreuses caractéristiques telles que la fréquence cardiaque ictal stable, les yeux fermés, la poussée pelvienne et les événements à plus long terme sont davantage associées aux CNEP's qu'aux crises épileptiques [34]. Alors que des décharges épileptiformes inter-ictal se produisent dans le cas de crises épileptiques, les activités électriques du cerveau maintiennent leur état normal dans les cas de CNEP. Par conséquent, le diagnostic CNEP est basé sur la surveillance vidéo-EEG et l'historique du patient. Cependant, la réalisation du diagnostic correct par l'examen visuel des enregistrements vidéo-EEG à long terme est directement liée à l'expérience du neurologue expert, et c'est un processus très long et fatigant [2][23]. Cela explique pourquoi la distinction entre les crises épileptiques et les CNEP's est un problème difficile. Par conséquent, des systèmes intelligents et automatiques de prédiction des crises sont nécessaires pour détecter et distinguer avec précision et rapidement ces crises.

Dans la littérature, de nombreuses études sont présentées pour détecter et distinguer les segments de crise épileptique et CNEP. Cependant, comme l'activité électrique du cerveau maintient sa situation normale dans le cas de CNEP, il est difficile de distinguer les segments inter-CNEP et CNEP à l'aide des enregistrements EEG.

Nous proposons dans ce mémoire un système de détection et de distinction automatique basé sur l'étude des crises épileptiques et des crises psychogène non-épileptique afin de distinguer entre eux à partir d'informations physiologiques. Notre objectif consiste à développer un système de détection et de distinction de crise en temps réel chez les victimes de ces troubles à partir des données EEG à court terme et des caractéristiques de sous-bande EEG. Les résultats de l'étude de [26] montrent que la bande bêta est la sous-bande EEG la plus efficace pour distinguer les segments de crise épileptique et CNEP. Ce système est motivée par le fait que spécialistes et les neurologues travaillent essentiellement à partir des données cérébrales pour détecter des éventuels crises et de diagnostiquer les CNEP's. Notre système consiste à utiliser certains moyens qui vont permettre collectes des signaux cérébraux tout en gardons un maximum de performance et confort de malade.

Le reste de ce document présentera le travail effectué afin d'élaborer un système automatique de détection des crises épileptiques et de distinction entre les crises épileptique et les CNEP's à partir des données EEG. Notre mémoire est organisé en quatre chapitres comme suite :

Chapitre 1 : "Pré-requis théoriques" : Nous abordant ce mémoire avec un premier chapitre sur les notions générales de l'épilepsie (définition, classification, traitement etc.), et les notions générales des CNEP's (définition, cause, diagnostic etc.). Ensuite, nous présenterons l'EEG ainsi que la structure générale d'un système de détection des crises d'épilepsie avec les signaux EEG seront évoqués, avec l'essentiel à connaître sur leurs modes de fonctionnement.

Chapitre 2 : "Etat de l'art sur les systèmes de détection des crises d'épilepsies et de distinction des CNEP's" : au sien de ce chapitre, nous discuterons certains travaux de recherche concernant la détection des crises d'épilepsies et la distinction des CNEP's, une comparaison de différentes approches par rapport à leurs techniques de détections est ensuite présentée pour mettre en évidence leurs points forts et points faibles en termes de critères d'évaluation. Puis, nous donnerons une classification des travaux déjà proposés.

Chapitre 3 : "Une méthode d'entropie approximative par ondelettes pour détecter et distinguer les crises épileptiques et les crises psychogènes non épileptiques à partir de l'EEG et ses sous-bandes" : dans ce chapitre nous présentons notre contribution pour la détection des crises d'épilepsies et la distinction des CNEP's à partir des signaux EEG, en détaillant les différentes phases par lesquelles notre système passe pour assurer une détection et distinction de crise rapide et efficace.

Chapitre 4 : "Simulation et évaluation de performances" : Dans ce dernier chapitre, nous présenterons l'ensemble de donnée utilisé de notre travail, ainsi que les paramètre de simulation. Ensuite, nous présenterons et discuterons sur les résultats avec certaines dautres recherches.

A la fin, nous terminerons notre mémoire par une conclusion générale.

CHAPITRE 1

GÉNÉRALITÉS SUR LES ÉPILEPSIES ET LES SIGNAUX

EEG

1.1 Introduction

L'épilepsie est un trouble chronique neurologique courant caractérisé par la survenue de crises de nature épileptique, qui se reproduisent plus ou moins fréquemment et de manière plus ou moins continue au cours de la vie d'un individu. Aujourd'hui, l'épilepsie reste une maladie méconnue avec de nombreux préjugés. Selon les statistiques, elle touche plus de 150 000 personnes en Algérie, environ 10 millions dans les pays industrialisés et 40 millions dans les pays en développement [20]. Encore un autre trouble complexe, difficile à diagnostiquer et à traiter est connue sous le nom de "crise psychogènes non épileptiques" (CNEP). Ces derniers sont phénoménologiquement similaires aux crises d'épilepsie, mais avec une origine psychologique. Ce trouble est souvent confondu avec l'épilepsie. Les CNEP's représentent 30% des patients référés pour une épilepsie résistante aux médicaments, et au moins 80% de ses patients sont traités avec des médicaments antiépileptiques. Le diagnostic le plus idéal pour cette pathologie est apporté par l'enregistrement vidéo-électroencéphalographie (EEG) des manifestations cliniques, où le médecin ne trouvera aucune anomalie électrique habituelle de l'épilepsie [33]. Ces troubles précitées feront le sujet de ce premier chapitre.

Nous entamerons ce chapitre avec des notions générales sur l'épilepsie. Dans la deuxième section, on va insister sur les crises épileptiques chez les adultes. La troisième section sera consacrée pour les crises psychogènes non épileptiques. Comme ce travail de recherche est basé sur le traitement du signal EEG, dans la section qui suivra, une description générale sur l'EEG de surface et les crises d'épilepsie sera donnée. La dernière section de ce chapitre exposera la structure générale d'un système de détection des crises d'épilepsie à base des signaux EEG. Enfin, nous clôturons ce chapitre avec une conclusion pour récapituler les points susmentionnés.

1.2 Crises épileptiques

1.2.1 Définition

La crise épileptique est une expression clinique résultant des décharges inhabituelles et exagérées d'un ensemble de neurones cérébraux (figure 1.1). Elle se caractérise par des anomalies soudaines, telles que des modifications de la conscience, des mouvements, des sensations ou des événements physiques que le patient les perçoit ou non. La sémiologie clinique d'une crise épileptique varie selon l'origine topographique et la propagation des décharges neuronales. Les crises épileptiques durent généralement peu de temps, puis se terminent et la personne revient à la normale. Cette réparation est complète et ne doit pas laisser de séquelles, sinon d'autres maladies sous-jacentes sont suspectées [40].

L'épilepsie : est une maladie neurologique chronique courante. Elle se caractérise par une tendance à avoir des crises récurrentes, appelées crises épileptiques [13]. Une personne souffre d'épilepsie si elle répond à l'un des critères suivants [13] :

- Elle a eu au moins deux crises spontanées (non provoquées).
- Elle a déjà eu des convulsions et risque d'en avoir d'autres.
- Elle a été déclenchée avec le syndrome d'épilepsie .



FIGURE 1.1 – Crise épilepsie [11].

1.2.2 Types de crises

Les crises épileptiques peuvent être classées en deux grandes catégories à savoir les crises généralisées et les crises focales. La figure 1.2 illustre les différents types et sous-types des crises épileptiques.

1.2.2.1 Crises généralisées

Leur origine est que la décharge neuronale se produit simultanément dans de vastes zones du cerveau et affecte même des organes cérébraux entiers. Parmi eux, nous avons :

- **Tonico-clonique** : Il s'agit probablement du type de crise le plus connu. La victime devient d'abord rigide, puis ses membres et son torse tremblent. Il est courant pour une personne de tomber alors qu'elle est inconsciente ou même de perdre le contrôle du sphincter [16].
- **D'absence** : Dans ce type le patient reste immobile, fixant l'infini, incapable de réagir. Elle peut durer pendant dix secondes. Elle apparaît beaucoup chez les enfants [16].
- **Myoclonique** : Elle se caractérise par des contractions soudaines dans une courte durée, n'affectent pas l'état de conscience [52].

- **Atoniques** : Le patient dans ce cas est exposé par une brusque perte musculaire ce qui provoque une chute avec une perte de conscience [52].

1.2.2.2 Crises focales

Une crise épileptique est dite partielle ou focale si la décharge intéresse seulement une partie des neurones. Parmi ces crises, nous avons :

- **Partielle simple** : Dans ce type, la personne souffre de contractions musculaires d'une partie du corps accompagnées de sensations telles que des fourmillements, sans perte de conscience [16].
- **Partielle complexe** : Elle ressemble à des crises d'absence accompagnée d'une perte de conscience avec des spasmes musculaires et une perte temporaire de mémoire [16].
- **Partielle avec généralisation** : C'est une évolution de la crise focale qui passe de localiser à généraliser [52].
- **Spasmes épileptiques** : Plus communes chez les enfants, particulièrement ceux de moins d'un an. Le symptôme est une extension et flexion du corps pendant cinq secondes [52].

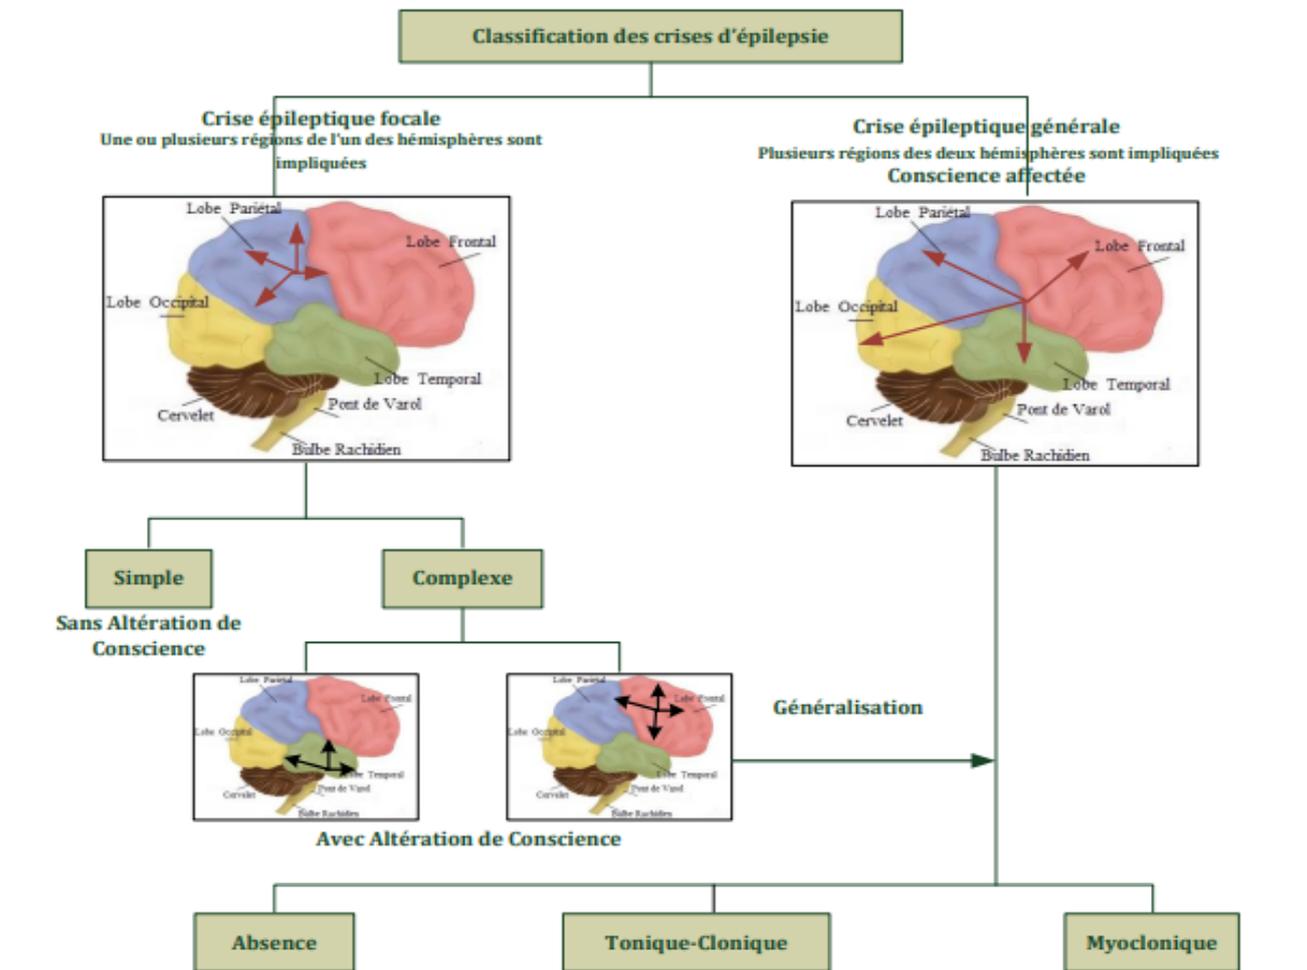


FIGURE 1.2 – Classification Des Crises Épileptique [38] .

1.2.3 Causes et symptômes

1.2.3.1 Causes

Les causes d'épilepsie sont très multiples et difficiles à comprendre car il existe de nombreuses formes de cette maladie. L'épilepsie peut être divisée en trois familles selon leurs causes connues (**épilepsie symptomatique**) non connue (**épilepsie idiopathique**) ou bien supposée mais non mise en évidence par les moyens médicaux actuels (**épilepsie cryptogénique**) [15].

Les causes de l'épilepsie symptomatique : Représente celles dont les causes connues, cette forme d'épilepsie peut être cause par [15] :

- Malformation congénitale.
- Encéphalite.
- Équilles d'une souffrance à la naissance.
- Accident vasculaire cérébral.
- Infections du Système Nerveux Central.
- L'alcoolisme
- Malformations cérébrales

Les causes de l'épilepsie idiopathique : Dite aussi constitutionnelles, actuellement, il n'existe aucune cause identifiable pouvant expliquer son origine, représenteraient environ 10 à 15% des cas d'épilepsies [14].

Les causes de l'épilepsie cryptogénique : Lorsqu'une cause est suspectée mais ne peut être étayée par les outils diagnostiques modernes, on parle d'épilepsie cryptogénique, représenteraient environ 60% des cas d'épilepsie [14].

1.2.3.2 Symptômes

Les symptômes des crises d'épilepsie diffèrent. Il peut s'agir de [12] :

- Secousses musculaires incontrôlées et localisées à un bras ou la moitié du corps.
- Hallucinations sensorielles : visuelles, auditives, gustatives ou olfactives (mauvaise odeur).
- Des périodes de perte de conscience ou de conscience altérée. Parfois, les yeux restent ouverts, avec un regard fixe.
- Chute brutale de la personne sans raison apparente.
- La personne a peur sans raison, elle peut même paniquer ou se mettre en colère.
- Une respiration bruyante.
- Dans certains cas, convulsions : contractions musculaires prolongées et involontaires dans les bras et les jambes.
- Troubles du langage.
- Douleurs ou signes végétatifs (salivation, apnée respiratoire, accélération du rythme cardiaque).

1.2.4 Traitement

Le traitement de l'épilepsie est appuyé sur la prise de médicaments antiépileptiques, mais dans la plupart des temps ce traitement se termine par l'échec et les crises persistent, la chirurgie peut alors être envisagée.

1.2.4.1 Traitement médicamenteux

À l'heure actuelle, plus d'une vingtaine de médicaments peut réduire la fréquence et l'intensité des crises. Au départ le patient prend un seul médicament dont la dose est augmentée jour par jour jusqu'à la dose minimale efficace la mieux tolérée, en effet il est nécessaire d'essayer plusieurs médicaments avant d'identifier un médicament capable de contrôler l'épilepsie à long terme avec des effets secondaires minimales. Pourtant, même aujourd'hui, environ 30% des patients n'ont aucun médicament efficace. L'épilepsie est qualifiée de "résistante aux médicaments" [31].

1.2.4.2 Traitement chirurgical

Après avoir que le patient ne répond pas aux médicaments, une intervention chirurgicale peut être envisagée sous certaines conditions. Si cela n'affecte pas la vie du patient, il consiste à enlever la zone qui provoque la crise. Autrement dit, pour pratiquer, toutes les crises du patient doivent provenir de la même région du cerveau. Cette opération délicate doit être effectuée par un centre professionnel [31].

1.3 L'épilepsie chez les adultes

L'épilepsie est un trouble cérébral qui provoque des convulsions. Les premières crises commencent souvent dans l'enfance et au début de l'âge adulte (vers l'âge de 20 ans) [1]. Les adultes souffrent d'épilepsie, où chaque personne peut avoir des développements différents. En fait, il existe environ 50 épilepsies ou syndromes d'épilepsie. Lorsqu'elle affecte différentes zones du cerveau, on parle de crises généraliser, par exemple la perte de conscience avec raideur et spasmes musculaires dans les extrémités. Cette crise peut aussi prendre la forme d'une brève absence de contact. Lorsqu'une zone est touchée, l'épilepsie provoque des symptômes différents selon la localisation de ces neurones [59]. Toutefois, quel que soit l'âge du malade, le diagnostic repose sur des signes cliniques, un EEG qui examine l'activité cérébrale et, si nécessaire, une imagerie cérébrale par IRM ou TDM [35].

1.4 Crises psychogènes non épileptiques

Une crise psychogène non épileptique (CPNE, ou CNEP) est définie comme un trouble soudain et paroxystique du comportement moteur, des sensations ou de la conscience similaire à une crise d'épilepsie. Ces crises sont associées à des processus psychogènes complexes et ne sont pas à une décharge neuronale excessive [33]. Les CNEP's représentent 30% des patients référés pour une épilepsie résistante aux médicaments, et au moins 80% de ses patients sont traités avec des médicaments antiépileptiques. Un tiers de ses patients ont été traités en service de réanimation [23]. À ce jour, il a été constaté que 1 patient sur 5 qui a été consulté par un neurologue et un spécialiste de l'épilepsie souffre de CNEP. Ces crises touchent majoritairement les femmes (75% femmes / 25% hommes). On estime que 5 personnes sur 100 000 par an souffrent de cette pathologie [34].

1.4.1 Symptômes

Les symptômes d'une pseudo-crise sont similaires à ceux d'une crise d'épilepsie, mais avec une différence importante :

- Les CNEP's peuvent apparaître après un événement émotionnel tel que le licenciement ou l'arrestation. Le stress déclenche également des crises d'épilepsie, ce qui les rend difficiles à distinguer. Cependant, un stress honteux ou sévère est plus susceptible de provoquer des pseudos-crisis que des crises d'épilepsie [33].
- Contrairement aux crises épileptiques qui durent usuellement quelques secondes et qui sont accompagnées d'une fatigue physique et mentale, les CNEP's durent plus longtemps et peuvent être accompagnées d'un rétablissement complet [33].
- Les crises causées par des pseudos-crisis ont tendance à être plus dramatiques que celles causées par des crises d'épilepsie [33].
- Les crises CNEP's causent rarement des lésions corporelles, à l'opposé des crises d'épilepsie qui peuvent entraîner des blessures [33].
- Les crises épileptiques entraînent souvent une perte de contrôle des intestins ou de la vessie, une salivation ou des morsures de la langue, tandis que cela peu commune dans les CNEP's [33].

1.4.2 Causes

Les crises psychogènes peuvent apparaître dans toutes les catégories d'âges sauf que les femmes ont trois fois plus susceptibles de les avoir que les hommes [23]. Il n'est pas toujours clair pourquoi une personne développe cet état de mal [34]. Dans ce qui suit, on va exposer quelques conditions associées aux CNEP's :

- **Histoire du traumatisme :** En effet, parmi les conditions qui provoquent les CNEP's on a les antécédents d'excès de sexe ou de traumatismes sexuels soit sans traitement adéquat, ou bien sans soutien, ou même sans prise de conscience correcte des événements traumatisants [2].
- **Conditions psychologiques :** Les pseudos-crisis sont classés comme une sorte de trouble de conversion, qui est un symptôme physique ou un témoignage d'un état psychologique. Certaines conditions psychologiques ont été associées au CNEP, telles que le trouble de la personnalité borderline, le trouble bipolaire, l'anxiété sévère et la dépression [2].
- **Douleur chronique :** Les conditions qui causent une douleur chronique persistante, telles que la fibromyalgie et le syndrome de fatigue chronique, augmentent l'éventualité de CNEP [2].

1.4.3 Diagnostic

Une CNEP est souvent diagnostiqué à tort comme de l'épilepsie tellement qu'il est difficile de les distinguer. Par conséquent, il est très difficile de déterminer la véritable cause de ce trouble. Cette incertitude est très stressante pour les patients et leurs familles qui ne peuvent pas dire si jamais les crises s'apaisent [33]. Le temps moyen pour diagnostiquer ce trouble est d'environ 7 ans(actuellement, ce délai est un peu plus moins), période pendant laquelle la plupart des patients ont été diagnostiqués et traités avec des médicaments antiépileptiques, mais les résultats n'ont pas été prometteurs [23]. Parmi les causes qui rendent le diagnostic plus difficile est que les médecins rarement qu'ils assistent aux crises et ils se basent sur la description des proches de patients qui peuvent être inexacte [34].

A cet effet, pour *un diagnostic* plus efficace ce dernier doit être fait par un neurologue spécialiste de l'épilepsie soit sur une vidéo de la crise filmée par l'entourage du patient, soit par un questionnaire très approfondie avec de nombreux facteurs et signes spécifiques rapportés par les proches du patient. Autrement, le diagnostic de certitude est celui d'un enregistrement d'une crise au cours d'un examen EEG (en vidéo), où le neurologue ne trouvera aucune anomalie électrique habituelle de l'épilepsie [2][34][23]. En plus de tout ça, il reste que le diagnostic le plus idéal est celui qui est mené dans le cadre d'une consultation pluridisciplinaire avec un suivi d'un neurologue et d'un psychiatre [23].

1.4.4 Traitement

La personne qui subisse des pseudos crises il ne prétend pas la souffrance. Il est capital pour le patient et ses proches que chacun comprend bien que la personne vraiment souffre de CNEP et n'est ni "folle", ni "simulatrice" et que ses crises sont bien réelles et ont un réel impact sur sa qualité de vie [34]. Certaines estimations disent que y a pas mal de personne atteintes de CNEP ne présentent plus de symptômes après le diagnostic [2].

Pour ce trouble, le traitement le plus approprié est un traitement psychologique ou psychiatrique dont le patient doit consulter un psychiatre ou un psychologue [2]. Le but de ce traitement est d'arrêter ou de réduire l'apparition des crises. Un psychologue ou un psychiatre va aider le patient à identifier trois types de facteurs :

- **Prédisposants (de vulnérabilité)** : Ils represents l'ensembles des facteurs neurologiques (traumatisme crânien, difficultés d'apprentissage, petites anomalies à l'IRM cérébral, etc.), des facteurs psychologiques tel que la dépression, les troubles anxieux dont le syndrome de stress post traumatique, des facteurs traumatiques qui peuvent être des abus (physiques, sexuels), de maltraitance affective, d'harcèlement [23].
- **Précipitants (déclenchants)** : Dans ce type de facteurs on peut distinguer deux catégories, ceux survenant dans l'année précédant l'apparition des symptômes comme situations stressantes ou conflictuelles, ceux qui sont présents régulièrement juste avant l'apparition des crises tel que L'anxiété, la tristesse, la colère, un sentiment d'impuissance [34].
- **Perpétuants (maintien)** : Ce type de facteurs est séparé en trois sous-types, ceux qui sont liés au patient (stress, anxiété, dépression, etc.), ceux qui sont liés à son entourage (anxiété, questionnement sur la gravité, Surprotection), ceux qui sont liés au milieu médical (multiplication des examens, des consultations, discours différents entre les professionnels) [23].

Ce traitement est également dédié à la détection et à la gestion des émotions. Si une expérience traumatisante est vécue, le thérapeute travaille avec le patient sur le traumatisme [34].

1.5 L'EEG de surface et les crises d'épilepsie

Le cerveau humain est le centre de contrôle du corps, il reste la maison la plus complexe et la plus mystérieuse de tous les organes. Il est composé de milliards de neurones, qui ont tous besoins de communiquer entre eux, cela se fait à l'aide de signaux chimiques et électriques. L'activité électrique du cerveau peut être mesurée à l'aide d'un appareil composé de plusieurs électrodes placées sur la surface du crâne, comme un électroencéphalogramme ou EEG.

L'électroencéphalogramme est une technologie développée par Hans Berger dans les années 1920. Il s'agit d'enregistrer l'activité électrique de certains des neurones du cortex. Un casque avec des dizaines d'électrodes est placé sur la tête du patient et connecté au système de détection. Cette technique permet de visualiser l'activité du cerveau. Il est utilisé pour surveiller le début et la progression des crises et fournit des informations supplémentaires aux informations obtenues à partir de la sémiotique [44].

1.5.1 Modalité d'enregistrement

L'EEG peut être adapté à chaque patient en fonction du diagnostic initial du médecin. Il existe plusieurs modalités d'EEG : EEG dit standard, EEG avec vidéo courte ou 24 h, Holter EEG [?] :

1.5.1.1 L'EEG standard : Montage 10/20

Le montage "10-20" est une technique largement utilisée pour décrire l'emplacement des électrodes du cuir chevelu dans les expériences EEG. Ceci garantit la reproductibilité de ces tests. Ce système est basé sur la relation entre la position des électrodes et la zone sous le cortex cérébral. Les nombres "10" et "20" font référence au fait que la distance réelle entre les électrodes adjacentes est de 10% ou 20% de la distance totale entre le crâne et l'avant vers l'arrière ou de droite à gauche. Dans la figure 1.3 nous voyons en routine 21 électrodes : Fp2, F4, C4, P4, O2, F8, T4, T6, Fz, Cz, Pz, Oz, Fp1, F3, C3, P3, O1, F7, T3, T5. "Fp" désigne les dérivations Frontopolar, "F" désigne les dérivations frontales, "C" désigne les dérivations centrales, "P" désigne les dérivations pariétale, "O" désigne les dérivations occipitales, et "T" désigne les dérivations du lobe tempore. Deux repères anatomiques sont utilisés pour le placement de base des électrodes EEG. Le premier est le nasion, qui est le point entre le front et le nez. Deuxièmement, l'inion, qui est le point le plus bas du crâne vu de derrière la tête, généralement indiqué par une crête proéminente, la durée d'enregistrement est d'au moins 15-20 minutes [5].

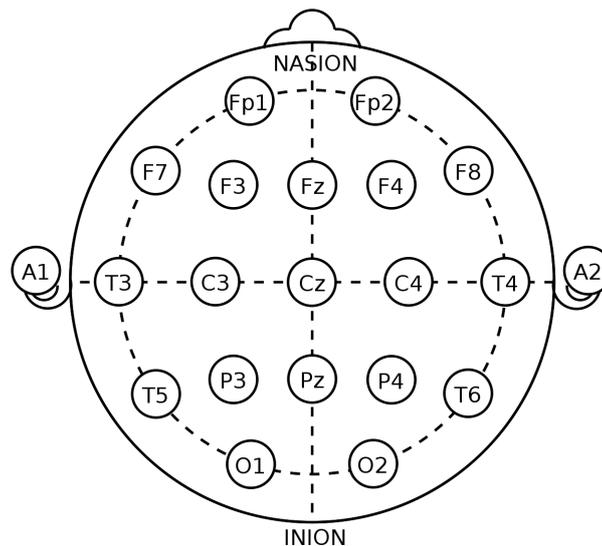


FIGURE 1.3 – Montage 10/20 [6].

1.5.1.2 Vidéo-EEG

Le vidéo-EEG est un test qui permet d'enregistrer ce que vous faites ou vivez sur une bande vidéo tandis qu'un test EEG enregistre vos ondes cérébrales (voir figure 1.4). L'objectif principale de cet examen est la possibilité de voir ce qui se passe lorsqu'une crise ou un événement se produit et en même temps de comparer l'image à ce qu'enregistre l'EEG [57]. Cette étude nécessite 2 à 5 jours d'hospitalisation pour effectuer un enregistrement EEG de 24 heures des crises à l'aide d'une vidéo synchronisée. L'examen se déroule dans une chambre où les électrodes (au moins 21 électrodes) sont collées sur l'ensemble du cuir chevelu de patient à l'aide d'une pâte conductrice. Pendant le test le patient devra rester dans son lit face a des caméras de surveillance [8].



FIGURE 1.4 – Video EEG [7].

1.5.1.3 Le Holter-EEG (Montage ambulatoire)

Dans la plupart des cas, le diagnostic clinique de l'épilepsie est erroné. La ligue internationale contre l'épilepsie alors recommande un examen EEG prolonger est pour classer le syndrome épileptique, sémiotique pour quantifier les crises (jour et nuit) et enregistrer l'EEG diagnostic préopératoire. Il s'agit d'un test dynamique dans lequel une électrode en forme de coupe est collée à la surface du cuir chevelu. Elle permet de confirmer le diagnostic d'épilepsie, éventuellement de quantifier les crises ou d'observer des anomalies inter critiques lorsque le patient est plus sujet aux crises dans les conditions de vie habituelles, lorsque le patient supporte difficilement l'hospitalisation, ou lorsque la crise survient la nuit. Le patient peut effectuer toutes les activités quotidiennes grâce à l'enregistreur porté Bretelles (voir figure 1.5) [9].



FIGURE 1.5 – Équipement Holter EEG [10].

1.5.2 Type des montages

L'EEG fournit un riche ensemble de données sur l'ensemble du cuir chevelu basé sur les décharges individuelles détectées par les électrodes. Cela se fait en connectant toutes les électrodes dans un soi-disant montage. Il existe trois montages : montage à référence commune, montage à référence moyenne et montage bipolaire.

1.5.2.1 Montage à référence commune

Dans ce montage, des électrodes d'intérêt sont placées sur le cuir chevelu, au-dessus de la région du cerveau, généralement selon la norme 10-20. L'électrode de référence est située à l'extérieur du cerveau, sur le scalp (voir figure 1.6). Les exemples de positionnement choisis pour l'électrode de référence dans la littérature sont les lobes des oreilles, la peau sur les mastoïdes (derrière les oreilles), le nez, le menton, certaines électrodes céphaliques (Cz, FPz) et la base du cou [50].

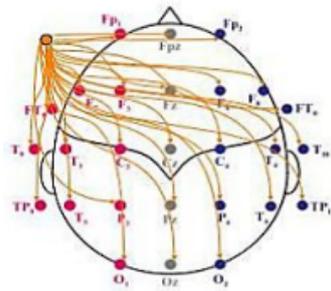


FIGURE 1.6 – Montage à Référence Commune [49].

1.5.2.2 Montage à référence moyenne

Dans ce montage à partir d'obtenus à l'aide d'une seule référence (co-référence), la référence moyenne peut être calculée comme la somme de l'activité de tous les canaux enregistrés divisés par le nombre de canaux plus un. Par défaut, cette méthode fournit également l'électrode de référence (voir figure 1.7). L'avantage de montage à référence de moyenne apparaît lorsque le même signal (artefact ou bruit) est présent sur toutes les électrodes, où ce signal est toujours annulé en soustrayant le signal d'intérêt. [50].

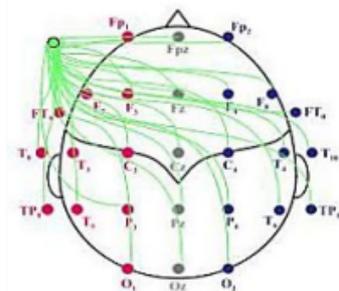


FIGURE 1.7 – Montage à Référence Moyenne [49].

1.5.2.3 Montage bipolaire

Dans un montage bipolaire, les signaux sont représentés par la différence de potentiel entre deux électrodes de mesure, où toutes les paires de voies sont envisageables. En pratique, ce montage est obtenu à partir du montage en référence commune en faisant la différence entre les voies. Il existe deux grandes catégories de montages bipolaires : le montage bipolaire longitudinal et le montage bipolaire transversal (voir figure 1.8). Dans les montages bipolaires longitudinaux, les chaînes d'électrodes s'étendent de l'avant vers l'arrière sur la tête, et dans le montage bipolaire transversal, le sens des chaînes s'étend de gauche à droite sur la tête [50].

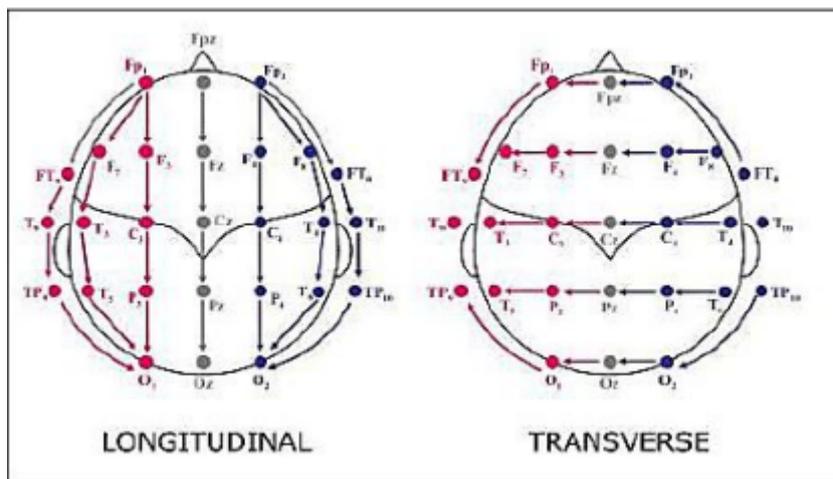


FIGURE 1.8 – Montage Bipolaire [55].

1.5.3 Bandes de fréquences principales des signaux EEG

Les rythmes cérébraux sont des signaux spontanés, c'est-à-dire qu'ils ne sont pas provoqués par des stimuli externes. Les rythmes sont utilisés en neurosciences cognitives pour classer les schémas de sommeil, pour identifier les schémas d'activité neuronale atypique associés à une pathologie (par exemple, l'épilepsie, les tumeurs cervicales) ou des états de conscience et de vigilance [42]. En ce qui concerne les rythmes cérébraux, nous pouvons identifier certains selon leur fréquence (voir la Table 1.1).

Rythme	Fréquence	Amplitude	Localisation	Corrélat
Delta	0-4 Hz	>30 uV	Antérieur, diffus	Sommeil lent Profond
thêta	4-8 Hz	20 uV	Centro temporal	Sommeil Léger
alpha	8-13 Hz	50 uV	Postérieur	Veille calme
Bêta	13-30 Hz	< 20 uV	Antérieur et moyen	Veille active
Gamma	>30 Hz	20 uV	Antérieur	Veille active

TABLE 1.1 – Principaux rythmes d'un EEG [24].

- **Delta** : fréquences jusqu'à 4 Hz, normales chez le très jeune enfant, elles peuvent ensuite caractériser certaines lésions cérébrales [24].

- **thêta** : fréquences entre 4 et 8 Hz, observées principalement chez l'enfant, l'adolescent et le jeune adulte. Elles caractérisent également certains états de somnolence ou d'hypnose[24].
- **Alpha** : fréquences comprises entre 8 et 13 Hz. Elles caractérisent un état de conscience apaisé, et sont principalement émises lorsque le sujet a les yeux fermés[24].
- **Bêta** : fréquences supérieures à 13 Hz (et généralement inférieures à 30 Hz). Elles apparaissent en période d'activité intense, de concentration ou d'anxiété[24].
- **Gamma** : au-delà de 30 Hz, fréquences rapides non étudiées dans ce travail de recherche[24].

1.5.4 Activités paroxystiques élémentaires

Les activités paroxystiques dans l'EEG ce sont des anomalies fréquentées qu'il faut reconnaître, interpréter et critiquer. Des fois elles permettent de conduire d'une manière rapide le diagnostic étiologique d'un certain nombre de situations pathologiques[29]. Les activités paroxystiques sont (voir figure 1.9) :

- **L'onde** : Toute différence de potentiel entre deux électrodes qui se traduit par un paroxysme EEG .[32]
- **La pointe** : Paroxysme EEG de brève durée (20 à 70 ms) [32].
- **La pointe lente** : Est une pointe de grande amplitude d'une durée comprise entre 70 et 200 ms ayant ainsi un aspect moins aigu qu'une pointe [32].
- **Les pointes ondes** : pointe suivie d'une onde lente de même polarité. Suivant le nombre de cycle par seconde des paroxysmes, on distingue les pointes ondes lentes qui sont à 2,5 c/s ou moins, les pointes ondes à 3 c/s et les pointes ondes rapides qui sont supérieures à 3 c/s, habituellement à 4 [32].
- **Les polypointes** : Succession de deux ou plusieurs pointes [32].
- **Les polypointes ondes** : Succession de pointes suivie immédiatement d'une onde lente [32].
- **L'onde triphasique** : Onde lente comportant trois composantes qui alternent par rapport à la ligne de base. Cette activité qui se répète d'une façon rythmique de 1 à 3 c/s s'observe dans les encéphalopathies métaboliques notamment [32].
- **Le complexe lent** : Séquence de deux ou de plusieurs ondes lentes habituellement de grande amplitude. Ce type d'activité qui survient habituellement sur un mode périodique se rencontre notamment dans les encéphalites [32].

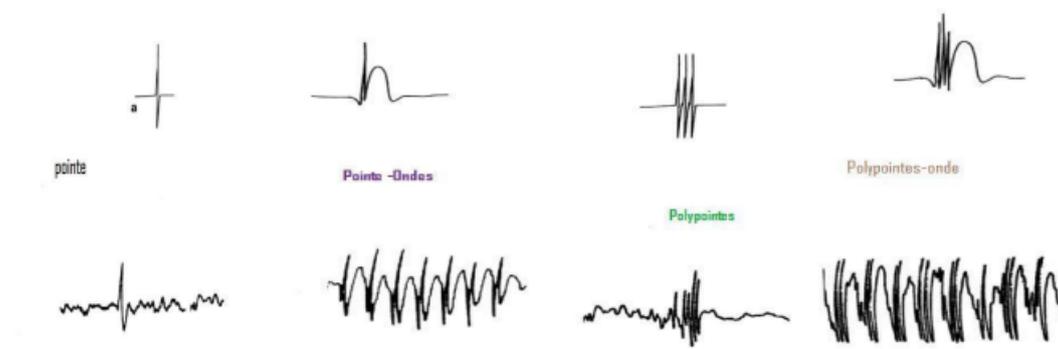


FIGURE 1.9 – Quelques Activités Paroxystiques [55].

1.5.5 Les perturbations de l'EEG

Il existe deux principales perturbations dans l'EEG : bruit et artefact :

1.5.5.1 Les bruits

Le bruit est un composant non identifié du signal mesuré comme un artefact et qui n'est pas informatif pour l'application. Il existe deux types de bruit : l'activité qui n'a généralement pas d'explication clinique connue pour le moment, comme les fréquences au-dessus de 30 Hz (les hautes fréquences) et le bruit de mesure, dû essentiellement à l'instrumentation (électrodes, fils électriques, alimentation, etc.) et à l'environnement [48].

1.5.5.2 Les artefacts

Les artefacts sont des activités électrophysiologiques non cérébrales d'origine corporelle enregistrés par l'EEG, comme des mouvements oculaires, des clignements, des activités musculaires et des activités cardiaques [48].

1.6 Système automatique pour prédire l'arrivée des crises d'épilepsie

L'électroencéphalographie (EEG) est un outil de diagnostic particulièrement efficace pour étudier l'anatomie fonctionnelle du cerveau lors d'une crise d'épilepsie [45]. Pour cela, il est nécessaire d'examiner les enregistrements EEG pendant de longues durées pour une prédiction précise de crises. Des neurologues expérimentés étudient l'épilepsie en examinant ces enregistrements sur plusieurs jours, semaines, mois ce qui nécessite une énorme quantité d'efforts humains et de temps. D'autre part la précision de diagnostic n'est pas plus cohérente même par des experts ayant diverses expériences dans ce domaine. Cela a motivé les chercheurs à développer des systèmes de prédiction automatique des crises pour résoudre ce problème [45]. Ces systèmes ont comme phases (voir figure 1.10) :

- **Pré-traitement des signaux** : En règle générale, pendant cette phase les données collectées sont soumises à un traitement préalable pour supprimer les artefacts et les bruits avant l'extraction des caractéristiques. Dans ce cas, les interférences de la ligne électrique de 50 à 60 Hz sont éliminées pour obtenir un signal EEG propre pour l'analyser [17].
- **Extraction des caractéristiques** : Les méthodes d'extraction non linéaires sont plus adaptées à l'extraction des caractéristiques tellement que les signaux EEG sont souvent très chaotiques avec des intensités de signal aussi petites que des millivolts. Les paramètres non linéaires peuvent capturer efficacement des informations cachées et des caractéristiques infimes dans le signal EEG. Cependant, certains chercheurs utilisent encore des méthodes d'extraction des caractéristiques de fréquences et de temps-fréquence [17].
- **Sélection et classement des caractéristiques** : L'objectif de cette étape est d'éliminer les caractéristiques redondantes et sélectionner à la fin uniquement ceux qui vont être utilisés dans la phase de classification. Pour cela, l'analyse des composants principaux et les moindres carrés partiels ont été appliqués pour supprimer les signaux EEG indésirables qui ne sont pas distinctifs [17].

- **Classification** : Le processus de classification est le dernier élément constitutif de ce système. La prédiction est faite à ce stade avec les caractéristiques sélectionnées introduites dans un classificateur. La machine vectorielle de soutien (SVM), le réseau neuronal artificiel (ANN) et les classificateurs la forêt aléatoires (RF) seront être utilisés pour prévoir la probabilité de crise [17].

Deux autres phases peuvent être ajoutés à ce système pour plus de précisions :

- **Régularisation** : Sous l'effet de la présence de bruits dans le signal EEG, les caractéristiques extraites peuvent être inexactes et même pour la classification qui en résulte. Dans ce cas, s'impose la régularisation qui est un processus qui consiste à éliminer l'influence du bruit sur la classification afin d'éviter les faux positifs [17].
- **Prise de décision** : Après l'élimination du bruit, le résultat obtenu de la régularisation sera transmise à la fonction de prise de décision qui est une alarme pour donner la sortie comme EEG pré-ictal si la crise est prédite correctement [17].

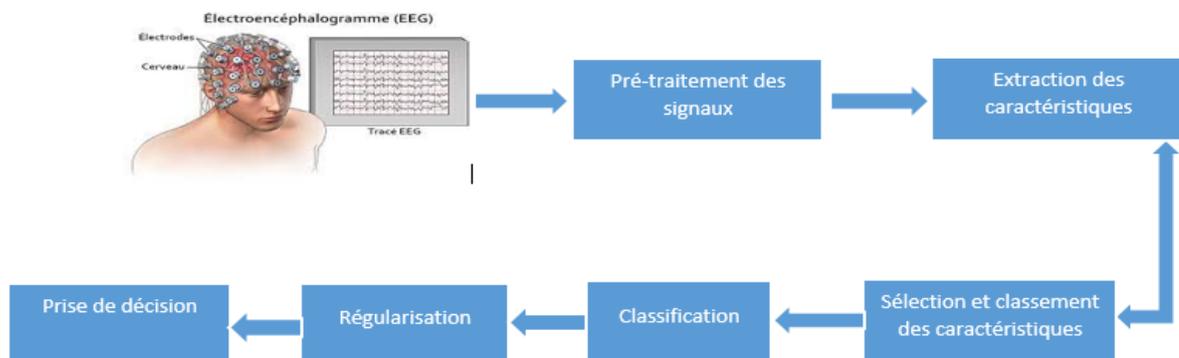


FIGURE 1.10 – Système IA pour la détection des crises [17].

1.7 Conclusion

Dans ce premier chapitre, d'abord, nous avons vu des notions générales sur l'épilepsie, suivie d'une mise en lumière sur les crises psychogènes non épileptiques. Ensuite, une description détaillée sur l'électro-encéphalogramme (EEG) a été présentée, où nous avons vu les différentes modalités d'enregistrement des signaux EEG et l'utilité de cette technologie pour le diagnostic des crises épileptiques. Enfin, nous avons abordé la structure générale d'un système IA pour la prédiction des crises épileptiques. Dans le chapitre suivant, nous examinerons quelques articles qui proposent un ensemble d'approches dédiées à la prédiction de l'avènement des crises d'épilepsie et la distinction des CNEP's.

CHAPITRE 2

ÉTAT DE L'ART SUR LES SYSTÈMES DE DÉTECTION DES CRISES D'ÉPILEPSIE ET DE DISTINCTION DES CNEP'S

2.1 Introduction

Les crises épileptiques peuvent être décrites comme une série de changements soudains et chroniques de l'activité électrique neuronale détectés par l'électroencéphalogramme (EEG), or que les crises non-épileptiques psychogènes (CNEP) sont un événement paroxystique qui ressemble du fait de leur contenu, comportemental ou expérientiel, aux crises d'épilepsie. Cependant, elles ne sont pas accompagnées des modifications électrophysiologiques. Dans le but de détecter les crises épileptiques et la détection des CNEP's, l'analyse des signaux EEG (superficiels, semi-invasifs ou invasifs) est la meilleure moyenne, pour cela plusieurs méthodes de traitement du signal telles que la transformée de Fourier rapide, la transformée en ondelettes, le calcul de coefficients de régression non linéaire et la modélisation autorégressive ont été développées. Ces méthodes sont capables de distinguer des épisodes critiques et des épisodes inter-critiques. Dans ce chapitre, nous exploitons un ensemble d'approches connues dédiées à la prédiction et l'anticipation de l'avènement des crises d'épilepsie et la distinction des CNEP's. En premier lieu, nous commençons par la présentation des critères d'évaluation sur lesquels nous nous baserons pour évaluer les approches étudiées. En second lieu, nous nous présenterons notre propre classification des solutions étudiées en montrant les principales différences et similarités entre eux. En dernier lieu, nous terminerons ce chapitre par une synthèse résumant les points forts et les points faibles des approches étudiés, suivie d' une conclusion.

2.2 Critères d'évaluation des approches existantes

Lors de l'usage clinique des méthodes de prédiction des crises épilepsie, il est nécessaire de faire une vérification adéquate des performances et de qualité. Différents critères d'évaluation ont été proposés sur la prédiction des crises épilepsie telles que la sensibilité, la spécificité, l'exactitude, latence et la valeur faussement positive et faussement négative [45]. En ce qui concerne les algorithmes de détection, généralement on peut rencontrer quatre situations :

- **Vrai Positives Détections (VPD)** : C'est le nombre des cas d'une prévisions correctes de crises épileptiques détectée par l'approche adoptée et par l'expert [45].
- **Fausses Négatives Détections (FND)** : C'est le nombre des crises épileptiques qui sont incorrectement détecter comme non-crisis (par contre l'expert a correctement détecter une anomalie paroxystique) [45].
- **Fausses Positives Détections (FPD)** : C'est le nombre de non-crise détecté incorrectement comme étant crise [45].
- **Vrai Négative Détections (VND)** : C'est le nombre de cas correctement prédits comme non-crise [45].
- **Temps** : C'est la largeur du temps d'enregistrements [38].

Voici sous-dessus, les définition de critères utilisés pour évaluer et comparer les performances de l'approche proposée :

2.2.1 La Sensibilité

C'est le pourcentage de crises correctement identifiée qui est obtenu par l'équation (2.1) [46]. Il s'agit de la métrique la plus utilisée lors de l'évaluation des résultats de détection. Cela démontre la puissance de la méthode pour détecter des crises [38].

$$\text{Sensibilité} = \frac{\text{VPD}}{\text{VPD} + \text{FND}} \times 100 \quad (2.1)$$

2.2.2 La Latence

L'objectif de l'algorithme prédictif est de détecter le début d'une crise quelque temps avant qu'elle ne se produise [46]. La latence est donc la différence de temps entre le moment où une anomalie est détectée par la méthode (t_d) et le moment où l'expert la détecte (t_c). Ce critères (mesurée en secondes) reflète la capacité de la méthode à détecter une crise le plus rapidement possible est obtenu par l'équation (2.2) [38].

$$\text{Latence} = (t_c - t_d) \quad (2.2)$$

2.2.3 La Spécificité

La spécificité est le nombre de fois que le détecteur annonce le début d'une activité épileptique en une heure sans une véritable crise. Ce critère correspond à la relation entre le VND et l'ensemble des VND et FPD et il est obtenu par l'équation (2.3) [46].

$$\text{Spécificité} = \frac{\text{VND}}{\text{VND} + \text{FPD}} \times 100 \quad (2.3)$$

2.2.4 Taux de faux négatif

Les faux négatif correspondent au nombre d'exemple reconnu par le modele comme négatif par contre en realité sont des exemples positifs. Le TFN est calcule par l'équation (2.4) [38].

$$TFN = \frac{FPD}{VND + FPD} \times 100 \tag{2.4}$$

2.2.5 Taux de faux positif

Les faux positifs (ou fausse alarmes) correspondent au nombre d'alertes, sur une période de temps, qui annoncent le début d'une activité épileptique en l'absence de crises. Le TFP est définie par l'équation(2.5) [38].

$$TFN = \frac{FND}{VPD + FND} \times 100 \tag{2.5}$$

2.2.6 Exactitude

L'exactitude mesure le taux de classification correcte des cas normaux et d'épilepsie par rapport au nombre de cas tester. Elle est définie par l'équation (2.6) [56].

$$Exactitude = \frac{VND + VPD}{VPD + FND + FPD + VND} \times 100 \tag{2.6}$$

2.3 Taxonomie des travaux examinés

Dans cette section nous offrons un classement des travaux que nous avons analysées selon une structure organisée en trois catégories. Nous commençons par la première catégorie qui représente les solutions basées sur deep learning. Dans la deuxième catégorie nous allons voir les solutions basées sur le traitement d'images. Enfin, dans la troisième catégorie nous concentrons sur les solutions basées sur la machine de learning. La figure (2.1) montre notre classification :

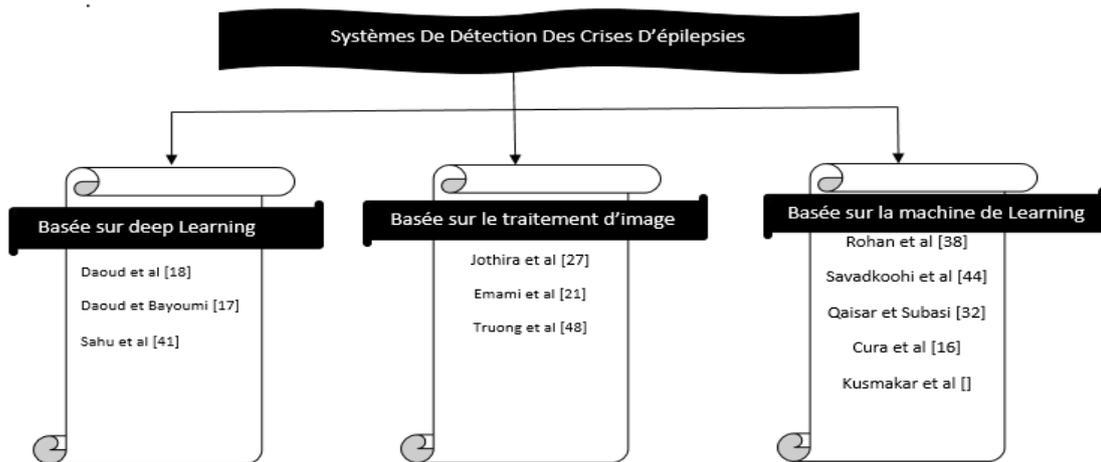


FIGURE 2.1 – Classification de systèmes de détection des crises épileptiques et de distinction des CNEP's étudiées.

2.4 Travaux antérieurs

2.4.1 Solutions basées sur deep Learning (DL)

2.4.1.1 IoT based Efficient Epileptic Seizure Prediction System Using Deep Learning

Daoud et al [28], ont proposé une approche de deep learning basé sur l'IoT pour la prédiction précise des crises d'épilepsie. Cette approche est basée sur la réception des enregistrements EEG qui sont mesurés à l'aide d'un casque sans fil disponible dans le commerce. Les données EEG sont ensuite envoyées au FPGA, où les algorithmes deep learning sont intégrés. L'approche reçoit le signal EEG brut en entrée sans prétraitement. Le FPGA envoie les résultats de prédiction au Raspberry Pi avec les données EEG enregistrées. Après avoir prédit l'état de crise au bord, le résultat de la prédiction positive déclenche une alarme au patient et envoie une notification au médecin et à tout service d'urgence choisi par SMS. L'enregistrement EEG continu est téléversé dans le cloud et doit être revu et évalué par le médecin. Daoud et al ont fourni un système qui garantit la détection des crises d'épilepsie grâce au Deep Learning avec une précision prédictive élevée de 96,1% avec une complexité moindre et un espace mémoire réduit, ce qui fait de ce système un bon choix pour les systèmes médicaux intelligents afin d'améliorer la qualité de vie des patients épileptiques accueillis par les médecins [28].

2.4.1.2 Efficient Epileptic Seizure Prediction based on Deep Learning.

Daoud et Bayoumi [27], ont suggéré une nouvelle approche de prédiction des crises d'épilepsie basée sur le deep learning et appliquée aux enregistrements EEG à long terme du cuir chevelu est proposée. Dans cette approche, Daoud et Bayoumi ont proposé quatre modèles. Dans le premier modèle, Multi-layer Perceptron (MLP), un deep simple réseau de neurones est formé chez des patients sélectionnés pour apprendre les paramètres du réseau qui peuvent effectuer la tâche de classification. Pour rendre l'exactitude plus satisfaisante ils ont proposé le deuxième modèle basé sur le Deep Convolutional Neural Network (DCNN) qui extrait les caractéristiques spatiales des positions des différentes électrodes et utilise le MLP pour la tâche de classification. Dans le but d'utiliser DCNN, les données EEG sont représentées dans une matrice dont la première dimension est le nombre de canaux et la deuxième dimension est le pas de temps. Dans le troisième modèle, la classification est effectuée en combinant DCNN avec un réseau bidirectionnel de mémoire à court terme (Bi-LSTM) comme modèle de base. Pour réduire le temps de formation, ils ont développé un quatrième modèle qui implémente une architecture Deep Convolutional Autoencoder (DCAE). Dans DCAE, ils ont pré-formé le modèle d'interface DCNN de manière non supervisée. Le processus de formation est ensuite exécuté avec quelques valeurs initiales qui aident le réseau à converger plus rapidement et à améliorer l'optimisation du réseau, en réduisant le temps de formation et en améliorant la précision. L'approche learning par transfert est utilisée pour former DCAE afin d'améliorer la généralisation entre différentes crises chez le même patient. Après la formation de l'entité d'application, l'encodeur formé est connecté au réseau Bi-LSTM pour la classification. Cette méthode garantit une précision de prédiction de 99,6%, une sensibilité de 99,72%, une spécificité de 99,60 %, un taux de faux positifs de 0,004 par heure et le temps de prédiction 1 heure avant la crise [27].

2.4.1.3 Epileptic Seizure Detection and Anticipation using Deep Learning with Ordered Encoding of Spectrogram Features

Avec les développements récents dans le domaine de deep learning, Sahu et al [51] ont proposé une nouvelle méthode basée sur le spectrogramme permettant de détecter et d’anticiper les crises épileptiques. A l’opposée des méthodes précédentes, cette méthode formule le descripteur de tenseur 3D compact pour représenter le signal EEG multicanal. La construction de spectrogramme se fait en divisant chaque signal d’EEG en trois (3) blocs de temps et 19 blocs de fréquence. Le descripteur proposé encode les spectrogrammes de signaux EEG multi-canaux dans un tenseur 3D de dimension $18 \times 19 \times 3$ par MMV représentatif calculé pour chacun de ces blocs de fréquences temporelles de canaux respectifs. Ce descripteur du tenseur 3D est fourni en tant qu’entrée au CNN pour apprendre des fonctionnalités avancées des données qui sont éventuellement utilisés pour la détection et l’anticipation de crises d’épilepsie. La méthode proposée par Sahu et al assure la détection des crises d’épilepsie avec une précision globale de 98,56 % et de 88,65 % dans la classification à 5 classes pour l’anticipation des crises d’épilepsie [51].

2.4.2 Solutions basées sur le traitement d’image

2.4.2.1 Classification of EEG signals for detection of epileptic seizure activities based on feature extraction from brain maps using image processing algorithms

Jothira et al [37]. Cette étude propose une nouvelle méthode d’extraction de caractéristiques basée sur des algorithmes de traitement d’image pour la détection automatique des crises dans les représentations de cartes cérébrales des signaux électroencéphalographiques (EEG) à l’aide de techniques de classification efficaces. La approche proposée extrait un composant indépendant (IC) dans le signal EEG à l’aide d’une analyse d’un composant indépendant et convertit chaque IC extrait en une image appelée carte du cerveau. Pour supprimer automatiquement les artefacts des cartes cérébrales, deux méthodes d’extraction de caractéristiques sont proposées tel-que le modèle de gradient de voisinage fermé (CNGP) et le modèle de texture combinée (CTP). Ensuite Les caractéristiques extraites sont introduites dans la machine vectorielle de support la moins carrée (LSSVM) pour la détection automatique des cartes du cerveau épileptique. Les résultats obtenus montrent que le classificateur LSSVM avec noyau RBF gaussien peut détecter les cartes d’épilepsie cérébrale avec un taux de haute précision. Expérimentalement, il est confirmé que le CNGP proposé pour les pixels voisins de 16 bits et le CTP pour les pixels voisins de 8 bits montraient un taux de classification efficace de 94% pour la détection de cartes du cerveau épileptique à partir de cartes artéfacts du cerveau [37].

2.4.2.2 Seizure detection by convolutional neural network-based analysis of scalp electroencephalography plot images

Emami et al [30]. Cette approche était faite en prenant en compte que les spécialistes expérimentés de l’épilepsie sont les responsables de détecter les crises directement en analysant visuellement les images de tracé EEG, plutôt que d’utiliser la détection automatique des crises. La détection des crises dans ce cas peut bénéficier des réseaux de neurones convolutifs (CNN), qui affichent des performances comparables à celles des experts en reconnaissance visuelle. L’approche réalisé par Emami et al détecte les crises d’épilepsie en traitant des données EEG qui sont converties en une série d’images de tracé. Ces images seront analysées par un médecin spécialisé en épilepsie, puis chaque image sera classée comme crise ou sans crise à l’aide de CNN [30].

2.4.2.3 A Generalised Seizure Prediction with Convolutional Neural Networks for Intracranial and Scalp Electroencephalogram Data Analysis

Truong et al [60]. Cette approche n'était pas performante vu qu'elle offre environ 60% comme taux de sensibilité et un FPR modeste. Rien n'empêche, elle a connue quelques améliorations qui ont affecté la sensibilité qui a été augmentée au-delà de 70% tandis que la FPR a chuté en dessous de 0,15/h. Dans le cadre de même système, une autre méthode a été proposé par [43] dans le but de mieux exploiter les informations de synchronisation. Parmi les contributions et nouveautés offertes par cette méthode, il y avait la capacité classifier les signaux ictal (c.-à-d. période de crise) et interictal (c.-à-d. période entre les crises) indépendamment de l'emplacement de cerveau, de patient, de type de crise et du contexte hospitalier avec une certaine plage de tolérance aux artefacts. En plus, elle a fournit la rationalité et la manière d'extraire les composants à haute fréquence de chaque technique de transformation/décomposition, a identifié les caractéristiques distinctives (comparaison illustrée fournie) des signaux ictal et interictal pour la classification et fournir une analyse complète des résultats à l'aide de l'exploitation du "receiver operating characteristics" (ROC) [43]. Le système de Truong et al fournit la détection et la prédiction de crises d'épilepsie grâce au traitement d'image avec des caractéristiques locales basées sur des fonctions de déviation et de fluctuation modifiées, en utilisant LS-SVM pour la classification, ce qui donne une sensibilité de 95,4 % et un FPR de 0,36/h [60].

2.4.3 Solutions basées sur la machine de Learning (ML)

2.4.3.1 Efficient Approach to Detect Epileptic Seizure using Machine Learning Models for Modern Healthcare System

Rohan et al [47], ont proposé un système qui explore un modèle de machine learning et de deep learning supervisé pour la classification des crises épileptiques à partir de l'ensemble de données du répertoire d'apprentissage automatique de l'université de California, Irvine (UCI). L'ensemble de données compte 11500 instances; chaque information contient 178 attributs. Le système de Rohan et al assure la détection des crises d'épilepsie en utilisant l'apprentissage automatique avec le XGBoost, machine learning et le deep learning avec l'ANN. Approche d'apprentissage profond propose un algorithme ANN qui a une précision améliorée et classifie avec précision les crises épileptiques des patients. La validation croisée 10-fold est utilisée à des fins de validation dans cette approche. L'algorithme XGBoost proposé offre une précision de test de 96,6% et l'ANN proposé offre une précision de test de 98,26% [47].

2.4.3.2 A machine learning approach to epileptic seizure prediction using Electroencephalogram (EEG) Signal

Savadkoochi et al [54], ont exploré une méthode de détecter les tendances significatives à partir d'un électroencéphalogramme épileptique (EEG) en utilisant d'apprentissage automatique. Les signaux utilisés dans ce travail sont des segments de 23,6 secondes de 100 enregistrements d'EEG de surface à canal unique recueillis avec un taux d'échantillonnage de 173,61 Hz. Le feature engineering a été réalisée en utilisant, en premier lieu, l'extraction des caractéristiques de chaque onde EEG dans les domaines de temps, de fréquence et de fréquence-temporelle via le filtre Butterworth, utterworth filter, Fourier Transform (FT) et Wavelet Transform (WT) respectivement. En deuxième lieu, la sélection des caractéristiques avec T-test et Sequential Forward Floating Selection (SFFS). Les algorithmes d'apprentissage SVM et KNN ont été appliqués pour classer le signal EEG prétraité. Au cours de ce

travail, la comparaison des performances était basée sur la précision, la sensibilité et la spécificité, où les résultats finaux ont montré que SVM a un léger avantage sur KNN [54].

2.4.3.3 Effective epileptic seizure detection based on the event-driven processing and machine learning for mobile healthcare

Qaisar et Subasi [41], ont proposé un système à base de machine learning pour le diagnostic précis et effectif des crises épileptiques. Pour réaliser la compression en temps réel et le traitement et la transmission effective du signal, ils ont utilisé une acquisition intelligente du signal par électroencéphalogramme (EEG). Les résultats expérimentaux montrent que grâce à la nature événementielle, une compression globale de 3,3 fois et une réduction de l'utilisation de la bande passante de transmission aient obtenues par cette méthode par rapport aux contreparties classiques. La performance du système de [41] est étudiée à l'aide d'un ensemble de données standard sur les crises épileptiques de trois classes EEG. La précision de classification la plus élevée est garantie pour une classe unique avec un taux de 97,5%. La meilleure précision moyenne de classement de 96,4% est atteinte pour trois classes. Les résultats de comparaisons de ce système avec les équivalents classiques montrent plus de trois fois et sept fois plus de performance respectivement en matière de gain de compression et d'efficacité de traitement tout en confondant une précision de classification comparable [41].

2.4.3.4 Classification of Psychogenic Non-epileptic Seizures Using Synchrosqueezing Transform of EEG Signals

Cura et al [26]. Dans cette étude, une nouvelle méthode basée sur la représentation temps-fréquence est proposée pour distinguer les segments EEG d'inter-CNEP, CNEP et des crises épileptiques. Cette méthode consiste à acquérir une représentation conjointe de segment EEG inter-CNEP, CNEP et de crise épileptique marquer par des experts et à extraire diverses caractéristiques des distributions TF acquises. Cura et al ont proposé d'utiliser la nouvelle méthode d'analyse TF "SST", qui produit une distribution TF presque idéale. Les caractéristiques de joint-TF sont calculées en utilisant les densités d'énergie obtenues par SST. Enfin, l'ensemble de fonctionnalités résultant est classé à l'aide d'algorithmes d'apprentissage automatique tels que les classificateurs Decision Tree (DT), Support Vector Machine (SVM), Random Forest (RF) et RUSBoost (RUSB). Dans cette méthode deux cas sont examinés: **(i) problème à Trois classes** : Cette classe permet identifier les segments CNEP à l'aide d'un ensemble de caractéristiques obtenues à partir de segments EEG appartenant à trois classes inter-CNEP's, CNEP's et de crise épileptique. Les résultats de l'évaluation de l'efficacité de l'approche basée sur la SST pour la classification des inter-CNEP, CNEP et des crises épileptiques sont les suivants : les Valeurs ACC, PRE et FDR les plus élevées obtenues à l'aide du classificateur RF (ACC : 95,8%, PRE : 91,4%, FDR : 8,6) la valeur SEN la plus élevée (90,3%) est obtenue à l'aide du classificateur RUSB pour la détection CNEP. De plus, pour tous les classificateurs, sauf SVM, ils ont eu des valeurs ACC 93%, SEN 82%, et PRE 86% et FDR 14%. **(ii) Problème à deux classes** : Dans cette classe les segments CNEP sont détectés à l'aide de deux conceptions différentes, conception dépendante du patient (PDD) et conception indépendante du patient (PID), à l'aide de fonctions TF articulaires obtenues uniquement à partir des segments inter-CNEP et CNEP. Les résultats de l'évaluation de l'efficacité de l'approche basée sur la PDD sont les suivants : Les précisions les plus élevées sont obtenues avec 92,3%, 95,2%, 97,5%, 97,3%, 98,3% et 98% en utilisant le classificateur RF pour six patients respectivement. Alors que le classificateur RUSB fournit les valeurs SEN maximales et les plus élevées sont obtenues à l'aide du classificateur RF. De plus, bien que la performance moyenne de classification la plus élevée soit atteinte avec des valeurs ACC 96,43%, SEN 96,8% et PRE 97,3 %

à l'aide du classificateur RF, la valeur SPE moyenne maximale est obtenue à l'aide du classificateur RUSB. Dans le cas au l'approche basée sur PID les valeurs moyennes de SEN sont presque 10% inférieures à celles de l'approche PDD. De plus, les approches PDD et PID donnent des valeurs FDR inférieures de 10% [26].

2.4.4 Improved Detection and Classification of Convulsive Epileptic and Psychogenic Non-epileptic Seizures Using FLDA and Bayesian Inference

Kusmakar et al [39]. L'étalon-or pour le diagnostique de CNEP est le suivi vidéo-électroencéphalographique (VEM), qui est un processus exigeant en ressources. Par conséquent, le besoin d'une méthode plus object de diagnostique CNEP est créé. Des capteurs accéléromètres ont été utilisés précédemment pour le diagnostique des crises épileptiques. Dans ce travail, Kusmakar et al ont proposé une nouvelle approche pour la détection et la classification des CNEP à l'aide d'un accéléromètre porté au poignet. Diverses caractéristiques de temps, de fréquence et d'espace d'ondelettes sont extraites du signal d'accélérométrie. La compression des fonctions est ensuite effectuée à l'aide de l'analyse discriminante linéaire de Fisher (FLDA). Un classificateur Bayésien est ensuite formé à l'aide de la méthode de l'estimateur du noyau. L'algorithme a été formé et testé sur les données recueillies auprès de 16 patients sous VEM. Dans ce travail, une approche basée sur FLDA et l'inférence bayésienne en utilisant une méthode non paramétrique d'estimation de la densité du grain est employée pour la détection automatisée et la classification des CNEP convulsives et des crises épileptiques à partir du signal d'accélérométrie. L'algorithme proposé a détecté les 16 événements (8 crises épileptiques, 8 CNEP) de l'ensemble de tests. De plus, l'algorithme a correctement classé les 8 événements CNEP (sens : 100 %) et 6 des 8 événements de crises épileptiques (sens : 75 %) [39].

2.5 Étude comparative

Divers systèmes pour but de détecter les crises épileptiques et de distinction des CNEP ont été proposer, tout en utilisant les caractéristiques de deep learning, de traitement d'image et de machine learning. Parmi ces systèmes, il y a ceux qui nous permettent de détecter les crises avant qu'elles ne surviennent, d'autres qui nous permettent la distinction des CNEP. Chaque système a ces avantages et inconvénients par rapport aux autres. Afin de mieux comprendre les différents systèmes étudiés dans ce chapitre en traitant le problème de détection des crises épileptiques et de distinction des CNEP, la table 2.1 présente une étude comparative réalisée sur divers systèmes préalablement analysés selon les critères d'évaluation discutés à la section 2.2.

Solution basée sur	Systèmes	Sensibilité	Spécificité	Taux de faux négatif	Taux de faux positif	Exactitude	
Deep learning	Daoud et al. [28]	97.41%	94.8%	Non renseigné	Non renseigné	96.1%	
	Daoud et Bayoumi [27]	99.72%	99.60%	Non renseigné	faible	96.6%	
	Sahu et al. [51]	95.49%	99.33%	Non renseigné	Non renseigné	98.56%	
Traitement d'image	Jothira et al. [37]	90.79%	97.52%	Non renseigné	Non renseigné	94.74%	
	Emami et al. [30].	Non renseigné	Non renseigné	Non renseigné	Moyen	Non renseigné	
	Truong et al. [60]	81.4%	Non renseigné	Non renseigné	Faible	Non renseigné	
Machine Learning	Qaiser et Subasi [41]	Non renseigné	Non renseigné	Non renseigné	Non renseigné	96.4%	
	Savadkoochi et al. [54]	99%	100%	Non renseigné	Non renseigné	99.5%	
	Rohan et al. [47]	Non renseigné	94%	Non renseigné	Non renseigné	95.33%	
	Cura et al. [26]	(I)	86.9%	Non renseigné	8.6%	Non renseigné	95.8%
		(II)	96.8%	Non renseigné	>10%	Non renseigné	96.4%
	Kusmakar et al. [39]	100%	93%	Non renseigné	Non renseigné	92%	

TABLE 2.1 – Étude comparative des différents systèmes analysés

Concernant les systèmes de détection des crises épileptiques, [28] [27] [51] sont des solutions avec un taux d'exactitude meilleur, avec un très bas taux de faux positif et avec une sensibilité et spécificité très élevées. Les solutions [37] [30] [60], leur problème d'applicabilité réside dans leurs sensibilités faibles par rapport à d'autres méthodes. Pour les systèmes [41] [54] [47], ils montrent des résultats relativement élevés en termes de sensibilité, de spécificité et d'exactitude, quoique ces résultats restent à confirmer compte tenu du nombre de patients utilisés dans le test. En ce qui concerne les systèmes de distinctions des CNEP's, parmi ceux qu'on nous avons analysés dans la section 2.4.3.4, nous constatons que le système [26] offre une exactitude plus élevée et un taux de faux négatif bas par rapport au système proposé par [39], sans ignorer que ce dernier offre une sensibilité idéale.

2.6 Synthèse

Une étude comparative des différents systèmes proposer par les articles vu dans la section 2.4 analysés selon les critères présentés dans la section 2.2 est présenté dans la table 2.1. Ces systèmes sont classés en trois catégories, [28] [27] [51] basés sur le deep (DL) learning, [37] [30] [60] basés sur le traitement d'image et [41] [54] [47] [26] [39] basé sur le machine learning (ML).

D'après cette table, nous pouvons constatés que les approches présentées par les systèmes [41] [54] [47] [26] [39] offrent des meilleures performances par rapport aux autres, malgré que leurs résultats restent à confirmer vu le nombre d'échantillons utiliser. Nous remarquons que tous ces systèmes sont basés sur le ML. Ces résultats nous pousse à faire une enquête sur l'avantage des systèmes basées sur le ML afin de résoudre la problématique et pour mieux les exploiter lors de la proposition de notre futur système. Parmi les différences entre ces systèmes, nous avons que les solutions basées sur les DL ainsi que sur le traitement d'image, traites des données non structurés, contrairement au ML, qui permet au programmeur de choisir directement et uniquement les données nécessaires pour le fonctionnement de son système. Cette différence représente un avantage pour les solutions de DL et le traitement d'image, parce qu'ils font la distinction entre les données nécessaires au fonctionnement du système sans l'intervention humaine, et les récupère automatiquement, ce qui fait qu'ils sont plus indépendants, et bizarrement, c'est la raison pour laquelle les résultats obtenus par ces deux catégories de systèmes sont inférieurs aux résultats de ML. En effet, pour avoir un système de qualité basée sur le DL ou sur le traitement d'image, des algorithmes très profonds sont nécessaire, cela implique le besoin d'utiliser des serveurs très puissant, un ordinateur (même avec de haute capacité) ne pourra pas dérouler ces algorithmes très complexes. Pour diminuer le coût, tous les systèmes proposés ont eu recours à l'utilisation d'un ordinateur, et contrairement aux solutions basées sur le ML, les systèmes basés sur le DL et le traitement d'image ont réduits la profondeur de leurs algorithmes, et c'est la raison pour laquelle leurs résultats de performance ont diminué.

Selon l'étude que nous avons fait et d'après les résultats obtenus nous avons vu les similarités et les différences de chacun des systèmes examinés et nous avons pu extraire les avantages et les inconvénients de ces systèmes en tenant compte de notre classification.

2.7 Conclusion

La majorité des techniques présentées dans ce chapitre se basent sur une combinaison de plusieurs informations collectées à partir de l'EEG pour la détection de survenue des crises épileptiques et la distinction des CNEP's. Différentes méthodes temporelles et fréquentielles ont permis la description des signaux et la détection rapide et précise des changements d'état. Au sein de ce chapitre, nous avons présenté notre propre taxinomie des travaux examinés, suivie d'une étude comparative entre ces travaux en tenant compte un ensemble de critères de performance, avant de terminer par une synthèse. Cela nous a permis d'extraire les problèmes auxquels nous devons faire face afin de proposer une solution plus complète qui répondra à la problématique et aux critères cités auparavant et nous allons voir notre proposition avec plus de détails dans chapitre suivant.

CHAPITRE 3

UNE MÉTHODE D'ENTROPIE APPROXIMATIVE PAR ONDELETTES POUR DÉTECTER ET DISTINGUER LES CRISES ÉPILEPTIQUES ET LES CRISES PSYCHOGÈNES NON ÉPILEPTIQUES À PARTIR DE L'EEG ET SES SOUS-BANDES

3.1 Introduction

Nous avons vu au sien de chapitre précédent que les systèmes étudiés offrent des bonnes performances, mais pour divers raisons, ils ont été jugés insuffisants pour répondre concrètement à toutes les questions de la problématique. Néanmoins, ces systèmes nous ont confirmé que la méthode la plus précise est bien celle qui utilise les données acquises à partir des capteurs physiologiques tels que l'électroencéphalogramme (EEG) dont ses signaux fournissent des informations très utiles pour détecter les crises en temps réel. À base de l'étude menée au niveau de différents services de soins du centre hospitalier universitaire (CHU) de Bejaia, nous proposerons dans ce chapitre un système portable de détection des crises en temps réel pour avoir une réponse rapide, et de distinction entre les crises épileptiques et les crises non épileptiques psychogènes (CNEP). La contribution de notre système reposera sur la surpasse des défaillances repérées dans les systèmes étudiés précédemment. Pour cet objectif, notre système exploitera un canal unique, et il concentra sur l'évaluation de l'activité dans les ondes de fréquences thêta, alpha et bêta.

3.2 Motivation

L'épilepsie et CNEP sont des véritables maladies, reconnues par la médecine. On estime que les CNEP touchent 2 à 33 personnes sur 100.000, ce qui en fait une pathologie assez fréquente. Ces personnes prennent parfois depuis plusieurs années des médicaments antiépileptiques qui ne servent à rien. Ainsi, environ 1 personne sur 5 qui consulte dans un centre spécialisé pour une épilepsie résistante aux traitements est en fait atteinte de CNEP. Pour ce type de trouble, l'EEG qui est un examen qui permet de mesurer et d'enregistrer l'activité électrique du cerveau, est le moyen le plus utilisé pour le diagnostic [44]. Pour aider les personnes touchées par ces pathologies, nous avons opté pour la conception d'un logiciel qui permet de détecter les crises en temps réel, et de distinguer entre les crises épileptiques et les CNEP's. Dans ce contexte, il existe pas mal de systèmes qui ont été proposés, mais hélas, ils arrivent toujours pas à répondre concrètement à tous les problèmes de ces pathologies. Parmi les majeurs problèmes à faire face, l'examen d'EEG qui est réalisé dans des cabinets médicaux ou dans des hôpitaux avec la présence des spécialistes, ce qui nécessite le déplacement de patient, et aussi nécessite beaucoup de temps, cela force les malades à vivre dans une incertitude car les crises peuvent se produire à n'importe quel moment ce qui met leur vie en danger constant. À cet effet, suite à l'observation des différents services de soins (services d'urgence, unité de réanimation, etc.) du CHU de Bejaia, nous focaliserons dans notre contribution sur la réalisation d'un système intelligent, et portable -sans la nécessité de déplacement du patient- pour la détection et la distinction rapide des crises en utilisant les signaux EEG. Afin de d'augmenter la performance de ce système, nous avons opté à utiliser le canal unique [19]. Cette réduction de nombre de canaux EEG nous permet aussi d'améliorer le confort du patient. De plus, parmi les cinq ondes de fréquence d'un signal EEG, seules les ondes **thêta**, **alpha** et **bêta** contiennent des informations sur les crises épileptiques [36] [24], et les résultats de l'étude menée par [26] montrent que la bande **bêta** est la sous-bande EEG la plus efficace pour distinguer les segments de crise épileptique et CNEP. Pour cela, nous nous concentrons sur l'évaluation de l'activité dans ces ondes de fréquences afin de concevoir notre système. La figure 3.1 illustre l'architecture générale d'un système de détection et de distinction de crises en temps réel pour une réponse rapide.

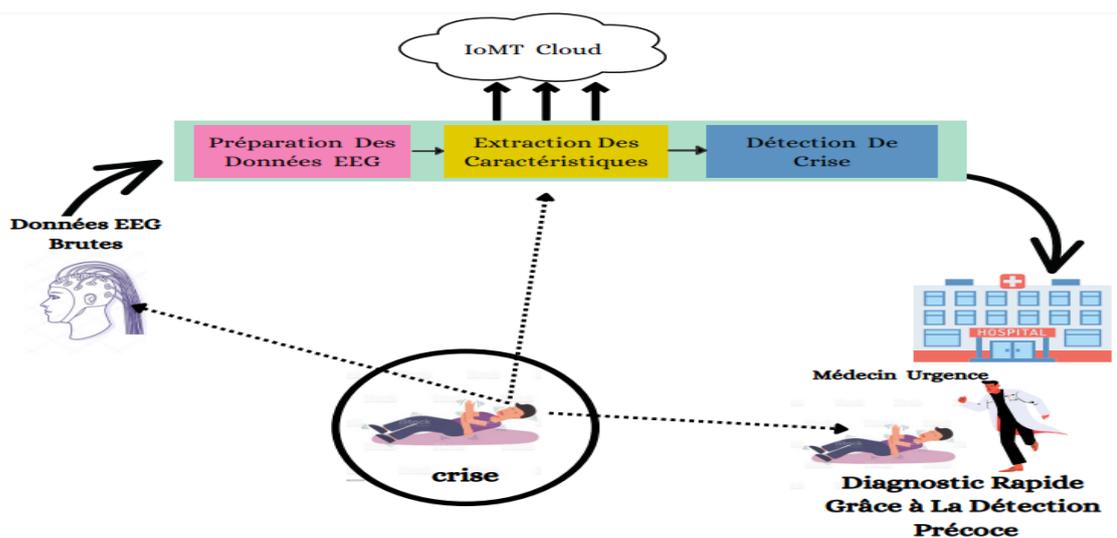


FIGURE 3.1 – Détection des crises en temps réel pour une réponse rapide.

3.3 Schéma fonctionnel de l'architecture proposée

Pour notre système, nous proposons une architecture qui favorise la détection et la distinction rapide des crises tout en garantissant le facteur de portabilité. La première étape de notre proposition consiste à l'acquisition de signal EEG brut. Cette étape est effectuée en plaçant des électrodes sur le cuir chevelu selon un positionnement bien précis, et dans notre système nous utilisons une base de données EEG prête. Ce signal EEG appelé brut est souvent perturbé par des bruits et des artefacts tels que l'interférence de la ligne électrique, le mouvement musculaire et le clignement des yeux. La présence de ces bruits et artefacts corrompra le signal et rendra l'extraction et la classification des caractéristiques moins précise. La deuxième étape (unité de filtrage) est l'étape de suppression des artefacts en utilisant le filtre Butterworth pour produire un signal EEG propre. Dans l'étape qui suit (unité de décomposition), les signaux EEG propres sont initialement traités et décomposés en plusieurs sous-bandes à l'aide du transformée en ondelettes discrète DWT (Discrete Wavelet Transform). Par la suite, les caractéristiques sont extraites de chaque sous-bande (unité extraction des caractéristiques) en calculant la valeur d'ApEn de chaque segment EEG et leurs sous-bandes. Grâce aux résultats obtenus dans les tâches précédentes, la P-valeur et la probabilité de séparation est calculé afin de déterminer le type de crise. Parallèlement, toutes les données analysées sont transférées et stockées dans le cloud d'internet des objets médicaux IoMT (Internet of Medical Things). Le module de cloud IoMT permet une connectivité à distance avec les services d'urgence, les médecins personnels et les membres de la famille ou les proches pour déclencher un sauvetage rapide et efficace des sujets susceptibles de souffrir de crises.

3.4 Le système de détection des crises proposé

Afin de réaliser notre système de détection des crises nous avons eu à faire des choix difficiles parmi plusieurs techniques pour obtenir un meilleurs résultats possibles. La première phase de l'algorithme que nous avons proposé pour la détection et distinction intelligente et automatique des crises épileptiques et crises psychogènes non épileptiques à partir des signaux EEG s'intéresse sur l'acquisition de données EEG à partir de patient. Ensuite, la deuxième phase consiste au prétraitement de signal EEG, et son objectif est de réduire les perturbations en utilisant le filtre de Butterworth. La phase suivante qui est la décomposition avec DWT, vise à éliminer les artefacts qui sont dans le signal EEG, et décomposer ces signaux en plusieurs sous-bandes d'ondelettes qui représentent les informations de détail et d'approximation. Par la suite, la phase d'extraction de caractéristiques qui consiste à calculer les valeurs ApEn des segments EEG et leurs sous-bandes. Ensuite, après le calcul des valeurs ApEn, nous calculons la probabilité de séparation entre chaque sous-ensemble de donnée afin de classe chaque type de crise. Enfin, le transfert des données au médecin via Internet est assuré par le module IoMT (Internet of-Medical Things) permettant une connectivité à distance.

3.4.1 Prétraitement

Dans la plupart des temps, les signaux EEG sont contaminés par beaucoup de bruit et d'artefacts ce qui diminuera la précision de l'extraction et de la classification des caractéristiques. Pour cela, la phase de prétraitement consiste à éliminer tous les bruits pendant l'enregistrement à l'aide de filtre Butterworth pour rendre le signal propre. Ensuite, nous utiliserons la transformation discrète en ondelettes DWT pour éliminer les artefacts et rendre le signal EEG prêt à être exploiter dans les prochaines phases.

3.4.1.1 Filtre de Butterworth

Au cours de cette phase, nous utiliserons le filtre Butterworth qui est un filtre de traitement du signal pour rendre la réponse en fréquence aussi plate que possible sur la bande passante. Ce filtre est également connu sous le nom de "filtre plat à amplitude maximale". Il a été décrit pour la première fois en 1930 par l'ingénieur et physicien britannique Stephen Butterworth dans son article intitulé "The Theory of Filter Amplifiers" [25]. Pour préserver les signaux EEG et réduire les bruits choisis par la fréquence de coupure, nous appliquerons sur les signaux un filtre passe-bande quadratique Butterworth de fréquence de coupure ω_c de 0,5 Hz et 70 Hz.

Les polynômes Butterworth standard peuvent servir à déterminer la fonction de transfert de n'importe quelle fréquence de coupure de filtre passe-bas ω_c , comme suit :

$$H(p) = \frac{G_0}{\prod_{k=1}^n (p - p_k)/\omega_c} \quad (3.1)$$

avec :

$$P = P^2 + 1.4142P + 1 \quad (3.2)$$

(Équation du filtre Butterworth de deuxième ordre [25])

Pour tous les filtres linéaires, le prototype étudié est un filtre passe-bas, qui peut être facilement modifié en filtre passe-haut ou localisé en série pour former un filtre passe-bande ou coupe-bande. La fréquence de coupure a été normalisée à 1 radian par seconde et dont la réponse en fréquence (Gain) est [25] :

$$G_n(\omega) = \frac{1}{\sqrt{1 + \omega^{2n}}} \quad (3.3)$$

Avec :

ω : la fréquence angulaire en radians par seconde.

n : le nombre de pôles du filtre égal au nombre d'éléments réactifs dans un filtre passif.

3.4.2 Transformée en ondelettes discrète (DWT, Discrete Wavelet Transform)

Une ondelette peut être littéralement définie comme une "petite" vague de durée finie et de moyenne nulle. Ce sont des fonctions mathématiques capables de localiser une fonction ou un ensemble de données dans le temps et la fréquence. Le concept général d'ondelette a été introduit par Grossman et Morlet au milieu des années 80 [18]. La transformation des ondelettes est un outil efficace dans le traitement du signal en raison de ses propriétés attrayantes telles que la localisation de fréquence de temps, parmi ces signaux le EEG. De manière générale, la transformation en ondelettes peut être exprimée avec l'équation suivante (3.4) [3] :

$$F(a, b) = \int_{-\infty}^{+\infty} f(x)\psi_{(a,b)}^*(x) dx \quad (3.4)$$

Avec :

F : représente le signal en ondelettes dans les paramètres a et b .

ψ : représente la fonction de décalage et de détail.

La transformée en ondelette discrète analyse également les signaux dans différentes bandes de fréquences avec différentes résolutions en décomposant le signal par une approximation grossière et une information détaillée. Cette technique est produite pour résoudre le problème de redondance CWT, cette redondance nécessite beaucoup de ressources informatiques [21].

Pour obtenir de meilleurs résultats dans l'extraction de caractéristiques avec l'algorithme ApEn, la décomposition en ondelettes sera utilisée comme deuxième niveau de prétraitement pour les segments EEG afin d'extraire cinq sous-bandes physiologiques, delta (0-4 Hz), thêta (4-8 Hz), alpha (8-13 Hz), bêta (13-30) et gamma (30-60 Hz), comme illustré dans la figure 3.2. Pour cet objectif, une transformée en ondelettes discrètes (DWT) à quatre niveaux avec une fonction d'ondelettes de Daubechies de troisième ordre (db3) sera utilisée. Puisque notre jeu de données est dans la gamme 0-60 Hz, les coefficients D1, D2, D3, D4 et A4 correspondant respectivement à 30-60 Hz, 15-30 Hz, 8-15 Hz, 4-8 Hz et 0-4 Hz sont sous-bandes physiologiques presque standard. Nous pouvons maintenant calculer l'entropie approximative chaque sous-bande du niveau suivant. Considérant que seules les ondes alpha, bêta et thêta qui contiennent des informations sur les crises [36] [24], nous focaliserons alors seulement sur elles dans la suite de notre travail.

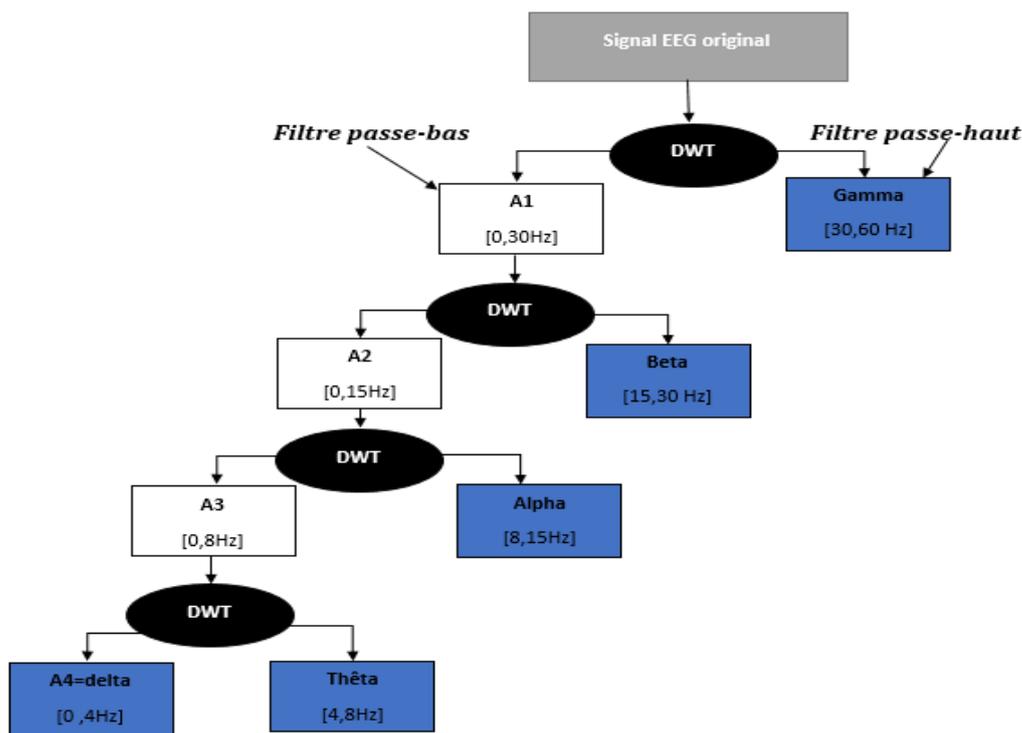


FIGURE 3.2 – Décomposition de la séquence EEG avec transformée en ondelettes discrètes et extraction de cinq sous-bandes physiologiques

3.4.3 Extraction de caractéristiques

3.4.3.1 Entropie approximative

La phase d'extraction des caractéristiques représente la phase la plus critique de notre système vu qu'elle offrira un ensemble de données primordiales. Après avoir utilisé la décomposition en ondelettes discrète sur le signal EEG prétraité avec le filtre Butterworth dans les phases précédentes, nous avons obtenu cinq sous-ondes de fréquence. Comme étape suivante, nous calculerons la valeur d'entropie approximative (ApEn) pour le signal EEG et ses ondes. L'ApEn est une technique largement utilisée pour l'analyse de grandes données EEG, en particulier dans les cas de maladies neuro-physique comme l'épilepsie, la schizophrénie, la toxicomanie [22]. Cette technique est utilisée pour quantifier le degré de régularité et l'imprévisibilité des fluctuations sur les données de séries chronologiques et nous donne beaucoup d'informations sur la complexité de ces données. La valeur de l'ApEn est déterminée comme indiqué ci-dessous [62] :

- Pour une série chronologique N point donnée :

$$X = \{x(1), x(2), x(3), \dots, x(N)\} \quad (3.5)$$

- Choisir m points sous-séquences du signal EEG comme ci-dessous :

$$X(i) = \{x(i+1), x(i+2), x(i+3), \dots, x(i+m-1)\} \quad (3.6)$$

- Pour $(1 \leq i \leq N+m-1)$, on définit la distance entre $X(i)$ et $X(j)$, $d[X(i), X(j)]$, comme la différence absolue maximale entre eux comme ci-dessous :

$$d[X(i), X(j)] = \max_{k=1,2,3,\dots,m} [|x(i+k-1) - X(j+k-1)|] \quad (3.7)$$

On définit RCO comme :

$$RCO = r * STD \quad (3.8)$$

STD est l'écart type de séquence, et r peut varier entre 0 et 1. Ensuite, nous définissons Θ comme ci-dessous :

$$\Theta_j = \begin{cases} 1 & \text{si } d[X(i), X(j)] \leq RCO \text{ pour } (1 \leq i \leq N+m-1) \\ 0 & \text{sinon} \end{cases} \quad (3.9)$$

On définit C_i^m :

$$C_i^m(RCO) = \frac{1}{N-m+1} \sum_{j=1}^{N-m+1} \Theta_j \quad (3.10)$$

- Ensuite, nous pouvons définir $\phi^m(r)$ comme ci-dessous :

$$\phi^m(r) = \frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \log C_i^m \quad (3.11)$$

- A la fin, pour m et r fixes, la valeur ApEn de la séquence est :

$$ApEn(m, RCO) = \phi^{m+1}(RCO) - \phi^m(RCO) \quad (3.12)$$

Après le calcul de l'ApEn pour le signal EEG et ses ondes avec $m=2, r=0.2 * \text{écart-type}(\text{segment})$ et $t=1\text{sec}$, nous procéderons à la dernière étape de cette phase qui consiste à l'analyse statistique avec test-t pour étudier le potentiel de séparation entre les groupes avec les caractéristiques extraites avec l'ApEn pour l'EEG et ses sous-ondes.

3.4.4 Classification

3.4.4.1 Test statistique (T-test)

Les tests statistiques nous permettent de faire des déclarations avec un certain degré de précision, mais ne peuvent en fait prouver ou réfuter quoi que ce soit. Un résultat significatif au niveau de probabilité de 95 % nous indique que nos données sont assez bonnes pour appuyer une conclusion avec une confiance de 95 %. Dans les travaux biologiques comme le nôtre, nous acceptons ce niveau d'importance comme étant raisonnable [62]. Le T-test est une analyse statistique pour estimer la probabilité de ségrégation entre deux groupes de données. La valeur t de deux échantillons avec des tailles d'échantillon égales/inégales, des variances inégales et des moyennes inégales est calculée comme suit [22] :

$$t = \frac{\bar{X}_1 - \bar{X}_2}{S_{\bar{X}_1 - \bar{X}_2}} \quad (3.13)$$

Les valeurs \bar{X}_1 et \bar{X}_2 sont des moyennes de l'échantillon 1 et de l'échantillon 2 respectivement, et le $S_{\bar{X}_1 - \bar{X}_2}$ est calculé comme suit :

$$S_{\bar{X}_1 - \bar{X}_2} = \sqrt{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)} \quad (3.14)$$

Où n_1 et n_2 sont les tailles d'échantillon et S_1 et S_2 sont les variances d'échantillon de deux échantillons.

- Afin d'obtenir la p-valeur (probabilité de ségrégation), le degré de liberté (df) est calculé comme suit :

$$df = \frac{\left(\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}\right)^2}{\frac{\left(\frac{S_1^2}{n_1}\right)^2}{n_1-1} + \frac{\left(\frac{S_2^2}{n_2}\right)^2}{n_2-1}} \quad (3.15)$$

Après le calcul du T-valeur et df nous pouvons extraire la P-valeur du tableau des p-valeurs de l'analyse t-test. Le Schéma fonctionnel de la méthode globale pour l'extraction des caractéristiques EEG est montré dans la figure 3.3.

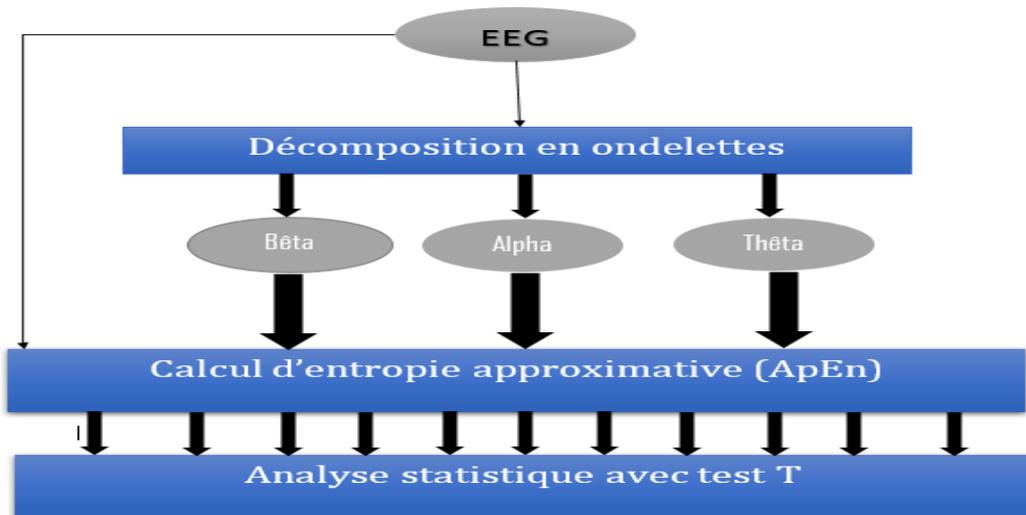


FIGURE 3.3 – Schéma fonctionnel de la méthode globale pour l'extraction des caractéristiques EEG.

3.5 Conclusion

Au sein de ce chapitre, nous avons présenté en détail les différentes phases de réalisation de notre système de détection des crises et de distinction entre les crises épileptiques et les CNEP's. Nous avons débuté ce chapitre par une motivation suivie d'une présentation générale de système proposé. Ensuite, nous avons entamé la description technique et détaillée des différentes phases de notre système, où nous avons parlé sur le prétraitement du signal EGG extrait depuis un canal unique avec le filtre Butterworth et le DWT, l'extraction des caractéristiques et la classification en utilisant l'ApEn et le T-test respectivement. Le chapitre suivant, sera consacré à l'évaluation de performances de notre système.

CHAPITRE 4

SIMULATION ET ÉVALUATION DE PERFORMANCES

4.1 Introduction

Dans notre travail, nous sommes assignés un objectif de détection des crises épileptiques et la distinction des crises psychogène non-épileptiques (CNEP). Dans le chapitre précédent, nous avons présenté notre contribution pour atteindre l'objectif tracé, ainsi que le fonctionnement général de notre système. Comme dernière partie de notre mémoire et dans ce chapitre, nous commençons par présenter le protocole expérimental et la description de l'ensemble de données EEG utilisé pour les simulations ainsi que l'environnement et les paramètres de simulation considérée pour l'évaluation de performances du système proposé. Ensuite, afin de valider les méthodes utilisées et citées au chapitre 3, nous présentons les résultats de simulations des différents cas de l'ensemble de données utilisé.

4.2 Protocole expérimental et description de l'ensemble de données

L'ensemble de données que nous avons utilisé dans notre travail a été recueilli auprès du Centre régional d'épilepsie, Grand hôpital métropolitain de Reggio Calabre, Université de Catanzaro, Italie [61]. Dans notre travail, nous avons analysé 15 enregistrements de séries chronologiques d'EEG, cinq (5) enregistrements de cinq (5) sujets sains (trois hommes, deux femmes), cinq (5) enregistrements de cinq (5) patients avec épilepsie (deux hommes, trois femmes) et cinq (5) enregistrements de cinq (5) patients avec CNEP (deux hommes, trois femmes). Les patients ont été recrutés successivement parmi ceux référés au centre susmentionné; les enregistrements d'EEG avec trop d'artefacts ont été exclus. Des témoins sains ont également été recrutés prospectivement au cours de la même période parmi les soignants ou le personnel soignant des patients. Le diagnostic CNEP a été établi sur la base d'un épisode typique enregistré pendant l'EEG-vidéo, survenant spontanément ou en réponse à des manœuvres de suggestion, l'EEG ne montrant ni activité ictal concomitante ni activité post-ictal (EEG diagnostique). Les témoins sains ne souffraient d'aucun trouble neurologique et avaient un examen neurologique normal. Aucun des 15 sujets ne prenait des médicaments chroniques ou n'avait reçu de médicaments au cours des 24 heures précédant l'EEG. L'étude a été menée à la suite de la Déclaration d'Helsinki et a été officiellement approuvée par le comité d'éthique de la recherche médicale local [61].

4.3 Acquisition EEG

Les enregistrements EEG que nous avons utilisés dans notre travail ont été réalisés dans une salle mal éclairée à l'aide de 19 électrodes de surface Ag/AgCl placées selon le système international 10/20. Ces EEG ont été enregistrés 10 à 20 minutes avant l'EEG diagnostique. Les enregistrements ont été réalisés avec un système Micromed Brain Quick (Micromed SpA, Mogliano Veneto (TV), Italie) avec un taux d'échantillonnage de 512 Hz, filtre passe-haut à 0,5 Hz, filtre passe-bas à 70 Hz, plus un filtre à encoche de 50 Hz avec une pente de 12 dB/Oct à 512 bit/seconde. Tous les signaux EEG ont été enregistrés à l'aide d'un montage avec les canaux Fp1, Fp2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T3, T4, T5, T6, Fz, Cz et Pz et la référence dans G2 (situé entre les électrodes Fz et Cz). Toutes les valeurs d'impédance cutanée de l'électrode ont été maintenues sous 5 K. Les données de l'EEG ont été enregistrées au repos pendant 20 minutes [61].

Les participants étaient confortablement assis dans une chaise inclinable et les yeux fermés. Les techniciens veillaient à ce que les sujets ne somnolent pas. À la fin, les EEG ont été réduits à 256 Hz, segmentés en enregistrements de 20 minutes et stockés sur un disque optique au format ASCII (American Standard Code for Information Interchange) pour traitement ultérieur. Les enregistrements EEG ont ensuite été examinés manuellement par des experts afin d'annuler les segments affectés par les artefacts [61]. Afin d'utiliser cet ensemble de données EEG dans le cadre de notre système, nous avons extraits 300 segments classés dans trois (3) ensembles A, B et C avec A contenant 100 segments des sujets sains, B contenant 100 segments des patients épileptiques et C contenant 100 segments des patients CNEP's. Les segments de chacun de ces ensembles sont d'un canal unique (A : 1 à 50 canal G2-O1 et 51 à 100 canal G2-O2, B : 1 à 50 canal G2-C4 et 51 à 100 canal G2-C3, C : 1 à 50 canal G2-Fp1 et 51 à 100 canal G2-Fp2) et chaque segment a une durée de 16 sec et il est échantillonné par 256 Hz et stockés au format (.mat).

4.4 Environnement de simulation

4.4.1 Paramètres de simulation

Pour la réalisation de notre système, nous avons opté à faire le développement sous Python qui est l'un des langages les plus utilisés dans le domaine d'analyse de données. Comme première étape, nous avons fait fonction de filtre Butterworth en utilisant les classes "butter" et "sosfilt" de la bibliothèque "scipy.signal". Ensuite, à l'aide de la méthode "wavedec(signal)" de package "pywt", nous avons procédé à la transformée en ondelettes discrète (DWT) pour l'extraction des cinq (5) sous-bandes de fréquence EEG afin de les utiliser pour calculer les valeurs d'approximation entropies (ApEn). Ce calcul est réalisé avec la fonction "ApEn(x, m,r, tau)" de package "EntropyHub". Enfin, à partir des valeurs ApEn's de chaque groupe, nous avons utilisé la fonction "ttest_ind(grp1,grp2)" pour estimer la probabilité de séparation de chaque deux groupes de données afin de classifier les différents types de crises. C'est ainsi fut développé notre système de détection et de distinction des crises épileptiques et CNEP's, simulé sous l'environnement Visual Studio Code (VS code 1.71.2) avec un ordinateur ayant un processeur INTEL I5-7200U 2.5GHz avec une VRAM GeForce GTX950M et une mémoire vive de 6Go (DDR4).

4.4.2 Résultats et Discussion

Après le pré-traitement et la décomposition de chaque segments EEG en sous-band fréquences, les valeurs ApEn's de chacun de ces segments et leurs sous-band ont été calculés et se sont représentés dans les figures 4.1, 4.2, 4.3 et 4.4 .

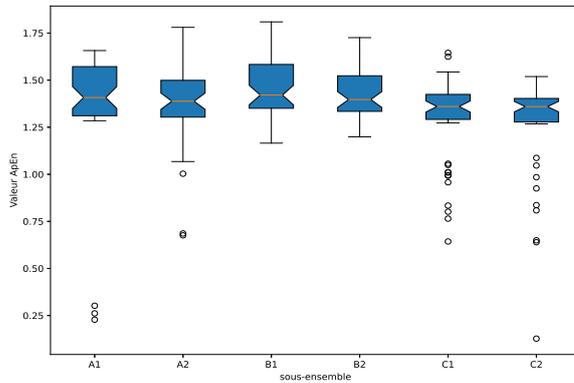


FIGURE 4.1 – Les valeurs ApEn de signal EEG de tous les segments de chaque sous-ensembles.

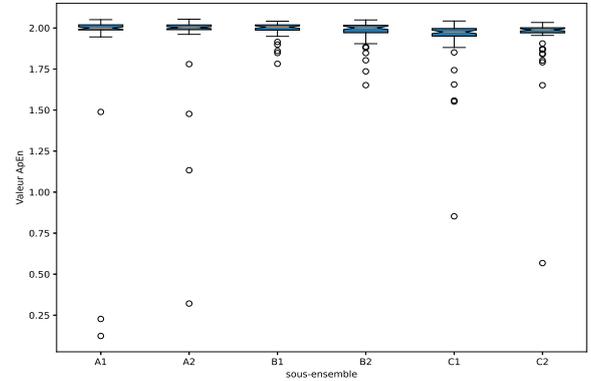


FIGURE 4.2 – Les valeurs ApEn de la sous-bande Bêta de tous les segments de chaque sous-ensembles.

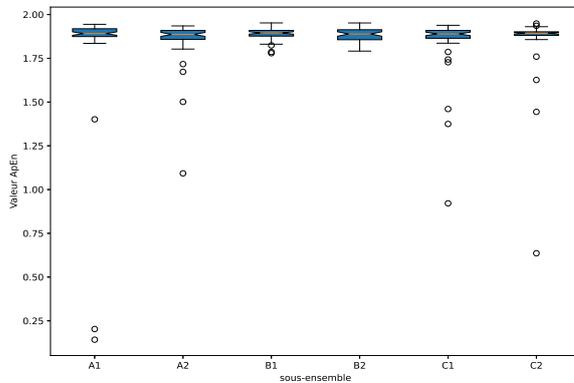


FIGURE 4.3 – Les valeurs ApEn de la sous-bande Alpha de tous les segments de chaque sous-ensembles.

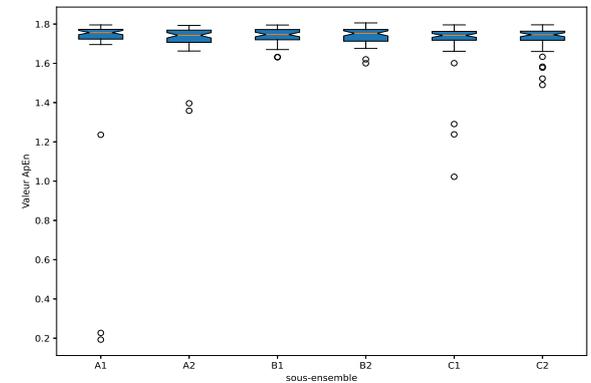


FIGURE 4.4 – Les valeurs ApEn de la sous-bande Thêta de tous les segments de chaque sous-ensembles.

Ensuite, les moyennes et les variances des valeurs ApEn ont été calculées pour chaque sous-ensembles et sont présentées dans la table 4.1 et la table 4.2 respectivement.

	EEG	Bêta	Alpha	Thêta
A1	1.3676	1.9200	1.8188	1.6790
A2	1.3792	1.9389	1.8537	1.8537
B1	1.4767	1.9904	1.8890	1.7411
B2	1.4417	1.9744	1.8846	1.74035
C1	1.3026	1.9257	1.8452	1.7041
C2	1.2672	1.9354	1.8534	1.7258

TABLE 4.1 – La moyenne des valeurs ApEn pour chaque sous-ensemble de segments EEG et leurs sous-bandes.

	EEG	Bêta	Alpha	Thêta
A1	0.3047	0.3641	0.3441	0.3095
A2	0.2017	0.2730	0.1302	0.0796
B1	0.1759	0.0500	0.0350	0.0392
B2	0.1440	0.0775	0.0398	0.0422
C1	0.2264	0.1847	0.1659	0.1386
C2	0.2585	0.2083	0.1901	0.0642

TABLE 4.2 – L'écartype des valeurs ApEn pour chaque sous-ensemble de segments EEG et leurs sous-bandes.

Avec ces paramètres, nous calculons le t-score et le degré de liberté (DF) pour tous les segments EEG et leurs sous-bandes. Grâce à ces valeurs, nous totalisons les P-valeurs du t-test (recto-verso). Les résultats de P-valeur et la probabilité de séparation de chaque paire de sous-ensemble sont présentés dans la table 4.3. Les problèmes suivants ont été abordés pour distinguer les sous-ensembles de données à l'aide de l'analyse statistique :

- Problème-1 : A1 versus B1. | Problème-7 : A1 versus B2.
- Problème-2 : A1 versus C1. | Problème-8 : A2 versus B1
- Problème-3 : B1 versus C1. | Problème-9 : A1 versus C2
- Problème-4 : A2 versus B2. | Problème-10 : A2 versus C1
- Problème-5 : A2 versus C2. | Problème-11 : B1 versus C2
- Problème-6 : B2 versus C2. | Problème-12 : B2 versus C1

	A1-B1	A1-C1	B1-C1	A2-B2	A2-C2	B2-C2	A1-B2	A2-B1	A1-C2	A2-C1	B1-C2	B1-C2
EEG	0.0323 (96.76%)	0.2335 (76.64%)	0.000048 (99.99%)	0.0807 (91.92%)	0.0187 (98.12%)	0.000077 (99.99%)	0.1268 (87.31%)	0.0123 (98.76%)	0.0819 (91.80%)	0.0799 (92.00%)	0.000088 (99.99%)	0.00045 (99.95%)
BETA	0.1827 (81.72%)	0.9225 (7.74%)	0.0197 (98.02)	0.3841 (61.58%)	0.9433 (5.66%)	0.2230 (77.69%)	0.3086 (69.13%)	0.1972 (80.27%)	0.7966 (20.33%)	0.7782 (22.17%)	0.0755 (92.44%)	0.0917 (90.52%)
ALPHA	0.1587 (84.12%)	0.6294 (37.05%)	0.0740 (92.59%)	0.1153 (88.46%)	0.9922 (0.77%)	0.2633 (73.66%)	0.1867 (81.32%)	0.0701 (92.98%)	0.5395 (46.04%)	0.7789 (22.10%)	0.2006 (79.93%)	0.1094 (89.05%)
THETA	0.1666 (83.33%)	0.6046 (39.53%)	0.0757 (92.42%)	0.2202 (77.97%)	0.9227 (7.27%)	0.1911 (80.88%)	0.1723 (82.76%)	0.1925 (80.74%)	0.3017 (69.82%)	0.3761 (62.38%)	0.1604 (83.95%)	0.0836 (91.63%)

TABLE 4.3 – Le P-valeur et la probabilité de séparation de chaque paire de sous-ensemble de segments EEG et leurs sous-bandes.

La probabilité de séparation pour la plupart des ensembles qui font l'objectif de notre système (A-B et B-C) est si bon et comme nous le voyons dans la table 4.3 et la plupart des paramètres extraits montrent une différence considérable. Nous avons comparé toutes les paires de sous-ensembles que nous intéresse et nous avons remarqué que la probabilité de séparation entre les différents états montre que le choix de canal pour chaque état (sain, épileptique et CNEP) était important dans notre cas. Pour A1-B1, nous avons une probabilité de séparation de 96.76% pour le signal EEG, 81.72% pour la sous-bande Bêta, 84.12% pour la sous-bande Alpha et 83.33% pour la sous-bande Thêta. Pour B1-C1, nous avons une probabilité de séparation très remarquable pour le signal EEG estimée de 99.99%, 98.02% pour la sous-bande Bêta, 92.59% pour la sous-bande Alpha et 92.42% pour la sous-bande Thêta. Pour A2-B2, nous avons une probabilité de séparation de 91.92% pour le signal EEG et 61.58%, 88.46% et 77.97% respectivement pour la sous-bande Bêta, Alpha et Thêta. Pour B2-C2, nous avons une bonne probabilité de séparation pour le signal EEG de 99.99%, sauf que pour le reste nous avons une probabilité de séparation moins bonne de 77.69%, 73.66% et 80.88% respectivement pour la sous-bande Bêta, Alpha et Thêta. Pour A1-B2, nous avons une probabilité de séparation moins bonne de 87.31%, 69.13%, 81.32% et 82.76% respectivement pour le signal EEG, sous-bande Bêta, Alpha et Thêta. En comparant ces dernières valeurs avec ceux de A2-B1, nous avons une probabilité de séparation assez bonne pour le signal EEG 98.76% et 80.27% pour la sous-bande Bêta, 92.98% pour la sous-bande Alpha et 80.74% pour la sous-bande Thêta. La comparaison de B1 avec C2 indique une bonne probabilité de séparation de 99,99% pour l'EEG, 92.44% pour la sous-bande Bêta. Les sous-bandes Alpha et Thêta montrent une probabilité de séparation moins bonne 79.93% et 83.95% respectivement. La probabilité de séparation pour B1-C2 dans le signal EEG montre une valeur presque idéale (99.95%), dans les sous-bandes Bêta, Alpha et Thêta sont 90.52%, 89.05% et 91.63%. Concernant les paires A-C, toutes les combinaisons ont donné des probabilités de séparation assez bonne dans le signal EEG et très mauvaises dans toutes les sous-bandes de fréquence.

À partir des résultats de notre proposition, nous pouvons déduire la meilleure combinaison de canaux à utiliser pour la détection et la distinction des crises épileptiques et des CNEP's. Dans notre cas, nous remarquons que la combinaison de canal qui a donné les meilleurs résultats pour la détection est (A:G2-O2,B:G2-C4) et pour la distinction est (B:G2-C4, C:G2-Fp1). Ces résultats obtenus ont montré que l'entropie approximative combinée avec l'analyse statistique peut être utile et applicable pour la détection et la distinction automatique des crises épileptiques et CNEP's.

4.5 Conclusion

Pour conclure ce travail, nous avons commencé dans ce chapitre par présenter l'ensemble de données EEG à utiliser dans notre système. Ensuite, nous avons décrit l'ensemble de paramètres de simulations qui ont interféré à la réalisation de notre système. Puis, nous avons entamé la présentation des différents paramètres à utiliser dans le cadre de réalisation de notre système, tel que les moyennes et l'écartypes des valeurs ApEn de chaque sous-ensemble de données. A la fin, nous avons présenté les P-valeurs et les probabilités de séparations entre chaque paire de sous-ensembles et leurs significations.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

Ce mémoire n'avait pas seulement l'objectif de créer un modèle de détection de distinction automatique des crises épileptiques et des CNEP's, mais aussi, d'apporter une contribution aux travaux déjà menés dans ce cadre. Au cours du premier chapitre, nous avons présenté les principales notions de neurophysiologie et d'électroencéphalographie dans le cas de l'épilepsie et de CNEP. Après avoir présenté les critères d'évaluation des systèmes existants, dans le chapitre 2, nous avons cités certains travaux sur la détection des crises d'épilepsie et sur la distinction des crises épileptiques et CNEP's, que nous avons étudiés et comparés grâce aux critères d'évaluation déjà mentionnés. Pour marquer notre contribution dans un système de détection et de distinction automatique de crise nous focalisons sur l'étape d'extraction de caractéristiques d'un signal EEG, mais nous avons présenté dans le chapitre 3, le filtre Butterworth qui a été utilisé pour éliminer les bruits, afin d'utiliser un signal EEG filtré. De plus, ce système utilise la décomposition on ondelette discrète (DWT) afin de décomposer le signal EEG en sous-bandes et de sélectionner seulement les bande Bêta, Alpha et Thêta et éliminer les artefacts dans le but de minimiser le coût de calculs et accélérer l'exécution en temps réel. Après cela, nous avons entamé l'extraction des caractéristiques en utilisant l'entropie approximative (ApEn) sur les segments EEG de chaque sous-ensemble et leurs sous-bandes. Puis, nous avons utilisé le t-test et calculé les P-valeurs et les probabilités de séparation entre les différents sous-ensembles. Le chapitre 4 a été consacré à la mise en oeuvre de l'approche proposée, la présentation, la discussion et l'interprétation des résultats obtenus. En effet, les résultats de P-valeurs nous a aidé même à déduire la meilleure combinaison de canaux à utiliser pour notre cas.

Pour conclure ce document, nous présentons des perspectives qui feront l'objet de nos futures recherches. À commencer d'abord par la réalisation d'une application mobile pour notre système de détection et le connecter à des casques d'EEG plus portables et confortables qui seront capable de capter le signal EEG dans les pires des cas afin de le mettre en uvre. Ensuite, réaliser une application multiplateforme pour la distinction entre les crises épileptiques et les crises psychogène non-épileptique en utilisant les signaux EEG afin d'accélérer le diagnostic des CNEP's. Nous espérons aussi faire des améliorations sur les performances de notre système de détection et de distinction, afin qu'il soit bénéfique à toutes personnes de toutes âges touchés par ces troubles.

BIBLIOGRAPHIE

- [1] Epilepsie chez l'adulte. <https://www.infosante.be/guides/epilepsie-chez-l-adulte>, (Consulté le 01 février 2022).
- [2] Crises psychogènes non épileptiques. <https://sante.vip/crises-psychogenes-non-epileptiques/>, (consulté le 15 février 2022).
- [3] Transformée en ondelettes. https://www.maxisciences.com/epilepsie/epilepsie-symptomes-traitement-que-faire-en-cas-de-crise-d-epilepsie_art36391.html, (Consulté le 19 mai 2022).
- [4] Cnep, les crises non-Épileptiques psychogÈnes. <https://www.chru-strasbourg.fr/cnep-les-crises-non-epileptiques-psychogenes/>, (consulté le 2 mars 2022).
- [5] 10-20 système de placement des électrodes. <https://faculty.washington.edu/chudler/1020.html>, (Consulté le 20 février 2022).
- [6] Montage 10 20. https://stringfixer.com/fr/10-20_system_%28EEG%29?fbclid=IwAR2qyvIz5zh3hFpRqvCvZaQm2Kq91UNFefJ7K49HATrCGKA_Mzygvs8kFw, (Consulté le 21 février 2022).
- [7] Video egg. <https://neurosoft.com/en/catalog/eeg/1677>, (Consulté le 21 février 2022).
- [8] Vidéoelectroencéphalogramme(eeg). <https://www.fo-rothschild.fr/patient/actes-medicaux/videoelectroencephalogramme-eeg>, (consulté le 22 février 2022).
- [9] fiche technique sur l'eeg. <https://neurologies.fr/fiche-technique-sur-leeg/>, (consulté le 23 février 2022).
- [10] Egg. <https://medlatec.vn/tin-tuc/dien-nao-do-la-gi-va-tat-tan-tat-nhung-kien-thuc>, (Consulté le 23 février 2022).
- [11] Epilepsie : symptômes, traitement, que faire en cas de crise d'épilepsie? <http://gwyddion.net/documentation/user-guide-fr/wavelet-transform.html>, (Consulté le 28 janvier 2022).
- [12] Reconnaître la crise d'épilepsie. <https://www.passeportsante.net/fr/Maux/Problemes/Fiche.aspx?doc=epilepsie-pm-symptomes-de-l-epilepsie>, (Consulté le 2 février 2022).
- [13] Anatomie des crises épileptiques. <https://www.ottawahospital.on.ca/fr/services-cliniques/deptpgrmcs/programmes/epilepsie/quest-ce-que-lepilepsie/>, (Consulté le 29 janvier 2022).
- [14] Comprendre l'Épilepsie. <https://www.fondation-epilepsie.fr/comprendre-epilepsie/causes/>, (Consulté le 31 janvier 2022).

- [15] Quelles sont les causes d'une crise d'épilepsie. <https://www.crise-epilepsie.com/causes/>, (Consulté le 31 janvier 2022).
- [16] Les types de crises épileptiques. <https://amelioresetasante.com/les-types-de-crisis-epileptiques/>, (Consulté le 7 février 2022).
- [17] U Rajendra Acharya, Yuki Hagiwara, and Hojjat Adeli. Automated seizure prediction. *Epilepsy & Behavior*, 88:251–261, 2018.
- [18] Hojjat Adeli, Ziqin Zhou, and Nahid Dadmehr. Analysis of eeg records in an epileptic patient using wavelet transform. *Journal of neuroscience methods*, 123(1):69–87, 2003.
- [19] Turkey Alotaiby, Fathi E Abd El-Samie, Saleh A Alshebeili, and Ishtiaq Ahmad. A review of channel selection algorithms for eeg signal processing. *EURASIP Journal on Advances in Signal Processing*, 2015(1):1–21, 2015.
- [20] N. Bengamra. La prise en charge de l'épilepsie. (consulté le 1 mars 2022).
- [21] Nor-Elhouda BOUZIANE and Fatima-Zouhra BAIDA. Analyse des signaux eeg par ondelettes.
- [22] Vallabh Budhkar, Sanskruta Dhotre, and Saurav Mitra. Analysis of epilepsy using approximate entropy algorithm. 2019.
- [23] W. El Hage C. Hingray. La lettre du psychiatre. (consulté le 17 février 2022).
- [24] Matthieu Caparos. *Analyse automatique des crises d'épilepsie du lobe temporal à partir des EEG de surface*. PhD thesis, Institut National Polytechnique de Lorraine, 2006.
- [25] Agustina Garcés Correa and Eric Laciár Leber. An automatic detector of drowsiness based on spectral analysis and wavelet decomposition of eeg records. In *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*, pages 1405–1408. IEEE, 2010.
- [26] Ozlem Karabiber Cura, Gülce Cosku Yilmaz, Hatice Sabiha Türe, and Aydin Akan. Classification of psychogenic non-epileptic seizures using synchrosqueezing transform of eeg signals. In *2021 29th European Signal Processing Conference (EUSIPCO)*, pages 1172–1176. IEEE, 2021.
- [27] Hisham Daoud and Magdy A Bayoumi. Efficient epileptic seizure prediction based on deep learning. *IEEE transactions on biomedical circuits and systems*, 13(5):804–813, 2019.
- [28] Hisham Daoud, Phillip Williams, and Magdy Bayoumi. Iot based efficient epileptic seizure prediction system using deep learning. In *2020 IEEE 6th World Forum on Internet of Things (WF-IoT)*, pages 1–6. IEEE, 2020.
- [29] Anne-Catherine Dunand and Pierre Jallon. Les activités paroxystiques pseudo-périodiques en électroencéphalographie. *Neurophysiologie Clinique/Clinical Neurophysiology*, 32(1):2–37, 2002.
- [30] Ali Emami, Naoto Kunii, Takeshi Matsuo, Takashi Shinozaki, Kensuke Kawai, and Hirokazu Takahashi. Seizure detection by convolutional neural network-based analysis of scalp electroencephalography plot images. *NeuroImage : Clinical*, 22:101684, 2019.
- [31] Justine Ferrari. Crise d'épilepsie : symptômes, causes, traitements. <https://www.medisite.fr/epilepsie-crise-depilepsie-symptomes-causes-traitements.5542073.732921.html>, (Consulté le 5 février janvier 2022).
- [32] P Gelisse, P Thomas, N Engrand, V Navarro, and A Crespel. Électroencéphalographie dans les états de mal épileptiques : glossaire, protocole et interprétation. *Revue neurologique*, 165(4):398–403, 2009.
- [33] Paulette Marie Gillig. Psychogenic nonepileptic seizures. *US National Library of Medicine National Institutes of Health*, (consulté le 31 2022 février).

- [34] Coraline Hingray. Les cnep. <https://www.lareponsesdupsy.info/cnep>, (consulté le 26 février 2022).
- [35] Edouard Hirsch. Epilepsie chez l'adulte. <https://www.deuxiemeavis.fr/pathologie/epilepsie-chez-l-adulte>, (Consulté le 01 février 2022).
- [36] Mahamat Ali Issaka. *Analyse des signaux EEG pour la détection automatique des crises d'épilepsie par des méthodes paramétriques*. PhD thesis, Université Gaston Berger, 2016.
- [37] Sairamya Nanjappan Jothiraj, Thomas George Selvaraj, Balakrishnan Ramasamy, Narain Ponraj Deivendran, and MSP Subathra. Classification of eeg signals for detection of epileptic seizure activities based on feature extraction from brain maps using image processing algorithms. *IET Image Processing*, 12(12):2153–2162, 2018.
- [38] Ibtissem Khouaja. *Imagerie cérébrale : Traitement et Modélisation Embarqués*. PhD thesis, Paris Est, 2017.
- [39] Shitanshu Kusmakar, Chandan K Karmakar, Bernard Yan, Terence J OBrien, Marimuthu Palaniswami, and Ramanathan Muthuganapathy. Improved detection and classification of convulsive epileptic and psychogenic non-epileptic seizures using flda and bayesian inference. In *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 3402–3405. IEEE, 2018.
- [40] LEIL1000-II. Anatomie des crises épileptiques. <https://www.rapport-gratuit.com/anatomie-des-cris-es-epileptiques/>, (Consulé le 31 janvier 2022).
- [41] Saeed Mian Qaisar and Abdulhamit Subasi. Effective epileptic seizure detection based on the event-driven processing and machine learning for mobile healthcare. *Journal of Ambient Intelligence and Humanized Computing*, pages 1–13, 2020.
- [42] Luck S. J. Teplan M. ollura, T. F. Eeg Électroencéphalographie. <http://www.cinq.ulaval.ca/EEG>, (Consulé le 12 février 2022).
- [43] Mohammad Zavid Parvez and Manoranjan Paul. Epileptic seizure detection by analyzing eeg signals using different transformation techniques. *Neurocomputing*, 145:190–200, 2014.
- [44] rapport gratuit. Epilepsie, eeg et l'état de l'art. <https://www.rapport-gratuit.com/epilepsie-eeg-et-letat-de-lart/>, (Consulté le 15 février 2022).
- [45] Khansa Rasheed, Adnan Qayyum, Junaid Qadir, Shobi Sivathamboo, Patrick Kwan, Levin Kuhlmann, Terence OBrien, and Adeel Razi. Machine learning for predicting epileptic seizures using eeg signals : A review. *IEEE Reviews in Biomedical Engineering*, 14:139–155, 2020.
- [46] Kh Rezaee, E Azizi, and J Haddadnia. Optimized seizure detection algorithm : a fast approach for onset of epileptic in eeg signals using gt discriminant analysis and k-nn classifier. *Journal of biomedical physics & engineering*, 6(2):81, 2016.
- [47] Tanbin Islam Rohan, Md Salah Uddin Yusuf, Monira Islam, and Shidhartho Roy. Efficient approach to detect epileptic seizure using machine learning models for modern healthcare system. In *2020 IEEE Region 10 Symposium (TENSYP)*, pages 1783–1786. IEEE, 2020.
- [48] Rebeca Romo-Vázquez. *Contribution à la détection et à l'analyse des signaux EEG épileptiques : débruitage et séparation de sources*. PhD thesis, Institut National Polytechnique de Lorraine, 2010.
- [49] Rebeca Romo-Vázquez. *Contribution à la détection et à l'analyse des signaux EEG épileptiques : débruitage et séparation de sources*. PhD thesis, Institut National Polytechnique de Lorraine, 2010.

- [50] Ricardo Antonio SALIDO RUIZ. Spécialité automatique, traitement du signal et des images, génie informatique. http://docnum.univ-lorraine.fr/public/DDOC_T_2012_0403_SALIDO_RUIZ.pdf, consulté le 25 février 2022.
- [51] Sameer Ranjan Sahu, Rama Krishna Sai Subrahmanyam Gorthi, and Subrahmanyam Gorthi. Epileptic seizure detection and anticipation using deep learning with ordered encoding of spectrogram features. In *2020 28th European Signal Processing Conference (EUSIPCO)*, pages 1065–1069. IEEE, 2021.
- [52] CHU SAINTE-JUSTINE. Types de crises. <https://www.chusj.org/fr/soins-services/E/Epilepsie/Parlons-d-epilepsie/Types-de-crisis>, (Consulté le 9 février 2022).
- [53] Inggi Saputro, Nita Maryati, Siti Solihati, Inung Wijayanto, Sugondo Hadiyoso, and Raditiana Patmasari. Seizure type classification on eeg signal using support vector machine. *Journal of Physics : Conference Series*, 1201:012065, 05 2019.
- [54] Marzieh Savadkoohi, Timothy Oladunni, and Lara Thompson. A machine learning approach to epileptic seizure prediction using electroencephalogram (eeg) signal. *Biocybernetics and Biomedical Engineering*, 40(3):1328–1341, 2020.
- [55] Sellam. *Electroencephalographie*. PhD thesis, Faculté médecine d’Oran.
- [56] Assya Snoussi. *Apport des techniques de traitement et de classification pour l’exploitation des signaux délectroencéphalogramme (EEG)*. PhD thesis, usthb, 2015.
- [57] MNJoseph I. Sirven MD Steven C. Schachter, MDPatty Osborne Shafer RN. Eeg vidéo. <https://www.epilepsy.com/learn/diagnosis/eeg/video-eeg>, consulté le 22 février 2022.
- [58] Abdulhamit Subasi and M Ismail Gursoy. Eeg signal classification using pca, ica, lda and support vector machines. *Expert systems with applications*, 37(12):8659–8666, 2010.
- [59] Charlotte Tourmente. L’épilepsie, une maladie qui survient aussi à l’âge adulte. <https://www.allodocteurs.fr/maladies-cerveau-et-neurologie-epilepsie-lepilepsie>, (Consulté le 01 février 2022).
- [60] Nhan Duy Truong, Anh Duy Nguyen, Levin Kuhlmann, Mohammad Reza Bonyadi, Jiawei Yang, and Omid Kavehei. A generalised seizure prediction with convolutional neural networks for intracranial and scalp electroencephalogram data analysis. *arXiv preprint arXiv:1707.01976*, 2017.
- [61] Giuseppe Varone, Sara Gasparini, Edoardo Ferlazzo, Michele Ascoli, Giovanbattista Gaspare Tripodi, Chiara Zucco, Barbara Calabrese, Mario Cannataro, and Umberto Aguglia. A comprehensive machine-learning-based software pipeline to classify eeg signals : A case study on pnes vs. control subjects. *Sensors*, 20(4):1235, 2020.
- [62] Hamed Vavadi, Ahmad Ayatollahi, Ahmad Mirzaei, et al. A wavelet-approximate entropy method for epileptic activity detection from eeg and its sub-bands. *Journal of Biomedical Science and Engineering*, 3(12):1182, 2010.

RÉSUMÉ

L'épilepsie est un trouble cérébral courant avec environ 1 % de la population mondiale souffrant de ce trouble. Environ 30 % des patients référés pour une épilepsie résistante aux médicaments sont en réalité touchés par des crises psychogènes non épileptiques (CNEP). Le signal EEG est la somme des activités électriques du cerveau et également utilisé dans la détection des crises d'épilepsie. Dans le cas des CNEP's, le diagnostic est fait à l'aide d'enregistrements vidéo-EEG à long terme et d'un historique détaillé du patient. Étant donné que cette méthode est coûteuse, il est très important de distinguer les signaux CNEP des signaux normaux de crise en utilisant uniquement des enregistrements EEG. Dans ce mémoire, une méthode d'entropie approximative en ondelettes est appliquée pour la détection et la distinction des crises d'épilepsie et des CNEP's à partir des signaux EEG. Tout d'abord, la transformation discrète en ondelettes (DWT) est appliquée pour décomposer le signal EEG en cinq sous-bandes physiologiques. Nous nous concentrons uniquement sur les ondes alpha, thêta et bêta car ce sont les seules ondes qui contiennent des informations sur les crises. Ensuite, l'entropie approximative (ApEn) qui est une mesure chaotique et peut être utilisée dans la complexité de l'estimation des séries temporelles appliquée à l'EEG et à ses sous-bandes. Nous avons utilisé cette méthode pour séparer les signaux EEG de trois groupes (sains, épileptiques et CNEP), chaque groupe ayant deux combinaisons de canaux uniques différentes. Pour évaluer la capacité de séparation du système proposé, nous avons opté pour l'analyse statistique T-test. Pour les meilleures combinaisons de canaux, nous avons une probabilité de séparation entre les crises épileptiques et les CNEP's de 99,99% pour le signal EEG et de 98,02% pour la sous-bande bêta, et une probabilité de séparation entre les crises épileptique et les sujets sains de 98,72 % pour signal EEG et 92,98%, 80,74% et 80,27% pour les sous-bandes alpha, thêta et bêta respectivement.

Mots clés : Crise épileptique, CNEP, EEG, DWT, Entropie approximative, T-test.

ABSTRACT

Epilepsy is a common brain disorder with approximately 1% of the world's population suffering from this disorder. About 30% of patients referred for drug-resistant epilepsy are actually affected by psychogenic non-epileptic seizures (PNES). The EEG signal is the sum of the electrical activities of the brain and also used in the detection of epileptic seizures. In the case of PNES, the diagnosis is made using long-term EEG-video recordings and a detailed patient history. Since this method is expensive, it is very important to distinguish PNES signals from normal seizure signals using only EEG recordings. In this manuscript, an approximate wavelet entropy method is applied for the detection and distinction of epileptic seizures and PNES from EEG signals. First, the Discrete Wavelet Transform (DWT) is applied to decompose the EEG signal into five physiological subbands. We focus only on alpha, theta and beta since these are the only waves that contain seizure information. Then, the approximate entropy (ApEn) which is a chaotic measure and can be used in the complexity of time series estimation applied to the EEG and its subbands. We used this method to separate EEG signals from three groups (healthy, epileptic, and CNEP) with each group having two different unique channel combinations. To evaluate the separation capacity of the proposed system, we opted for the statistical analysis T-test. For the best channel combinations, we have a probability of separation between epileptic seizures and PNES of 99.99% for the EEG signal and 98.02% for the beta sub-band, and a probability of separation between seizures and healthy subjects of 98.72% for EEG and 92.98%, 80.74% and 80.27% for alpha, theta and beta subbands respectively.

Keywords : Epileptic seizure, PNES, EEG, DWT, Approximate entropy, T-test.