

الجمهورية الجزائرية الديمقراطية الشعبية
REPUBLIC ALGERIENNE DEMOCRATIQUE ET POPULAIRE
وزارة

التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
جامعة أبو بكر بلكايد – تلمسان

Université Aboubakr Belkaïd– Tlemcen –
Faculté de TECHNOLOGIE



THESE

Présentée pour l'obtention du grade de DOCTORAT 3^{ème} Cycle

En : Génie biomédical

Spécialité : Instrumentation Biomédical

Par : Ghembaza Fayza

Sujet

Détection des pathologies cérébrales par analyse
temps–fréquence du signal Electroencéphalographique
(EEG)

Soutenue publiquement, le , devant le jury composé de :

M. HADJ SLIMANE ZineEddine
M. DJEBBARI Abdelghani
M. MESSADI Mahammed
M. MEGNAFI Hicham

Professeur Univ. Tlemcen
Professeur Univ. Tlemcen
Professeur Univ. Tlemcen
MCA ESSA, Univ. Tlemcen

Président
Directeur de thèse
Examineur
Examineur



DÉDICACES

A mon cher époux Lotfi

Tous les mots du monde ne sauraient exprimer la profonde gratitude que je te témoigne pour tous les efforts et les sacrifices que tu n'as jamais cessé de consentir pour mon instruction et mon bien-être.

C'est à travers tes encouragements que j'ai opté pour cette thèse de doctorat, et c'est à travers tes critiques que je me suis réalisée. J'espère avoir répondu aux espoirs que tu as fondés en moi.

Je te rends hommage par ce modeste travail en guise de ma reconnaissance éternelle et de mon infini amour.

Que Dieu tout puissant te garde et te procure santé, bonheur et longue vie et que tu demeures le flambeau illuminant le chemin de nos enfants.

A...

Mes adorables enfants...

Fatima Zohra, Mohammed et Yasser

Mon père...

Ma soeur...

Mes tantes...

Mes oncles...

Toute ma famille...

Mes beaux parents...

Toute ma belle famille...

Je dédicace ce modeste travail.

REMERCIEMENTS

"La réussite est de pouvoir aller d'échec en échec sans perdre son enthousiasme."

Ralph Waldo Emerson

Et si l'aventure de la thèse de doctorat est longue et semée d'embûches, elle amène à se découvrir soi-même, parce qu'une aventure ne se vit jamais seul.

Avant tout, je souhaite exprimer ma gratitude et ma reconnaissance à **Allah**, le Tout-Puissant et l'Unique digne d'adoration, pour tous les bienfaits qu'Il m'a accordés et pour m'avoir donné la force, la patience et le courage nécessaires pour réussir tout au long de mon parcours doctoral.

Je tiens ensuite à exprimer ma profonde gratitude envers mon directeur de thèse, **Pr Abdelghani DJEBBARI**, Professeur à l'université de Tlemcen et directeur du Laboratoire de recherche de génie biomédical (GBM) de m'avoir honoré par son encadrement, son soutien inestimable, son expertise et sa patience tout au long de ma recherche. Je tiens également à souligner l'importance de ses commentaires constructifs, qui ont permis d'améliorer significativement la qualité de ma thèse.

Je souhaite également remercier les membres du jury : le **Pr Zine Eddine HADJ SLIMANE**, Professeur à l'université de Tlemcen, le **Pr Mahammed MESSADI** Professeur à l'université de Tlemcen, ainsi que le **Dr Hicham MEGNAFI** Maître de conférence à l'École Supérieure de Sciences et de Technologies appliquées (ESSAT) à Tlemcen, pour leur temps et leur engagement dans l'évaluation de ce travail. Leurs commentaires et leurs suggestions ont été d'une grande aide pour améliorer mon travail.

Je tiens également adresser un remerciement particulier à **Mme Boublenza Lamia** pour son précieux soutien, ses conseils éclairés et l'aide qu'elle m'a apportée. Je souhaite également remercier ma collègue **Hasnaoui lyna** pour son aide, son partage de connaissances et son soutien tout au long de mon parcours.

Enfin, je voudrais adresser mes remerciements les plus sincères à tous ceux qui ont contribué de près ou de loin, à leurs manières, à la concrétisation de ce travail et qui m'ont apporté leur soutien et leur encouragement tout au long de ma thèse de doctorat. Je leur suis infiniment reconnaissant et leur témoigne mes sincères remerciements.

Ghembaza Fayza

RÉSUMÉ

L'épilepsie est une neuropathologie chronique, caractérisée par des manifestations cliniques paroxystiques transitoires provenant d'une décharge anormale et excessive d'une population neuronale. L'électroencéphalographie (EEG) est la modalité de référence d'exploration cérébrale pour la détection et le diagnostic de l'activité épileptiforme, il permet d'évaluer l'activité bioélectrique cérébrale par le biais d'un ensemble d'électrodes placées sur le cuir chevelu. D'autre part, le suivi des patients présentant un risque de crise d'épilepsie est essentiel pour garantir un traitement optimal et prévenir les complications des crises ultérieures. Ainsi, la prédiction des crises permet aux patients de recevoir une alerte précoce et d'agir efficacement par le biais de médicaments ou d'autres mesures préventives. Le cadre scientifique de cette thèse se concentre sur le développement de nouvelles approches de détection et de prédiction de l'occurrence d'une crise d'épilepsie et de localiser les générateurs corticaux continus par le traitement des signaux EEG. Les approches proposées reposent principalement sur des techniques de traitement du signal, notamment les distributions temps-fréquence quadratiques (QTFDs) tels que le spectrogramme (SP), la distribution de Pseudo Wigner-Ville lissée (SPWVD) et la distribution de Choi-Williams (CWD), ainsi que des nouvelles caractéristiques pertinentes extraites des signaux EEG et des approches de complexité non linéaire comme l'entropie de Renyi (RE) pour éventuellement les incorporer dans des classificateurs d'apprentissage supervisé performants pour la détection et la prédiction d'éventuelles anomalies paroxystiques critiques. L'algorithme proposé est évalué sur la base de données du Children's Hospital Boston (CHB MIT) ainsi que celle de la Temple University Hospital (TUH), produisant ainsi des résultats encourageants en termes de taux total de classification (Acc), de sensibilité (Sens) et de taux de fausses alarmes (FPR).

Mots-clés Électroencéphalogramme ; Épilepsie ; Détection ; Prédiction ; Distribution Choi-Williams ; Spectrogramme ; Distribution de Pseudo Wigner-Ville lissée ; Machine à vecteur de support ; K-voisins les plus proches

ABSTRACT

Epilepsy is a chronic neuropathology characterized by transient paroxysmal clinical manifestations resulting from abnormal and excessive discharge of a neuronal population. Electroencephalography (EEG) is the reference modality for exploring brain activity to detect and diagnose epileptiform activity, evaluating the brain's bioelectrical activity through a set of electrodes placed on the scalp. Additionally, monitoring patients at risk of epileptic seizures is essential to ensure optimal treatment and prevent complications from future seizures. Predicting seizures allows patients to receive early warning and take effective action through medication or other preventive measures. The scientific framework of this thesis focuses on developing novel approaches for detecting and predicting the onset of epileptic seizures and locate continuous cortical generators through EEG signal processing. The proposed approaches are primarily based on signal processing techniques, including quadratic time-frequency distributions (QTFDs) such as spectrograms (SP), Smoothed Pseudo Wigner-Ville Distribution (SPWVD) and Choi-Williams Distribution (CWD), as well as novel relevant feature extraction from EEG signals and nonlinear complexity approaches such as Renyi entropy (RE), potentially incorporated into high-performing supervised learning classifiers for detecting and predicting potential critical paroxysmal anomalies. The proposed algorithm is evaluated using the Children's Hospital Boston (CHB MIT) and the Temple University Hospital (TUH) datasets, yielding encouraging results in terms of total classification accuracy (Acc), sensitivity (Sens) and false alarm rates (FPR).

Keywords : Electroencephalogram; Epilepsy; Detection; Prediction; Choi-Williams distribution; Spectrogram; Pseudo Wigner-smoothed city distribution; Support vector machine; K-nearest neighbors

TABLE DES MATIÈRES

Dédicaces	1
Remerciements	2
Résumé	3
Abstract	4
Table des matières	5
Liste des figures	8
Liste des tableaux	11
Introduction générale	12
1 Contexte médicale de la thèse	15
1.1 Introduction	15
1.2 Système nerveux (SN)	15
1.3 le cerveau	16
1.3.1 Composition cellulaire du cerveau	17
1.3.2 L'activité électrique du cerveau	18
1.4 Enregistrements électrophysiologiques de l'activité cérébrale	18
1.4.1 L'électroencéphalographie (EEG)	18
1.4.2 Les activités rythmiques cérébrales	22
1.4.3 EEG pathologique	24
1.4.4 Les Perturbations de l'EEG	26
1.5 L'épilepsie	27
1.5.1 Définition	27
1.5.2 Les étiologies des crises d'épilepsie	27
1.5.3 Classification des crises épileptiques	28
1.6 Bases de données EEG	36
1.6.1 La base de données CHB-MIT	36
1.6.2 La base de données TUH	37
1.7 Conclusion	37
2 Méthodes d'analyse temps-fréquence	39
2.1 Introduction	39
2.2 Définition de la stationnarité	39
2.3 Les caractéristiques du signal EEG	40
2.3.1 Non-stationnarité et la stochastique du signal	40
2.3.2 Faible rapport signal/bruit (SNR)	40

2.3.3	Non-linéarité du signal EEG	40
2.4	Nécessite de l'analyse temps-fréquence	40
2.4.1	Analyse de Fourier	40
2.4.2	Limitations des représentations temporelle et spectrale	42
2.5	Représentations temps-fréquence	42
2.5.1	Les représentations temps-fréquence linéaire	42
2.5.2	Représentations temps-fréquence quadratiques	45
2.6	Conclusion	59
3	Classification des signaux EEG	61
3.1	Introduction	61
3.2	Extraction des caractéristiques	61
3.2.1	Caractéristiques temporelles	61
3.2.2	Caractéristiques fréquentielles de l'EEG	68
3.2.3	Caractéristiques temps-fréquence de l'EEG	69
3.3	Techniques de classification	73
3.3.1	Réseaux de neurones artificiels	74
3.3.2	Analyse discriminante linéaire (LDA)	76
3.3.3	Machines à vecteurs de support	76
3.3.4	Classifieur des k plus proches voisins	78
3.3.5	Classifieur Bayésien Naïf	81
3.3.6	Arbre de décision	81
3.4	Métriques de performances	82
3.5	Conclusion	85
4	Détection des crises d'épilepsie par analyse temps-fréquence du signal EEG	86
4.1	Introduction	86
4.2	Algorithmes de détection des crises épileptiques : État-de-l'art	86
4.3	Méthodologie	93
4.3.1	L'analyse temps fréquence des signaux EEG	94
4.3.2	Caractéristique temps-fréquence développée	96
4.3.3	Algorithme d'apprentissage	98
4.4	Nombre optimal de niveaux	101
4.5	Interprétation des résultats de classification	102
4.6	Comparaison des performances avec d'autres méthodes	107
4.7	Conclusion	109
5	Prédiction des crises épileptiques : Résultats de l'algorithme et interprétation.	112
5.1	Introduction	112
5.2	État de l'art des algorithmes de prédiction de crises épileptiques	112
5.3	Méthodologie	114
5.3.1	Distribution Pseudo Wigner-Ville lissée (SPWVD)	116
5.3.2	Canaux sélectionnés par l'entropie de Renyi étendue dans le domaine temps-fréquence	116
5.3.3	Extraction des caractéristiques	120
5.3.4	Résultats de la classification	121
5.4	Comparaison des performances avec d'autres méthodes	126
5.5	Conclusion	127
	Conclusion générale	128

Publications	130
Bibliographie	132

LISTE DES FIGURES

1.1	Différents parties du cerveau. (Image extraite du site http://martelsvt.e-monsite.com)	16
1.2	Schéma de la structure d'un neurone et ses principales composantes. [1]	17
1.3	Tracé original d'un patient présentant une activité normale.(Image extraite du site https://hal.science/tel-01504058/document)	19
1.4	Système de positionnement des électrodes 10–20. (a) Emplacement des électrodes (Image extraite du site https://theses.hal.science/tel-01720427/document), (b) Les différents part du cerveau. (Image extraite du site https://www.istockphoto.com)	20
1.5	Différents types de montage EEG	22
1.6	Les principaux rythmes cérébraux de l'EEG	24
1.7	Fuseaux Sigma et Complexe-K [2]	24
1.8	Démarche de la classification des épilepsies. (Image extraite du site https://www.cen-neurologie.fr)	28
1.9	Différents graphoéléments paroxystiques visibles à l'EEG.(Image extraite du site https://www.quizlet.com)	29
1.10	Épilepsie d'absence.(Image extraite du site https://www.cen-neurologie.fr)	30
1.11	Différentes phases de la crise tonico-clonique avec le signal EEG de chaque phase.(Image extraite du site https://www.unifr.ch)	31
1.12	Crises partielles, à l'endormissement ou au réveil, chez un enfant de 8 ans.(Image extraite du site https://www.realites-pediatriques.com)	32
1.13	Définition des crises généralisées et des crises focales.(Image extraite du site https://www.cen-neurologie.fr)	33
1.14	Épilepsie absences typique chez un enfant de 6 ans. (bouffée de pointes–ondes à 3 Hz).(Image extraite du site https://www.realites-pediatriques.com)	34
1.15	Brève bouffée de polypointes-ondes généralisées synchrones. (Image extraite du site https://www.cen-neurologie.fr)	34
1.16	Syndrome de West chez un nourrisson de 6 mois (a) Salve de spasmes au réveil (b) Hypsarythmie au sommeil (Image extraite du site https://www.realites-pediatriques.com)	35
2.1	Analyse temporel d'un signal non-stationnaire	41
2.2	STFT du signal EEG contenant la crise épileptique à différentes longueurs de fenêtre	44
2.3	Spectrogramme de signal EEG contenant la crise épileptique à différentes longueurs de fenêtre	48
2.4	WVD d'un signal EEG contenant la crise épileptique	50

2.5	Relation entre les représentations temps-fréquence	52
2.6	SPWVD d'un signal EEG contenant la crise épileptique	53
2.7	CWD d'un signal EEG épileptique à différents valeurs de paramètre σ	54
2.8	ZAM d'un signal EEG contenant la crise épileptique	55
2.9	BJ d'un signal EEG contenant la crise épileptique	56
2.10	RD d'un signal EEG contenant la crise épileptique	57
2.11	MHD d'un signal EEG contenant la crise épileptique	57
2.12	PD d'un signal EEG contenant la crise épileptique	58
3.1	Représentation TF originale vs représentations TF obtenues en ne conservant que les points dont le grand axe est parallèle à l'axe du temps ou à l'axe des fréquences.	73
3.2	Schéma d'un PMC avec mise en valeur d'un neurone.	76
3.3	Effet du coefficient de régularisation C [3]. A) petites valeurs de C; B) grandes valeurs de C	77
3.4	Comparaison d'hyperplans avec différents noyaux [3]. A) noyau linéaire, B) noyau RBF C) noyau polynomial.	78
4.1	Diagramme d'un système automatique de détection des crises épileptique	87
4.2	Schéma Bloc de l'approche de détection proposée pour chaque TFR	93
4.3	Le spectrogramme d'un signal EEG avec et sans crise de l'enregistrement 03 de la base de données CHB-MIT Scalp EEG. (a) Sain (b) Épileptique	94
4.4	La SPWVD d'un signal EEG avec et sans crise de l'enregistrement 03 de la base de données CHB-MIT Scalp EEG. (a) Sain (b) Épileptique	95
4.5	La CWD d'un signal EEG avec et sans crise de l'enregistrement 03 de la base de données CHB-MIT Scalp EEG. (a) Sain (b) Épileptique	95
4.6	Le tracé de contours des quatre bandes fréquentielle, δ (0,5-4 Hz), θ (4-8 Hz), α (8-13 Hz) et β (13-32 Hz), de chaque représentation TF d'un signal EEG épileptique de l'enregistrement 03 de la base de données CHB-MIT Scalp EEG. (a) Spectrogram (b) SPWVD (c) CWD	96
4.7	Tracé tridimensionnel des SPWVD du signal EEG de l'enregistrement 09 de la base de données CHB MIT scalp EEG.	97
4.8	La surface du contour à 1/4 des magnitudes maximales de la SPWVD d'un signal EEG de l'enregistrement 03 de la base de données CHB MIT. (a) Tracé tridimensionnel (b) Tracé de Contour	98
4.9	La surface du contour à 2/4 des magnitudes maximales de la SPWVD d'un signal EEG de l'enregistrement 09 de la base de données CHB MIT. (a) Tracé tridimensionnel (b) Tracé de Contour	98
4.10	L'histogramme des valeurs de TF-area-CWD pour chaque nombre de niveaux appliqué a un seul canal du signal EEG avec et sans crise.(a) 1 niveau (b) 2 niveaux (c) 3 niveaux (d) 4 niveaux (e) 5 niveaux	101
4.11	L'histogramme des valeurs de TF-area-SPWVD pour chaque nombre de niveaux appliqué a un seul canal du signal EEG avec et sans crise.(a) 1 niveau (b) 2 niveaux (c) 3 niveaux (d) 4 niveaux (e) 5 niveaux	102
4.12	L'histogramme des valeurs de TF-area-SP pour chaque nombre de niveaux appliqué a un seul canal du signal EEG avec et sans crise.(a) 1 niveau (b) 2 niveaux (c) 3 niveaux (d) 4 niveaux (e) 5 niveaux	103
4.13	Les mesures de performances pour chaque QTFD et chaque classifieurs en utilisant la technique "Train-Test Split". (a) SVM (b) kNN (c) DT	107

4.14	Les mesures de performances pour chaque QTFD et chaque classifieurs en utilisant la technique k-fold. (a) SVM (b) kNN (c) DT	111
5.1	L'état de la crise d'épilepsie. État inter-critique, pré-critique, critique et post-critique d'un seul canal de chb09 de la base de données CHB-MIT. .	115
5.2	Diagramme de l'algorithme développé pour la prédiction des crises d'épilepsie	116
5.3	Schéma fonctionnel global de la première méthode de pré-traitement . .	117
5.4	Schéma fonctionnel global de la deuxième méthode de pré-traitement . .	118
5.5	Contours des SPWVDs des signaux EEG inter-ictal, pré-ictal et ictal de l'enregistrement 09 de la base de données CHB-MIT. (a) Inter-ictal, (b) Pré-ictal, (c) Ictal	119
5.6	Variation de l'entropie de Renyi des signaux EEG pré-ictaux et inter-ictaux de la base de données CHB-MIT.	119
5.7	Le système international 10-20. (a) Parties du cerveau, (b) Placement des électrodes sur le cuir chevelu	120
5.8	La variation de chaque caractéristique extraite du SPWVD des signaux EEG pré-ictaux et inter-ictaux de la base de données CHB-MIT. (a) L'énergie (E), (b) Puissance moyenne (PM), (c) Moyenne quadratique (RMS), (d) Taux de passage de zéro (ZCR)	121
5.9	Les valeurs de performance de tous les sujets de la base de données CHB-MIT pour la première approche utilisant le classificateur SVM. (a) Taux de classification, (b) Taux de fausse prédiction	125
5.10	Les valeurs de performance de tous les sujets de la base de données CHB-MIT pour la première approche utilisant le classificateur kNN. (a) Taux de classification, (b) Taux de fausse prédiction	125
5.11	Les valeurs de performance de tous les sujets de la base de données CHB-MIT pour la première approche utilisant le classificateur DT. (a) Taux de classification, (b) Taux de fausse prédiction	126

LISTE DES TABLEAUX

1.1	Caractéristiques des différents patients de la base de données CHB-MIT scalp EEG	37
4.1	Caractéristiques temporelles et leur conversation en domaine conjoint T-F	90
4.2	Caractéristiques fréquentielles et leur conversation en domaine conjoint T-F	90
4.3	Les résultats de la TF-area appliquée à la CWD pour chaque nombre de niveaux, les résultats obtenus sont pour un seul canal.	99
4.4	Les résultats de la TF-area appliquée à la SPWVD pour chaque nombre de niveaux, les résultats obtenus sont pour un seul canal.	99
4.5	Les résultats de la TF-area appliquée à la SP pour chaque nombre de niveaux, les résultats obtenus sont pour un seul canal de l'enregistrement o2 de la base de données Bonn.	100
4.6	Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur SVM	104
4.7	Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur kNN	105
4.8	Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur DT	106
4.9	Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur SVM en utilisant la technique 10-fold	108
4.10	Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur kNN en utilisant la technique 10-fold	109
4.11	Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur DT en utilisant la technique 10-fold	110
4.12	Nombre optimal de niveaux de chaque bande fréquentielle pour chaque QTFD de SVM, kNN et DT	110
4.13	Comparaison des méthodes existantes pour la détection des crises épileptiques.	110
5.1	Les résultats expérimentaux de classification pour la première méthodologie de pré-traitement (70/30).	122
5.2	Résultats expérimentaux de classification pour la deuxième méthodologie de pré-traitement (70/30).	122
5.3	Les résultats expérimentaux de classification pour la première méthodologie de pré-traitement (5 fold).	122
5.4	Les résultats expérimentaux de classification pour la deuxième méthodologie de pré-traitement (5 fold).	123
5.5	Taux de classification de la prédiction et taux de faux positifs (FPR) des deux méthodes proposées pour chaque patient.	124
5.6	Comparaison des méthodes existantes pour la prédiction des crises épileptiques.	127

INTRODUCTION GÉNÉRALE

L'ÉPILEPSIE est une maladie chronique du système nerveux qui se caractérise par une activité électrique convulsive récurrente, soudaine, excessive et auto-entretenu qui peut affecter un groupe de neurones dans le cerveau. Cette perturbation électrique est généralement de courte durée, mais peut entraîner des changements dans le comportement, les mouvements et les niveaux de conscience du patient, souvent accompagnés d'une perte de la posture verticale et d'une altération des sens qui peuvent causer des blessures graves, voire la mort [4, 5].

L'Organisation Mondiale de la Santé (OMS) et ses partenaires considèrent l'épilepsie comme un problème de santé publique majeur, touchant plus de 70 millions de personnes dans le monde. Environ cinq millions d'individus sont diagnostiqués épileptiques chaque année, dont environ 30% ne peuvent être traités médicalement ou chirurgicalement. Il s'agit de l'une des neuropathies les plus courantes au monde, classée en quatrième position après la migraine, l'accident vasculaire cérébral et la maladie d'Alzheimer [6, 7]. Par conséquent, il est crucial de disposer d'un diagnostic et d'une prédiction précis, rapides et intégrés du processus de crise d'épilepsie pour répondre aux besoins urgents des patients.

Le dépistage précoce des crises d'épilepsie peut influencer de manière significative le choix d'un traitement médical approprié. Les professionnels de santé diagnostiquent généralement l'épilepsie à l'aide de l'électroencéphalographie (EEG), qui explore l'activité électrique spontanée du cerveau humain, produite pendant une tâche cognitive ou au repos, à l'aide de multiples électrodes positionnées sur le cuir chevelu du patient, conformément au système international 10-20 de Jasper [8]. Cet examen de diagnostic est non-invasif, indolore et généralement effectué visuellement par les neurologues pour détecter une crise d'épilepsie. Cependant, cette méthode d'analyse est limitée, longue, fastidieuse, coûteuse, et peut être source d'ambiguïtés et de désaccords entre experts, surtout lorsqu'un grand nombre d'électrodes est utilisé. L'utilisation de systèmes de traitement automatique robustes et fiables pourrait aider les neurologues cliniciens à évaluer efficacement un grand volume de données EEG et à accélérer le diagnostic. En outre, les systèmes de neurostimulation implantables en boucle fermée et les dispositifs de neurostimulation réactifs pourraient être équipés de systèmes d'identification automatique des crises pour prévenir les crises d'épilepsie [9].

Les signaux EEG présentent un comportement non linéaire et non stationnaire, avec des variations du contenu spectral dans le temps. Par conséquent, l'utilisation de distributions temps-fréquence (TFD) est souvent nécessaire pour analyser simultanément les aspects temporels et fréquentiels du signal. Les TFD fournissent une représentation plus informative de la localisation temporelle des différentes composantes spectrales dans le signal EEG, permettant ainsi une meilleure localisation des composantes spectrales dans le signal analysé. Cette approche offre une technique plus adaptée à la reconnaissance des crises d'épilepsie.

En effet, l'étape essentielle de la détection des crises épileptiques consiste à extraire les caractéristiques qui décrivent le comportement des signaux EEG. Afin d'optimiser

les performances du classificateur, il est primordial que cette étape réduise la dimension du signal d'origine tout en préservant le maximum d'informations pertinentes. Une sélection de caractéristiques inadéquate peut entraîner une classification inefficace, d'où l'importance de choisir avec soin les caractéristiques clés qui représentent l'ensemble des données. En résumé, la sélection de ces caractéristiques est une étape cruciale pour obtenir des résultats précis et fiables dans la détection des crises épileptiques.

L'objet de cette étude est d'explorer le potentiel des représentations temps-fréquence pour extraire des informations précieuses sur le comportement épileptique dans les signaux EEG. Le but ultime est de développer un cadre de traitement de signal automatisé pour détecter les crises d'épilepsie de manière plus fiable et robuste. Pour ce faire, des caractéristiques ont été extraites à partir des contours des représentations temps-fréquence (TFR), en utilisant les distributions de Pseudo Wigner-Ville lissée (SPWVD), de Choi-Williams (CWD) et le spectrogramme (SP). Les caractéristiques extraites ont été utilisées pour l'apprentissage de plusieurs classificateurs différents. Les résultats expérimentaux ont montré une précision de classification fiable. Cette étude est une contribution importante pour la détection précise des crises épileptiques à partir des signaux EEG multicanal.

La prédiction des crises d'épilepsie, de leur gravité et de leur durée est une préoccupation majeure pour les patients et leurs familles en raison des risques de blessures et de sécurité associés à ces événements. Il est donc crucial d'anticiper ces crises le plus tôt possible pour éviter les effets indésirables. Les signaux EEG présentent des caractéristiques distinctives telles que des pointes, des ondes aiguës et des complexes pointes-ondes, qui peuvent être utilisées pour prédire les crises. Cependant, les enregistrements EEG ne sont pas stationnaires et peuvent varier d'une crise à l'autre, d'une électrode à l'autre et d'un patient à l'autre, ce qui pose un défi pour les chercheurs en matière de prédiction fiable et robuste. Par conséquent, il est essentiel de développer des méthodes précises et fiables pour prédire les crises d'épilepsie afin d'améliorer la sécurité et la qualité de vie des patients.

Cette thèse avait également pour objectif de développer un algorithme permettant la détection des activités épileptiformes dans la phase pré-critique des signaux EEG. Pour ce faire, des méthodes d'analyse temps-fréquence fiables ont été appliquées aux signaux EEG, et l'avantage de la combinaison de techniques d'analyse de la complexité des signaux telles que l'entropie de Renyi et les distributions quadratique temps-fréquence a été exploré pour chaque canal EEG dans le but de localiser la zone épileptogène. L'entropie de Renyi a été utilisée car elle est capable de différencier de manière fiable les signaux EEG contenant des crises de ceux de l'arrière-plan, avec des performances supérieures [10].

Organisation de la thèse

Cette thèse est structurée en cinq chapitres :

1. *Le premier chapitre* Dans ce chapitre, nous avons pour objectif de fournir une vue d'ensemble complète et cohérente des notions anatomiques et physiologiques du système nerveux, ainsi que des concepts fondamentaux de l'électroencéphalogramme en tant que modalité de référence pour l'étude du cerveau. Nous aborderons également les bases de l'épilepsie, y compris les étiologies des crises épileptiques et les différents types de crises, ainsi que la présentation des bases de données EEG utilisées dans notre étude.
2. *Le deuxième chapitre* a pour objectif de décrire les principes fondamentaux et les concepts clés liés au traitement de signaux non stationnaires, en particulier les représentations temps-fréquence, y compris les représentations linéaires. Nous

mettons l'accent sur les distributions temps-fréquence quadratiques (QTFDs) en présentant leur formulation mathématique et leurs propriétés caractéristiques.

3. *Le troisième chapitre* Dans le troisième chapitre, nous nous concentrons sur les principes mathématiques de diverses techniques d'extraction de caractéristiques significatives permettant de décrire le comportement des signaux EEG dans différents domaines, notamment temporel, fréquentiel et temps-fréquence. Nous examinons également les systèmes de classification employés pour la reconnaissance et la classification des crises épileptiques.
4. *Le quatrième chapitre* Dans le quatrième chapitre, nous examinons les techniques actuelles de détection de crises d'épilepsie dans la littérature scientifique, puis nous présentons en détail l'algorithme que nous avons développé pour détecter les crises épileptiques à partir de signaux EEG. Nous analysons également les résultats obtenus et comparons notre approche à d'autres méthodes existantes dans la littérature pour évaluer ses avantages et ses limites.
5. *Le cinquième chapitre* Le cinquième chapitre explore l'état de l'art des techniques de prédiction de crises d'épilepsie décrites dans la littérature. Nous détaillons également l'algorithme que nous avons élaboré pour prédire les crises épileptiques à partir des signaux EEG, qui repose sur une combinaison de distributions quadratiques temps-fréquence et de méthodes d'analyse de la complexité du signal. Nous procédons ensuite à une analyse des résultats obtenus et comparons les performances de notre approche avec celles des techniques de prédiction de crises épileptiques les plus couramment utilisées ces dernières années.

CONTEXTE MÉDICALE DE LA THÈSE



1.1 INTRODUCTION

L'épilepsie est l'une des affections neurologiques chroniques les plus courantes. Elle est caractérisée par des crises imprévisibles et spontanées résultant de décharges excessives, hypersynchroniques et auto-entretenues dans une population assez étendue de neurones. Ces crises peuvent varier en forme et en intensité.

La mesure des activités physiologiques du cerveau est un défi pour la médecine moderne. L'électroencéphalographie (EEG) permet de mesurer l'activité électrique cérébrale à la surface du cuir chevelu en captant les potentiels postsynaptiques générés par plusieurs neurones. Les signaux EEG sont amplifiés pour être enregistrés par un ordinateur, étant donné qu'ils sont de l'ordre du microvolt. Ces signaux ont une forme proche d'une onde sinusoïdale et ont une fréquence commune allant de 0,5 Hz à 60 Hz. L'EEG de surface est une méthode non invasive largement utilisée en neurologie, notamment pour diagnostiquer et suivre l'épilepsie. Cette section traite de l'aspect médical de la thèse. Elle commence par une présentation des fondements anatomiques et physiologiques du cerveau, suivie des enregistrements électrophysiologiques de l'activité cérébrale, y compris l'électroencéphalogramme (EEG). Ensuite, une revue des origines et des mécanismes de l'apparition de l'épilepsie est présentée. Enfin, la section se termine avec une description des bases de données utilisées dans ce travail.

1.2 SYSTÈME NERVEUX (SN)

Le système nerveux (SN) est un ensemble de structures qui réceptionnent, intègrent, transforment, transmettent et traitent les influx nerveux, en vue de contrôler et coordonner toutes les parties du corps. En outre, il peut recevoir des informations de l'environnement externe et interagir avec celui-ci.

Le système nerveux (SN) est constitué de deux divisions principales : le système nerveux central (SNC) et le système nerveux périphérique (SNP). Le SNC, qui traite les informations, est composé de l'encéphale et de la moelle épinière. Le SNP est formé des nerfs crâniens qui proviennent de l'encéphale, ainsi que des nerfs rachidiens qui proviennent de la moelle épinière. Le SNP comporte deux subdivisions fonctionnelles : le système nerveux somatique et le système nerveux autonome (SNA). Le rôle principal du SNP est de transmettre les influx nerveux vers ou depuis de nombreuses structures de l'organisme.

En effet, l'encéphale est l'organe principal du système nerveux situé à l'intérieur de la boîte crânienne et relié à l'extrémité supérieure de la moelle épinière. Il est constitué du cerveau, du cervelet et du tronc cérébral, ainsi que de tous les nerfs qui relient les muscles et les organes sensoriels. Sa principale fonction est l'émission des influx

nerveux, le traitement des données transmises par ces influx et la création des processus de pensée au plus haut niveau.

1.3 LE CERVEAU

Le cerveau est la principale structure de l'encéphale, avec un poids de 1,3 à 1,4 kg, soit 2% de la masse totale du corps humain. Il est responsable de la gestion de presque toutes les fonctions biologiques, des plus simples aux plus complexes. Le volume moyen du cerveau est de 1130 cc pour les femmes et 1260 cc pour les hommes. Il est entouré par le liquide céphalo-rachidien (LCR) qui le protège des chocs. Le cerveau contient environ 100 milliards de cellules nerveuses.

Le cerveau, structure complexe du système nerveux central, est composé de matière grise appelée cortex cérébral et de deux hémisphères cérébraux reliés par le corps calleux, composé de matière blanche. Chaque hémisphère est divisé en lobes frontal, pariétal, occipital et temporal, qui sont responsables de fonctions cérébrales spécifiques 1.1.

- Le lobe frontal est communément associé aux fonctions de la parole et du langage, ainsi qu'à des processus cognitifs supérieurs tels que la planification, le raisonnement, la coordination motrice volontaire et la régulation de l'humeur.
- Le lobe pariétal est fortement impliqué dans la perception sensorielle, ainsi que dans le raisonnement spatial et la réception des messages sensoriels provenant du corps. Il joue également un rôle important dans la coordination des mouvements corporels.
- Le lobe occipital est le centre visuel.
- Le lobe temporal est associé à la mémoire et aux émotions.




FIGURE 1.1 – Différentes parties du cerveau. (Image extraite du site <http://martelsvt.e-monsite.com>)

Dans l'ensemble, l'hémisphère droit du cerveau contrôle le côté gauche du corps tandis que l'hémisphère gauche contrôle le côté droit. Le développement de matière grise dans le cortex est associé à la présence de neurones, des cellules hautement spécialisées et fonctionnellement distinctes.

1.3.1 Composition cellulaire du cerveau

En effet, le cerveau humain est constitué principalement de deux types de cellules : les cellules nerveuses ou neurones et les cellules gliales. Le cerveau contient environ 86 milliards de neurones et un nombre équivalent de cellules gliales [11]. Les neurones sont des cellules spécialisées dans la transmission de l'information, tandis que les cellules gliales remplissent des fonctions de soutien et de protection des neurones. Les cellules gliales comprennent plusieurs types de cellules, tels que les astrocytes, les oligodendrocytes et les microglies, chacun avec leurs propres fonctions spécifiques.

Les neurones

En effet, le neurone est la cellule la plus importante dans le système nerveux et est responsable de la transmission de l'information entre les différentes parties du cerveau et avec le reste du corps. Les neurones sont capables de recevoir et d'intégrer l'information provenant de diverses sources, et de générer des impulsions électriques, qui sont transmises le long de l'axone, une longue extension du neurone. Les neurones sont également capables de communiquer avec d'autres neurones en utilisant des neurotransmetteurs, des substances chimiques qui permettent la transmission des signaux d'un neurone à l'autre à travers les synapses.

Bien que la forme et la taille des neurones puissent varier considérablement, ils sont généralement composés de trois parties principales : le corps cellulaire, ou soma, qui fournit de l'énergie au neurone ; l'axone, qui transmet les influx nerveux en direction centrifuge depuis le corps cellulaire ; et les dendrites, qui reçoivent les signaux provenant d'autres neurones et les transmettent au corps cellulaire via des synapses, qui agissent comme des émetteurs pour les neurones en transmettant le potentiel d'action. La structure d'un neurone est illustrée dans la Figure 1.2.




FIGURE 1.2 – Schéma de la structure d'un neurone et ses principales composantes. [1]

Effectivement, la grande variabilité des connexions neuronales est l'une des caractéristiques principales du cerveau humain. Les neurones sont capables de communiquer entre eux de manière sélective, formant ainsi des circuits qui traitent différentes informations [12]. Cette communication est réalisée à travers des liaisons chimiques spécialisées

appelées synapses, où des neurotransmetteurs sont libérés dans l'espace inter-neuronal pour activer ou inhiber les neurones cibles. Cette communication synaptique est essentielle pour la transmission de l'information dans le cerveau et permet une grande plasticité cérébrale, c'est-à-dire la capacité du cerveau à s'adapter et à changer en réponse à l'environnement et à l'expérience.

Les cellules gliales

Les cellules gliales sont un type de cellules du système nerveux qui ont pour fonction de soutenir les cellules neuronales. Elles leur fournissent notamment des nutriments et de l'oxygène, ainsi qu'un soutien physique et une protection. Les cellules gliales ont également un rôle dans l'élimination des cellules mortes et produisent la myéline, qui est un tissu adipeux qui recouvre certains axones et agit comme une gaine isolante. Enfin, les cellules gliales jouent un rôle important dans la transmission de l'influx nerveux en accélérant cette transmission, et elles sont impliquées dans des fonctions cérébrales telles que la pensée, la perception, la mémoire et la conscience.

1.3.2 L'activité électrique du cerveau

La communication entre les neurones est interprétée par l'activité électrique du cerveau. Cette activité peut prendre deux formes de signaux électriques : les potentiels d'action (PA), qui permettent la communication à courte et à longue distance, et les potentiels post-synaptiques (PSP), qui permettent la communication à courte distance. L'activité électrique des neurones produit des courants ioniques dans la matrice extracellulaire du cerveau. Ces courants sont assurés par les neurones pyramidaux des couches corticales III, V et VI grâce à leur disposition en macrocolonnes perpendiculaires à la surface corticale. Cette disposition permet l'ajout de courants locaux. La sommation spatiale de ces courants ioniques est caractérisée par un potentiel électrique. Ce potentiel peut être recueilli par une électrode placée à la surface de la tête à condition qu'il y ait une synchronisation simultanée de milliers de cellules. Ces signaux peuvent être enregistrés par des outils d'enregistrement électrophysiologique tels que l'électroencéphalogramme (EEG). Ces enregistrements sont possibles grâce à la disposition structurée des neurones pyramidaux dans le cortex cérébral.

1.4 ENREGISTREMENTS ÉLECTROPHYSIOLOGIQUES DE L'ACTIVITÉ CÉRÉBRALE

L'enregistrement électrophysiologique de l'activité cérébrale est une technique de diagnostic précieuse en neurophysiologie et neuropathologie, fournissant des données directement liées à l'activité cérébrale. Les premiers enregistrements ont été réalisés en 1924 par le psychiatre allemand Hans Berger, en utilisant des électrodes cutanées [13]. Cette découverte a marqué le début de la technologie de l'Electroencéphalographie (EEG), toujours utilisée aujourd'hui comme outil de diagnostic visuel par les neurologues.

1.4.1 L'électroencéphalographie (EEG)

En 1924, le neuropsychiatre allemand Hans Berger a découvert l'existence des signaux d'EEG chez l'homme, ce qui lui a valu le surnom de "père de l'électroencéphalo-

lographie". Il a poursuivi ses recherches et a enregistré des signaux EEG humains plus longs d'une durée de 1 à 3 minutes en 1929. Il a également identifié deux rythmes cérébraux, à savoir le rythme alpha et le rythme bêta, comme des composantes clés de l'EEG, et a établi une corrélation entre l'activité cérébrale et les variations dans les signaux EEG [13].

EEG : Mesure

L'électroencéphalographie (EEG) est une technique d'exploration cérébrale qui permet d'évaluer l'activité électrique du cerveau. Elle est non-invasive et indolore, et est utilisée à des fins cliniques, thérapeutiques ou de recherche en neurosciences. Pour recueillir les signaux électriques, des électrodes, souvent composées de chlorure d'argent (AgCl), sont placées sur le cuir chevelu à des zones bien définies du crâne selon le système international de Jasper 10-20. Pour améliorer la conductivité, une pâte conductrice faite de pierre ponce et de chlorure de sodium est utilisée. Les signaux électriques recueillis sont de très faibles amplitudes, généralement dans la plage de 0.5 à 100 μ V, et sont amplifiés à l'aide d'un dispositif d'amplification avant d'être affichés sous forme de courbes. Ces courbes représentent l'évolution de l'activité cérébrale au fil du temps et sont appelées électroencéphalogramme (EEG).

L'EEG est une méthode importante pour diagnostiquer les troubles neurologiques causés par des anomalies de l'activité cérébrale. Il est principalement utilisé pour détecter l'épilepsie et peut également aider à évaluer la confusion et le coma. L'EEG joue également un rôle crucial dans la distinction entre les troubles mentaux et les troubles organiques.




FIGURE 1.3 – Tracé original d'un patient présentant une activité normale. (Image extraite du site <https://hal.science/tel-01504058/document>)

Le système 10–20

Les électrodes sont placées sur le scalp selon un standard appelé système de Jasper 10-20, qui a été proposé par la Fédération internationale des sociétés d'électroencéphalographie et de neurophysiologie clinique (FISENC). Ce système permet un positionnement spatial identique en utilisant des repères anatomiques spécifiques à chaque patient [14].

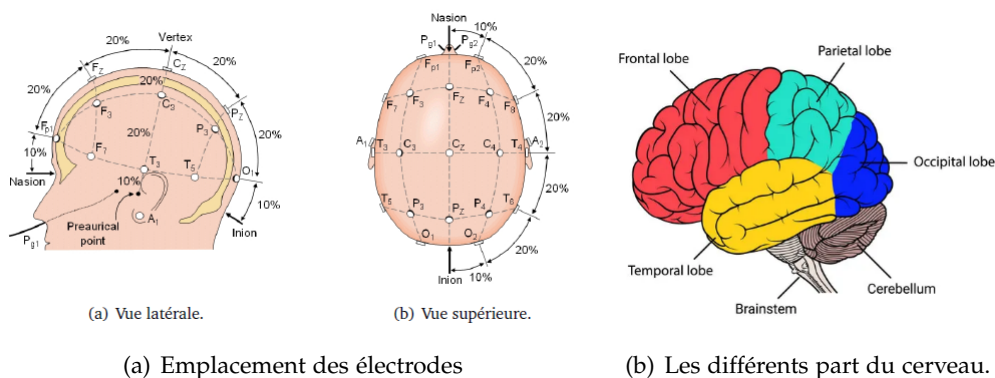


FIGURE 1.4 – Système de positionnement des électrodes 10–20.

(a) Emplacement des électrodes (Image extraite du site

<https://theses.hal.science/tel-01720427/document>),(b) Les différents part du cerveau. (Image extraite du site <https://www.istockphoto.com>)

Cette technique utilise des repères anatomiques précis tels que le nasion, l'inion et les repères pré-auriculaires pour positionner les électrodes. Les électrodes sont placées à des intervalles de 10% ou 20% de la distance totale entre ces repères. Chaque électrode est désignée par un nom spécifique composé de lettres majuscules et de chiffres, qui permettent d'identifier la région cérébrale adjacente.

Les lettres majuscules dans le système de positionnement de Jasper 10-20 sont utilisées pour identifier les régions où les électrodes sont placées, en référence aux régions cérébrales adjacentes : A pour l'oreille, C pour le centre, P pour le pariétal, F pour le frontal, Fp pour le frontal polaire, O pour l'occipital, T pour le temporal, et z pour l'axe central. Les chiffres pairs sont utilisés pour indiquer que l'électrode est placée sur l'hémisphère droit et les chiffres impairs pour l'hémisphère gauche. Le schéma de positionnement des électrodes est illustré par la figure 1.4.

Le développement de technologies d'enregistrement avancées et de meilleures électrodes a permis l'augmentation du nombre d'électrodes placées dans des positions intermédiaires pour l'EEG. Aujourd'hui, il est possible d'enregistrer avec 64, 128 voire 256 électrodes grâce à l'EEG à haute résolution (EEG-HR). Cette version améliorée de l'EEG traditionnel permet une meilleure résolution spatiale (de 64 à plus de 100 électrodes) et temporelle (la fréquence d'échantillonnage est de 1kHz).

EEG : montage

L'activité électrique du cerveau produit des changements de potentiel qui peuvent être enregistrés sur le cuir chevelu. Pour déterminer cette distribution, on utilise un enregistrement à plusieurs canaux qui permet de fournir des informations sur la localisation et la latéralisation de l'activité cérébrale.

Les enregistrements EEG sont réalisés en utilisant des arrangements ordonnés de dérivations électroencéphalographiques pour couvrir de manière symétrique la surface du scalp. Cependant, il est difficile de trouver une référence de potentiel céphalique complètement nulle. Pour résoudre ce problème, il existe différentes combinaisons de montages possibles, classées en fonction de la disposition électro-anatomique, de l'orientation spatiale et de la nature de l'entrée de la chaîne. Il y a quatre types d'assemblages possibles, notamment le montage en référence commune, en référence moyenne, bipolaire et en référence moyenne pondérée ou Laplacien [15] (Voir Figure 1.5). Cette configuration facilite l'interprétation électroencéphalographique (EEG).

1. Montage référentiel

Le montage référentiel permet de mesurer la différence de potentiel entre une électrode et une électrode de référence. Il est important de choisir une référence la plus inactive possible, mais il est impossible de trouver une référence de potentiel céphalique totalement nulle. Les montages référentiels ont l'avantage de préserver la forme et l'amplitude de la forme d'onde. On distingue deux catégories de références : les références céphaliques et les références extra-céphaliques.

Pour surmonter le problème de la référence non nulle, il est recommandé d'utiliser le montage en référence commune moyenne. Cette technique consiste à représenter la référence du montage par la moyenne de l'ensemble des potentiels mesurés, créant ainsi une référence "virtuelle" inactive. Cette approche suppose que la tête est pratiquement isolée électriquement du reste du corps et que les sources intracérébrales, modélisées comme des dipôles électriques, génèrent des potentiels de somme nulle sur la surface de la tête.

Le montage en référence commune moyenne présente un avantage majeur, il permet de minimiser l'influence des artefacts et de l'électrode active sur une seule électrode. Cependant, la référence moyenne est affectée par l'activité de l'électrode d'intérêt et l'amplitude du potentiel diminue légèrement avec le nombre d'électrodes utilisées pour calculer la moyenne. De plus, en présence d'une anomalie focale de forte amplitude, les montages en référence commune moyenne peuvent produire des images déroutantes car l'anomalie sera reflétée dans des canaux inactifs avec une polarité opposée, ce qui entraîne des inversions de phase indésirables. Les montages laplaciens sont fortement recommandés pour surmonter les problèmes des montages moyens communs. Ils utilisent plusieurs électrodes plutôt qu'une seule comme référence, mais chaque canal a une référence différente, qui n'est pas la même pour tous les canaux. La tension à chaque électrode est comparée à la tension moyenne locale des électrodes immédiatement environnantes. Les montages laplaciens peuvent être utiles pour mettre en évidence et analyser des formes d'onde hautement localisées en filtrant une activité étendue. Cependant, certains canaux n'ont que trois électrodes environnantes, tandis que d'autres en ont quatre, ce qui peut causer des problèmes en cas d'artefacts ou de bruit au niveau d'une électrode. En outre, il peut être difficile de comparer l'activité entre les canaux car la référence est différente pour chaque canal.

2. **Montage bipolaire** Ce montage consiste à mesurer la différence de potentiel entre deux électrodes placées sur le cuir chevelu, l'une à côté de l'autre selon le système international de Jasper. On peut distinguer deux principales catégories de montages bipolaires classées selon la disposition des électrodes : le montage bipolaire antéro-postérieur (AP), également appelé longitudinal, qui explore d'avant en arrière, et le montage bipolaire transversal qui explore de droite à gauche.

Les montages bipolaires sont efficaces pour l'analyse de décharges localisées et révèlent des gradients de potentiel importants entre les canaux adjacents. Ce type de montage permet également de réduire les artefacts par rapport aux montages référentiels car il élimine l'artefact d'une référence défaillante. Les limitations incluent la distorsion de forme et en particulier l'amplitude des formes d'onde.

En général, il n'y a pas de montage parfait pour l'enregistrement de l'activité cérébrale. Cependant, les différents montages peuvent être complémentaires les uns aux autres. Ils ont tous pour objectif de transformer l'activité cérébrale en signaux électriques bidimensionnels qui peuvent être enregistrés. Cela se fait en utilisant différentes électrodes qui captent l'activité cérébrale à différents endroits sur le scalp. Les montages

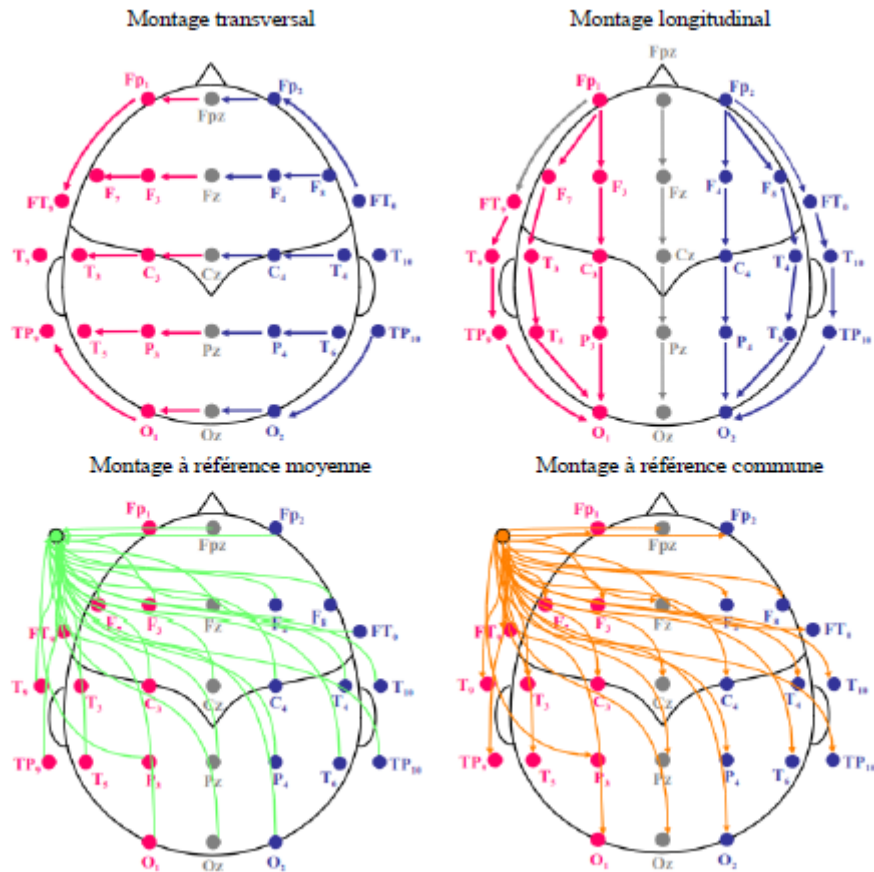


FIGURE 1.5 – Différents types de montage EEG

peuvent ainsi déformer les informations spatiales et introduire des erreurs dans l'interprétation des signaux enregistrés.

1.4.2 Les activités rythmiques cérébrales

L'analyse visuelle de l'EEG est essentielle pour diagnostiquer certains troubles électrophysiologiques cérébraux. Elle examine les principales composantes de l'EEG telles que la durée, l'amplitude, la forme et la fréquence. Les changements dans ces composantes se traduisent par des formes périodiques dans le tracé EEG appelées les rythmes cérébraux.

Un rythme cérébral correspond à une oscillation électromagnétique dans une plage de fréquences spécifique qui est générée par l'activité électrique synchronisée d'un grand nombre de neurones du cerveau. L'EEG permet d'identifier cinq types d'activités rythmiques du cortex cérébral, classées selon leur bande de fréquence : delta (δ), theta (θ), alpha (α), beta (β) et gamma (γ). La figure 1.6 illustre les principaux rythmes cérébraux du signal EEG.

Rythme Delta :

Il s'agit d'un rythme cérébral lent de basse fréquence, variant de 0,5 à 2 ou 4 Hz, avec une amplitude très élevée, allant jusqu'à 200 microvolts. Ce rythme se manifeste lors d'une méditation profonde ou d'un état de sommeil sans rêves, et est présent en

grande quantité chez l'enfant, mais diminue avec l'âge. Sous ce rythme, la conscience du monde physique n'existe plus et la notion de temps est perdue. Certaines pathologies comme la démence, la schizophrénie, l'épilepsie ou les tumeurs cérébrales sont associées à une activité delta anormale, tout comme certaines pathologies du sommeil telles que le somnambulisme et la somnolence. Ces ondes sont principalement présentes au niveau des lobes temporaux et, de manière subjective, au niveau des lobes occipitaux.

Rythme Thêta :

Il s'agit d'un rythme qui se manifeste lors de la relaxation intense et de la méditation profonde, même en étant éveillé. Les ondes thêta ont une fréquence assez basse (de 4 à 8 Hz) et une amplitude élevée, allant de 50 à 100 microvolts. Ces ondes sont liées à notre subconscient et régissent la partie du mental entre le conscient et l'inconscient, contenant les mémoires et les sensations. Elles gouvernent également nos attitudes, croyances et comportements, et sont associées aux états de super créativité, d'inspiration et de conscience spirituelle. Les ondes cérébrales thêta reflètent la partie du système limbique et de la région de l'hippocampe. Les enfants de la naissance à l'âge de 7 ans fonctionnent principalement en ondes delta et thêta à basses fréquences, ce qui signifie qu'ils peuvent acquérir un grand volume d'informations.

Rythme Alpha :

Ce rythme correspond à un état de relaxation éveillé avec les yeux fermés et au repos. Quand les yeux s'ouvrent ou qu'une activité intellectuelle survient brusquement, ces ondes disparaissent, ce qui est appelé blocage alpha. Les ondes alpha sont produites par la substance blanche du cerveau.

Ce rythme est appelé alpha et se situe entre 8 et 13 Hz avec une amplitude de 25 à 60 μV . Il apparaît lorsque les yeux sont fermés et lors d'une relaxation ou d'une respiration profonde. Il diminue lors d'une activité mentale intense telle que la pensée ou le calcul.

Les ondes alpha sont captées à l'arrière de la tête dans la région occipitale, ainsi que dans le cortex et sa bande périphérique. Elles aident à synchroniser les deux hémisphères du cerveau, le droit qui est plus créatif et le gauche qui est plus rationnel. En outre, elles favorisent la créativité et les processus d'apprentissage.

Rythme Bêta :

Ce rythme correspond à un état d'éveil et de concentration pendant les activités courantes et intenses de la journée. Étonnamment, les ondes cérébrales passent en phase bêta pendant le sommeil paradoxal, qui est une courte période de sommeil avec des rêves, comme si les activités du rêve étaient des activités courantes. Ce rythme est caractérisé par des oscillations de haute fréquence, habituellement entre 12 et 30 Hz, et de faible amplitude, de l'ordre de 10 à 30 μV .

Les ondes beta ont leur origine dans les lobes temporaux et se reflètent de manière subjective dans les lobes occipitaux et frontaux du cerveau de manière asynchrone.

Rythme Gamma :

Ce rythme est appelé activité gamma et se situe à des fréquences élevées, de 30 à 120 Hz, avec des amplitudes faibles et une occurrence rare, le rendant difficilement détectable sur un EEG de surface. L'activité gamma est associée à la réflexion intellectuelle

et survient lors d'états de conscience actifs tels que la concentration sur un problème ou la perception attentive. Elles sont importantes pour l'intégration des réflexions, des apprentissages et des informations reçues. Contrairement aux autres types d'ondes cérébrales, les ondes gamma proviennent de toutes les zones du cortex cérébral.




FIGURE 1.6 – Les principaux rythmes cérébraux de l'EEG

Autres patterns d'activité remarquables : D'autres motifs d'activité cérébrale surprenants apparaissent en parallèle avec les rythmes classiques, tels que le complexe K et le fuseau sigma (sleep spindles).

- Complexes-K Les formes ondulatoires cérébrales particulières, avec une forte amplitude, comportent le complexe-K et le fuseau sigma. Le complexe-K est détectable généralement sur l'EEG en phases de stade 2 du sommeil, qui est un stade de sommeil léger où le réveil est facile. Le complexe-K est caractérisé par un bref et intense pic électro-encéphalique négatif et peut susciter des réponses aux stimuli externes qui interfèrent avec le sommeil [2].
- Fuseaux Sigma s bandes sigma sont des augmentations rapides de l'activité électroencéphalographique qui durent généralement entre une demi-seconde et deux secondes et se produisent dans une plage de fréquence de 12 à 14 Hz. Elles sont observées lors du stade 2 du sommeil et peuvent être repérées sur l'EEG. La figure 1.7 illustre ces bandes sigma.

1.4.3 EEG pathologique

L'électroencéphalogramme permet de détecter les perturbations fonctionnelles ou lésionnelles dans les aires corticales de la surface du cerveau, de les quantifier et de



FIGURE 1.7 – Fuseaux Sigma et Complexe-K [2]

suivre leur évolution dans le temps. Les anomalies du tracé peuvent se présenter sous forme de modification des fréquences et de l'amplitude, permanente ou transitoire, ainsi que de la présence de figures anormales. Deux types d'anomalies peuvent être observés : les ondes lentes et les paroxysmes. L'examen est particulièrement utile pour étudier les troubles de la vigilance et les manifestations épileptiques.

Les ondes lentes

La présence d'ondes lentes de forte amplitude dans l'électroencéphalogramme, ayant une fréquence de 0.5 à 4Hz ou de 4 à 8Hz, peut être un signe de "souffrance cérébrale" localisée ou généralisée. Des études ont montré que ces ondes peuvent être causées par une diminution des afférences corticales cholinergiques en provenance du cerveau antérieur basal, ainsi que par des lésions de la substance blanche, du thalamus et de la formation réticulaire mésencéphalique.

Les Anomalies paroxystiques

es anomalies paroxystiques sont des événements pathologiques transitoires qui se caractérisent par une apparition et une disparition brusques. Elles se distinguent nettement des activités électriques permanentes de fond en raison de leur amplitude qui atteint au moins deux fois celle de l'activité de fond. Ces anomalies apparaissent sous forme d'éléments caractéristiques, soit isolés, soit groupés en séquences pouvant être localisées, bilatérales synchrones ou asynchrones, et pouvant s'organiser en crise épileptique électrique.

Un paroxysme EEG peut avoir une morphologie simple, telle qu'une pointe ou une onde raide, ou complexe, telle que des polypointes, des polypointes-ondes, une pointe-onde rapide ou une pointe-onde lente.

- La pointe est une décharge électrique brève de haute amplitude, qui dure entre 10 et 70 millisecondes, et peut être mono ou polyphasique.
- La pointe lente ou onde pointue est une onde qui a une apparence moins pointue et une durée qui varie entre 70 et 200 ms. Si la pente raide se trouve à l'avant de l'élément graphique, on parle d'une onde à front raide. En revanche, si la pente raide se trouve à l'arrière de l'élément, on parle d'une onde à dos raide.
- Les pointes-ondes sont des complexes qui se composent d'une pointe immédiate suivie d'une onde lente de même polarité, avec une amplitude plus ou moins importante. Il y a deux types de pointes-ondes : les pointes-ondes lentes, dont la fréquence est inférieure à 2.5Hz, et les pointes-ondes rapides, dont la durée est supérieure ou inférieure à 70ms.
- Les poly-pointes : elles sont constituées de deux ou plusieurs pointes regroupées en un temps très court.
- Les polypointes-ondes représentent une série de poly-pointes suivies immédiatement par une ou plusieurs ondes lentes.
- L'onde triphasique est une onde lente qui a trois composantes : une petite onde négative, une grande onde positive et une autre petite onde négative.

Les anomalies paroxystiques élémentaires sont organisées rythmiquement lors d'une crise épileptique. Leur absence ne permet pas d'écarter un diagnostic d'épilepsie. En revanche, leur présence dans l'EEG de surface est une aide importante pour diagnostiquer l'épilepsie.

1.4.4 Les Perturbations de l'EEG

Le signal EEG collecté à la surface du crâne est constitué de deux types de signaux. D'une part, les signaux électriques cérébraux générés par les neurones dans le cerveau. D'autre part, les signaux appelés artefacts, qui proviennent de l'extérieur du cerveau. Ces artefacts ont souvent une énergie importante et peuvent perturber considérablement l'analyse clinique et la qualité des résultats. Les perturbations dans l'EEG peuvent être regroupées en deux catégories : les artefacts et le bruit.

les artefacts

Les artefacts sont des activités électrophysiologiques enregistrées par l'EEG qui sont d'origine corporelle, comme les mouvements oculaires, les clignements, les mouvements musculaires et les battements cardiaques.

1. Les mouvements oculaires :

Les mouvements des yeux, qu'ils soient volontaires ou involontaires, peuvent causer des différences de potentiels sur les électrodes frontales et temporales. Ces différences peuvent causer des distorsions importantes dans le signal EEG et rendre son interprétation difficile. Les mouvements oculaires se produisent principalement dans la zone frontale et les zones temporales.

2. Les clignements :

Les clignements sont des mouvements mécaniques des paupières qui peuvent causer des artefacts sur le signal EEG en raison de la déflexion du signal qu'ils provoquent. Ces artefacts sont principalement observés sur les électrodes frontales dans le cas d'un montage bipolaire et leur répartition sur les voies de mesure dépend de la position de l'électrode de référence dans le cas d'un montage référentiel commun.

3. Les mouvements musculaires :

Les mouvements de la tête, des muscles faciaux ou du cou génèrent des phénomènes électriques rapides dus à l'activité musculaire. Cette activité génère un signal à haute fréquence d'amplitude supérieure à l'activité EEG mesurable. Ce signal peut masquer l'activité cérébrale et perturber l'analyse.

4. L'activité cardiaque :

Les mouvements cardiaques entraînent un léger mouvement de la tête qui n'est généralement pas perçu. Cependant, ce mouvement peut être détecté par les électrodes situées près d'une artère, ce qui génère un artefact. Ces artefacts peuvent parfois ressembler à des pointes intercritiques, ce qui rend leur différenciation difficile.

Les bruits

Le bruit est une composante non informative du signal EEG qui n'est pas considéré comme un artefact. Il y a deux types de bruit : le bruit de mesure, qui est de haute fréquence (40 Hz) et est principalement causé par l'instrumentation (électrodes, fils électriques), et le bruit électromagnétique, qui est lié à l'environnement. Le bruit est souvent modélisé comme un processus stationnaire qui découle d'une variable aléatoire.

1.5 L'ÉPILEPSIE

1.5.1 Définition

L'épilepsie est un trouble du cerveau qui se caractérise par une propension persistante à générer des crises. Ces crises sont causées par des décharges électriques excessives et soudaines dans un groupe de cellules neuronales ou dans le cerveau dans son ensemble. La Ligue internationale contre l'épilepsie (LICE) définit la crise d'épilepsie comme un phénomène transitoire de signes et/ou de symptômes résultant de l'activité neuronale excessive ou synchrone anormale dans le cerveau [16].

Les crises d'épilepsie peuvent avoir différentes intensités et fréquences, entraînant des symptômes tels que des troubles comportementaux, des contractions musculaires involontaires, la perte de conscience, des convulsions des bras et des jambes qui peuvent causer des blessures graves, voire la mort. Cette maladie est présente dans toutes les régions du monde et n'est pas liée à une classe sociale particulière. Les personnes atteintes d'épilepsie peuvent avoir un niveau d'intelligence normal et de nombreuses personnalités célèbres ont été épileptiques tout au long de l'histoire.

1.5.2 Les étiologies des crises d'épilepsie

Les épilepsies peuvent avoir des causes génétiques ou résulter de lésions ou de facteurs non lésionnels. On distingue trois types d'épilepsies : l'épilepsie symptomatique, l'épilepsie cryptogénique et l'épilepsie idiopathique.

1. Les épilepsies symptomatiques sont causées par des lésions cérébrales structurelles diffuses ou focales telles que des malformations congénitales, des encéphalites, des traumatismes crâniens, des accidents vasculaires cérébraux, des tumeurs, des infections du système nerveux central, des maladies neurologiques évolutives, des anomalies chromosomiques et des malformations cérébrales. Ces lésions peuvent être évolutives ou fixes.
2. Les épilepsies cryptogéniques : ce sont des crises d'épilepsie pour lesquelles une cause suspectée échappe aux moyens de diagnostic actuels. Elles peuvent survenir en l'absence de toute lésion cérébrale prouvée mais ne correspondent pas aux critères des épilepsies idiopathiques. Grâce au développement de nouvelles technologies d'exploration, le nombre de ces crises cryptogéniques est en constante diminution.
3. Les épilepsies idiopathiques sont principalement causées par une prédisposition génétique, qui peut être prouvée ou présumée, et qui survient sans lésion cérébrale. Elles se caractérisent par un examen neurologique normal et ne nécessitent pas d'autres examens que l'EEG.

La prédisposition génétique ne signifie pas que l'épilepsie est héréditaire. La transmission de l'épilepsie est complexe et ne se produit que dans un petit nombre de cas. De plus, la même anomalie peut avoir des conséquences différentes chez différentes personnes.

Les épilepsies symptomatiques ou cryptogéniques sont les plus courantes chez les adultes atteints d'épilepsie, représentant 70% des cas. Elles sont généralement partielles, ce qui signifie que les crises ne se produisent que dans une partie du cerveau. Les épilepsies idiopathiques d'origine génétique, quant à elles, représentent 30% des cas d'épilepsie chez les adultes. Elles sont généralement généralisées, c'est-à-dire que les

crises se produisent dans tout le cerveau, et sont souvent apparues dans l'enfance ou l'adolescence, liées à une atteinte cérébrale survenue dans l'enfance.

1.5.3 Classification des crises épileptiques

En 2017, la Ligue internationale contre l'épilepsie (LICE) a publié une nouvelle classification des crises épileptiques et des épilepsies. Cette classification est basée sur celle formulée en 1981, mais elle est révisée pour mieux répondre aux besoins de classification dans différents contextes cliniques. La nouvelle classification est hiérarchique et est conçue pour être applicable dans divers environnements mondiaux.

Il est recommandé d'adopter un diagnostic en trois niveaux pour prendre en compte le type de crises, le type d'épilepsie, le syndrome d'épilepsie et l'étiologie de l'épilepsie. Cette approche est proposée par la Ligue internationale contre l'épilepsie dans sa classification révisée de 2017 [17].

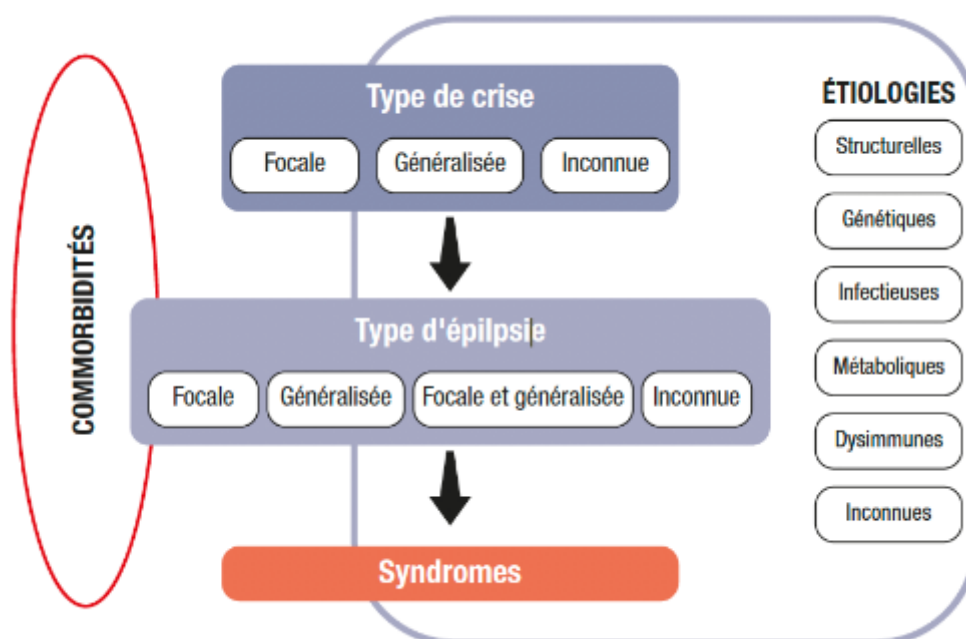


FIGURE 1.8 – Démarche de la classification des épilepsies. (Image extraite du site <https://www.cen-neurologie.fr>)

Types de crises d'épilepsie

Il est présumé que le clinicien a déjà identifié la crise comme étant une crise d'épilepsie et cette étape ne vise pas à développer un algorithme de diagnostic pour différencier la crise d'un événement non épileptique.

Types d'épilepsie

Cette étape permet de déterminer le type d'épilepsie, qui peut être l'épilepsie focale, l'épilepsie généralisée, l'épilepsie généralisée et focale combinée ou une catégorie non déterminée ou inconnue. Cette classification a été mise à jour en 2017 pour inclure la nouvelle catégorie d'épilepsie généralisée et focale combinée en plus des deux types de crises d'épilepsie connus depuis 1981.

1. Crises généralisées :

es crises généralisées sont provoquées par une décharge soudaine et simultanée des deux hémisphères cérébraux, qui se propage rapidement à travers les réseaux de neurones, souvent entraînant une perte de conscience.

Les enregistrements d'EEG sont utilisés pour détecter les décharges de pointes, polypointes, pointes-ondes ou polypointes-ondes bilatérales. Ces décharges sont synchrones et symétriques sur les deux hémisphères et peuvent être considérées comme des marqueurs de l'épilepsie. La figure 1.9 montre des exemples de ces formes d'EEG.

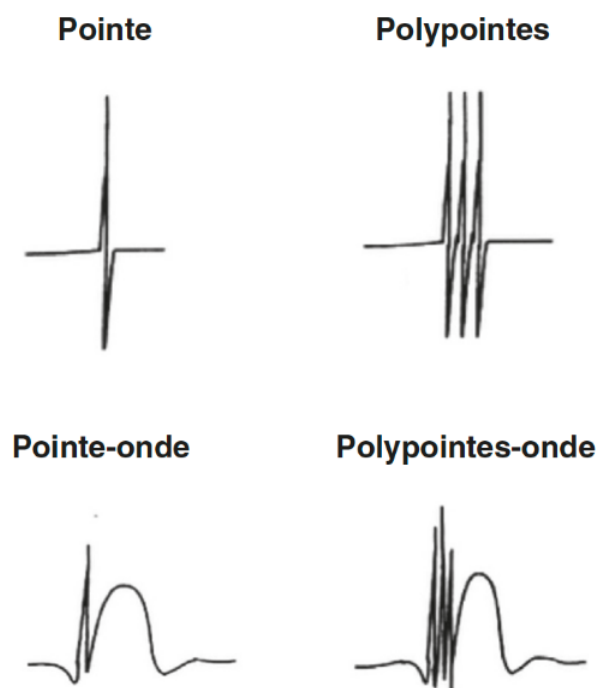


FIGURE 1.9 – Différents graphoéléments paroxystiques visibles à l'EEG. (Image extraite du site <https://www.quizlet.com>)

De nombreux types de crises sont inclus dans cette catégorie, à savoir les absences typiques et atypiques, les crises myocloniques, cloniques, toniques, tonico-cloniques et les crises atoniques.

- La crise d'absence est caractérisée par une perte de contact immédiate avec l'environnement pendant quelques secondes, accompagnée de signes tels que le scintillement des paupières et les mouvements de la bouche, comme illustré dans la figure 1.10. Après la crise, la personne touchée reprend généralement ses activités normales. Les enfants sont les plus susceptibles de souffrir de ce type de crise.
- Les crises myocloniques sont causées par une activité électrique anormale dans la région du cerveau qui contrôle les mouvements. Elles se manifestent par des secousses musculaires intenses et involontaires qui affectent différentes parties du corps, telles que les jambes, les bras, le tronc et le cou. Elles peuvent durer quelques instants et entraîner des chutes, mais ne causent généralement pas de perte de conscience. Ces crises sont également caractérisées par une activité électrique spécifique enregistrée sur l'EEG, appelée poly-pointes et pointes-ondes généralisées.




FIGURE 1.10 – Épilepsie d'absence. (Image extraite du site <https://www.cen-neurologie.fr>)

- es crises cloniques sont des crises caractérisées par des spasmes récurrents des membres associés à une perte de conscience. Elles sont dues à un déséquilibre au niveau des synapses excitateurs et inhibiteurs dans le cerveau, entraînant une décharge sur le cortex. Les principaux symptômes sont la perte de conscience, les convulsions plus ou moins violentes, les yeux réversés et la cyanose. La crise dure généralement entre 10 et 30 secondes. Contrairement aux crises myocloniques, les spasmes des crises cloniques sont rythmés et plus violents. Après la crise, il peut y avoir une phase de coma post-traumatique.
- La crise tonique se caractérise par une hyperactivité paroxystique d'un groupe de neurones, provoquant une chute soudaine du sujet, une perte de conscience et une contraction musculaire soutenue. Cela peut également entraîner une apnée, une cyanose et une hypersécrétion bronchique et salivaire. Il est possible que la personne touchée se morde le bord latéral de la langue pendant la crise.
- Les crises atoniques, également appelées crises astatiques, sont caractérisées par une perte brutale de tonus musculaire et une chute soudaine des jambes. La personne touchée perd son tonus musculaire, s'effondre par terre et peut subir des spasmes. Cette crise dure moins de 15 secondes et la personne redevient rapidement alerte. Elle est plus fréquente chez les enfants, mais peut également toucher les adultes.

La crise tonico-clonique est également appelée "grand mal". Elle survient de manière soudaine, sans avertissement préalable. Cette crise se compose de trois phases : la phase tonique, la phase clonique et la phase post-critique. La phase tonique est caractérisée par une contraction musculaire intense et prolongée, suivie de la phase clonique où la personne subit des convulsions musculaires rythmiques. La phase post-critique est une période de récupération pendant laquelle le patient peut ressentir de la confusion ou de la somnolence.

La crise tonico-clonique, également appelée « grand mal », est la plus impressionnante des crises épileptiques pour l'entourage du patient. Elle se déroule en trois phases distinctes : la phase tonique, la phase clonique et la phase post-critique. La première phase dure de 10 à 20 secondes et est marquée par

une perte de conscience immédiate, une raideur musculaire généralisée et des contractions. Des signes tels qu'une mâchoire crispée, un arrêt de la respiration, une présence d'écume sur la bouche, une augmentation du rythme cardiaque et de la pression sanguine peuvent également se produire. La deuxième phase, la phase clonique, dure environ 30 secondes et est caractérisée par des spasmes rapides des quatre membres. La phase post-critique, ou résolutive, est la dernière phase et peut durer de quelques minutes à quelques heures. Cette phase est considérée comme une phase de relaxation et de prolongement dans le sommeil. Pendant cette phase, la personne atteinte peut perdre le contrôle de sa vessie et de ses intestins. Elle reprendra lentement sa conscience et pourra sembler confuse, déprimée ou somnolente. La durée totale de la crise est d'environ 5 à 10 minutes.




FIGURE 1.11 – Différentes phases de la crise tonico-clonique avec le signal EEG de chaque phase. (Image extraite du site <https://www.unifr.ch>)

2. Crises focales ou crises partielles

Les crises focales se produisent dans une région spécifique d'un hémisphère cérébral en raison d'une activité électrique anormale ou d'une décharge paroxystique localisée. Cependant, dans certaines situations, la crise peut se propager à l'autre hémisphère plus tard au cours de la crise, ce qui est appelé une généralisation secondaire de type tonico-clonique.

Les crises focales se manifestent par des symptômes spécifiques qui varient en fonction de la région du cerveau affectée. Le diagnostic se fait principalement par l'examen clinique et les résultats de l'EEG qui révèlent des décharges épileptiformes focales. Ces crises sont caractérisées par leur brièveté, leur aspect paroxystique et la stéréotypie de leurs manifestations. Il existe trois types de crises focales, qui se différencient selon la conscience et la motricité. Les crises focales peuvent évoluer vers des crises tonico-cloniques bilatérales.

— Les crises focales sans altération de la conscience : Les crises focales avec conscience préservée, autrefois appelées "crises partielles simples", sont caractérisées par une absence de modification de la conscience chez la personne

atteinte. Elle reste consciente et peut décrire la crise de manière précise. Les symptômes ressentis dépendent de la région affectée et peuvent inclure des sensations physiques telles que des picotements ou des odeurs étranges, ainsi que des symptômes subjectifs tels que des sentiments de peur, des hallucinations ou une impression de déjà-vu.

- Les crises focales avec altération de la conscience : Les crises partielles complexes, autrefois appelées « crises partielles complexes », se caractérisent par une altération de la conscience et/ou une amnésie immédiate. La personne atteinte subit un arrêt moteur où elle reste immobile, regarde dans le vide, indifférente aux sollicitations extérieures, et effectue des gestes spontanés dont elle n'a pas conscience (marcher au hasard, taper un objet avec la main, claquer des lèvres). Après la crise, des symptômes tels que la confusion, des étourdissements, des maux de tête, de la fatigue ou des palpitations peuvent survenir.
- Les crises focales peuvent évoluer vers une crise bilatérale convulsive, qui était auparavant appelée « crise secondairement généralisée ». Cela se produit lorsque la décharge paroxystique de la crise focale se propage à l'ensemble du cortex. Il est important de souligner que la généralisation peut prendre différentes formes et n'est pas limitée à la manifestation tonico-clonique.



FIGURE 1.12 – Crises partielles, à l'endormissement ou au réveil, chez un enfant de 8 ans. (Image extraite du site <https://www.realites-pediatriques.com>)

3. **Épilepsie Généralisée et Focale Combinée** Il existe un nouveau groupe de types d'épilepsie classés par la Ligue internationale contre l'épilepsie (LICE) en 2017. Il correspond aux patients souffrant de crises qui sont à la fois focales et généralisées. Le diagnostic est établi sur des critères cliniques et des résultats d'EEG. L'EEG peut montrer des décharges épileptiformes généralisées de pointes-ondes ainsi que des décharges focales entre les crises.
4. **Les crises non classées** Il existe des crises dont la classification comme généralisées ou focales n'est pas certaine en raison de nos connaissances actuelles. Ainsi, ces crises sont regroupées dans la catégorie des crises inconnues ou non classées.




FIGURE 1.13 – Définition des crises généralisées et des crises focales. (Image extraite du site <https://www.cen-neurologie.fr>)

syndrome d'épilepsie

On peut classer les épilepsies en fonction des syndromes épileptiques, qui correspondent à des groupes de caractéristiques spécifiques, incluant le type de crises, le type de maladies épileptiques, les caractéristiques de l'EEG et de l'imagerie, l'âge, les comorbidités associées, l'étiologie et le type de traitement. L'identification d'un syndrome épileptique est importante car elle permet de mieux comprendre l'épilepsie et d'adapter le traitement en conséquence.

Identifier un syndrome épileptique permet de diriger les recherches sur les causes de l'épilepsie, de choisir un traitement antiépileptique adapté, d'établir un pronostic de l'évolution de la maladie ainsi que d'évaluer la présence éventuelle de troubles psychiatriques ou cognitifs associés.

La partie suivante décrit certains des syndromes épileptiques les plus connus, tels que l'épilepsie-absence de l'enfant, l'épilepsie myoclonique juvénile, l'épilepsie avec crises tonico-cloniques du réveil, le syndrome de West et le syndrome de Lennox-Gastaut.

- **Épilepsie-absence de l'enfant** : Ce syndrome est une forme d'épilepsie généralisée d'origine génétique présumée qui touche généralement les enfants autour de l'âge de 6 ans. Les crises d'absence typiques sont le type de crise le plus fréquent et peuvent survenir jusqu'à 10 fois par jour. Il peut également être associé à d'autres types d'épilepsie, tels que les crises généralisées tonico-cloniques (rares et tardives dans l'évolution) et les crises myocloniques. Sur l'enregistrement électrique, on observe des décharges de pointes-ondes généralisées synchrones à 3 cycles/s, favorisées par l'hyperpnée. En termes de pronostic, il est possible d'arrêter le traitement après la puberté. Figure 1.14.
- **Épilepsie myoclonique juvénile** : Ce syndrome fait également partie des épilepsies généralisées d'origine génétique présumée et peut s'associer avec d'autres types de crises telles que les crises tonico-cloniques généralisées et les crises d'absences, mais les crises myocloniques matinales sont prédominantes. Il se manifeste généralement à l'adolescence. L'enregistrement EEG montre des bouffées




FIGURE 1.14 – Épilepsie absences typique chez un enfant de 6 ans. (bouffée de pointes-ondes à 3 Hz).
Image extraite du site <https://www.realites-pediatriques.com>)

de pointes-ondes généralisées synchrones, qui sont favorisées par la stimulation lumineuse intermittente (Voir Figure 1.15).

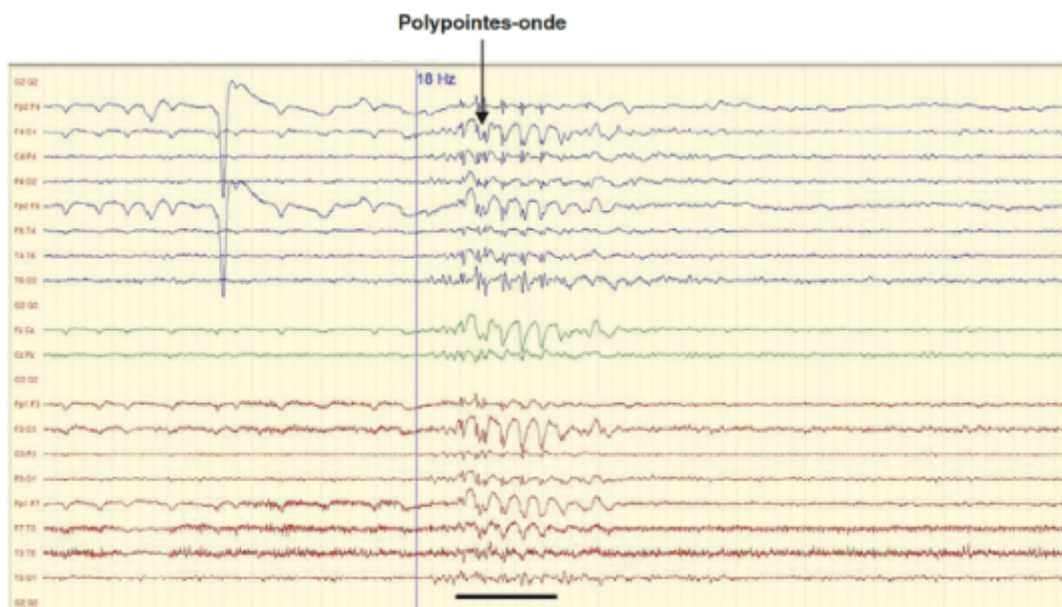



FIGURE 1.15 – Brève bouffée de polypointes-ondes généralisées synchrones. (Image extraite du site <https://www.cen-neurologie.fr>)


- **Épilepsie avec crises tonico-cloniques du réveil** : Ce type de syndrome affecte généralement les adolescents et les adultes, et appartient à la même famille que les précédents. Il est caractérisé par un seul type de crise : la crise généralisée tonico-clonique, qui peut être déclenchée par le manque de sommeil ou la

consommation d'alcool. L'enregistrement EEG montre des pointes-ondes et des pointes généralisées.

- **Syndrome de West** : Il s'agit d'une forme d'épilepsie qui se développe chez les nourrissons et appartient à la catégorie des épilepsies avec crises généralisées, focales ou de début inconnu. Les étiologies de cette maladie peuvent être diverses, telles que des facteurs génétiques ou structurels. Les spasmes en flexion sont le type de crise dominant. Les nourrissons de six mois sont généralement touchés et une régression psychomotrice ainsi qu'une activité électrique anormale à l'EEG (appelée hypsarythmie) sont également présentes.



(a) a



(b) b

FIGURE 1.16 – Syndrome de West chez un nourrisson de 6 mois (a) Salve de spasmes au réveil (b) Hypsarythmie au sommeil (Image extraite du site <https://www.realites-pediatriques.com>)

- **Syndrome de Lennox-Gastaut** : Il s'agit d'une encéphalopathie épileptique qui appartient au groupe des épilepsies avec crises généralisées, mais qui peut avoir

des causes diverses (génétiques, structurelles, métaboliques). Les crises associées sont de différents types : tonico-cloniques, absences atypiques, atoniques, toniques pendant le sommeil. Ce syndrome est associé à une régression psychomotrice et apparaît généralement à l'âge de 6 ans. Sur le plan EEG, on observe des pointes-ondes généralisées lentes de moins de 2,5 cycles/s avec des rythmes rapides pendant le sommeil.

1.6 BASES DE DONNÉES EEG

Les bases de données EEG sont utiles pour la recherche sur l'épilepsie. Elles fournissent aux chercheurs des données EEG de haute qualité avec des informations cliniques détaillées sur les patients. Cela permet aux chercheurs de mieux comprendre les mécanismes de l'épilepsie, d'identifier de nouveaux biomarqueurs pour prédire les crises, de développer de nouveaux traitements et d'améliorer les résultats des patients. Cependant, il y a un manque considérable de données EEG disponibles malgré le fait que l'EEG soit la modalité la plus courante pour mesurer l'activité électrique du cerveau.

Nous avons utilisé deux bases de données internationales pour cette étude, qui présentent différentes conditions d'enregistrement, telles que le nombre d'électrodes crâniennes utilisées, le sexe et l'âge des patients, ainsi que le type de crises, etc. Nous avons inclus la base de données CHB-MIT et la base de données TUH.

1.6.1 La base de données CHB-MIT

La base de données "CHB-MIT" contient des enregistrements d'EEG intracrânien de 23 patients pédiatriques atteints d'épilepsie réfractaire évalués pour une intervention chirurgicale à l'Hôpital des enfants de Boston. Il y a 24 cas, comprenant 5 garçons âgés de 3 à 22 ans, 17 filles et un sujet de sexe inconnu âgé de 1,5 à 19 ans. Cette base de données a été développée en collaboration avec des chercheurs du MIT et est disponible gratuitement en ligne via la base de données physiologiques "Physionet" sous le nom "CHB-MIT". Le lien pour y accéder est <https://physionet.org/content/chbmit/1.0.0/>. [18].

La base de données CHB MIT contient 686 fichiers d'enregistrement EEG crânien, dont 198 ont des crises d'épilepsie. Les signaux EEG ont été enregistrés simultanément sur 23 ou 24/26 chaînes différentes, selon le montage bipolaire du système international de Jasper 10/20. Ils ont été enregistrés à une fréquence de 256 Hz pour réduire les bruits indésirables, avec une résolution de 16 bits, pendant 916 heures. Les données EEG ont été segmentées en enregistrements EEG d'une à quatre heures pour chaque sujet. Les experts en électroencéphalographie ont identifié et étiqueté le déclenchement et la durée de chaque crise, y compris différents types de crises comme la crise partielle simple (SP), la crise partielle complexe (CP), et la crise tonico-clonique généralisée (GTC).

Le tableau 1.1 présente les caractéristiques de base de la base de données. Pour éliminer les interférences électriques, la fréquence de la ligne électrique de 60 Hz a été supprimée à l'aide d'un filtre coupe-bande lors de toutes les expériences. En outre, pour réduire les composantes de fréquence plus élevées et les artefacts musculaires, un filtre passe-bas Butterworth bidirectionnel à réponse impulsionnelle infinie (IIR) d'ordre 5 avec une fréquence de coupure de 42 Hz a été appliqué à chaque canal.

Il existe deux types d'enregistrements EEG : ceux sans crise qui ne montrent aucun événement épileptique, et ceux de crises qui révèlent au moins une crise épileptique.

Patient	Sexe	Age	Type de crise	Nbr de canaux	Durée du set	Nombre de crises
Chb 01	F	11	SP, CP	23	40h 55min	7
Chb 02	M	11	SP, CP, GTC	23	35h 26min	3
Chb 03	F	14	SP, CP	23	38h 00min	7
Chb 04	M	22	SP, CP, GTC	23	156h 06min	4
Chb 05	F	7	CP, GTC	23	39h 00min	5
Chb 06	F	1.5	CP, GTC	23	67h 13min	10
Chb 07	F	14.5	SP, CP, GTC	23	67h 05min	3
Chb 08	M	3.5	SP, CP, GTC	23	20h 00min	5
Chb 09	F	10	CP, GTC	23	68h 27min	4
Chb 10	M	3	SP, CP, GTC	23	50h 02min	7
Chb 11	F	12	SP, CP, GTC	23	34h 19min	3
Chb 12	F	2	SP, CP, GTC	23/25/24	24h 09min	40
Chb 13	F	3	SP, CP, GTC	23/20/18	33h 00min	12
Chb 14	F	9	CP, GTC	23	26h 00min	8
Chb 15	M	16	SP, CP, GTC	26/32	40h 00min	20
Chb 16	F	7	SP, CP, GTC	23/18	19h 00min	10
Chb 17	F	12	SP, CP, GTC	23/18	21h 00min	3
Chb 18	F	18	SP, CP	18/23	36h 03min	6
Chb 19	F	19	SP, CP, GTC	18/23	30h 32min	3
Chb 20	F	6	SP, CP, GTC	23	28h 02min	8
Chb 21	F	13	SP, CP	23	33h 23min	4
Chb 22	F	9	-	23	31h 00min	3
Chb 23	F	6	-	23	21h 29min	7
Chb 24	-	-	-	23	-	16

TABLE 1.1 – Caractéristiques des différents patients de la base de données CHB-MIT scalp EEG

1.6.2 La base de données TUH

Le corpus TUH est la plus grande base de données accessible au public dans le monde pour les enregistrements EEG. Il a été collecté entre 2002 et 2020 au Temple University Hospital, un hôpital de recherche et d'enseignement. Cette base de données contient plus de 25 000 enregistrements EEG provenant de plus de 14 000 sujets, de tous âges et sexes. Les enregistrements ont été effectués en utilisant le système international 10-20 de Jasper, avec une résolution de 16 bits et une fréquence d'échantillonnage variant de 250 à 1024 Hz. Tous les signaux EEG ont été rééchantillonnés à 250 Hz pour cette étude, et les enregistrements EEG multicanaux avec plusieurs canaux allant de 20 à 128 font référence aux signaux bruts.

Dans cette étude, nous avons utilisé le corpus TUEP V1.0.0. Ce corpus contient des enregistrements EEG de 100 patients épileptiques et 100 patients non épileptiques, ainsi que des notes du neurologue pour chaque patient. Il y a plus de 1799 fichiers provenant de 570 sessions de 200 patients, dont 1473 fichiers dans 436 sessions de 100 patients sont épileptiques et 326 fichiers dans 134 sessions de 100 patients ne sont pas épileptiques. Les signaux EEG ont été enregistrés avec différents types de crises, tels que la crise partielle simple, la crise partielle complexe, la crise focale, la crise généralisée, la crise d'absence, la crise tonique, la crise clonique et la crise tonico-clonique. [19].

1.7 CONCLUSION

L'épilepsie est une pathologie cérébrale résultant de diverses manifestations neuronales. L'examen d'électroencéphalogramme (EEG) est essentiel en neurologie pour surveiller et évaluer l'activité du système nerveux. Cette méthode utilise des électrodes placées sur des zones précises du cuir chevelu humain, conformément au système international de Jasper 10-20, pour suivre l'activité électrique du cerveau. L'EEG permet de détecter les crises épileptiques caractérisées par des ondes, des pointes ondes, des poly-

pointes ondes, etc., et d'identifier les sites affectés tout en suivant l'évolution temporelle et spatiale des anomalies.

Dans ce chapitre, nous avons étudié la structure et le fonctionnement du système nerveux, en examinant les fonctions des neurones et du cerveau pour comprendre les signaux électroencéphalographiques (EEG) liés à la fonction cérébrale et diagnostiquer des pathologies telles que l'épilepsie. Nous avons également décrit la base de données qui a été traitée dans le cadre de cette étude.

L'analyse de l'activité électrique du cerveau se réalise à l'aide d'instruments tels que l'EEG, permettant la détection de décharges paroxystiques dans le signal électrique cérébral. Le prochain chapitre sera consacré aux techniques de traitement numérique du signal, en particulier les méthodes temps-fréquence quadratiques, qui sont très utiles dans ce domaine.

MÉTHODES D'ANALYSE TEMPS-FRÉQUENCE

2

2.1 INTRODUCTION

L'électroencéphalogramme (EEG) est un outil essentiel pour l'étude et le diagnostic des troubles neurologiques, notamment l'épilepsie, car il fournit des informations précieuses sur les différents états physiologiques du cerveau. Les signaux EEG anormaux ou pathologiques peuvent montrer un comportement non-stationnaire, tels que des pointes, des poly-pointes, des ondes pointues et des ondes lentes, qui peuvent être spécifiques aux patients atteints d'épilepsie. Les neurologues qualifiés examinent généralement les signaux EEG visuellement pour identifier les troubles neurologiques, mais cette méthode est limitée car elle est fastidieuse, chronophage, coûteuse et peut entraîner des interprétations ambiguës ou des désaccords entre les experts, surtout lorsque le nombre d'électrodes augmente.

Le traitement du signal consiste à extraire des informations utiles à partir du signal en le transformant à l'aide de techniques permettant de mieux comprendre les informations qu'il contient. De nombreuses techniques ont été proposées pour analyser les composants des signaux et quantifier leurs informations.

Pour comprendre le comportement et la dynamique des milliards de neurones interconnectés à partir du signal EEG, différentes techniques de traitement du signal sont nécessaires. Le signal EEG est dynamique, instable et non-stationnaire, présentant des caractéristiques significatives non-linéaires et non-gaussiennes. L'analyse temps-fréquence est une solution optimale et puissante pour étudier les signaux non-stationnaires, car elle permet de caractériser l'énergie de l'EEG et d'autres signaux dans le domaine temporel et dans le domaine fréquentiel.

Ce chapitre a pour objectif d'introduire les connaissances de base de l'analyse temps-fréquence. Nous commencerons par expliquer la notion de stationnarité, puis nous montrerons que l'analyse de Fourier n'est pas adaptée pour étudier les signaux non-stationnaires. Enfin, nous examinerons les différentes classes de l'analyse temps-fréquence, en abordant leurs avantages et inconvénients respectifs.

2.2 DÉFINITION DE LA STATIONNARITÉ

Un signal est considéré comme stationnaire s'il peut être décomposé en une somme discrète de sinusoides dans le cas déterministe, ou si ses propriétés statistiques ne varient pas au cours du temps dans le cas aléatoire. Les signaux non-stationnaires se caractérisent donc par une dépendance temporelle variable de leur contenu spectral.

En d'autres termes, un signal non-stationnaire est défini par des propriétés statistiques qui varient dans le temps ou par une durée d'existence limitée par rapport à la durée d'observation [20].

2.3 LES CARACTÉRISTIQUES DU SIGNAL EEG

Le signal EEG présente des caractéristiques spécifiques qui rendent son interprétation complexe. Pour développer et concevoir une technique efficace de traitement des signaux EEG, il est essentiel de définir ces propriétés. Les propriétés les plus importantes sont brièvement décrites ci-dessous.

2.3.1 Non-stationnarité et la stochastique du signal

L'activité neuronale du cerveau peut varier dans sa structure et les charges et décharges neuronales d'une même région du cuir chevelu peuvent changer en intensité au fil du temps [21]. Les différents états physiologiques du cerveau, comme l'épilepsie ou les stades de sommeil, ont un impact sur les caractéristiques statistiques des signaux EEG, ce qui entraîne une variation temporelle des paramètres statistiques. En conséquence, le signal EEG est considéré comme non-stationnaire.

2.3.2 Faible rapport signal/bruit (SNR)

En raison de la conductivité des électrodes sur le cuir chevelu qui est affectée par les mouvements du corps, le clignotement des yeux, l'activité musculaire et d'autres facteurs environnementaux dynamiques, les signaux EEG présentent généralement un faible rapport signal/bruit (SNR).

2.3.3 Non-linéarité du signal EEG

Même si le cerveau humain est un système complexe et non linéaire, il est possible de représenter les signaux EEG qui en résultent à l'aide d'un modèle linéaire. Cependant, des études ont démontré que les signaux EEG s'adaptent mieux aux modèles non linéaires [22].

2.4 NÉCESSITE DE L'ANALYSE TEMPS-FRÉQUENCE

2.4.1 Analyse de Fourier

Un signal est enregistré en fonction du temps, ce qui permet d'obtenir une vue chronologique des variations des paramètres du système. Cependant, il est également possible de représenter un signal dans le domaine fréquentiel, en indiquant la présence et les caractéristiques des différentes composantes fréquentielles du signal. Figure 2.1 illustre un signal non-stationnaires dans son domaine temporel.

L'analyse de Fourier est une technique mathématique fondamentale pour comprendre les signaux périodiques. Elle permet de représenter un signal dans le domaine fréquentiel en indiquant la présence de différentes composantes fréquentielles du signal. La transformée de Fourier est la méthode qui permet de passer d'un signal dans le domaine temporel à un signal dans le domaine fréquentiel comme exprimé par 2.1.




FIGURE 2.1 – Analyse temporel d'un signal non-stationnaire

$$S(f) = \mathcal{F}_{t \rightarrow f} s(t) = \int_{-\infty}^{+\infty} s(t) e^{-j2\pi f t} dt \quad (2.1)$$

La transformée de Fourier inverse, quant à elle, permet de retrouver le signal d'origine à partir de sa représentation dans le domaine fréquentiel. La formule de cette transformée inverse est donnée par 2.2 ;

$$s(t) = \mathcal{F}_{f \rightarrow t}^{-1} S(f) = \int_{-\infty}^{+\infty} S(f) e^{-j2\pi f t} df \quad (2.2)$$

La représentation d'un signal dans le domaine fréquentiel, est une approche courante pour interpréter la nature d'un signal. Cette représentation utilise la transformée de Fourier du signal $S(f)$, qui permet de visualiser les différentes composantes fréquentielles du signal. En pratique, il est courant de calculer le carré de la magnitude de la transformée de Fourier, ce qui facilite l'interprétation visuelle de la représentation fréquentielle.

Cependant, la représentation fréquentielle ne peut pas fournir d'informations sur les caractéristiques temporelles du signal, telles que la durée des composantes ou leurs lois de modulation de fréquence. Ces informations sont particulièrement importantes pour les signaux modulés en fréquence ou non-stationnaires, c'est-à-dire les signaux dont les propriétés statistiques varient dans le temps. Dans ces cas, il est nécessaire d'utiliser des techniques d'analyse plus avancées pour extraire ces informations temporelles.

Propriétés des signaux dans la représentation (t,f)

Les propriétés du signal représenté dans le domaine bidimensionnel (t,f) comprennent les éléments suivants :

- **Domaine temporel**
 - Durée, $T = t_{end} - t_{start}$ pour chaque composante du signal
 - Plages de temps et l'amplitude relatives à des transitoires entre t_{start} et t_{end} .
- **Domaine fréquentiel**
 - Bande passante $B = f_{max} - f_{min}$
 - Fréquence instantanée $f_i(t)$
 - Largeur de bande instantanée $B_i(t)$
 - Bande-passante instantanée totale du signal
- **Domaine temps-fréquence**
 - Fréquence instantanée

- Distribution d'énergie dans le plan temporel et fréquentiel
- Nombre de composantes dans le domaine (t,f)

2.4.2 Limitations des représentations temporelle et spectrale

La représentation temporelle d'un signal ne fournit pas toutes les informations sur son comportement fréquentiel. Les signaux non-stationnaires nécessitent des méthodes d'analyse spectrale pour obtenir des informations sur leur comportement fréquentiel. La densité spectrale de puissance est une méthode efficace pour représenter le contenu fréquentiel d'un signal, mais ne fournit pas d'informations sur la durée ou la localisation temporelle de chaque composante. La représentation spectrale d'un signal doit être complétée par d'autres méthodes d'analyse pour obtenir une vue d'ensemble du signal étudié.

Le caractère variable des propriétés statistiques des signaux non-stationnaires rend les représentations temporelle et spectrale peu adaptées à leur analyse. Afin d'obtenir une localisation temporelle des composantes spectrales d'un signal, il est nécessaire d'utiliser des techniques d'analyse temps-fréquence qui permettent d'identifier conjointement les informations dans les domaines temporel et fréquentiel [23, 24, 25, 26, 27].

L'analyse temps-fréquence présente de nombreux avantages, notamment en affichant les informations de fréquence dans le temps pour une interprétation simplifiée des signaux. Cette méthode est particulièrement utile pour les signaux EEG contenant des événements hautement localisés tels que des pointes et interruptions couramment observés lors de crises d'épilepsie. L'analyse temps-fréquence permet de visualiser le contenu énergétique d'un signal EEG, aidant à comprendre ses caractéristiques pour une meilleure analyse et un traitement approprié. Cependant, il est important de noter que certaines méthodes d'analyse temps-fréquence peuvent ne pas offrir une haute résolution simultanément dans les domaines temporel et fréquentiel. Il est crucial de sélectionner une représentation temps-fréquence appropriée en fonction des caractéristiques d'intérêt et de l'application.

2.5 REPRÉSENTATIONS TEMPS-FRÉQUENCE

Les représentations temps-fréquence (TFR) sont classées en trois catégories : linéaires, quadratiques et d'ordre supérieur. Nous examinerons maintenant les différents modèles de TFR utilisés dans la littérature pour modéliser l'EEG et évaluerons leur pertinence.

2.5.1 Les représentations temps-fréquence linéaire

Les représentations temps-fréquence (TFR) linéaires respectent le principe de linéarité. Cela signifie que si un signal $x(t)$ est une combinaison linéaire de certaines composantes, alors le TFR de $x(t)$ sera également une combinaison linéaire du TFR de chaque composante. Ce principe est défini par l'équation de linéarité 2.5.1 [23].

$$\forall(\alpha_1, \alpha_2) \text{ et } \forall(e_1, e_2), H[\alpha_1 e_1 + \alpha_2 e_2] = \alpha_1 H[e_1] + \alpha_2 H[e_2]$$

Transformée de Fourier à temps-court (STFT)

La transformée de Fourier (TF) est un outil essentiel en traitement de signal. Elle permet de décomposer le signal en une combinaison de composantes harmoniques pon-

dérées à des fréquences fixes. Cette transformation est linéaire et réversible, et possède de nombreuses propriétés importantes. La formule de la transformée de Fourier d'un signal d'énergie finie $x(t)$ est donnée par l'équation 2.3.

$$X_x(f) = \int_{-\infty}^{+\infty} x(t).e^{-j2\pi ft} dt \quad (2.3)$$

En effet, la transformée de Fourier ne fournit pas d'informations temporelles sur les différentes composantes fréquentielles du signal, ce qui limite sa capacité à analyser les signaux non stationnaires qui varient dans le temps [28]. La TFCT est une technique couramment utilisée en traitement de signal pour analyser des signaux non stationnaires. Elle permet d'obtenir une représentation temps-fréquence d'un signal, en calculant la transformée de Fourier pour chaque fenêtre temporelle. Cela permet de suivre les variations de fréquence du signal au cours du temps et donc de mieux comprendre la dynamique du signal. Ainsi, la TFCT d'un signal $x(t)$ peut être calculée en utilisant l'équation 2.4.

$$STFT_x(t, f) = \int_{-\infty}^{+\infty} x(\tau)h^*(\tau - t)e^{-j2\pi f\tau} d\tau \quad (2.4)$$

avec $h(t)$ représente la fenêtre d'analyse utilisée pour découper le signal en segments courts, $h(\tau - t)$ représente une version retardée de la fenêtre d'analyse $h(t)$, qui est centrée autour du temps t , et τ est la variable de temps qui parcourt l'ensemble des temps dans l'intervalle $(-\infty, \infty)$, sur lequel est effectuée la convolution entre le signal d'entrée $x(t)$ et la fenêtre d'analyse $h(t)$.


La transformée de Fourier à court terme (TFCT), également connue sous le nom de transformée de Fourier à fenêtre glissante (STFT), est utilisée pour l'analyse de signaux quasi-stationnaires. Elle suppose que le signal est presque stationnaire pendant toute la durée de la fenêtre d'analyse, qui est glissée le long de l'axe du temps. Cette transformée est utilisée pour déterminer les fréquences et les phases des sections locales de signaux qui varient le long de l'axe des temps. Elle est largement utilisée dans le domaine de l'électroencéphalographie pour l'analyse de l'activité cérébrale.

Cependant, un inconvénient majeur de la STFT est la taille de la fenêtre d'analyse $h(t)$. Il est important de trouver un compromis entre une bonne sélection temporelle et une bonne résolution fréquentielle. Ainsi, une bonne résolution temporelle nécessite une fenêtre de courte durée tandis qu'une bonne résolution fréquentielle nécessite une fenêtre de longue durée.

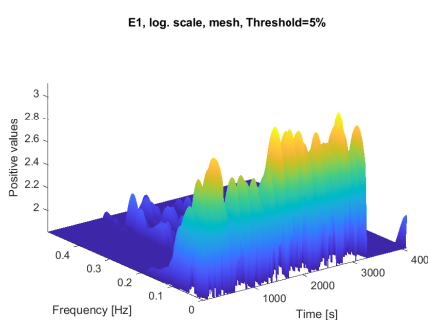
La Figure 2.2 présente des tracés de contour et tridimensionnels de la STFT obtenue à partir d'enregistrements EEG d'un patient épileptique de la base de données CHB-MIT. Différentes tailles de fenêtres d'analyse "Hamming" ont été utilisées, de 1 jusqu'à 4 secondes, afin d'obtenir une meilleure résolution dans le plan temps-fréquence. La Figure 2.2 (b) montre une amélioration de la résolution temporelle avec des périodes de fenêtres glissantes de 2 secondes, tandis que la Figure 2.2 (a) présente une mauvaise résolution fréquentielle et que la Figure 2.2 (c) présente une mauvaise résolution temporelle. Ces figures illustrent clairement l'effet de la longueur de la fenêtre d'analyse sur les STFT obtenus. Cependant, il est difficile d'obtenir une bonne localisation simultanément dans les domaines temporel et fréquentiel car la STFT ne dépend que d'une seule fenêtre, et cette limitation est liée au principe d'incertitude de Heisenberg [29, 30], qui décrit l'impossibilité de connaître avec suffisamment de précision la localisation temporelle et fréquentielle d'un signal. Ce principe est formulé par la relation suivante 2.5 :

$$\sqrt{\Delta t^2} \sqrt{\Delta f^2} \geq \frac{E_x}{4\pi} \quad (2.5)$$


L'équation 2.5 exprime la relation entre la résolution temporelle Δt et la résolution fréquentielle Δf d'un signal. La résolution temporelle représente la précision avec laquelle on peut déterminer l'instant auquel une variation de signal se produit. Elle est liée à la taille de la fenêtre d'analyse utilisée pour déterminer les propriétés du signal, à savoir sa fréquence et son amplitude. Une fenêtre de petite taille permet une résolution temporelle élevée, mais une résolution fréquentielle plus faible, car elle ne permet pas d'analyser les variations de fréquence lentes. La résolution fréquentielle représente la précision avec laquelle on peut déterminer la fréquence d'un signal. Elle est liée à la durée de la fenêtre d'analyse. Une fenêtre de grande taille permet une résolution fréquentielle élevée, mais une résolution temporelle plus faible, car elle ne permet pas d'analyser les variations de fréquence rapides.




(a) Durée de la fenêtre = 1 s



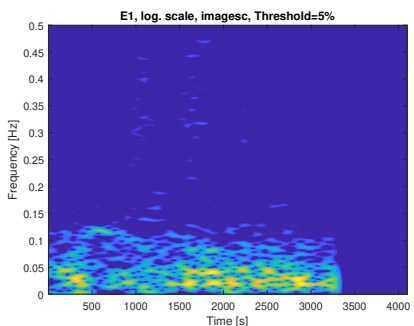
(b) Durée de la fenêtre = 1 s




(c) Durée de la fenêtre = 2 s



(d) Durée de la fenêtre = 2 s



(e) Durée de la fenêtre = 4 s



(f) Durée de la fenêtre = 4 s

FIGURE 2.2 – STFT du signal EEG contenant la crise épileptique à différentes longueurs de fenêtre

D'autre part, il a été prouvé que la fenêtre gaussienne est la seule fenêtre qui ren-contre la limite inférieure du principe de Heisenberg [29, 31].

Transformée en ondelettes

La transformée en ondelettes (WT) est une autre distribution TF linéaire qui permet de représenter un signal en fonction du temps et de l'échelle. Contrairement à la STFT, la WT utilise une fenêtre de longueur variable en mettant à l'échelle l'axe de la fenêtre, plutôt qu'une fonction de fenêtre de durée fixe. La WT d'un signal $x(t)$ est définie par l'équation suivante (référéncée dans [23, 26]) :

$$WT_x(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} x(t) \frac{1}{\sqrt{|a|}} \Psi^* \left(\frac{t-b}{a} \right) dt \quad (2.6)$$

où a et b sont respectivement l'échelle et le décalage temporel, $\Psi(t)$ est la fonction d'ondelette choisie et $*$ représente l'opérateur de conjugaison complexe. La WT permet d'obtenir une bonne résolution en temps et en échelle, mais elle peut être coûteuse en termes de calcul et présente des artefacts de bordure qui doivent être pris en compte dans l'analyse.

La WT est obtenue en convoluant un signal $x(t)$ avec une fenêtre $g(t)$ qui est décalée temporellement de « b » et étirée d'un facteur d'échelle « a ». Le choix de « a » permet d'obtenir une représentation TF similaire à la STFT, où « a » est inversement proportionnel à la fréquence. Ainsi, la WT offre une résolution spectrale élevée pour les basses fréquences mais une résolution temporelle faible, tandis que pour les hautes fréquences, la WT offre une résolution temporelle élevée, ce qui permet de mieux représenter les singularités. Cependant, la résolution spectrale est faible pour les hautes fréquences, ce qui oblige d'assurer un compromis entre la résolution temporelle et fréquentielle [23].

2.5.2 Représentations temps-fréquence quadratiques

Les méthodes de représentation temps-fréquence linéaires, telles que la transformée de Fourier et la transformée en ondelettes, sont largement utilisées dans le traitement du signal. Cependant, l'interprétation de ces représentations peut être difficile car les concepts de linéarité et d'énergie sont difficiles à concilier. Par exemple, une forte oscillation dans une plage de fréquences donnée peut conduire à une forte concentration d'énergie, ce qui peut masquer les activités plus faibles à des fréquences voisines. Les méthodes de représentation temps-fréquence quadratiques, telles que la distribution de Wigner-Ville, permettent de surmonter ce problème en fournissant une représentation plus fine de la distribution d'énergie en fonction du temps et de la fréquence [23]. Ces méthodes sont particulièrement utiles pour l'analyse de signaux physiologiques, tels que l'électroencéphalographie (EEG), qui présentent souvent des activités non linéaires et non stationnaires. En fournissant une représentation plus précise de la distribution d'énergie, les méthodes quadratiques peuvent aider à identifier des événements informatifs dans les signaux physiologiques, ce qui peut avoir des implications cliniques importantes en termes d'aide au diagnostic médical.

L'énergie d'un signal $x(t)$ à énergie finie s'exprime par 2.7 :

$$E_x = \int_{-\infty}^{+\infty} |x(t)|^2 dt = \int_{-\infty}^{+\infty} |X(f)|^2 df \quad (2.7)$$

Avec $|x(t)|^2$ et $|X(f)|^2$ constituent des densités d'énergie temporelle et spectrale du signal $x(t)$, respectivement. Une distribution temps-fréquence énergétique $T_x(t, f)$ combine le concept de puissance instantanée et le concept de densité spectrale d'énergie en une seule distribution d'énergie conjointe.

L'interprétation énergétique du signal peut également être exprimée à travers les propriétés marginales présentées par les équations 2.8 et 2.9.

$$\int_{-\infty}^{+\infty} T_x(t, f) df = p_x(t) = |x(t)|^2 \quad (2.8)$$

$$\int_{-\infty}^{+\infty} T_x(t, f) dt = P_x(f) = |X(f)|^2 \quad (2.9)$$

Ces équations montrent que les densités d'énergie unidimensionnelles $p_x(t)$ et $P_x(f)$ sont des densités marginales de la distribution temps-fréquence $T_x(t, f)$. De plus, l'énergie du signal peut être déterminée en intégrant $T_x(t, f)$ sur l'ensemble du plan temps-fréquence [32].

La représentation temps-fréquence corrélative combine la corrélation temporelle $r_x(\tau)$ et la corrélation fréquentielle $R_x(\nu)$. Les représentations temps-fréquence quadratique sont donc interprétables en termes de corrélation [23]. Les propriétés marginales sont exprimées par les équations 2.10 et 2.11.

$$T_x(\tau, 0) = r_x(\tau) = \int_{-\infty}^{+\infty} x(t + \tau)x^*(t) dt \quad (2.10)$$

$$T_x(0, \nu) = R_x(\nu) = \int_{-\infty}^{+\infty} X(f + \nu)X^*(f) df \quad (2.11)$$

La variable τ représente le décalage temporel et la variable ν représente le décalage fréquentiel dans la corrélation $T_x(\tau, \nu)$ [23].

En conservant la notion de distribution de l'énergie du signal dans le plan temps-fréquence, on peut exprimer la forme générale des représentations temps-fréquence quadratiques comme suit :

$$TFR_x(t, f) = \iint_{-\infty}^{+\infty} K(\nu, \tau; t, f)x(\tau)x^*(\nu) d\nu d\tau \quad (2.12)$$

$$TFR_x(t, f) = \iint_{-\infty}^{+\infty} \hat{K}(\nu, \tau; t, f)X(\tau)X^*(\nu) d\nu d\tau \quad (2.13)$$

où $x(t)$, $x(\tau)$, $x^*(\nu)$ (avec $(X(f)), (X(\tau)X^*(\nu))$) est le signal analytique du signal, et $K(\nu, \tau; t, f)$ ($\hat{K}(\nu, \tau; t, f)$) représentent le noyau temps-fréquence.

Les représentations temps-fréquence qui respectent le diagramme de covariance du groupe des translations en temps et fréquence, et qui sont définies par l'équation 2.12, sont classées dans la classe de Cohen, représentée par l'équation 2.14.

$$TFR_x(t, f) = \iint_{-\infty}^{+\infty} e^{2i\pi\xi(s-t)} f(\xi, \tau) z(s + \frac{\tau}{2}) z^*(s - \frac{\tau}{2}) e^{-2i\pi f\tau} d\xi ds d\tau \quad (2.14)$$

où $f(\xi, \tau)$ est une fonction de pondération, ou également appelé la fonction noyau de la distribution vérifiant $f(\xi, \tau) = f^*(-\xi, -\tau)$ pour garantir le caractère réel de $TFR_x(t, f)$.

Les distributions temps-fréquence les plus connues en traitement du signal sont la transformée de Wigner-Ville, la transformée de Rihaczek, la transformée de Margenau-Hill, la distribution de Page, ainsi que les distributions de Choi-Williams. Chacune de ces distributions est caractérisée par une fonction de pondération $f(\zeta, \tau)$ différente. Dans la section suivante, nous allons présenter ces distributions avec leur fonction de pondération, en commençant par la forme quadratique de la transformée de Fourier à court terme.

Spectrogramme

Le spectrogramme est une représentation tridimensionnelle qui permet de visualiser la variation de la densité spectrale ou de la puissance d'un signal en fonction du temps. Il est dérivé de la transformée de Fourier à court terme (STFT) sous sa forme quadratique [33], et est exprimé par (2.15) :

$$SP_x(t, f) = |STFT_x(t, f)|^2 \quad (2.15)$$

Comme pour la STFT, le spectrogramme est soumis au principe d'incertitude de Heisenberg, ce qui implique un compromis entre la résolution temporelle et la résolution fréquentielle. En d'autres termes, augmenter la résolution temporelle entraîne une diminution de la résolution fréquentielle, et vice versa. La figure 2.3 présente des tracés de contour et des tracés tridimensionnels de spectrogrammes d'enregistrements EEG provenant d'un patient épileptique de la base de données CHB-MIT. La même fenêtre d'analyse temporelle et les mêmes tailles ont été utilisées pour la STFT afin d'obtenir la meilleure résolution possible dans le plan temps-fréquence.

La Figure 2.3 (b) du spectrogramme montre une amélioration de la résolution temporelle et fréquentielle avec des périodes de fenêtres glissantes de 2 secondes, tandis que les Figures 2.3 (a) et (c) présentent respectivement une mauvaise résolution fréquentielle et temporelle. Ces résultats illustrent l'importance de la longueur de la fenêtre d'analyse pour obtenir des spectrogrammes de qualité.

Cette représentation est une forme quadratique particulière qui peut être interprétée en termes d'énergie du signal. Cependant, elle ne satisfait pas les propriétés de marginalités [23].

Distribution de Wigner-Ville (WVD)

La distribution de Wigner-Ville a été développée en 1932 en mécanique quantique par Eugene Wigner, et introduite en traitement du signal par J. Ville en 1948. Elle permet de surmonter l'inconvénient majeur de la STFT et du spectrogramme, qui est de trouver un compromis entre les résolutions temporelle et fréquentielle.

La distribution de Wigner-Ville est une méthode d'analyse temps-fréquence qui est obtenue en appliquant la transformée de Fourier à la fonction d'auto-corrélation du signal. Cette méthode est exprimée par (2.16) [34].

$$WVD_x(t, f) = W_x(t, f) = \int_{-\infty}^{+\infty} x(t - \frac{\tau}{2}) \cdot x^*(t - \frac{\tau}{2}) e^{-j2\pi f\tau} d\tau \quad (2.16)$$

avec $x(t)$ est le signal à analyser, $W_x(t, f)$ est la distribution de Wigner-Ville du signal $x(t)$, qui est une fonction conjointe du temps t et de la fréquence f , $x^*(t)$ est le complexe conjugué de $x(t)$, τ est le temps de retard, f est la fréquence.

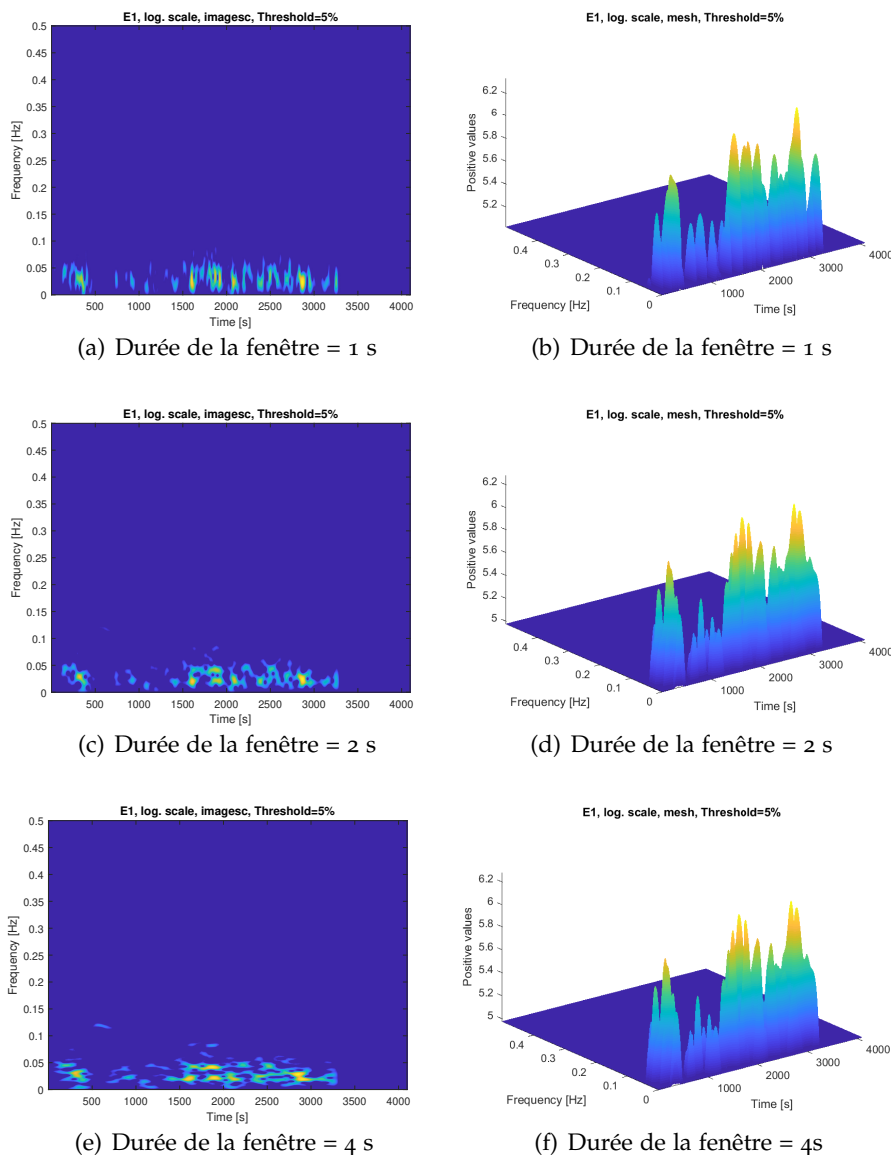


FIGURE 2.3 – Spectrogramme de signal EEG contenant la crise épileptique à différentes longueurs de fenêtre

Cette distribution peut également être obtenue si l'on impose à la fonction de pondération $f(\zeta, \tau)$ d'être indépendante des deux variables ζ et τ cela veut dire que $f(\zeta, \tau) = 1$.

Parmi toutes les représentations temps-fréquence énergétiques, la distribution de Wigner-Ville est considérée comme la plus basique et la plus populaire en traitement du signal en raison de sa capacité à satisfaire un grand nombre de propriétés mathématiques désirables.

La WVD est considérée comme une distribution temps-fréquence énergétique de base et populaire en traitement du signal, car elle satisfait de nombreuses propriétés mathématiques désirables et possède des performances supérieures à celles du spectrogramme. Elle est souvent utilisée comme point de départ pour explorer d'autres distributions temps-fréquence.

Propriétés de la distribution de Wigner-Ville Les propriétés les plus importantes de la distribution de Wigner sont les suivantes [35] :

- La distribution de Wigner est toujours à valeur réelle même si le signal est à valeur complexe, c'est-à-dire $WVD_x^*(t, f) = WVD_x(t, f)$.
- La WVD satisfait les propriétés de marginalités suivantes 2.17, 2.18.

La marginale en temps

$$\int_{-\infty}^{+\infty} W_x(t, f) df = |x(t)|^2 \quad (2.17)$$

La marginale en fréquence

$$\int_{-\infty}^{+\infty} W_x(t, f) dt = |X(f)|^2 \quad (2.18)$$

- La WVD satisfait la conservation de l'énergie

$$\iint_{-\infty}^{+\infty} W_x(t, f) dt df = \int |x(t)|^2 dt = \int |X(f)|^2 df = E_x \quad (2.19)$$

Avec E_x es l'énergie totale du signal $x(t)$

- La WVD n'est pas toujours positive.
- La WVD satisfait la covariance par le groupe des translations en temps et fréquence.
- La WVD satisfait la conservation du produit scalaire, appelée aussi unitarité ou Moyal :

$$\left| \int x(t)y^*(t) dt \right|^2 = \iint WVD_x(t, \nu) WVD_y(t, f) dt d\nu = \langle \langle W_x, W_y \rangle \rangle \quad (2.20)$$

où $\langle \langle W_x, W_y \rangle \rangle$ est le produit scalaire entre les distributions de Wigner W_x et W_y .

- Fréquence instantanée : La fréquence instantanée $f_x(t)$ d'un signal $x(t)$ est donnée par le moment d'ordre 1 de sa distribution temps-fréquence, $\frac{1}{2\pi} \frac{d}{dt} \Phi_x(t)$, où $\Phi_x(t)$ est la phase instantanée du signal $x(t)$ supposée analytique, comme exprimée en (2.21);

$$f_x(t) = \frac{1}{2\pi} \frac{d}{dt} \Phi_x(t) = \frac{\int f W_x(t, f) df}{\int W_x(t, f) df} \quad (2.21)$$

On peut également exprimer la fréquence instantanée comme $\frac{\int f W_x(t, f) df}{\int W_x(t, f) df}$.

- Retard de groupe : Le temps de propagation de groupe $T_x(f)$ du signal $x(t)$ est donné par le moment d'ordre 1 de sa distribution temps-fréquence, $\frac{1}{2\pi} \frac{d}{df} \Phi_x(t)$, où $\Phi_x(t)$ est la phase instantanée du signal $x(t)$ supposée analytique.

$$T_x(f) = \frac{1}{2\pi} \frac{d}{df} \Phi_x(t) = \frac{\int t W_x(t, f) dt}{\int W_x(t, f) dt} \quad (2.22)$$

On peut également exprimer le retard de groupe comme $\frac{\int t W_x(t, f) dt}{\int W_x(t, f) dt}$.

- Conservation du support du signal temporel et fréquentiel : Si $x(t) = 0$ pour tout $t \notin (t_1, t_2)$, alors $W_x(t, f) = 0$ pour tout $t \notin (t_1, t_2)$. De même, si $|X(f)| = 0$ pour tout $f \notin (f_1, f_2)$, alors $W_x(t, f) = 0$ pour tout $f \notin (f_1, f_2)$, comme exprimé en (2.23) & (2.24);

$$x(t) = 0, \forall t \notin (t_1, t_2) \longrightarrow W_x(t, f) = 0, \forall t \notin (t_1, t_2) \quad (2.23)$$

$$|X(f)| = 0, \forall f \notin (f_1, f_2) \longrightarrow W_x(t, f) = 0, \forall f \notin (f_1, f_2) \quad (2.24)$$

- Conservation des moments du signal : Les moments du signal sont conservés dans la distribution temps-fréquence. Plus précisément, pour tout entier positif n , on a $\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} t^n W_x(t, f) dt df = \int_{-\infty}^{+\infty} t^n |x(t)|^2 dt$ et $\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f^n W_x(t, f) dt df = \int_{-\infty}^{+\infty} f^n |Z(f)|^2 df$, comme exprimé en (2.25) & (2.26) ;

$$\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} t^n W_x(t, f) dt df = \int_{-\infty}^{+\infty} t^n |x(t)|^2 dt \quad (2.25)$$

$$\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f^n W_x(t, f) dt df = \int_{-\infty}^{+\infty} f^n |Z(f)|^2 df \quad (2.26)$$

La distribution de Wigner-Ville est une méthode de traitement de signal qui permet d'obtenir une résolution en temps et en fréquence du signal. Elle se caractérise par une grande concentration temps-fréquence et possède des propriétés intéressantes telles que la préservation du support de fréquence, la fréquence instantanée et le retard de groupe [35, 36, 37]. Cependant, la Wigner-Ville distribution (WVD) présente un inconvénient majeur en raison de sa nature quadratique et de l'existence de valeurs négatives. Les termes de termes croisés de nature oscillatoire sont inévitables en raison des phénomènes d'interférence entre les auto-termes du signal analysé. Cette énergie d'interférence n'est pas représentative du signal analysé, comme illustré dans la Figure 2.4. Par conséquent, le spectrogramme offre une meilleure résolution par rapport à la distribution Wigner-Ville (WVD) dans le plan temps-fréquence.

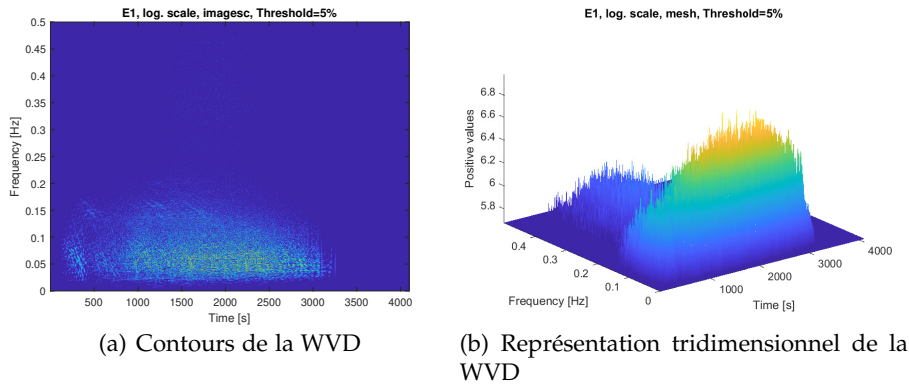


FIGURE 2.4 – WVD d'un signal EEG contenant la crise épileptique

Le terme d'interférence est réduit en annulant la partie négative du spectre et en doublant la partie positive pour préserver l'énergie. Cette technique de traitement est appelée la transformée en signal analytique, qui permet de séparer les différentes composantes de fréquence du signal EEG. En effet, la représentation du signal analytique ne contient que des fréquences positives, ce qui évite les termes d'interférences et améliore la résolution temps-fréquence.

La fonction d'ambiguïté La fonction d'ambiguïté (AF) est une fonction corrélative bi-dimensionnelle dépendant du délai temporel τ et de son dual dans le domaine fréquentiel Doppler ν . Elle a été introduite par Woodward [38] et est utilisée depuis longtemps dans les domaines du sonar et du radar. L'équation de la fonction d'ambiguïté est donnée par 2.27 :

$$AF_x(\tau, \nu) = \int_{-\infty}^{+\infty} x\left(t + \frac{\tau}{2}\right) \cdot x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi\nu t} dt \quad (2.27)$$

La fonction d'ambiguïté est utile pour décrire la résolution temporelle et fréquentielle des signaux.

Les fonctions de corrélation temporelle et spectrale sont utilisées pour simplifier l'équation de la fonction d'ambiguïté, comme exprimés dans (2.29) & (2.30), respectivement. La corrélation temporelle est notée $q_x(t, \tau)$ entre le signal et sa version retardée, tandis que $Q_x(f, \nu)$ est la corrélation spectrale. Ces fonctions sont utilisées pour dériver une forme alternative de la fonction d'ambiguïté, qui peut être plus facile à calculer et à interpréter. En utilisant ces fonctions de corrélation temporelle $q_x(t, \tau)$ et spectrale $Q_x(f, \nu)$, l'équation 2.27 devient :

$$AF_x(\tau, \nu) = \int_{-\infty}^{+\infty} q_x(t, \tau) e^{-j2\pi\nu t} dt = Q_x(f, \nu) e^{-j2\pi\tau f} df \quad (2.28)$$

avec $q_x(t, \tau)$ et $Q_x(f, \nu)$ sont exprimés respectivement comme suit :

$$q_x(t, \tau) = \int_{-\infty}^{+\infty} x(t + \frac{\tau}{2}) \cdot x^*(t - \frac{\tau}{2}) \quad (2.29)$$

$$Q_x(f, \nu) = \int_{-\infty}^{+\infty} X(f + \frac{\nu}{2}) \cdot X^*(f - \frac{\nu}{2}) \quad (2.30)$$

La fonction d'ambiguïté possède des propriétés marginales corrélées, est maximale à l'origine et a une valeur maximale égale à l'énergie du signal. Il est important de souligner que la distribution de Wigner-Ville et la fonction d'ambiguïté sont duales dans le sens où elles constituent une paire de transformées de Fourier. Cette dualité est exprimée par l'équation ??, où $WVD_x(t, f)$ représente la distribution de Wigner-Ville du signal $x(t)$.

$$AF_x(\tau, \nu) = \iint_{-\infty}^{+\infty} WVD_x(t, f) e^{-j2\pi(\nu t - \tau f)} dt df \quad (2.31)$$

Un signal temporel peut être représenté dans différents domaines, notamment le domaine de décalage temporel dans les variables (t, τ) , le domaine de fréquence doppler dans (ν, f) , l'ambiguïté (doppler-lag) dans (ν, τ) et le domaine temps-fréquence (Wigner) dans (t, f) . La Figure ?? fournit une illustration schématique de ces domaines de représentation.

Pseudo Distribution Wigner-Ville Lissée (SPWVD)

En exploitant la nature oscillatoire des termes croisés et pour réduire l'effet des artefacts de ces termes, on peut appliquer un double lissage séparable en temps et en fréquence, contrôlé par deux fenêtres indépendantes, temporelle et fréquentielle, représentées respectivement par les fonctions $g(t)$ et $H(f)$. Cela permet de construire la distribution de Pseudo Wigner-Ville Lissée (SPWVD) [39], définie par l'équation 2.32,

$$SPWVD_x(t, f) = W_x(t, f) = \int_{-\infty}^{+\infty} h(\tau) \int_{-\infty}^{+\infty} g(s - t) z(s + \frac{\tau}{2}) \cdot z^*(s - \frac{\tau}{2}) ds e^{-j2\pi\nu\tau} d\tau \quad (2.32)$$

où $z(t)$ est le signal analytique associé au signal réel $x(t)$ et g et h sont deux fenêtres paires et réelles, avec $h(0) = G(0) = 1$. La SPWVD est obtenue en effectuant une intégration sur les variables temporelle et fréquentielle, où la convolution entre deux fenêtres et la fonction d'autocorrélation croisée du signal sont impliquées. Cette distribution est utile pour analyser le contenu fréquentiel et temporel d'un signal.

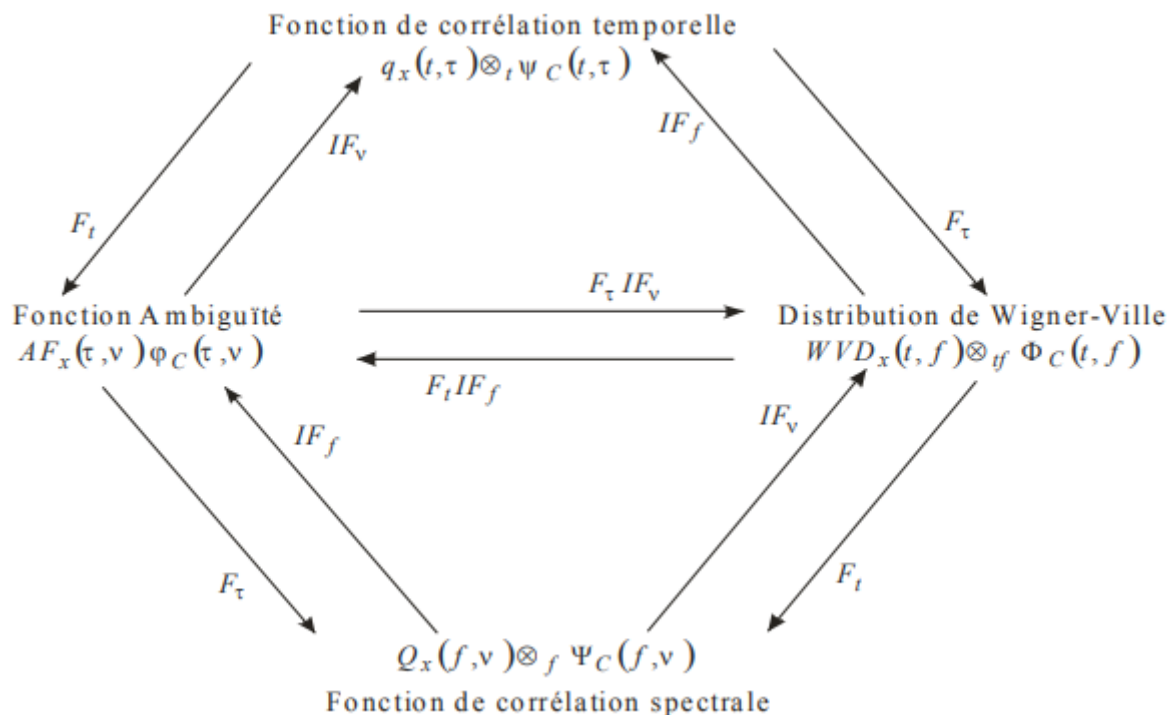


FIGURE 2.5 – Relation entre les représentations temps-fréquence

Toutes les distributions de la classe de distributions quadratiques peuvent être obtenues en convoluant la distribution de Wigner–Ville avec une fonction de noyau ayant une propriété de filtre passe-bas. Le passage au domaine d’ambiguïté permet d’illustrer cette opération de lissage car dans le domaine de Wigner–Ville, il est impossible de distinguer la région correspondant aux auto-termes de celle associée aux termes d’interférences. Cela est possible dans le domaine d’ambiguïté car les termes d’interférences sont situés de part et d’autre de l’origine, contrairement au domaine de Wigner–Ville où ils sont situés entre les auto-termes.

Les distributions de noyau ont pour objectif de convertir la distribution de Wigner–Ville en fonction d’ambiguïté en atténuant les termes d’interférence. Pour y parvenir, une fonction de noyau passe-bas est multipliée à la fonction d’ambiguïté, concentrée autour de l’origine dans le plan (τ, ν) , avant de revenir au plan temps-fréquence (t, f) . Cependant, l’utilisation d’une fonction noyau ayant un support étalé dans le domaine de Wigner–Ville, qui correspond à une fonction passe-bas étroite dans le domaine d’ambiguïté, entraîne une forte atténuation des termes d’interférence mais une mauvaise concentration temps-fréquence. En revanche, une fonction de lissage ayant un support étroit dans le domaine de Wigner–Ville, qui correspond à une fonction de support étalé dans le domaine d’ambiguïté, est caractérisée par une faible atténuation des termes d’interférences et une bonne concentration temps-fréquence.

Le lissage passe-bas est nécessaire pour réduire les termes d’interférence, mais cela diminue la résolution temps-fréquence. Il est donc recommandé de trouver un compromis entre une forte atténuation des termes d’interférence et une bonne concentration temps-fréquence.

La Figure 2.6 présente la SPWVD d’un signal EEG enregistré chez un patient épileptique. La SPWVD obtenue montre une meilleure résolution temps-fréquence mais avec

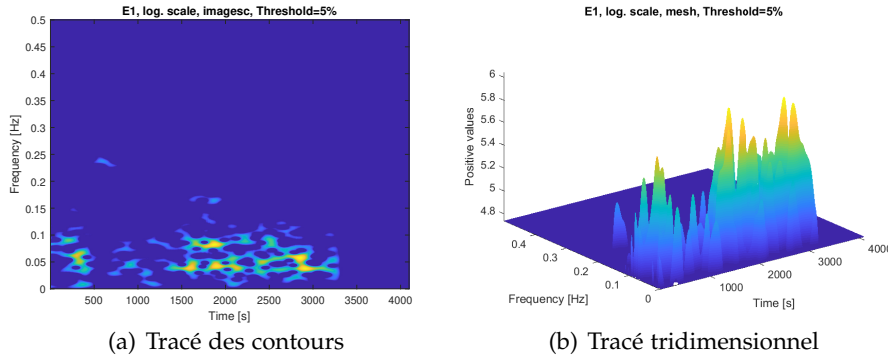


FIGURE 2.6 – SPWVD d'un signal EEG contenant la crise épileptique

une diminution des bandes d'énergie dans le domaine temps-fréquence. En ajustant la durée des fenêtres de lissage, il est possible d'obtenir une meilleure résolution temps-fréquence tout en réduisant le nombre de termes croisés dans le plan temps-fréquence.

Distribution de Choi-Williams

La distribution de Choi-Williams (CWD) est une version améliorée de la distribution de Wigner-Ville qui a été proposée en 1989 par H.Choi et W.J.Williams. Elle est également appelée la distribution exponentielle (ED) en raison du terme exponentiel dans sa formule [40]. L'objectif de la CWD est de réduire davantage les termes d'interférences dans la lecture des distributions temps-fréquence par rapport à la SPWVD.

La distribution de Choi-Williams (CWD) est une version améliorée de la distribution de Wigner-Ville pour réduire les termes d'interférences dans la lecture des distributions temps-fréquence. Cette distribution appartient à la classe de distributions quadratiques et sa fonction noyau a une forme de produit de deux variables ξ et τ [40, 41, 42].

$$f(\xi, \tau) = \exp \frac{-(\pi \xi \tau)^2}{2\sigma^2} \quad (2.33)$$

La fonction noyau est exprimée comme une exponentielle, où le facteur d'échelle σ contrôle la fenêtre de lissage. Cette fonction noyau réduit les termes d'interférences dus à la nature non-linéaire de la transformation. Elle permet l'accès à la fréquence instantanée et au retard de groupe tout en satisfaisant aux conditions de marginalité.

La distribution de Choi-Williams est obtenue en utilisant une fonction de pondération $f(\xi, \tau)$ donnée par l'équation 2.33 dans l'équation de Cohen 2.14.

$$CWD_x(t, f) = \sqrt{2/\pi} \iint_{-\infty}^{+\infty} \frac{\sigma}{|\tau|} e^{\frac{-2\sigma^2(s-t)}{\tau^2}} x\left(s + \frac{\tau}{2}\right) x^*\left(s - \frac{\tau}{2}\right) e^{-2i\pi f\tau} ds d\tau \quad (2.34)$$

Cette distribution est représentée par l'équation 2.34, où σ est le facteur d'échelle et contrôle la fenêtre de lissage. La fonction du noyau de Choi-Williams réduit les termes d'interférences causés par la nature non linéaire de la transformation et assure l'accès à la fréquence instantanée et au retard de groupe.

En combinant la fonction de pondération avec l'équation d'ambiguïté 2.27, on obtient l'équation 2.35. Cette dernière équation montre clairement l'effet de la fonction du noyau de Choi-Williams sur les termes d'interférences.

$$AF_x(\tau, \nu) = f(\xi, \tau) \int_{-\infty}^{+\infty} x(t + \frac{\tau}{2}) \cdot x^*(t - \frac{\tau}{2}) e^{-j2\pi\nu t} dt \quad (2.35)$$

La distribution de Choi-Williams est particulièrement utile pour l'analyse de signaux non-stationnaires à composantes multiples. Dans ces signaux, la fonction d'ambiguïté peut être décomposée en auto-termes, qui correspondent à chaque composante, et en termes d'interférence, qui se trouvent de part et d'autre de l'origine et correspondent à des paires de composantes. En appliquant une forte pondération aux régions proches de l'origine et une faible pondération aux régions éloignées de l'origine, le noyau exponentiel permet de renforcer les auto-termes et d'atténuer les termes d'interférences.

Dans la distribution de Choi-Williams, une petite valeur de σ lisse les termes d'interférences, mais diminue la résolution temps-fréquence, tandis qu'une grande valeur de σ augmente la concentration des auto-termes, mais atténue faiblement les termes d'interférences, transformant la distribution de Choi-Williams en une WVD. Les Figures 2.7 présentent des exemples de CWD d'un signal EEG d'un patient épileptique pour différentes valeurs de σ . Ces Figures 2.7 montrent que la CWD a une meilleure résolution temps-fréquence avec une valeur de σ plus petite, mais cela entraîne également une diminution de l'énergie dans les bandes temps-fréquence. Les choix de la valeur de σ dépendent des objectifs de l'analyse et des caractéristiques du signal étudié.

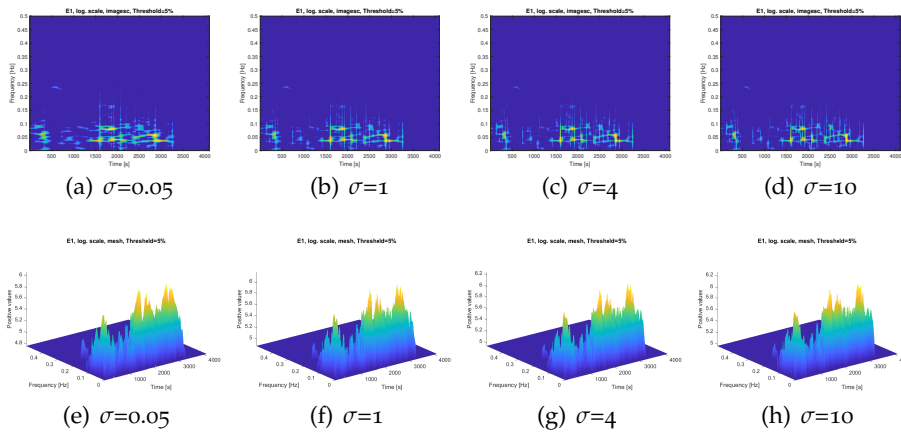


FIGURE 2.7 – CWD d'un signal EEG épileptique à différents valeurs de paramètre σ

Distribution de Zhao–Atlas–Marks (ZAM)

La distribution exponentielle (ED) appelée distribution de Zhao-Atlas-Marks (ZAM) a été proposée en 1990 par Y. Zhao, L.E. Atlas et R.J. Marks dans le but d'éliminer complètement l'effet des termes croisés de la représentation temps-fréquence des signaux de manière plus précise [43].

La distribution ZAM fait partie de la classe de Cohen et utilise la même TFR que la distribution Choi-Williams. Elle est appelée distribution en forme de cône car sa fonction de noyau $f(\xi, \tau)$ a une forme conique.

$$f(\xi, \tau) = \frac{\sin(\pi\xi\tau)}{\pi\xi\tau} e^{-2\pi\alpha\tau^2} \quad (2.36)$$

Le paramètre ajustable α est utilisé pour contrôler la largeur de la base du cône. La fonction noyau en cône est localisée autour de l'origine et sur l'axe τ . La distribution

ZAM est obtenue en appliquant cette fonction noyau sur la fonction de distribution de Cohen $AF_x(\tau, \nu)$ en utilisant l'équation 2.37.

$$ZAM_x(t, f) = \iint_{-\infty}^{+\infty} f(\xi, \tau) AF_x(\tau, \nu) e^{-j2\pi(\nu t - \tau f)} d\xi d\tau \quad (2.37)$$

La distribution ZAM est efficace pour éliminer complètement les termes croisés situés dans la même région que les termes propres grâce à son noyau de cône, mais cela se fait au prix d'une perte de la propriété de marginalité fréquentielle, ce qui signifie qu'elle n'est pas en mesure de fournir une information précise sur la distribution de l'énergie dans la direction fréquentielle. La Figure 2.8 montre le tracé des contours et le tracé tridimensionnel de la représentation de la distribution ZAM pour des signaux EEG épileptique.

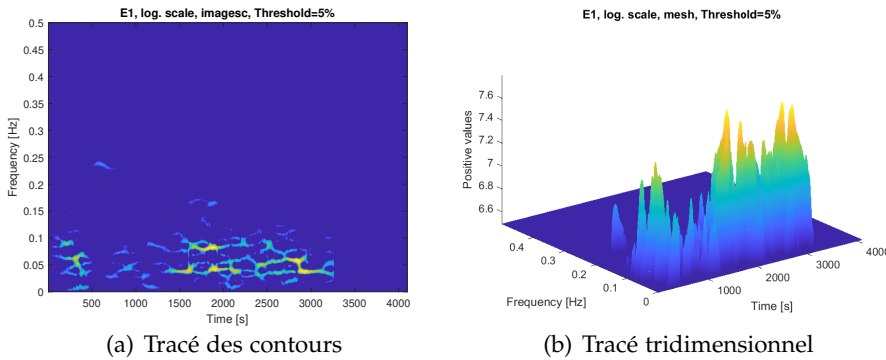


FIGURE 2.8 – ZAM d'un signal EEG contenant la crise épileptique

Distribution de Born–Jordan (BJD)

En imposant une résolution temporelle et fréquentielle à la distribution de Choi–Williams, on obtient la distribution de Born–Jordan (BJD), qui est définie par une fonction de pondération $f(\xi, \tau)$ de type produit. Cette fonction noyau permet de réduire l'énergie des termes d'interférences. La distribution de Born–Jordan est obtenue en intégrant le produit de deux fenêtres centrées en $t - \frac{\alpha\tau}{2}$ et $t + \frac{\alpha\tau}{2}$ dans l'axe temporel, et pondérées par la fonction noyau, le tout intégré sur l'axe fréquentiel.

La distribution de Born–Jordan est une autre méthode de distribution temps-fréquence qui utilise le noyau de cône de la distribution de Choi–Williams pour réduire l'énergie des termes d'interférences. La fonction de pondération $f(\xi, \tau)$ est définie par l'équation 2.38, où α est une constante.

$$f(\xi, \tau) = \frac{\sin(2\pi\alpha\tau\xi)}{2\pi\alpha\tau\xi} \quad (2.38)$$

La distribution de Born–Jordan est donnée par l'équation 2.39. Cette équation implique l'intégration de toutes les valeurs possibles de τ , où $x(t)$ est le signal d'entrée, f est la fréquence et t est le temps.

$$BJD_x(t, f) = \int_{-\infty}^{+\infty} \frac{1}{2\alpha|\tau|} \int_{t-\alpha\tau}^{t+\alpha\tau} x\left(s + \frac{\tau}{2}\right) \cdot x^*\left(s - \frac{\tau}{2}\right) e^{-j2\pi f\tau} d\tau \quad (2.39)$$

Cette distribution permet de réduire significativement le taux de termes d'interférences [44]. La Figure 2.9 montre le tracé des contours et le tracé tridimensionnel de la représentation de la distribution de Born–Jordan pour des signaux EEG épileptique.

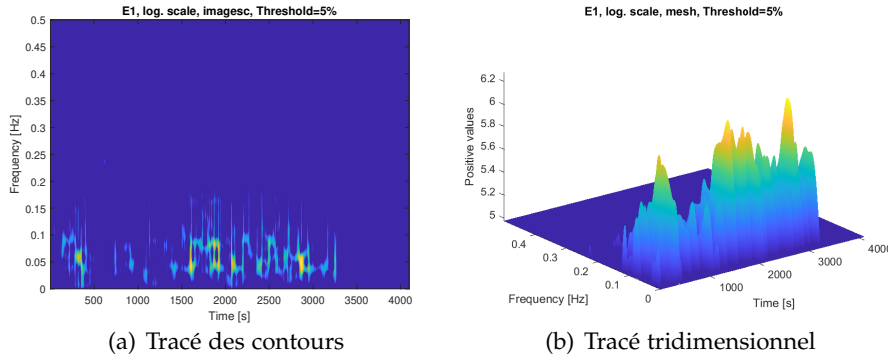


FIGURE 2.9 – BJT d'un signal EEG contenant la crise épileptique

Distribution de Rihaczek

La distribution de Rihaczek, également connue sous le nom de distribution de Kirkwood-Rihaczek, appartient à la classe de Cohen et a été dérivée bien avant dans le contexte de la mécanique quantique [45].

La distribution de Rihaczek permet d'estimer l'énergie d'un signal déterministe complexe dans un intervalle fini de temps et de fréquence élémentaire. Pour cela, elle utilise une interaction d'énergie entre le signal et un filtre passe-bande, dans un intervalle temporel réduit δ_T centré sur l'instant t et filtré dans un intervalle fréquentiel de largeur δ_B centré sur f , comme exprimé dans 2.40

$$\delta_T \delta_B [x(t) X^*(f) e^{-j2\pi f t}] \quad (2.40)$$

Cette expression est une densité d'énergie complexe au point (t, f) à partir de laquelle la définition de la distribution est obtenue en (2.41) ;

$$RD_x(t, f) = \int_{\tau} x(t + \tau) \cdot x^*(t) e^{-j2\pi f \tau} d\tau = x(t) X^*(f) e^{-j2\pi f t} \quad (2.41)$$

La distribution de Rihaczek est une densité d'énergie complexe qui peut être interprétée comme une densité d'énergie complexe au point (t, ν) avec une fonction de noyau donnée par $f(\xi, \tau) = e^{-j2\pi \xi \tau}$. Elle possède plusieurs propriétés intéressantes telles que la conservation de l'énergie, la compatibilité avec le filtrage et la modulation, la conservation du support, l'unitarité, la fréquence instantanée et le retard de groupe.

La distribution Rihaczek présente une bonne résolution temporelle et fréquentielle car elle est nulle lorsque le signal est nul aux intervalles de temps $x(t)$ et de fréquence $X(f)$. De plus, elle localise parfaitement les impulsions et les ondes sinusoïdales.

La distribution de Rihaczek a un inconvénient majeur car ses valeurs ne sont pas toujours des nombres réels positifs, ce qui empêche son interprétation comme une mesure de l'énergie du signal contenue dans un rectangle infinitésimal centré autour du point (t, f) . De plus, ses valeurs sont le plus souvent des nombres complexes, ce qui rend la représentation graphique difficile, car ses parties réelles et imaginaires ou son module et sa phase doivent être extraits de manière presque arbitraire. La Figure 2.10 montre le tracé des contours et le tracé tridimensionnel de la représentation de la distribution de Rihaczek pour des signaux EEG épileptique.

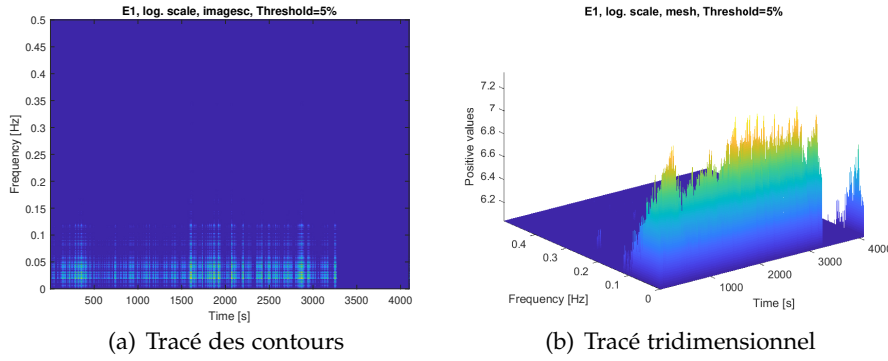


FIGURE 2.10 – RD d'un signal EEG contenant la crise épileptique

Distribution de Margneau–Hill (MHD)

La distribution de Margneau-Hill (MHD) est la partie réelle de la distribution de Rihaczek, qui appartient également à la classe de Cohen avec une fonction de noyau produit. La fonction de noyau de la MHD est donnée par l'équation 2.42.

$$f(\xi, \tau) = \cos(\pi\xi\tau) \tag{2.42}$$

En utilisant cette fonction de noyau, l'expression de la MHD peut être écrite comme l'équation 2.43.

$$MHD_x(t, f) = \frac{1}{2} \int_{-\infty}^{+\infty} x(t + \tau) \cdot x^*(t) + x(t) \cdot x^*(t - \tau) e^{-j2\pi f\tau} d\tau \tag{2.43}$$

La distribution de Margneau-Hill (MHD), obtenue à partir de la partie réelle de la distribution de Rihaczek, possède plusieurs propriétés telles que la conservation de l'énergie, les propriétés marginales, la valeur réelle, la covariance de translation et de dilatation, la conservation du support au sens large, la fréquence instantanée et le retard de groupe. Cependant, la structure d'interférence qui se produit à des emplacements différents par rapport au WVD constitue son inconvénient principal. Les interférences se produisant à deux points différents (t_1, f_1) et (t_2, f_2) apparaissent simultanément en (t_1, f_2) et (t_2, f_1) . La Figure 2.11 montre le tracé des contours et le tracé tridimensionnel de la représentation de la distribution de Margneau-Hill pour des signaux EEG épileptique.

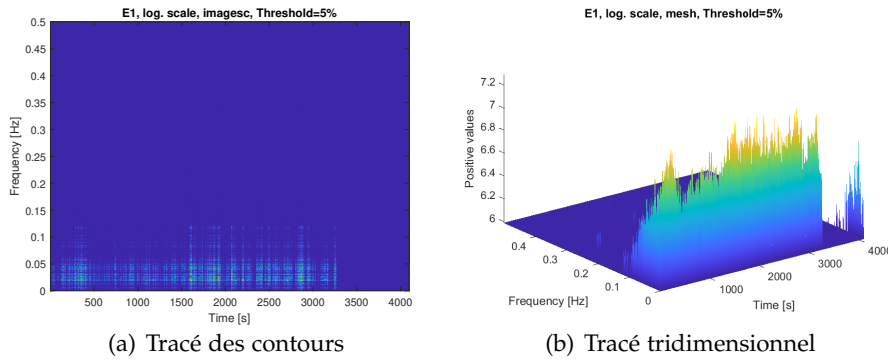


FIGURE 2.11 – MHD d'un signal EEG contenant la crise épileptique

Distribution de Page

La distribution de Page est une méthode alternative de représentation temps-fréquence basée sur la densité d'énergie à chaque instant du signal en considérant un temps d'exécution et l'instant présent pour définir le spectre d'exécution. Elle est également appelée "spectre instantané de puissance". La distribution de Page est définie par l'équation (2.44);

$$P^-(t, f) = \frac{d}{dt} |X_t^-(f)|^2 \quad (2.44)$$

Où $X_t^-(f)$ est exprimé par (2.45) :

$$X_t^-(f) = \int_{-\infty}^{+\infty} x_t(t') e^{-j2\pi f t'} dt' \quad (2.45)$$

Le signe $(-)$ fait référence aux instants antérieurs observés jusqu'à $-\infty$.

La distribution de Page est également un élément de la classe de Cohen avec une fonction de noyau défini par (2.46);

$$f(\xi, \tau) = e^{j\xi|\tau|/2} \quad (2.46)$$

La distribution de Page peut être exprimé en (2.47);

$$P^-(t, f) = \frac{d}{dt} \left\{ \left| \int_{-\infty}^t x(u) e^{-j2\pi f u} du \right|^2 \right\} = 2\Re \{ x^*(t) X_t^-(f) e^{j2\pi f t} \} \quad (2.47)$$

La distribution de Page est une forme de distribution énergétique du signal analysé, similaire aux distributions Rihaczek et Margenau-Hill présentées précédemment. La Figure 2.12 montre le tracé des contours et le tracé tridimensionnel de la représentation de la distribution de Page pour des signaux EEG épileptique.

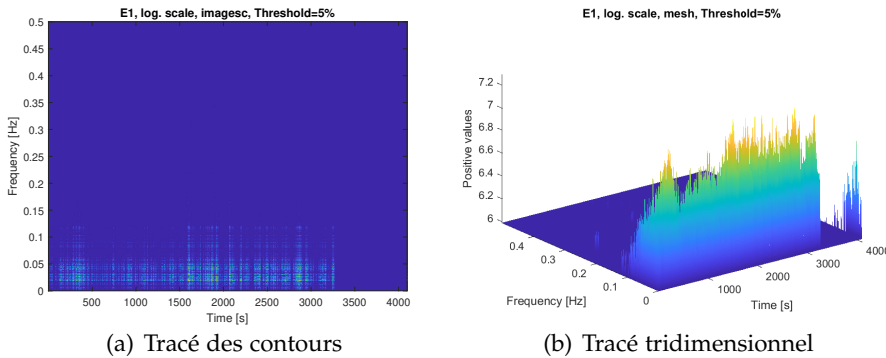


FIGURE 2.12 – PD d'un signal EEG contenant la crise épileptique

Distribution B-modifiée étendue (EMBD)

La distribution B-modifiée étendue (EMBD) est une amélioration de la distribution B-modifiée (MBD) récemment introduite. Elle appartient à la famille des "lag-independant (LI) kernels" et se caractérise par l'ajout d'une fonction noyau identique à travers la direction du retard dans la fonction d'ambiguïté et indépendante du retard [33, 46, 47], comme exprimé en (2.5.2);

$$EMBD(t, \tau) = g_\beta(t) = \frac{\cosh^{-2\beta}(t) e^{2j\pi ft} dt}{\int_{-\infty}^{+\infty} \cosh^{-2\beta}(t) dt} \cos^{-2\alpha}(\tau)$$

Le filtre de noyau est défini dans le plan temps-retard et est contrôlé par deux nombres réels positifs, β et α , qui contrôlent le degré de lissage et contrôlent la forme et la taille du noyau dans l'axe temporel et fréquentiel, respectivement. Les valeurs de β et α sont comprises entre 0 et 1.

En ajustant β et α , avec un noyau séparable visant à lisser indépendamment le plan temps-fréquence dans les domaines temporel et fréquentiel, l'EMBD caractérise mieux les signaux dont les composantes apparaissent dans les domaines temporel ou fréquentiel. Cela permet à l'EMBD d'offrir un bon compromis entre la résolution dans le plan temps-fréquence et les termes-croisées.

Distribution à noyau compact (CKD)

Une extension de l'EMBD, appelée distribution à noyau compact (CKD), est une autre QTFD à noyau séparable récemment introduite [47]. Le noyau CKD est mathématiquement défini avec plusieurs paramètres de contrôle pour ajuster indépendamment la forme et la taille du noyau de lissage, comme exprimé en (2.5.2) ;

$$CKD(t, \tau) = \begin{cases} e^{2c} e^{\frac{cD^2}{\zeta^2 - D^2} + \frac{cE^2}{\tau^2 - E^2}} & |\zeta| < D, |\tau| < E \\ 0 & \text{Ailleurs.} \end{cases}$$

Les paramètres E et D définissent respectivement la forme et la taille des fenêtres de retard et Doppler, tandis que c permet d'ajuster indépendamment la longueur de la fenêtre.

La distribution à noyau compact (CKD) est une QTFD à noyau séparable qui dispose de plus de paramètres de contrôle pour ajuster indépendamment la forme et la taille du noyau de lissage par rapport à l'EMBD. La CKD offre les meilleures performances en termes de résolution temporelle et fréquentielle pour les signaux dont les termes automatiques sont presque parallèles à l'axe du temps ou de la fréquence, mais ses performances se dégradent pour les signaux dont les termes propres sont éloignés de l'axe temporel ou fréquentiel du domaine (t, f) .

2.6 CONCLUSION

Dans ce chapitre, nous avons montré l'intérêt d'utiliser des méthodes d'analyse temps-fréquence pour étudier le contenu des signaux EEG. En effet, nous avons également décrit diverses méthodes d'analyse temps-fréquence, leur contexte théorique et leur classification en deux grandes catégories : les méthodes d'analyse temps-fréquence linéaire et les méthodes d'analyse temps-fréquence quadratique. Nous avons examiné leur structure à travers des exemples comparatifs et présenté les avantages et les inconvénients de chaque méthode.

La première catégorie de méthodes d'analyse temps-fréquence comprend la transformée de Fourier à court terme et la transformée en ondelettes, tandis que la deuxième catégorie repose sur la distribution de Wigner-Ville. La classe de Cohen est déterminée par la fonction de noyau d'analyse utilisée et intègre plusieurs techniques d'analyse temps-fréquence. Les différentes représentations temps-fréquence ont leurs avantages et

leurs inconvénients en termes de résolution et de temps de calcul, ainsi que de termes d'interférence inévitables en raison de leur nature quadratique. Pour sélectionner la méthode appropriée pour l'analyse des signaux EEG, une étude théorique est nécessaire en fonction des caractéristiques du signal et des besoins spécifiques de l'analyse.

Dans le prochain chapitre, nous examinerons les caractéristiques que l'on peut extraire des signaux EEG ainsi que les techniques de classification associées. Nous débutons avec les caractéristiques en domaine temps-fréquence et abordons les méthodes disponibles pour sélectionner les caractéristiques dans la littérature. Enfin, nous détaillons notre système de classification en présentant ses différentes propriétés.

3.1 INTRODUCTION

Nous subdivisons l'analyse des signaux EEG en trois phases principales; l'analyse, l'extraction de caractéristiques pertinentes et la classification. L'analyse du signal EEG est réalisé par l'analyse temps-fréquence, suivie de l'extraction de caractéristiques pertinentes qui permet de décrire les signaux EEG en utilisant un ensemble de valeurs intrinsèques. Cela permet de réduire les trois dimensions initiales en une matrice de données bidimensionnelle, sur laquelle la classification des signaux EEG est appliquée.

Ce chapitre se concentre sur l'extraction de caractéristiques pertinentes des signaux EEG dans les domaines temporel, fréquentiel et temps-fréquence. Il présente également des méthodes de classification supervisée, telles que les réseaux neuronaux artificiels (RNA), Machines à vecteurs de support (SVM), Classifieur des k plus proches voisins (kNN), le classificateur Naive Bayes (NBC) et le classifieur d'arbre de décision (DT), pour déterminer l'état de santé des patients épileptiques.

3.2 EXTRACTION DES CARACTÉRISTIQUES

L'extraction de caractéristiques est une étape cruciale dans l'analyse des signaux EEG, qui consiste à identifier un ensemble de valeurs intrinsèques décrivant l'information pertinente des signaux EEG. Ces caractéristiques sont regroupées dans un vecteur appelé "vecteur de caractéristiques". Cette étape vise à faciliter l'étape de classification des signaux EEG en passant de 3 dimensions initiales à une matrice de données bidimensionnelle. Différentes techniques ont été développées dans la littérature pour extraire les caractéristiques à partir des signaux EEG, telles que l'analyse temporelle, fréquentielle ou spatiale. Dans cette thèse, nous nous concentrons sur l'extraction de caractéristiques dans le domaine temps-fréquence pour identifier les crises d'épilepsie.

3.2.1 Caractéristiques temporelles

Les caractéristiques temporelles du signal EEG sont calculées à partir du signal EEG brut ou de signaux décomposés dans le domaine temporel [48]. Ces caractéristiques sont basées sur des mesures telles que l'amplitude, l'entropie et les moments statistiques du signal EEG. Cette section se concentre sur la description et l'explication mathématique des caractéristiques temporelles courantes et de celles qui impliquent des concepts d'entropie.

Moments statistiques

Les caractéristiques statistiques temporelles des signaux EEG, telles que la moyenne (μ), la variance (σ^2), l'asymétrie (γ) (skewness), l'aplatissement (k) (kurtosis), les valeurs minimales (Min) et maximales (Max), le coefficient de variation (STD) et l'écart interquartile (IQR) sont couramment utilisées pour différencier les enregistrements d'EEG ictaux des enregistrements normaux. Ces caractéristiques sont calculées dans le domaine temporel et permettent de quantifier diverses propriétés des signaux EEG. En particulier, la distribution statistique des signaux EEG pendant les crises diffère de celle des signaux normaux, ce qui permet d'utiliser ces caractéristiques pour détecter les épisodes épileptiques.

$$\mu_{(t)} = \frac{1}{N} \sum_n z[n] \quad (3.1)$$

$$\sigma_{(t)}^2 = \frac{1}{N} \sum_n (z[n] - \mu_{(t)})^2 \quad (3.2)$$

$$\gamma_{(t)} = \frac{1}{N\sigma_{(t)}^3} \sum_n (z[n] - \mu_{(t)})^3 \quad (3.3)$$

$$k_{(t)} = \frac{1}{N\sigma_{(t)}^4} \sum_n (z[n] - \mu_{(t)})^4 \quad (3.4)$$

$$STD_{(t)} = \frac{\sigma_{(t)}}{\mu_{(t)}} \quad (3.5)$$

$$IQR_{(t)} = z\left[\frac{3(N+1)}{4}\right] - z\left[\frac{N+1}{4}\right] \quad (3.6)$$

Caractéristiques temporelles basées sur l'amplitude

Les mesures d'amplitude telles que l'énergie (E), la puissance moyenne (P), l'écart absolu médian de l'amplitude (EAB) et la valeur quadratique moyenne (RMS) sont représentatives de l'amplitude. L'énergie représente la somme des carrés du signal, la puissance moyenne représente le carré moyen du signal et la RMS représente la racine carrée de la puissance moyenne. Ces caractéristiques sont définies comme suit, respectivement :

$$E(t) = \sum_{n=1}^N z[n]^2 \quad (3.7)$$

$$P(t) = \frac{\sum_{n=1}^N z[n]^2}{N} \quad (3.8)$$

$$EAB(t) = \frac{1}{N} \sum_{n=1}^N (|z[n] - \mu_{(t)}|) \quad (3.9)$$

$$RMS(t) = \sqrt{\frac{\sum_{n=1}^N z[n]^2}{N}} \quad (3.10)$$

Avec z est le signal analytique du signal EEG réel x en temps discret. Le concept d'énergie non linéaire (NE) est une extension de l'énergie classique (mesure quadratique) qui prend en compte des termes décalés et retardés dans la séquence, appelés

termes d'énergie. Cette approche a été proposée pour la première fois dans l'article [49] et est définie mathématiquement par l'équation suivante 3.11 :

$$NE(X) = \sum_{i=1}^{N-2} (x^2[i] - x[i+1]x[i-1]) \quad (3.11)$$

où X est le signal d'entrée de longueur N . Cette formule calcule la somme des carrés des valeurs du signal, pondérée par les différences de valeurs entre des échantillons décalés.

Le concept d'énergie non linéaire (NE) étend le concept d'énergie pour inclure des termes indéfinis de séquences décalées et retardées. Si un signal a un mouvement harmonique simple avec une amplitude A et une fréquence d'oscillation ω , le NE est proportionnel à $A^2\omega^2$ lorsque la fréquence d'échantillonnage est élevée [49]. Ainsi, des valeurs élevées de NE peuvent indiquer à la fois des valeurs décalées dans une fréquence d'oscillation et une amplitude élevées.

Le taux de passage à zéro

Le taux de passage à zéro (ZCR) est une mesure temporelle qui fournit des informations sur la répartition des fréquences dans le spectre de puissance d'un signal. Elle est largement utilisée dans de nombreux domaines, tels que le traitement de la parole et l'ingénierie biomédicale [50]. Le ZCR correspond au nombre de fois où l'amplitude du signal traverse l'axe zéro dans un intervalle de temps donné. En d'autres termes, il s'agit du nombre de fois où le signal change de signe, divisé par la durée de l'intervalle (W_l). Le ZCR est défini par (3.12).

$$ZCR(i) = \frac{1}{2W_l} \sum_{n=1}^{W_l} |sgn[x_i(n)] - sgn[x_i(n-1)]| \quad (3.12)$$

D'où $sgn(\cdot)$ est la fonction signe.

L'entropie

L'entropie est une mesure de la complexité de l'information d'un système désordonné. Une valeur élevée d'entropie indique une irrégularité ou une imprévisibilité accrue, tandis qu'une faible valeur indique une régularité élevée. Cette mesure est utilisée dans divers domaines tels que la thermodynamique, la physique statistique et la théorie de l'information. Dans le domaine de l'interface cerveau-ordinateur (BCI), l'entropie peut être utilisée pour mesurer le degré d'anomalie dans le système [51].

L'entropie est souvent utilisée pour l'analyse des signaux EEG épileptiques en raison de sa capacité à repérer les comportements aléatoires des signaux EEG et à mesurer leur impureté [52]. Elle permet de déterminer la présence d'une crise d'épilepsie ou d'inspecter l'état des crises d'épilepsie. L'entropie peut être subdivisée en entropie spectrale et en entropie intégrée [52]. Les entropies spectrales sont calculées à partir des composantes d'amplitude du spectre de puissance du signal, tandis que les entropies intégrées sont calculées directement à l'aide d'une série temporelle.

1. L'entropie spectrale (SEN)

L'entropie spectrale est une mesure normalisée de l'entropie de Shannon qui évalue la complexité spectrale d'un signal EEG en utilisant les composantes d'amplitude d'un spectre de puissance de la série temporelle [53]. Elle est souvent utilisée pour analyser les signaux EEG épileptiques car elle permet de mesurer

l'irrégularité des signaux [52]. La SEN (Spectral Entropy) est une mesure d'entropie spectrale qui quantifie la puissance dans chaque fréquence p_f multipliée par le logarithme de cette même puissance multipliée par -1 [53].

$$SEN = \sum_f p_f \cdot \log\left(\frac{1}{p_f}\right) \quad (3.13)$$

2. **Entropie de Shannon (ShEn)** L'entropie de Shannon est une mesure utilisée pour quantifier la quantité d'information contenue dans une source d'information et reflète l'incertitude des processus ou des quantités aléatoires. Cette mesure a été introduite par Claude Shannon en 1948 et s'est étendue à l'entropie spectrale [54]. Elle est définie comme la somme des probabilités d'occurrence de chaque valeur dans X multipliée par le logarithme de la même probabilité avec un facteur de correction négatif. Sa formule mathématique est :

$$ShEn(X) = - \sum_i p_i \log p_i \quad (3.14)$$

où p_i est la probabilité d'une occurrence de chacune des valeurs dans X .

Le principal avantage de la méthode ShEN est sa meilleure adaptation aux distributions normales [55]. Cependant, cette méthode présente également des inconvénients tels que la perte d'informations due à l'agrégation, la surestimation du niveau d'entropie si trop de zones sont utilisées [56] et l'incapacité à expliquer les relations temporelles entre différentes valeurs extraites d'un signal de série temporelle [57].

3. **Entropie de Renyi (RE)** L'entropie de Renyi est une généralisation mathématique de l'entropie de Shannon qui permet de quantifier la diversité, l'incertitude ou le caractère aléatoire d'un système. Elle est couramment utilisée pour estimer la complexité spectrale des signaux de séries temporelles [58]. Cette mesure peut être calculée dans le domaine temporel avec (3.15);

$$RE(X) = \frac{\alpha}{1 - \alpha} \log_2 \sum_{i=0}^m P(x_i)^\alpha \quad (3.15)$$

Dans cette formule, $\alpha \neq 1$ représente un paramètre de non-étendue et p_i définit la puissance spectrale totale. Lorsque $\alpha = 1$, l'entropie de Renyi produit une quantité superficielle d'entropie lisse similaire à celle de l'entropie de Shannon (ShEn). En revanche, pour un ordre de $\alpha \geq 2$, l'entropie de Renyi fournit une borne inférieure liée à son entropie lisse [59].

Le principal avantage de RE est sa capacité à être indépendante de la fonction de densité [60]. Cependant, son principal inconvénient est de ne pas posséder les propriétés de ramification et de sommation [61].

4. **Entropie de Tsallis (TE)**

L'entropie de Tsallis est une mesure de l'incertitude d'un système qui permet de caractériser son comportement physique. Elle est utile pour décrire les systèmes présentant des effets de mémoire à long terme, des interactions à longue portée et des contraintes spatio-temporelles multifractales [62]. En électroencéphalographie (EEG), les coefficients de Tsallis sont utilisés pour différencier les pointes, les rafales et les rythmes continus. Le TE est défini par (3.16);

$$TE = \frac{1 - \sum_{i=1}^W P_i^q}{q - 1} \quad (3.16)$$

où q est la mesure de non-extensivité, p_i décrit l'ensemble discret de probabilités avec W configurations microscopiques [63].

Le TE permet de mesurer les changements brusques et les effets de mémoire à long terme dans un signal de série temporelle, par opposition à l'entropie de Shannon. Ses avantages incluent la fourniture d'informations plus détaillées que l'entropie de Shannon conventionnelle, en particulier lorsqu'elle est utilisée pour évaluer différents rythmes et l'analyse en rafale de l'EEG [64]. Cette méthode aide également à mesurer l'incertitude des systèmes généralisés et est mieux adaptée pour traiter les mesures non-gaussiennes [55]. Cependant, le principal inconvénient du TE est la sélection aléatoire de l'indice q , sans méthode automatisée ou théorie pour son calcul [65].

5. **L'entropie approximative (ApEn)** est une mesure de régularité et de fluctuation dans une série temporelle finie, dérivée de l'entropie de Kolmogorov. Elle permet de détecter les changements dans le comportement sous-jacent et de comparer la similarité des échantillons par la longueur du motif (m) et le coefficient de similarité (r). Cette mesure est invariante à l'échelle, car le critère de similarité est équivalent à l'écart type des données [53]. Mathématiquement, l'ApEn est donnée par (3.17);

$$ApEn(X, m, r) = \ln \frac{C_m(r)}{C_{m+1}(r)} \quad (3.17)$$

où $C_m(r)$ est la moyenne du motif de longueur m et $C_{m+1}(r)$ est la moyenne du motif de longueur $m + 1$.

La moyenne des motifs est déterminée en comptant le nombre de motifs similaires de longueur m et $m + 1$ dans la série temporelle. Pour ce faire, on utilise la fonction $C_{im}(r)$ qui est définie par (3.18);

$$C_{im}(r) = \frac{n_{im}(r)}{N - m + 1} \quad (3.18)$$

où $n_{im}(r)$ est le nombre de motifs de longueur m qui ont une similarité supérieure à r et N est la longueur totale de la série temporelle. ApEn est sensible à la longueur du motif, et pour éviter la condition $\ln(0)$. En théorie, une série temporelle très irrégulière donne une ApEn de valeur élevée, tandis qu'une série temporelle avec un grand nombre de motifs similaires donne une ApEn de valeur faible.

L'entropie approximative présente plusieurs avantages, notamment sa capacité à être calculée pour une série de données bruitées relativement courte, sa capacité à différencier divers types de systèmes et sa précision statistique. Cependant, elle présente également des inconvénients tels que son interprétation limitée en présence de bruit important, sa dépendance à la longueur de la série temporelle et ses biais dus à l'auto-apparition. De plus, elle peut donner des valeurs imprécises pour les signaux particulièrement courts et manque de cohérence en raison de sa forte dépendance à la longueur des données [66, 53, 67, 68].

6. **Entropie de l'échantillon (SampEn)**

La SampEn est une entropie qui mesure la régularité d'un signal physiologique indépendamment de la longueur du motif. Elle compare le nombre total de vecteurs

modèles de taille m et $m+1$, ce qui réduit le biais de l'entropie approximative. Elle peut être calculée en utilisant (3.19);

$$\text{SampEn}(X, m, r) = \log \phi^m(r) - \log \phi^{m+1}(r) \quad (3.19)$$

où $\phi^{m+1}(r)$ contient le nombre total de paires de vecteurs de longueur $m+1$ et $\phi^m(r)$ contient le nombre total de paires de vecteurs de longueur m .

La valeur de SampEn d'un ensemble de données est plus élevée si elle est plus imprévisible pour une longueur de motif (m) et un critère de similarité (r) donnés, et cela reste vrai pour toutes les valeurs différentes de m et r . Une valeur élevée de SampEn implique donc un signal hautement imprévisible, et vice versa. SampEn est relativement cohérente, contrairement à l'ApEn. Cela signifie que SampEn peut être calculée pour des séries relativement courtes de données bruitées et peut différencier une variété de systèmes tels que les systèmes périodiques et multi-périodiques, les systèmes chaotiques et les systèmes stochastiques.

L'entropie de l'échantillon (SampEn) mesure la régularité d'un signal physiologique indépendamment de la longueur du motif. Elle est utile pour les séries de données bruyantes et est capable de différencier une grande variété de systèmes. Elle surpasse l'entropie approximative avec la théorie des nombres aléatoires et maintient une cohérence relative. Les auto-appariements ne sont pas comptés, ce qui réduit le biais et les valeurs d'entropie sont plus cohérentes sur différentes longueurs de motifs. Cependant, l'inconvénient majeur de SampEn est son incohérence pour les données éparses. [68].

7. L'entropie de permutation (PE)

L'entropie de permutation (PE) mesure la complexité locale des séries temporelles en identifiant les couplages entre les signaux de ces séries [69, 70, 71]. Pour chaque motif de permutation d'ordre m composé de $m!$ motifs, la probabilité que le vecteur modèle $u[i]$ ait le même motif que le motif de permutation est calculée en (3.20);

$$p(\pi_k) = \frac{1}{N - m + 1} \sum_{i=0}^{N-m} f(u[i], \pi_k) \quad (3.20)$$

Avec $f(u[i], \pi_k) = 1$ si $u[i]$ et k ont le même motif, sinon c'est zéro. Le motif est défini par l'ordre des éléments de $u[i]$. Ainsi, le PE est défini par (3.21);

$$PE(X) = - \sum_{k=1}^{m!} p(\pi_k) \log p(\pi_k) \quad (3.21)$$

La dynamique du signal EEG peut être étudiée en identifiant les motifs de permutation d'éléments variables dans la série temporelle du signal. L'entropie de permutation est une mesure de la complexité locale de la série temporelle, qui augmente avec l'asymétrie du signal à des fréquences élevées. Cependant, aux basses fréquences, les permutations correspondant aux pics et aux creux du signal sont rares.

Les avantages significatifs de l'entropie de permutation sont sa simplicité, sa robustesse, son efficacité et sa résistance à la complexité de calcul [72]. Cette méthode est applicable aux données réelles et elle produit des résultats rapides, indépendamment des données bruitées. Elle convient également à l'analyse des processus non linéaires [73] et est utile pour le traitement d'énormes ensembles de données

avec moins de temps de prétraitement et de réglage fin des paramètres de complexité [73]. Cependant, sa principale limite est son incapacité à distinguer des modèles bien définis d'une conception particulière [74].

8. **Entropie floue (FuzzEn)** L'entropie floue (FuzzEn) est une mesure d'incertitude du processus basée sur une séquence à moyenne nulle [75]. Elle représente l'information de l'aléatoire et est définie comme l'entropie d'un ensemble flou dont les éléments ont des degrés d'appartenance différents. Les fonctions d'appartenance varient de 0 à 1.

Considérons un signal fenêtré $u[i]$ dont la moyenne est supprimée :

$$u[i] = [x[i]x[i+1] \dots x[i+m-1]]^T - \bar{x}[i]\mathbf{1}, \quad (3.22)$$

où $\bar{x}[i] = \frac{1}{m} \sum_{j=0}^{m-1} x[i+j]$ et $\mathbf{1}$ est un vecteur colonne de uns. Pour calculer un indice d'auto-similarité ϕ à partir de la séquence u , la mesure FuzzEn utilise une fonction gaussienne. L'entropie floue est définie comme suit :

$$\phi^{(m)}(r) = \frac{1}{(N-m)(N-m-1)} \sum_{j=0}^{N-m} \sum_{i=0}^{N-m} \exp\left(-\frac{d_{ij}^2}{2r^2}\right), \quad (3.23)$$

avec $d_{ij} = \|u[i] - u[j]\|_\infty$. Cette distance d_{ij} est petite et relative à la courbe de Gauss avec la variance r^2 si le signal x est auto-similaire, ce qui entraîne une forte augmentation de $\phi^{(m)}(r)$.

Le but principal de la méthode FuzzEn est de quantifier la variation de l'indice d'auto-similarité ϕ lorsqu'on augmente la longueur de la fenêtre m de 1. Cela est formalisé à travers la fonction *FuzzEn*, qui est définie comme la différence entre les logarithmes de deux valeurs d'entropie floue ϕ pour des longueurs de fenêtre adjacentes m et $m+1$ et pour une variance r donnée, comme exprimé en (3.24) ;

$$FuzzEn(X, m, r) = \log\phi^m(r) - \log\phi^{m+1}(r) \quad (3.24)$$

L'entropie floue mesure les incertitudes ambiguës des signaux très irréguliers, tandis que l'entropie ShEn traite de la mesure des incertitudes probabilistes. L'avantage de cette entropie est qu'elle est insensible au bruit et qu'elle est très sensible aux changements dans le contenu de l'information.

9. **Entropie de distribution (DistEn)** L'entropie de distribution (DistEn) est une mesure de l'incertitude d'un processus qui est estimée à l'aide d'un histogramme [76]. Pour construire cet histogramme, on utilise la distance $d_{ij} = \|u[i] - u[j]\|_\infty$ entre les vecteurs modèles $u[i]$ et $u[j]$ définis précédemment pour FuzzEn, et on le divise en B bacs. Ainsi, la DistEn est définie comme l'entropie de la distribution de la distance d_{ij} , exprimée en (3.25) ;

$$DistEn(X, m, B) = -\frac{1}{\log B} \sum_{i=1}^B p_i \log p_i \quad (3.25)$$

Avec, p_i est la fréquence relative de chaque bac. Une valeur élevée de DistEn indique une forte imprévisibilité de la séquence originale X .

De manière indirecte, il existe d'autres caractéristiques qui reflètent la fréquence du signal, notamment le nombre de passages par zéro, dont une valeur élevée indique la présence de composantes à haute fréquence, et le nombre d'extrêmes locaux, qui représente le nombre total de maxima et de minima locaux dans le signal.

3.2.2 Caractéristiques fréquentielles de l'EEG

Les signaux EEG contiennent des informations sur les modèles d'activité cérébrale qui peuvent être utilisées pour comprendre les processus cognitifs et pathologiques. L'analyse des signaux EEG dans le domaine fréquentiel permet d'extraire des caractéristiques utiles pour identifier les composantes du signal qui correspondent à des bandes de fréquence spécifiques. La densité spectrale de puissance (DSP) et la DSP normalisée sont des outils couramment utilisés pour extraire des caractéristiques fréquentielles des signaux EEG. Ces caractéristiques fournissent des informations sur la répartition de l'énergie du signal sur les différentes bandes de fréquences, ce qui peut être utilisé pour identifier des modèles caractéristiques du signal EEG [48].

1. L'énergie est une mesure de la quantité d'activité dans une certaine plage de fréquences spécifiées dans l'EEG. En général, ces plages de fréquences correspondent à des activités normales de l'EEG, comme les ondes alpha, bêta, delta et thêta. En extrayant l'énergie de ces plages de fréquences, on peut déterminer la rythmicité de l'EEG dans chaque plage de fréquences, ce qui peut aider à identifier les modèles anormaux d'activité cérébrale.
2. La fréquence moyenne pondérée en intensité (IWMF) est une caractéristique qui permet de calculer la moyenne pondérée de la distribution de fréquence d'un signal EEG. Elle est calculée en utilisant la densité spectrale de puissance (DSP) normalisée. La DSP normalisée représente la puissance du signal dans chaque bande de fréquence normalisée par rapport à la puissance totale du signal. La fréquence moyenne pondérée en intensité est calculée en multipliant chaque valeur de DSP normalisée par sa fréquence correspondante et en sommant les produits. Cette caractéristique permet d'évaluer la fréquence dominante ou prédominante du signal EEG, comme exprimée en (3.26);

$$IWMF(X) = \sum_x x[k] \cdot f[k] \quad (3.26)$$

Avec $x[k]$ est la DSP normalisée d'une époque EEG à la fréquence $f[k]$.

3. La largeur de bande pondérée en intensité (IWBW) est une mesure qui permet d'évaluer la largeur de la densité spectrale de puissance (DSP) en termes d'écart-type (SD). Elle est obtenue en utilisant la DSP normalisée et la fréquence moyenne pondérée en intensité (IWMF). L'IWBW est exprimée en (3.27);

$$IWBW(X) = \sqrt{\sum_x x[k] \cdot (f[k] - IWMF(X))^2} \quad (3.27)$$

Avec $x[k]$ est la DSP normalisée. L'IWBW est plus petit pendant les activités de crise puisque le PSD est plus net d'après les modèles de crise dans les signaux EEG typiques. Plus précisément, l'IWBW mesure l'écart entre chaque fréquence et la fréquence moyenne pondérée en intensité. Cette caractéristique est utile pour différencier les activités de crise, où le PSD est plus net, des activités EEG normales. En effet, l'IWBW est plus petit pendant les activités de crise.

4. La fréquence de crête est une caractéristique importante de la DSP de l'EEG. Elle est définie comme la fréquence à laquelle la puissance moyenne de la DSP atteint son maximum, et se situe dans la bande de demi-largeur maximale (FWHM) de la DSP. La FWHM est la plage de fréquences où la DSP est supérieure à la moitié de sa valeur maximale. Ainsi, la fréquence de crête est un indicateur de la fréquence à

laquelle le signal EEG présente une activité maximale. Dans le cas de l'épilepsie, la fréquence de crête peut être utilisée pour différencier les signaux EEG épileptiques des signaux EEG normaux, car les fréquences de ces deux types de signaux sont généralement différentes.

5. La bande passante de la fréquence dominante est une mesure de la largeur de la bande de fréquences autour de la fréquence de crête. Elle est définie comme la largeur de la bande à mi-hauteur maximale (FWHM) de la densité spectrale de puissance (DSP) à la fréquence de crête. En général, pour un signal EEG normal, la bande passante de la fréquence dominante est plus large que celle d'un signal EEG épileptique, car les activités épileptiques sont généralement associées à une fréquence plus restreinte et plus intense. Ainsi, une bande passante plus étroite peut être un indicateur de la présence d'une activité épileptique dans un signal EEG.
6. Le rapport de puissance des époques actuelles et de fond à la même plage de fréquences est une mesure comparative de la puissance des signaux EEG. Pour effectuer cette mesure, la puissance de l'époque actuelle est comparée à celle du bruit de fond, qui représente le niveau de puissance de fond du signal. Étant donné que la puissance des signaux EEG est généralement plus élevée que celle du bruit de fond, le rapport de puissance sera donc supérieur à 1.

L'entropie spectrale (SE) est une mesure de l'incertitude d'un signal EEG sur la répartition de sa puissance en fonction de la fréquence. Elle permet d'analyser la diversité des fréquences présentes dans un signal EEG. Pour calculer l'entropie spectrale, on utilise la densité spectrale de puissance (DSP) normalisée, qui représente la répartition de la puissance en fonction de la fréquence. On calcule la somme de la DSP normalisée multipliée par le logarithme de la DSP normalisée pour chaque fréquence. Plus la DSP est uniformément répartie, plus l'entropie spectrale est élevée, et inversement [77]. Une faible entropie spectrale peut indiquer une activité cérébrale anormale ou une altération de la connectivité cérébrale. La SE est exprimée en (3.28);

$$SE(X) = - \sum_k x[k] \log x[k] \quad (3.28)$$

3.2.3 Caractéristiques temps-fréquence de l'EEG

Dans cette section, nous définissons des caractéristiques temps-fréquence extraites à partir de distributions temps-fréquence quadratiques (QTFDs) du signal EEG.

Caractéristiques statiques

Les caractéristiques temporelles-fréquentielles sont souvent utilisées pour distinguer les signaux EEG normaux des signaux épileptiques dans chaque bande de fréquence spécifiée. Afin de tirer parti des informations supplémentaires fournies par les transformations temps-fréquence, les caractéristiques temporelles présentées dans la section 3.2.1 sont étendues au domaine temps-fréquence en remplaçant les moments unidimensionnels par les moments bidimensionnels correspondants. Les caractéristiques incluent la moyenne (μ), la variance (σ^2), l'écart type (STD), l'asymétrie (γ) (skewness), l'aplatissement (k) (kurtosis), les valeurs minimales (Min) et maximales (Max) définies comme suit :

$$\mu_{(t,f)} = \frac{1}{NM} \sum_n \sum_m \rho_x[n, m] \quad (3.29)$$

$$\sigma_{(t,f)}^2 = \frac{1}{NM} \sum_n \sum_m (\rho_x[n, m] - \mu_{(t,f)})^2 \quad (3.30)$$

$$\gamma_{(t,f)} = \frac{1}{NM\sigma_{(t,f)}^3} \sum_n \sum_m (\rho_x[n, m] - \mu_{(t,f)})^3 \quad (3.31)$$

$$k_{(t,f)} = \frac{1}{NM\sigma_{(t,f)}^4} \sum_n \sum_m (\rho_x[n, m] - \mu_{(t,f)})^4 \quad (3.32)$$

$$STD_{(t,f)} = \sigma_{(t,f)} / \mu_{(t,f)} \quad (3.33)$$

Entropies étendues au domaine temps-fréquence

L'entropie est une caractéristique importante pour la détection des crises d'épilepsie à partir des signaux EEG. Elle mesure les incertitudes et les complexités des signaux décomposés. L'entropie peut être calculée dans le domaine temps-fréquence pour adapter sa formulation à la représentation temps-fréquence et discriminer deux classes différentes de signaux à large bande. Plusieurs types d'entropie ont été utilisés dans la littérature, notamment ShEn, RE, ApEn, SampEn2D, PE et WPE [78, 79, 80, 81, 72, 82].

Entropie de Shannon L'entropie de Shannon est une mesure de l'incertitude dans la distribution de probabilité d'un signal [83]. Elle peut être étendue dans le domaine temps-fréquence en utilisant la représentation temps-fréquence du signal comme exprimé en (3.34) :

$$ShEn(\rho_x(t, f)) = - \sum_{n=1}^N - \sum_{k=1}^M \rho_x(t, f) \log_2(\rho_x(t, f)) \quad (3.34)$$

où $\rho_x(t, f)$ est la représentation temps-fréquence d'un signal $x(t)$. En raison des valeurs négatives contenues dans la représentation temps-fréquence, l'application de l'entropie de Shannon reste limitée [47].

Entropie de Renyi (RE) L'entropie de Renyi est une mesure généralisée de l'entropie de Shannon. Elle est également utilisée dans le domaine temps-fréquence pour évaluer l'incertitude des signaux EEG. L'équation (3.35) montre l'extension de l'entropie de Renyi dans le domaine temps-fréquence en utilisant la représentation temps-fréquence $\rho_x(t, f)$ d'un signal $x(t)$ [46].

$$H(\rho_x(t, f)) = \frac{1}{1-\alpha} \log_2 \iint_{-\infty}^{+\infty} \rho_x(t, f)^\alpha(t, f) dt df \quad (3.35)$$

Où $\rho_x(t, f)$ est la représentation temps-fréquence d'un signal $x(t)$. Pour une forme générale de QTFD, le paramètre α doit être un entier impair puisque l'intégration avec des puissances impaires annule la structure oscillatoire inter-terme d'un DFT [84].

L'entropie de Renyi présente plusieurs avantages par rapport à l'entropie de Shannon dans l'analyse des signaux EEG. En particulier, elle permet une meilleure discrimination entre les signaux de crise et les signaux de fond, ce qui peut être crucial dans la détection des crises d'épilepsie. De plus, contrairement à l'entropie de Shannon, l'entropie de Renyi reste inchangée pour différentes fonctions de densité, ce qui la rend plus

robuste à certaines variations dans les signaux. Ces avantages ont été démontrés dans plusieurs études [85, 60].

Entropie de l'échantillon bidimensionnelle (SampEn2D) L'entropie de l'échantillon bidimensionnelle (SampEn2D) est une méthode de quantification de l'irrégularité des représentations en deux dimensions basée sur le concept de SampEn unidimensionnelle [86, 81]. La représentation temps-fréquence d'un signal $x(t)$ de longueur w est notée $\rho_x(t, f)$, et $g_m(i, j)$ est la matrice de cette représentation. $g_m(i, j)$ est une fenêtre carrée de longueur m avec un point de départ en (i, j) . Le nombre total de fenêtres carrées générées pour les tailles m et $m + 1$ est noté N_m et est donné par $N_m = (w - m) * (w - m)$. L'expression en (3.36) montre la comparaison des motifs ;

$$d[g_m(i, j), g_m(a, b)] = \max(|u(i + k, j + l) - u(a + k, b + l)|) \quad (3.36)$$

où $1 \leq a, b \leq w - m$, $(a, b) \neq (i, j)$, et $0 \leq k, l \leq m - 1$. Cette expression calcule la distance entre deux fenêtres carrées $g_m(i, j)$ et $g_m(a, b)$ de la représentation temps-fréquence d'un signal, en comparant chaque élément de la matrice u correspondant aux deux fenêtres et en prenant le maximum de ces différences. On calcule ensuite la probabilité de similarité et le rapport de similarité moyen. La méthode SampEn2D permet de quantifier l'irrégularité des signaux en deux dimensions, ce qui est utile pour l'analyse des données EEG, par exemple.

$$\phi(i, j)^m(r) = \frac{d[g_m(i, j), g_m(a, b)] \leq r}{N_m - 1} \quad (3.37)$$

$$\Phi^m(r) = \frac{1}{N_m} \sum_{i, j=1}^{i, j=w-m} \phi(i, j)^m \quad (3.38)$$

$$\phi(i, j)^{m+1}(r) = \frac{d[g_{m+1}(i, j), g_{m+1}(a, b)] \leq r}{N_m - 1} \quad (3.39)$$

$$\Phi^{m+1}(r) = \frac{1}{N_m} \sum_{i, j=1}^{i, j=w-m} \phi(i, j)^{m+1} \quad (3.40)$$

La SampEn2D est définie en 3.41 [86] :

$$SampEn2D(X, m, r) = -\frac{\log \Phi^{m+1}(r)}{\log \Phi^m(r)} \quad (3.41)$$

où $\Phi^{m+1}(r)$ contient le nombre total de paires de vecteurs de longueur $m + 1$ et $\Phi^m(r)$ contient le nombre total de paires de vecteurs de longueur m .

Entropie de distribution bi-dimensionnelle (DistEn2D) L'entropie de distribution bidimensionnelle (DistEn2D) a été récemment proposé pour quantifier l'irrégularité des représentations de deux dimensions. L'algorithme de DistrEn2D d'une représentation $\rho_x(t, f)$ du signal $x(t)$ de taille $h * \omega$, avec $\rho = \{u_{i,j}\}_{i=1,2,\dots,h}^{j=1,2,\dots,\omega}$ est défini comme suit : une normalisation entre 0 et 1 de la représentation ρ est effectuée pour créer des matrices bidimensionnelles $X_{k,l}^m$ ($k = 1, 2, \dots, h - (m_h - 1)$ et $l = 1, 2, \dots, \omega - (m_\omega - 1)$), de taille $m_h * m_\omega$, appelées matrices modèles, où $m = [m_h, m_\omega]$ désigne le vecteur de dimension d'intégration. Ensuite, la matrice de distance $D = \{d_{k,l}\}_{l=1,2,\dots,\omega-(m_\omega-1)}^{k=1,2,\dots,h-(m_h-1)}$ est calculé et considéré comme le plus grand élément de la différence absolue de $X_{k,l}^m$ et $X_{a,b}^m$, avec a

et b passent respectivement de 1 à $h - (m_h - 1)$ et de 1 à $w - (m_w - 1)$. Ensuite, nous utilisons l'approche de l'histogramme avec M cases pour estimer la fonction de densité de probabilité empirique de D . Enfin, la DistrEn2D de la représentation ρ est exprimé comme suit (3.42) [87] :

$$DistEn2D(\rho, m, M) = -\frac{1}{\log M} \sum_{i=1}^M p_i \log p_i \quad (3.42)$$

Avec, p_i désigner la probabilité (fréquence) relative de chaque bac.

Concentration d'énergie du signal

La concentration d'énergie est l'une des caractéristiques les plus intéressantes des représentations temps-fréquence. Elle consiste en l'analyse de la répartition de l'énergie d'un signal dans le temps et la fréquence, permettant ainsi d'identifier des instants ou des bandes de fréquences spécifiques où l'énergie est fortement concentrée. Cette analyse peut fournir des informations précieuses sur les caractéristiques d'un signal pour des applications de diagnostic.

Une représentation TF performante devrait être capable de concentrer l'énergie du signal autour de la fréquence instantanée tout en éliminant les termes croisés. La mesure de la concentration d'énergie EC dans le domaine temps-fréquence est déterminée par l'équation suivante [88] :

Une représentation TF efficace doit concentrer l'énergie du signal autour de la fréquence instantanée tout en éliminant les termes croisés. La concentration d'énergie EC peut être mesurée dans le domaine temps-fréquence en utilisant l'expression en (3.43)[88] :

$$EC = \left| \sum_{t=1}^N \sum_{f=1}^M |\rho[t, f]|^{1/q} \right|^q, q > 1 \quad (3.43)$$


Dans cette équation, t et f sont des valeurs discrètes, N est le nombre d'échantillons temporels et M est le nombre d'échantillons fréquentiels de la TF. La représentation temps-fréquence est dénotée par $\rho(t, f)$. Cette mesure de concentration d'énergie peut fournir des informations supplémentaires pour le diagnostic d'un phénomène particulier [88].

Direction de l'énergie


Une approche alternative pour extraire des caractéristiques temps-fréquence repose sur la direction de l'énergie du signal dans le domaine temps-fréquence. Cette approche est basée sur l'hypothèse selon laquelle lors d'une crise, l'énergie du signal se concentre principalement le long de l'axe des fréquences en raison de la signature du pic ou le long de l'axe des temps en raison de la tonalité caractéristique. À l'inverse, en l'absence de crise, l'énergie du signal est uniformément répartie dans toutes les directions dans le domaine temps-fréquence. Par conséquent, la concentration d'énergie de tous les points temps-fréquence ayant une orientation parallèle à l'axe du temps ou de la fréquence est supérieure à celle de fond de l'EEG. Une mesure de parcimonie telle que la concentration d'énergie peut être utilisée pour discriminer entre les TFD des signaux de crise et celles des signaux sans crise [89].

Les figures 3.1 illustrent les représentations temps-fréquence (TF) d'une crise d'épilepsie et des signaux EEG de fond. Les figures suivantes montrent les représentations TF des mêmes signaux en ne conservant que les orientations pertinentes. Dans le cas des

signaux de crise, l'énergie du signal est mieux conservée car elle ne maintient que les orientations pertinentes, alors que pour les signaux non épileptiques, la dispersion est plus importante dans le domaine TF. Ces figures démontrent l'efficacité de la concentration d'énergie pour distinguer les représentations TF des signaux de crise et celles des signaux non-crise.



(a) La crise d'épilepsie avant l'orientation de l'énergie (b) La crise d'épilepsie après l'orientation de l'énergie



(c) Le fond EEG avant l'orientation de l'énergie (d) Le fond EEG après l'orientation de l'énergie

FIGURE 3.1 – Représentation TF originale vs représentations TF obtenues en ne conservant que les points dont le grand axe est parallèle à l'axe du temps ou à l'axe des fréquences.

Autres caractéristiques

De plus, d'autres caractéristiques sont souvent utilisées pour observer les amplitudes des signaux correspondant à des sous-bandes de fréquences spécifiques, notamment l'énergie, la puissance moyenne et la valeur efficace. La longueur de la ligne est également une caractéristique utilisée pour estimer la dimension fractale des coefficients de décomposition DWT.

Il y a des caractéristiques qui appartiennent au domaine fréquentiel et qui sont également étendues dans le domaine temps-fréquence, qui sont présentées dans la section 4.2.

3.3 TECHNIQUES DE CLASSIFICATION

Une étape cruciale pour identifier les crises d'épilepsie à partir des signaux EEG est la classification de ces signaux en fonction de l'état du patient. Le but de cette classification est d'attribuer automatiquement une classe à un vecteur de caractéristiques préalablement extrait et de délimiter une frontière entre deux ou plusieurs classes. Les algorithmes utilisés pour cette tâche sont appelés "classifieurs". Les classifieurs peuvent apprendre à identifier la classe d'un vecteur de caractéristiques à partir d'ensembles d'apprentissage, composés de vecteurs de caractéristiques étiquetés avec leur classe

d'appartenance. Un bon classifieur est caractérisé par sa capacité à maximiser la distance entre les classes à distinguer. Ces caractéristiques sont présentées dans la section 4.2.

Dans la littérature, diverses techniques de classification des signaux EEG ont été proposées pour identifier les crises d'épilepsie. Dans la section suivante, nous présenterons les classifieurs les plus couramment utilisés et les plus puissants pour la détection de la crise d'épilepsie à partir des signaux EEG.

3.3.1 Réseaux de neurones artificiels

Les Réseaux de neurones artificiels (RNA) sont inspirés du fonctionnement et de l'architecture du cerveau humain, chaque neurone artificiel traitant les signaux d'entrée pondérés par des poids pour produire un signal de sortie. Les RNA sont composés de plusieurs neurones artificiels interconnectés et organisés en trois couches (entrée, cachée et sortie), caractérisés par leur état d'excitation et les poids synaptiques associés. Les fonctions d'activation les plus utilisées sont les fonctions linéaires, sigmoïdes et gaussiennes [90]. Les RNA permettent ainsi de créer des frontières de décision non-linéaires pour des problèmes de classification.

Architecture de réseaux de neurones

Il existe différentes architectures de réseaux de neurones, mais généralement, on les classe en deux catégories essentielles : les réseaux de neurones récurrents, également appelés réseaux de neurones à rétroaction (feedback), et les réseaux de neurones feed-forward, ou réseaux de neurones non-bouclés ou sans rétroaction [81].

1. **Les réseaux de neurones non-bouclés ou "Feed-Forward"** : Le réseau de neurones non bouclé est un réseau neuronal qui n'a pas de boucles de rétroaction, et qui est composé de différentes couches, notamment une couche d'entrée, une ou plusieurs couches cachées, ainsi qu'une couche de sortie.

Un réseaux de neurones non bouclé est non-récurrent, contient des couches d'entrée, de sortie et des couches cachées. L'information circule à partir des entrées vers les sorties dans une seule direction. Les réseaux de neurones non-bouclés sont qualifiés comme statiques puisque le temps n'y joue aucun rôle fonctionnel [91]. Toutes les couches sont connectées aux couches précédentes et aux couches suivantes avec un poids de connexion. Les neurones de la couche cachée, appelée aussi unité de traitement, sont commandés par une fonction d'activation. Ce type de réseau comprend deux groupes d'architectures, à savoir les réseaux mono-couches et les réseaux multi-couches.

Les réseaux de neurones se distinguent par la présence ou non de neurones intermédiaires appelés neurones cachés entre les unités d'entrée et de sortie. Les réseaux non-bouclés mono-couche ont une couche d'entrée qui reçoit les entrées à traiter et se projette en une couche de sortie de neurones qui transmettent les résultats du traitement à l'extérieur. Les réseaux non-bouclés multi-couches ont une ou plusieurs couches cachées qui effectuent un prétraitement des entrées reçues par la couche d'entrée avant de transmettre les résultats à la couche de sortie où la réponse finale est déterminée. Les perceptrons multi-couches (Multilayer Perceptrons, MLP) sont les réseaux les plus couramment utilisés de cette catégorie. Les couches cachées permettent aux MLP de modéliser des relations non linéaires entre les entrées et les sorties.

2. **Réseaux de neurones bouclés (Feedback)**

Les réseaux bouclés, ou réseaux récurrents, diffèrent des réseaux non-bouclés en ce qu'ils permettent la présence d'au moins un cycle où l'information peut retourner à son point de départ. Cela suppose que la sortie d'un neurone peut être fonction d'elle-même, permettant à l'information de circuler dans les deux sens via des boucles. Les réseaux bouclés sont des systèmes dynamiques non linéaires qui évoluent continuellement jusqu'à l'obtention d'un état d'équilibre, et nécessitent une prise en compte de la notion du temps. Ils sont utilisés pour modéliser des processus dynamiques non-linéaires, la commande de processus ou le filtrage [92, 93].

Avantages et inconvénients des réseaux de neurones

Les réseaux de neurones présentent plusieurs avantages importants, tels que :

- Une réponse rapide grâce à des opérations simples assurant une utilisation rationnelle des ressources informatiques.
- Une grande flexibilité, pouvant représenter des fonctions linéaires ou complexes avec une bonne capacité de généralisation.
- Un apprentissage robuste aux erreurs, au bruit et aux données manquantes.

Ces avantages font des réseaux de neurones des outils très utiles pour diverses tâches de traitement de données, y compris en électroencéphalographie, en analyse temps-fréquence et en classification [94].

Les réseaux de neurones ont également des inconvénients qui doivent être pris en compte :

- La difficulté de trouver la bonne structure qui permette au réseau d'apprendre efficacement les exemples. Il est difficile de prédire le nombre de neurones cachés, les valeurs initiales des poids du réseau ou encore le réglage du pas d'apprentissage nécessaires pour un problème donné.
- Un temps d'apprentissage parfois énorme, surtout lorsqu'il s'agit de bases de données massives.
- La structure statique des réseaux de neurones, qui les rend moins adaptables à des tâches changeantes.
- Le risque de sur-apprentissage (Over-fitting) où le réseau de neurones se limite à reproduire exactement ce qu'on lui a appris sans généraliser.
- Le réseau de neurones est une boîte noire dont le fonctionnement interne est difficile à comprendre une fois qu'il a effectué son apprentissage.

Le Réseau de Neurones Récurrent (RNR), le Réseau de Neurones Probabiliste, et le Réseau de Neurones à Base Radiale (RBNN) ont été largement exploités à détecter les crises d'épilepsie qui se manifestent dans les signaux EEG [95, 96]. Le Perceptron Multicouches (PMC), également connu sous le nom de "MultiLayer Perceptron" (MLP), est un autre réseau très populaire et largement utilisé dans le domaine de la classification en général. Les différences entre ces architectures sont dues à la nature de leurs neurones et à leur mode de connexion.

Perceptron multicouches (PMC)

Le perceptron multicouches (PMC) est une famille de RNA qui se compose de neurones interconnectés en plusieurs couches : une couche d'entrée, une ou plusieurs couches cachées, et une couche de sortie. La sortie de chaque neurone est connectée à l'entrée des neurones de la couche suivante. En ajoutant des couches cachées, le PMC permet de modéliser des fonctions non-linéaires. La figure 3.2 illustre un PMC avec une couche cachée et une couche de sortie pour trois variables d'entrée. Les entrées sont




FIGURE 3.2 – Schéma d'un PMC avec mise en valeur d'un neurone.

pondérées par des poids spécifiques et sommées en ajoutant un biais. Cette somme devient l'argument d'une fonction d'activation, telle qu'une fonction à seuil ou une fonction sigmoïde. La couche de sortie détermine la classe du vecteur de caractéristiques d'entrée [97].

Le PMC est un RNA ayant une architecture "feedforward" qui permet d'approximer toute fonction continue "lisse", ce qui en fait un approximateur universel s'il est suffisamment grand en nombre de neurones et de couches. Il est également capable de classifier n'importe quel nombre de classes, ce qui le rend très flexible pour s'adapter à une grande variété de problèmes. Le PMC est particulièrement populaire pour des problèmes de classification supervisée ou de régression, malgré sa sensibilité au sur-apprentissage, notamment avec des données EEG bruitées et non-stationnaires. Pour minimiser ce risque, une sélection et une régularisation minutieuses de l'architecture sont nécessaires.

3.3.2 Analyse discriminante linéaire (LDA)

L'analyse discriminante linéaire (LDA) est un classifieur linéaire utilisant des fonctions linéaires pour distinguer les différentes classes [98]. Elle a été utilisée avec succès dans diverses applications, telles que la reconnaissance faciale, les techniques biométriques, la finance, le marketing, et l'analyse des vibrations [99]. En tant que méthode d'extraction de caractéristiques, elle permet de réduire la dimensionnalité des données en projetant celles-ci dans un espace de plus petite dimension, où les classes sont mieux séparées.

Le classifieur appelé LDA de Fisher est utilisé pour trouver la combinaison linéaire des caractéristiques qui permet de mieux séparer les données représentant différentes classes en réduisant les coûts de calcul. Pour les problèmes à deux classes, la classe d'un vecteur caractéristique est déterminée en fonction de l'hyperplan sur lequel il se trouve. LDA suppose une distribution normale des données et des matrices de covariance égales. L'hyperplan séparateur est obtenu en maximisant la distance entre les deux classes moyennes et en minimisant la variance interclasse pour obtenir une discrimination de classe maximale. La transformation optimale est obtenue en résolvant un problème généralisé de valeurs propres. LDA est utilisée avec succès dans de nombreuses applications, telles que la reconnaissance faciale, la finance, le marketing, etc [98, 99].

3.3.3 Machines à vecteurs de support

Les machines à vecteurs de support (SVM : Support Vector Machine), développées par Vapnik en 1999, sont des techniques de classification discriminante à apprentissage




FIGURE 3.3 – Effet du coefficient de régularisation C [3].
A) petites valeurs de C ; B) grandes valeurs de C

supervisé performantes, particulièrement pour les bases de données à haute dimension et fortement déséquilibrées. Les SVM reposent sur la création d'une séparation de deux groupes de points par un classificateur linéaire, appelé l'hyperplan, discriminant de marge maximale. L'hyperplan maximise les marges pour augmenter les capacités de généralisation et classifier les nouveaux exemples inconnus [100].

Les vecteurs de support sont les points les plus proches utilisés pour déterminer l'hyperplan. Pour maximiser la marge qui est la distance minimale entre l'hyperplan et les échantillons les plus proches de chaque classe, l'hyperplan qui maximise cette marge est considéré comme étant l'hyperplan séparateur optimal.

Les SVM linéaires sont une forme simple d'algorithme de classification, mais ils sont applicables uniquement si les données sont linéairement séparables. Pour des problèmes réels où les données ne sont pas linéairement séparables, une fonction non linéaire peut être utilisée pour séparer les données avec une augmentation minimale de la complexité du classifieur. Dans ce cas, le processus de classification se compose de deux étapes : la projection des vecteurs d'entrée dans un nouvel espace, suivi de l'utilisation de l'algorithme SVM pour trouver l'hyperplan optimal qui sépare les données dans cet espace. La régularisation de la SVM est importante pour optimiser la classification, avec le paramètre C (appelé contrainte de régularisation) étant un facteur important de régularisation. Le paramètre C est impliqué dans la fonction de minimisation des poids de l'hyperplan, qui prend en compte à la fois les poids de l'hyperplan et les erreurs de classification proportionnelles. Ainsi, le paramètre C indique l'importance accordée aux échantillons mal classés par rapport à la frontière de séparation.

Le paramètre C dans la SVM est crucial pour optimiser la classification. Il peut être interprété comme une tolérance au bruit du classifieur ou comme un compromis pour maximiser la marge de l'hyperplan en présence d'erreurs de classification. Une grande valeur de C va privilégier la classification précise des données d'entraînement même si cela implique des marges plus petites, ce qui peut entraîner un risque de surapprentissage. En revanche, une faible valeur de C va maximiser la marge, même si cela diminue la précision de la classification. La fonction de minimisation des poids de l'hyperplan inclut le paramètre C , comme exprimé en (3.44) ;

$$\min\left(\frac{1}{2}\|W\|^2 + C \sum_{i=1}^m \zeta\right) \quad (3.44)$$

D'autre part, pour résoudre le problème de données non linéaires, nous utilisons les fonctions noyau qui relient les vecteurs d'entrée à un espace de caractéristiques de grande dimension. Un produit scalaire entre les données et cet espace de dimensions plus grandes est alors recommandé. Les fonctions noyau non linéaires permettent de




FIGURE 3.4 – Comparaison d’hyperplans avec différents noyaux [3].
A) noyau linéaire, B) noyau RBF C) noyau polynomial.

calculer les produits directement dans l’espace d’origine, sans passer par la projection et la correspondance avec cet espace de dimensions supérieures. Parmi les fonctions noyau les plus couramment utilisées, on peut citer la fonction gaussienne, la fonction polynomiale et la fonction de base radiale (RBF), formulées respectivement, comme donné en (3.45);

$$K(x, y) = \exp\left(\frac{-\|x - y\|^2}{2\sigma^2}\right) \quad (3.45)$$

Le SVM avec les fonctions noyau est une méthode d’apprentissage supervisé qui permet de résoudre des problèmes de classification non linéaire en projetant les données d’entrée dans un espace de caractéristiques de grande dimension, où elles peuvent être linéairement séparées. Le choix de la fonction de noyau est crucial dans cette méthode, car elle permet de mesurer la similitude entre les vecteurs d’entrée dans l’espace de caractéristiques. Le SVM avec une fonction de noyau gaussienne, également appelé SVM-RBF (Radial Basis Function), est une méthode populaire pour la classification non linéaire en raison de sa grande flexibilité et de sa capacité à gérer des données hautement dimensionnelles. La figure 3.4 montre l’hyperplan de séparation avec différentes fonctions de noyau. Cette figure montre l’effet de différentes fonctions de noyau sur la forme de l’hyperplan de séparation.

Le classificateur SVM présente de nombreux avantages, notamment l’utilisation facile des limites non linéaires, des performances compétitives par rapport aux autres méthodes, et de bonnes propriétés de généralisation grâce à la maximisation de marge et au terme de régularisation, qui le rendent insensible au sur-apprentissage et à l’effet de la dimension. Cependant, ces avantages sont obtenus au détriment d’une faible vitesse d’exécution [101].

3.3.4 Classifieur des k plus proches voisins

Le classifieur des k plus proches voisins (kNN) est une méthode d’apprentissage supervisé non paramétrique qui repose sur la notion de proximité entre les instances de données d’apprentissage. Contrairement à certains autres algorithmes de classification, le kNN ne construit pas de modèle pendant la phase d’apprentissage. Au lieu de cela, l’échantillon d’apprentissage est associé à une fonction de distance et d’une fonction de choix de la classe en fonction des classes des k voisins les plus proches. L’algorithme kNN suppose que des objets similaires existent à proximité. Cette méthode est simple et ne nécessite pas de supposition sur la distribution des données, mais peut être sensible aux valeurs aberrantes et peut nécessiter un choix approprié du nombre k de voisins [102].

L’algorithme de classification kNN est une méthode d’apprentissage supervisé non paramétrique qui ne nécessite pas de construire un modèle. Au lieu de cela, il utilise

une fonction de distance pour trouver les k individus les plus similaires dans l'ensemble d'apprentissage à l'individu à classer. Ces k voisins sont ensuite utilisés pour déterminer la classe majoritaire de l'individu à classer. La métrique utilisée pour mesurer la distance entre les individus dépend du type de données et de la tâche de classification en question. Les avantages de l'algorithme kNN incluent sa simplicité et sa capacité à fonctionner sur des données non linéaires. Cependant, il peut être sensible aux données bruitées et peut être coûteux en termes de temps de calcul pour les grands ensembles de données.

Ce algorithme dépend de deux paramètres à ajuster pour des meilleurs résultats : le nombre de voisins retenus K et la fonction de similarité entre deux instances pour comparer le nouveau cas aux cas déjà classés.

Le nombre de voisins retenus K : Le nombre de voisins retenus K est un paramètre crucial de l'algorithme KNN. Il doit être choisi avec soin car il affecte directement la performance du classificateur. Il doit être une petite valeur entière positive et impaire pour éviter les égalités de votes. La valeur de K influence la flexibilité de la frontière de décision, ce qui affecte le biais et la variance du modèle. Un faible K (par exemple, $K = 1$) produit une frontière très flexible avec un faible biais et une variance élevée. D'autre part, un grand K produit une frontière de décision presque linéaire. Le choix de K dépend de la complexité du problème de classification.

La fonction de similarité : La fonction de similarité dans l'algorithme kNN est essentielle pour estimer la classe de la nouvelle instance à classer en calculant la distance entre cette instance x et chaque instance de l'ensemble d'apprentissage. Cette mesure de distance doit satisfaire aux propriétés suivantes :

$$d(\omega_i, \omega_i) = 0 \quad (3.46)$$

$$d(\omega_i, \omega_j) = d(\omega_j, \omega_i) \quad (3.47)$$

$$d(\omega_i, \omega_j) \leq d(\omega_i, \omega_k) + d(\omega_j, \omega_k) \quad (3.48)$$

Avec sont $\omega_i, \omega_j, \omega_k$ des individus appartenant a l'ensemble d'apprentissage Ω . Il existe une variété de mesures de distance disponibles.

1. La distance Euclidienne

La mesure de distance euclidienne est la plus couramment utilisée et populaire pour l'algorithme KNN. Elle correspond à la racine carrée de la somme des carrés des différences entre les éléments correspondants des deux vecteurs représentant les instances. Pour des attributs numériques, comme exprimé en 3.49 ;

$$d(X, Y) = \sqrt{\sum_{i=1}^p (x_i(p) - y_i(p))^2} \quad (3.49)$$

où X et Y sont deux instances représentées par des vecteurs de p attributs.

2. La distance euclidienne pondérée :

La distance euclidienne pondérée est une version modifiée de la distance euclidienne qui prend en compte les poids pour chaque élément d'entrée $x(i)_p$. Les

poids permettent de donner une importance différente à chaque attribut dans le calcul de la distance selon le poids correspondant w_p . La formule de la distance euclidienne pondérée est donnée par l'équation 3.50

$$d(X, Y) = \sqrt{\sum_{i=1}^p (w_i \cdot (x_i(p) - y_i(p))^2)} \quad (3.50)$$

3. La mesure de Mahalanobis [103] La distance de Mahalanobis mesure la distance entre un vecteur d'attributs, représentant l'instance à classer x_i , et la distribution D . Elle généralise l'idée de mesurer la distance en termes d'écart types de x_i à la moyenne de D . Si x_i est à la moyenne de la distribution D , la distance est nulle. Elle peut également être définie comme la mesure de dissemblance entre x_i et le vecteur d'apprentissage y_i de la même distribution. La distance de Mahalanobis est donnée par 3.51 :

$$d(X, Y) = \sum_{n=1}^N \sum_{m=1}^M a_k(n, m) [x_i(n) - y_i(n)][x_i(m) - y_i(m)] \quad (3.51)$$

La distance de Mahalanobis est sans unité, car elle est calculée en divisant la distance euclidienne par l'écart type de chaque variable, ce qui annule l'effet des unités de mesure. Ainsi, elle est utilisable pour comparer des variables de différentes unités de mesure. De plus, la distance de Mahalanobis est invariante à l'échelle. Cela signifie que si toutes les variables sont multipliées par un même facteur, la distance de Mahalanobis entre les points reste la même. Par conséquent, elle est robuste aux changements d'échelle dans les données. Enfin, la distance de Mahalanobis prend en compte les corrélations entre les variables de l'ensemble de données. Elle mesure la distance en fonction des relations entre les variables, et pas seulement de manière indépendante pour chaque variable. Cela rend la distance de Mahalanobis plus appropriée pour les ensembles de données multivariés où les variables sont corrélées.

4. La distance de Minkowski

La distance de Minkowski est une généralisation de la distance euclidienne et de la distance de Manhattan. Elle permet de calculer la distance entre deux vecteurs de données dans un espace à p dimensions, où p est le nombre d'attributs ou de caractéristiques des données. La distance d'ordre ν est donnée par l'équation 3.52, où ν est un paramètre réel.

$$d(X, Y) = \left(\sum_{i=1}^p (x_i(p) - y_i(p))^\nu \right)^{\frac{1}{\nu}} \quad (3.52)$$

Si $\nu = 1$, alors la distance de Minkowski est équivalente à la distance de Manhattan. Si $\nu = 2$, la distance de Minkowski est équivalente à la distance euclidienne. La distance de Minkowski est sans unité et invariante à l'échelle pour toutes les valeurs de ν , ce qui signifie que la distance ne dépend pas de l'unité de mesure des attributs et est insensible à l'étendue des données.

Le classificateur kNN (k-Nearest Neighbor) est simple à implémenter et intuitif. Il peut atteindre des performances élevées sans hypothèses sur la distribution des données d'apprentissage. Il présente l'avantage de ne pas nécessiter de phase d'apprentissage,

de produire des résultats faciles à comprendre et d'être robuste aux attributs manquants et à la qualité des données. Cependant, l'algorithme kNN a un temps d'apprentissage lent et ses performances dépendent du choix du nombre de voisins k et de la distance utilisée. De plus, l'algorithme nécessite un espace mémoire important pour stocker les données.

3.3.5 Classifieur Bayésien Naïf

La classification naïve de Bayes combine la connaissance antérieure des classes avec de nouvelles preuves recueillies à partir des données. Le classificateur Naive Bayes est basé sur le théorème de Bayes, qui permet de calculer la probabilité postérieure d'une paire de variables aléatoires X et Y en fonction de la probabilité a priori $P(Y)$, de la probabilité conditionnelle de classe $P(X|Y)$ et de la preuve $P(X)$ [104]. Ce classificateur est simple et efficace, mais il repose sur l'hypothèse que les attributs sont indépendants, ce qui peut ne pas être le cas dans la réalité.

$$P(C|Y_1, \dots, Y_n) = \frac{P(Y_1, \dots, Y_n|C)P(c)}{P(Y_1, \dots, Y_n)} \quad (3.53)$$

Le classifieur Naive Bayes est basé sur l'hypothèse d'indépendance entre les variables, ce qui implique que la présence ou l'absence d'une caractéristique particulière d'une classe n'est pas liée à la présence ou à l'absence d'une autre caractéristique de la même classe, même si ces caractéristiques décrivent le même modèle. En conséquence, la fonction de décision du classifieur Naive Bayes est obtenue en déterminant la probabilité a posteriori maximale, qui prend la forme en 3.54 [104] :

$$P(c|y_1, y_2, \dots, y_n) = \frac{P(c) \prod_{i=1}^n P(Y_i|c)}{P(y_1, y_2, \dots, y_n)} \quad (3.54)$$

Avec y_i sont les caractéristiques d'un ensemble d'échantillons x_i associés à leur étiquettes de classe c_{x_i} .

Le classificateur Naive Bayes présente l'avantage de surpasser des méthodes de classification plus complexes en termes de temps et de performance, même avec un petit nombre de données d'apprentissage. Ceci le rend particulièrement utile pour des applications de diagnostic médical automatisé.

3.3.6 Arbre de décision

Un arbre de décision est un modèle de classification graphique qui utilise des tests sur les attributs des caractéristiques pour répartir les données dans des sous-arbres jusqu'à atteindre une feuille qui contient le résultat final. Le choix de la règle de décision de chaque nœud se fait en fonction d'un critère de pureté, qui peut être la minimisation de l'entropie ou de l'impureté des branches. Les caractéristiques les plus discriminantes sont utilisées pour les premières règles de décision, situées près de la racine. La capacité de ce modèle est déterminée par la profondeur de l'arbre et les hyperparamètres, tels que le nombre minimum de données pour diviser un nœud et le nombre minimum de données par feuille. Les arbres de décision sont largement utilisés dans divers domaines tels que la reconnaissance de la parole, la reconnaissance de l'écriture manuscrite, la classification de données médicales et la prédiction de maladies [105].

Les arbres de décision sont des modèles de classification performants qui peuvent générer des règles de classification en trouvant les variables discriminantes dans un

grand volume de données. Ils sont donc très utiles pour l'apprentissage supervisé et couramment utilisés dans l'exploration des données.

3.4 MÉTRIQUES DE PERFORMANCES

Pour évaluer la performance d'un algorithme de détection de crises épileptiques, plusieurs métriques de validation sont utilisées. Elles sont basées sur quatre scénarios possibles

- le vrai positif (VP) qui correspond à la détection d'un événement qui doit être détecté
- le faux positif (FP) qui correspond à la détection d'un événement qui ne doit pas être détecté
- le faux négatif (FN) qui correspond à la non-détection d'un événement qui doit être détecté
- le vrai négatif (VN) qui correspond à la non-détection d'un événement qui ne doit pas être détecté

Les mesures de performance les plus couramment utilisées sont la sensibilité (Sens), la spécificité (Spec), le taux de classification global (Acc), la précision (Prec), le score F1 (F1-score) et l'aire sous la courbe (AUC).

Les mesures de performance les plus couramment utilisées sont la sensibilité (Sens), la spécificité (Spec), le taux de classification global (Acc), la précision (Prec), le score F1 (F1-score) et l'aire sous la courbe (AUC).

- **Sensibilité (Sens)** La sensibilité (ou le taux de vrais positifs) est une mesure de performance qui évalue la capacité d'un algorithme de détection des crises épileptiques à identifier les segments EEG qui contiennent réellement des événements épileptiques. Elle est calculée en divisant le nombre de segments EEG positifs correctement identifiés par l'algorithme (c'est-à-dire les vrais positifs) par le nombre total de segments positifs dans le jeu de données. Ainsi, la sensibilité mesure la capacité de l'algorithme à détecter les vrais événements épileptiques, et une sensibilité élevée indique que l'algorithme est capable de détecter efficacement les crises épileptiques. L'équation 3.55 représente la formule mathématique pour calculer la sensibilité (Sens) d'un algorithme de détection de crises épileptiques.

$$Sens = \frac{VP}{VP + FN} \quad (3.55)$$

Elle est définie comme le rapport entre le nombre de vrais positifs (VP) et la somme du nombre de vrais positifs et de faux négatifs (FN). En d'autres termes, la sensibilité mesure la capacité de l'algorithme à détecter les événements épileptiques réels (vrais positifs) par rapport à ceux qui ont été omis (faux négatifs). Plus la sensibilité est élevée, meilleure est la capacité de l'algorithme à détecter les crises épileptiques.

- **Spécificité (Spec)** La spécificité (Spec) est une métrique de validation d'algorithme de détection de crises épileptiques. Elle mesure la proportion de segments EEG négatifs correctement classés par l'algorithme par rapport au nombre total de segments EEG négatifs réels. Elle est calculée à partir de la formule suivante :

$$Spec = \frac{VN}{VN + FP} \quad (3.56)$$

où VN représente le nombre de vrais négatifs, c'est-à-dire le nombre de segments EEG négatifs correctement classés comme tels par l'algorithme, et FP représente le nombre de faux positifs, c'est-à-dire le nombre de segments EEG négatifs classés à tort comme positifs par l'algorithme.

- **Taux total de classification (Acc)** Le taux total de classification (Acc) est une mesure de la performance de l'algorithme de détection des crises épileptiques qui évalue la proportion de segments EEG correctement classés par rapport à l'ensemble des segments considérés pour la classification.

$$Acc = \frac{VN + VP}{VN + FN + FP + VP} \quad (3.57)$$

où VN est le nombre de vrais négatifs, VP est le nombre de vrais positifs, FN est le nombre de faux négatifs et FP est le nombre de faux positifs. L'équation (3.57) permet de calculer le taux total de classification (Acc). Ce taux représente le nombre total de segments EEG correctement classés par l'algorithme, c'est-à-dire la somme des vrais positifs et des vrais négatifs, divisé par le nombre total de segments considérés pour la classification, c'est-à-dire la somme de tous les cas possibles : vrais positifs, faux positifs, vrais négatifs et faux négatifs. En d'autres termes, Acc mesure la proportion de segments EEG correctement classés par l'algorithme sur l'ensemble des segments à classer.

Le taux total de classification (Acc) est une mesure globale de la performance de l'algorithme de détection de crises épileptiques, qui prend en compte le nombre de vrais positifs (VP), de vrais négatifs (VN), de faux positifs (FP) et de faux négatifs (FN). Une augmentation du taux total de classification indique une amélioration globale de la performance de l'algorithme de détection de crises épileptiques, tandis qu'une diminution indique une dégradation de la performance. Cependant, il est important de tenir compte des autres mesures de performance, telles que la sensibilité, la spécificité et la précision, pour comprendre en détail comment l'algorithme fonctionne et où les erreurs sont commises.

- **Précision (Prec)** La précision est calculée comme le rapport des vrais positifs sur la somme des vrais positifs et des faux positifs. Cela permet d'évaluer la proportion de segments de données EEG identifiés positifs par l'algorithme qui sont réellement positifs, comme exprimé en (3.58);

$$Prec = \frac{VP}{VP + FP} \quad (3.58)$$

où VP (Vrais positifs) est le nombre de segments de données EEG qui sont réellement positifs et qui sont correctement identifiés comme positifs par l'algorithme. FP (Faux positifs) est le nombre de segments de données EEG qui sont réellement négatifs, mais qui sont identifiés à tort comme étant positifs par l'algorithme. Une précision élevée indique que la plupart des segments EEG classés positifs par l'algorithme sont effectivement des vrais positifs, c'est-à-dire des segments contenant une crise épileptique. Cela signifie qu'il y a un faible taux de faux positifs, c'est-à-dire que peu de segments normaux sont classés comme positifs. La précision est donc un indicateur important de la qualité de l'algorithme de détection de crises épileptiques.

- **Mesure de score F (F1-score)** La mesure de score F (F1-score) est une mesure de performance qui combine à la fois la précision et la sensibilité. Elle permet d'évaluer l'algorithme en tenant compte des vrais positifs et des faux négatifs.

Cette mesure est particulièrement utile lorsque les classes de données sont déséquilibrées (c'est-à-dire qu'il y a beaucoup plus d'exemples d'une classe que de l'autre), car elle prend en compte à la fois la précision et la sensibilité. Le F1-score est une mesure comprise entre 0 et 1, où 1 indique une performance parfaite et 0 une performance nulle. Elle est calculée comme la moyenne harmonique de la précision et de la sensibilité, comme exprimé en (3.59) ;

$$F_1 \text{ Score} = 2 \times \frac{\text{Prec} \times \text{Sens}}{\text{Prec} + \text{Sens}} \quad (3.59)$$

Une augmentation du F1-score indique une amélioration de la performance de l'algorithme, tandis qu'une diminution indique une détérioration. Le F1-score est souvent utilisé en classification binaire, où l'objectif est de détecter une classe positive (par exemple, la détection d'une crise épileptique) parmi une classe négative (par exemple, l'activité normale du cerveau).

- **Aire sous la courbe (AUC)** L'aire sous la courbe (AUC) est une mesure de performance couramment utilisée pour évaluer les performances d'un algorithme de classification binaire. Cette mesure évalue la capacité de l'algorithme à discriminer entre les classes positives et négatives en calculant la surface sous la courbe ROC (Receiver Operating Characteristic). La courbe ROC est créée en traçant le taux de vrais positifs (Sensibilité) en fonction du taux de faux positifs (1 - Spécificité) pour différents seuils de classification. Ainsi, une AUC élevée indique une meilleure capacité de l'algorithme à distinguer les classes positives et négatives, tandis qu'une AUC faible indique une faible capacité de discrimination. La valeur AUC varie de 0,5 (classification aléatoire) à 1,0 (classification parfaite).

Les rapports de vraisemblance (LR) sont des mesures statistiques utilisées pour évaluer la performance des tests diagnostiques. Ils sont basés sur la sensibilité et la spécificité du test et permettent d'évaluer la probabilité d'un résultat positif ou négatif en présence ou en absence de la maladie ou de l'attribut étudié. Le rapport de vraisemblance positif (LR+) compare la probabilité d'un résultat de test positif en présence de l'attribut d'intérêt à la probabilité d'un résultat positif en l'absence de cet attribut, tandis que le rapport de vraisemblance négatif (LR-) compare la probabilité d'un résultat de test négatif en présence de l'attribut d'intérêt à la probabilité d'un résultat négatif en l'absence de cet attribut. Un LR+ élevé indique une forte probabilité de maladie ou d'attribut, tandis qu'un LR- faible indique une forte probabilité d'absence de maladie ou d'attribut. Les valeurs comprises entre 0 et 1 diminuent la probabilité de la maladie, et plus le LR est proche de zéro, plus les preuves contre un diagnostic de maladie sont fortes. Les valeurs égales à zéro n'ont aucun effet sur la probabilité du prétest, il n'y a donc pas de diagnostic pour elles. Le coefficient de corrélation de Matthews (MCC) est une autre mesure d'évaluation de la performance des tests diagnostiques. Il est basé sur la sensibilité, la spécificité, les vrais positifs, les vrais négatifs, les faux positifs et les faux négatifs du test. Le MCC mesure la corrélation entre les résultats du test et les résultats réels, en prenant en compte les erreurs positives et négatives. Le MCC varie entre -1 et 1, où 1 indique une corrélation parfaite entre le test et les résultats réels, 0 indique une absence de corrélation et -1 indique une corrélation inversée parfaite.

Contrairement à d'autres métriques, le MCC n'est pas affecté par le problème des ensembles de données déséquilibrés. Il se situe dans l'intervalle [-1, +1], où une valeur de 1 indique la meilleure correspondance entre les valeurs réelles et prédites, indiquant une classification parfaite. Un MCC nul correspond à une absence totale de correspondance, indiquant une mauvaise classification. En analyse des classifications binaires, le MCC

est une métrique compréhensible des données déséquilibrées [106]. Le LR+, LR- et le MCC sont exprimés en (3.60), (3.61), et (3.62), respectivement.

$$\text{LR+} = \frac{\text{Sens}}{1 - \text{spec}} \quad (3.60)$$

$$\text{LR-} = \frac{1 - \text{Sens}}{\text{spec}} \quad (3.61)$$

$$\text{MCC} = \frac{(\text{VP} \cdot \text{VN}) - (\text{FP} \cdot \text{FN})}{\sqrt{(\text{VP} \cdot \text{FP}) \cdot (\text{VP} \cdot \text{FN}) \cdot (\text{VN} \cdot \text{FP}) \cdot (\text{VN} \cdot \text{FN})}} \quad (3.62)$$

3.5 CONCLUSION

Ce chapitre présente les techniques employées dans le cadre de cette thèse dédié a la détection des crises d'épilepsie. Nous avons décrit les différents caractéristiques des signaux EEG qui peuvent être extraites du domaine temporel, fréquentiel ainsi que le domaine temps-fréquence. Ensuite, nous avons présenté dans la deuxième partie de ce chapitre, la théorie mathématique, les différents types et le principe fondateur des classificateur de l'apprentissage supervisé tels que; Les réseaux de neurones artificiels (RNA), Analyse discriminante linéaire (LDA), les machines à vecteur support (SVM), le classificateur des k plus proches voisins (kNN), classifieur Naif de Bayes (NBC) et l'arbre de décision (DT). Le prochain chapitre présentera les résultats de la nouvelle approche proposé dans ce travail dédié a la détection de la crise épileptique, pour différentes base de données.

DÉTECTION DES CRISES D'ÉPILEPSIE PAR ANALYSE TEMPS-FRÉQUENCE DU SIGNAL EEG

4

4.1 INTRODUCTION

L'objectif principal de cette étude est de concevoir et d'implanter un algorithme efficace et résistant pour la détection des crises épileptiques à partir de l'analyse et la classification de signaux EEG. Cet algorithme est basé sur l'analyse des signaux EEG dans le domaine temps-fréquence pour détecter l'activité épileptiforme associée aux crises d'épilepsie.

Dans ce chapitre, nous avons abordé les principaux axes de recherche liés à la détection des crises d'épilepsie à partir des signaux EEG, en accordant une attention particulière à l'analyse temps-fréquence. Nous avons ensuite présenté notre méthode de détection des activités épileptiformes dans les signaux EEG, ainsi que les résultats obtenus sur diverses bases de données. Enfin, nous avons effectué une étude comparative entre les résultats obtenus à l'aide de notre méthode et ceux présentés dans la littérature.

4.2 ALGORITHMES DE DÉTECTION DES CRISES ÉPILEPTIQUES : ÉTAT-DE-L'ART

L'apparition d'une crise d'épilepsie est caractérisée par des changements brutaux dans la nature, l'amplitude et la fréquence spectrale du signal EEG. Cette section présente une vue d'ensemble concise mais non exhaustive des méthodes et algorithmes utilisés pour le traitement, l'analyse, l'exploration et la classification des signaux EEG dans le but de détecter l'activité épileptique. Nous nous concentrons sur les principaux axes de recherche relatifs à la détection des crises d'épilepsie à partir de signaux EEG, en nous limitant à l'analyse temps-fréquence. Il est important de souligner que cette technique est particulièrement adaptée pour l'analyse des signaux EEG, car elle permet de suivre l'évolution temporelle des différentes bandes de fréquences du signal, permettant ainsi de mieux comprendre les modifications qui ont lieu lors de l'apparition d'une crise.

Généralement, trois étapes principales forment un système automatisé conçu pour l'analyse des événements pré-critiques, critiques et post-critiques. La première étape consiste à utiliser un filtre pour éliminer toutes les composantes confusionnelles telles que le bruit et les artefacts, afin de ne conserver que le signal d'intérêt. La deuxième étape consiste à extraire les caractéristiques pertinentes du signal, c'est-à-dire à trouver




FIGURE 4.1 – Diagramme d'un système automatique de détection des crises épileptique

la représentation qui correspond mieux aux exigences d'analyse et aux attributs requis. Enfin, la troisième étape consiste à analyser et classer les valeurs des descripteurs extraits pour déterminer les valeurs physiologiques souhaitées, ce qui permet d'identifier les événements critiques et de les caractériser. Ce processus automatisé permet une analyse plus rapide, plus précise et plus objective que l'analyse manuelle du signal. La figure 4.1 montre un exemple de diagramme de système automatisé pour l'analyse des événements pré-critiques, critiques et post-critiques.

De nombreuses méthodes et algorithmes ont été développés pour la détection automatique des crises d'épilepsie, qui sont largement documentés dans la littérature. Ces méthodes se concentrent principalement sur l'extraction de caractéristiques à partir des données EEG dans le domaine temporel [107], le domaine fréquentiel [108], telles que l'analyse du spectre marginal de Hilbert (HMS)[109], la transformation en ondelettes[110], l'énergie des signaux EEG [111], les mesures chaotiques [52] et les mesures d'entropie [112, 113]. Ces caractéristiques sont ensuite utilisées pour classer les signaux EEG en événements épileptiques et non-épileptiques.

Certains algorithmes combinent différentes méthodes pour améliorer la détection automatique des crises d'épilepsie. Par exemple, l'algorithme proposé par Ocak [114] utilise une combinaison des transformées en ondelettes et de l'entropie approximative (ApEn). De même, l'algorithme de Lee [115] utilise la transformée en ondelettes (WT) en combinaison avec la reconstruction de l'espace de phase (PSR) et la distance euclidienne (ED), basée sur un réseau de neurones avec des fonctions d'appartenance floues pondérées (NEWFM).

Les signaux EEG sont non-stationnaires et non-linéaires, avec une variabilité dans leur contenu spectral au fil du temps. Pour analyser simultanément le signal dans les domaines temporel et fréquentiel, les distributions temps-fréquence (TFD) sont nécessaires. Ces TFD fournissent une image plus révélatrice de la localisation temporelle des composantes spectrales d'un signal et sont plus adaptées à la reconnaissance des crises. Récemment, de nombreux algorithmes ont été développés pour analyser les données EEG en utilisant la TFD pour la reconnaissance automatique des crises d'épilepsie.

Une étude menée par Tzallas *et al.* [116] vise à explorer les caractéristiques des signaux électroencéphalographiques (EEG) dans le domaine temps-fréquence. Pour ce faire, les auteurs ont analysé des segments de signaux EEG en utilisant différents paramètres de résolution temps-fréquence, de fenêtres temporelles et de sous-bandes de fréquences. Ils ont utilisé la distribution pseudo-Wigner ville lissée (SPWVD) pour extraire les caractéristiques spectrales du signal, en reflétant la distribution d'énergie dans le plan temps-fréquence. Ensuite, les auteurs ont appliqué l'analyse en composantes principales (PCA) sur les caractéristiques obtenues. Les résultats ont montré un taux de classification de 97,72% en utilisant un réseau neuronal artificiel (ANN), ce qui suggère que les caractéristiques spectrales extraites peuvent être utilisées pour la classification des signaux EEG.

L'étude menée par Tzallas *et al.* [117] visait à appliquer leur méthode précédente à différentes TFD pour classer les signaux EEG. Pour cela, ils ont utilisé une base de données différente et ont appliqué la transformée de Fourier à court terme (TFCT) ainsi

que 12 autres TFD pour extraire des caractéristiques spectrales du signal. Ils ont ensuite utilisé un classificateur ANN pour classifier les signaux EEG. Les résultats ont montré un taux de classification global de 99,28%. Cependant, l'utilisation d'une fenêtre de lissage temps-fréquence identique pour chaque TFD rendait la méthode moins appropriée pour les applications pratiques.

L'étude menée par Fani et al. [118] a utilisé les caractéristiques dérivées de la fréquence instantanée (FI) et de l'énergie du signal EEG pour classifier les signaux EEG en différentes classes. La fréquence instantanée est la fréquence dominante à un instant donné et varie au cours du temps. Les auteurs ont utilisé la FI dans la bande fréquentielle de 0 – 30Hz, qui est importante pour l'analyse des signaux EEG. Ils ont également examiné l'énergie du signal EEG dans les sous-bandes spectrales δ , θ , α et β . Les sous-bandes spectrales sont des bandes de fréquences qui se chevauchent dans le signal EEG et sont souvent utilisées pour caractériser différents états cérébraux. Les auteurs ont utilisé un classificateur ANN pour classifier les signaux EEG en différentes classes et ont obtenu un taux de classification de 95,3% avec une longueur de segment EEG de 5 secondes.

Markos et al.[119] proposent un algorithme pour extraire des caractéristiques spectrales à partir du signal EEG en utilisant des seuils spectraux pour diviser le signal en plusieurs sous-bandes de fréquence. Ils ont ensuite extrait différentes caractéristiques spectrales telles que l'énergie des sous-bandes, l'énergie totale de l'EEG, l'énergie fractionnelle des sous-bandes et l'entropie spectrale. Ils ont utilisé un classificateur de forêt aléatoire pour classifier les signaux EEG. Cependant, l'augmentation du nombre de seuils spectraux possibles peut entraîner une plage de sous-bande de fréquence supérieure à 2Hz, ce qui peut affecter la capacité à détecter des modulations de fréquence dans des bandes plus étroites. En conséquence, cela pourrait empêcher une analyse plus approfondie des sous-bandes de fréquence et réduire la précision de la classification.

Dans leur étude, Zhang *et al.* ont utilisé une technique de transformation en paquets d'ondelettes (WT) pour extraire des caractéristiques temporelles et fréquentielles de l'EEG. La WT est une technique de transformation de signal qui permet d'analyser le signal en fonction de l'échelle et de la fréquence. En utilisant la WT, les auteurs ont obtenu des caractéristiques temporelles et fréquentielles de l'EEG à différentes échelles de temps et de fréquence. Ensuite, ces caractéristiques ont été utilisées comme entrées pour un réseau de neurones convolutif (CNN) qui a été entraîné pour classer les signaux EEG en deux groupes : les signaux normaux et les signaux anormaux. Les résultats de l'étude ont montré que cette approche a atteint un taux de classification de 98,4% en utilisant une base de données de 5000 signaux EEG, ce qui indique que la combinaison de la WT et du CNN est une approche efficace pour l'analyse des signaux EEG [120].

Ces résultats montrent que les caractéristiques temporelles et fréquentielles des signaux EEG peuvent être extraites de manière efficace pour la classification des signaux normaux et anormaux. Les techniques de classification telles que les réseaux de neurones artificiels, les réseaux de neurones convolutifs et les forêts aléatoires ont montré une grande précision pour la classification des signaux EEG. Cependant, la sélection de la méthode de classification appropriée dépendra des spécifications de l'application et de la nature des signaux EEG à classer.

Certains auteurs se concentrent sur l'extraction de caractéristiques statistiques dans le plan temps-fréquence de l'EEG. Guerrero *et al.* [121] ont utilisé la distribution Smoothed Pseudo Wigner-Ville (SPWVD) et le modèle sinusoidal de McAulay-Quatieri pour former un vecteur de caractéristiques basé sur des mesures telles que la longueur, la fréquence et l'énergie (L, F, E) dans chaque segment. Cette méthode a été appliquée à

deux bases de données : une de l'université de Bonn et l'autre collectée auprès de sept patients épileptiques adultes pendant les stades de repos et d'éveil dans le département de neurophysiologie de l'Université de Clinique à Pampelune, en Espagne. Cependant, la durée des enregistrements EEG n'était pas très longue. Les résultats ont montré une sensibilité de 72,1% et une spécificité de 96%.

De plus, *Donos et al.* ont proposé un algorithme basé sur des caractéristiques statistiques dans le domaine temps-fréquence pour détecter les crises d'épilepsie à l'aide d'un dispositif de stimulation à rétroaction implantable. Les caractéristiques comprennent la moyenne, la variance, l'écart absolu moyen, l'asymétrie, l'aplatissement, la longueur de ligne, l'autocorrélation, la puissance dans la bande de fréquence infrarouge, ainsi que le rapport de puissance entre les bandes alpha, bêta et gamma, calculées sur la base de contacts EEG intracrâniens localisés dans la zone d'apparition des crises. L'algorithme utilise le classificateur Random Forrest pour améliorer la précision globale de la classification, atteignant une amélioration de 93,84

En combinant l'analyse spectrale avec l'analyse de la complexité d'EEG, plusieurs études ont obtenu des résultats prometteurs en termes de classification de signaux EEG. Dans l'étude de Liang et al. [122], les caractéristiques EEG ont été extraites à partir de l'entropie approximative (ApEn) avec le spectre de puissance moyenne pour chaque sous-bande de 4,0Hz. Les auteurs ont utilisé la machine à vecteurs de support à fonction de base radiale (RBFSVM) et la machine à vecteurs de support linéaire (SVM) comme classificateurs et ont obtenu des taux de classification globaux respectifs de 85,9% et 96,83%–98,67%.

Dans une autre étude [123], Pal et al. ont employé diverses caractéristiques entropiques telles que l'entropie de permutation (PE), l'entropie de Tsallis (TsE), l'entropie de Kolmogorov (KE), l'entropie de Reyni (RE) et l'entropie d'échantillon (SampEn) pour identifier une crise épileptique à l'aide de cinq classificateurs différents. Les meilleurs résultats ont été obtenus avec le classificateur d'arbre de décision, qui a abouti à un taux de classification de 97%.

Dans l'étude de Ridouh et al. [124], les signaux EEG de la base de données de l'université de Bonn ont été analysés à l'aide de la transformée en ondelettes quadratiques (QTFD) et en particulier le spectrogramme (SP), la distribution de Choi-Williams (CWD) et la SPWVD. Les pics de crise ont été identifiés en trouvant les valeurs maximales des QTDFs calculés, et l'entropie marginale de Renyi (RME) normalisée a été extraite pour différentes longueurs de fenêtre pour SP et SPWVD. Les résultats montrent que la SPWVD avec la RME a fourni les meilleurs résultats pour le problème d'identification des pics en termes de résolution temps-fréquence. La classification des signaux a été effectuée par un seuil qui a été défini par la moyenne de la moyenne mobile de l'énergie pour chaque bande, et les résultats ont été utilisés comme entrée d'une fonction de score pour classer chaque signal.

Boubechir *et al.* ont cherché à améliorer la performance des systèmes automatisés de détection et de classification des crises épileptiques. Pour cela, ils ont transformé certaines caractéristiques temporelles pertinentes telles que la moyenne, la variance, l'asymétrie, l'aplatissement, le coefficient de variation, l'amplitude de l'écart absolu médian, l'amplitude de la moyenne quadratique (RMS), l'intervalle interquartile (IQR), et l'entropie de Shannon (SE), ainsi que des caractéristiques fréquentielles telles que la puissance maximale des bandes de fréquence, le flux spectral, le centroïde spectral, le roll-off spectral, la planéité spectrale, et l'entropie spectrale, dans le domaine temps-fréquence conjoint (TF). Ils ont validé ces caractéristiques en utilisant des procédures d'étalonnage. Ces caractéristiques TF ont permis une amélioration de 7% des résultats de classifica-

tion par rapport à la version originale. Les résultats de précision obtenus sont de 98,57%, 97,14%, 98,57% et 97,14% pour SP, WVD, SPWVD, CWD respectivement. Cependant, il convient de noter que le signal EEG a été enregistré à partir d'un segment EEG à canal unique d'une durée de 23,6 secondes. Les caractéristiques temporelles et fréquentielles converties dans le domaine TF sont présentées dans les tableaux 4.1 et 4.2.

Caractéristiques	Domaine temporel	Domaine conjoint T-F
Moyenne [125, 126]	$\mu_{(t)} = \frac{1}{N} \sum_n z[n]$	$\mu_{(t,f)} = \frac{1}{NM} \sum_n \sum_m \rho_x[n, m]$
variance [125, 126]	$\sigma_{(t)}^2 = \frac{1}{N} \sum_n (z[n] - \mu_{(t)})^2$	$\sigma_{(t,f)}^2 = \frac{1}{NM} \sum_n \sum_m (\rho_x[n, m] - \mu_{(t,f)})^2$
L'asymétrie [125, 126]	$\gamma_{(t)} = \frac{1}{N\sigma_{(t)}^3} \sum_n (z[n] - \mu_{(t)})^3$	$\gamma_{(t,f)} = \frac{1}{NM\sigma_{(t,f)}^3} \sum_n \sum_m (\rho_x[n, m] - \mu_{(t,f)})^3$
L'aplatissement [125, 126]	$k_{(t)} = \frac{1}{N\sigma_{(t)}^4} \sum_n (z[n] - \mu_{(t)})^4$	$k_{(t,f)} = \frac{1}{NM\sigma_{(t,f)}^4} \sum_n \sum_m (\rho_x[n, m] - \mu_{(t,f)})^4$
L'écart absolu médian de l'amplitude [126]	$EAB = \frac{1}{N} \sum_{n=1}^N (z[n] - \mu_{(t)})$	$EAB_{(t,f)} = \frac{1}{NM} \sum_{n=1}^N \sum_{m=1}^M (\rho_x(n, m) - \mu_{(t,f)})$
Écart type [125]	$STD_{(t)} = \frac{\sigma_{(t)}}{\mu_{(t)}}$	$STD_{(t,f)} = \frac{\sigma_{(t,f)}}{\mu_{(t,f)}}$
La valeur quadratique moyenne RMS [77]	$RMS(t) = \sqrt{\frac{\sum_{n=1}^N z[n]^2}{N}}$	$RMS(t, f) = \sqrt{\frac{\sum_{n=1}^N \sum_{m=1}^M \rho_x(n, m)}{NM}}$
Plage interquartile [127]	$IQR(t) = z[\frac{3(N+1)}{4}] - z[\frac{N+1}{4}]$	$IQR(t, f) = \frac{1}{M} \sum (\rho_x[\frac{3(N+1)}{4}, k] - \rho_x[\frac{N+1}{4}, k])$
L'entropie de Shannon [126, 77]	$ShEn = -\sum_{n=1}^N z[n] \log_2(z[n])$	$ShEn_{(t,f)} = -\sum_{n=1}^N -\sum_{k=1}^M \rho_x(n, m) \log_2(\rho_x(n, m))$

TABLE 4.1 – Caractéristiques temporelles et leur conversion en domaine conjoint T-F

Caractéristiques	Domaine fréquentiel	Domaine conjoint T-F
Flux spectral [126]	$F_1 = \sum_{m=1}^M (Z^l(m) - Z^{l-1}(m))^2$	$F_{(t,f)1} = \sum_{n=1}^L \sum_{m=1}^P (\rho_x[n, m] - \rho_x[n+L, m])^2$
Spectral Roll-Off [126]	$F_2 = \lambda \sum_{m=1}^M Z[m] $	$F_{(t,f)2} = \lambda \sum_{n=1}^N \sum_{m=1}^M \rho_x[n, m] $
La planéité spectrale [126]	$F_3 = \frac{1}{\frac{(\prod_{m=1}^M Z[m]) \overline{M}}{\prod_{m=1}^M Z[m]}}$	$F_{(t,f)3} = \frac{1}{\frac{(\prod_{n=1}^N \prod_{m=1}^M \rho_x[n, m]) \overline{NM}}{(\prod_{n=1}^N \prod_{m=1}^M \rho_x[n, m])}}$
Puissance maximale de deux bandes fréquentiel [77, 125]	$F_4 = \sum_{m=1}^{\sigma} Z[m] ^2$ $F_5 = \sum_{m=\sigma+1}^M Z[m] ^2$	$F_{(t,f)4} = \sum_{n=1}^N \sum_{m=1}^{M_{\sigma}} \rho_x[n, m]$ $F_{(t,f)5} = \sum_{n=1}^N \sum_{m=M_{\sigma+1}}^M \rho_x[n, m]$ Avec $M_{\sigma} = M/f_s$
L'entropie spectrale [77]	$F_6 = \frac{1}{\log(M)} \sum_{m=1}^M P(Z[m]) \log P(Z[m])$	$F_{(t,f)6} = \frac{1}{1-\alpha} \log_2(\sum_{n=1}^N \sum_{m=1}^M \rho_x^{\alpha}[n, m])$

TABLE 4.2 – Caractéristiques fréquentielles et leur conversion en domaine conjoint T-F

Dans le tableau 4.2, le flux spectral représente la différence entre les magnitudes spectrales normalisées de l'amplitude de la transformée de Fourier à l et $l-1$ trames, avec $Z^{(l)}$ et $Z^{(l-1)}$, L et P représentent respectivement le décalage prédéterminé et le total des sous-bandes dans le domaine temps-fréquence. La concentration spectrale inférieure au seuil est définie comme le Spectral Roll-Off. La planéité spectrale indique si la distribution de l'énergie dans le domaine fréquentiel est lisse ou hérissée. Enfin, l'entropie spectrale mesure la régularité du spectre de puissance du signal EEG en domaine fréquentiel et est définie comme l'entropie de Renyi dans le domaine temps-fréquence [58].

Une méthode basée sur la direction de l'énergie a été introduite pour distinguer les signaux EEG normaux des signaux anormaux [89]. Cette méthode exploite le fait que l'énergie est concentrée dans les domaines temporel et fréquentiel lors d'une crise,

alors que dans l'absence de crise, l'énergie est uniformément distribuée dans toutes les directions dans le domaine temps-fréquence. Les auteurs ont utilisé un rapport entre l'énergie du signal concentrée dans les domaines temporel et fréquentiel et l'énergie totale du signal, ainsi que certaines caractéristiques telles que l'asymétrie, l'aplatissement, la fréquence de crête (PF) et l'amplitude de la PF. Cette méthode a été appliquée à une base de données EEG de nouveau-nés, qui contenait 200 époques EEG d'une durée de 8 secondes, avec 256 échantillons acquis à une fréquence d'échantillonnage de 32 Hz. Les résultats ont montré une supériorité de la caractéristique proposée par rapport aux caractéristiques traditionnelles de temps et de fréquence. Cependant, l'étude a des limites en raison de l'utilisation d'un nombre restreint de caractéristiques, seulement cinq, pour un enregistrement EEG à canal unique, même si une précision de classification de 98,25% a été obtenue.

La plupart des travaux antérieurs dans le domaine de l'électroencéphalographie (EEG), de l'analyse temps-fréquence et de la classification se sont concentrés sur l'extraction de caractéristiques de signal à partir de la fréquence et de l'énergie instantanée des signaux EEG. Cependant, la prochaine section présentera une nouvelle approche pour extraire des caractéristiques à partir de la représentation temps-fréquence d'un signal EEG, en la considérant comme une image de texture et en utilisant des techniques de segmentation d'image.

Les auteurs de l'étude [128] ont utilisé des descripteurs d'image TF pour extraire les caractéristiques TF, en se basant sur les descripteurs de texture de Haralick. L'algorithme a permis d'atteindre une précision de classification globale légèrement améliorée, soit 99,07%, 99,09%, 98,77% et 98,69% pour les méthodes SP, WVD, SPWVD et CWD, respectivement. Dans une autre étude, les auteurs ont utilisé le descripteur de texture de motif binaire local (LBP), qui permet d'étiqueter les pixels de l'image TF en seuillant le voisinage circulaire (P, R) de chaque pixel (i, j) avec la valeur centrale, puis en additionnant les valeurs seuillées pondérées par des puissances de deux. Ce descripteur a conduit à un taux de classification de 90.67%, 98%, 98%, 98.67%, 97.33% et 99,33% pour ZAM, SP, WVD, SPWVD, CWD et BJD, respectivement [129].

Dans une étude plus récente, Ramakrishnan *et al.* [130] ont proposé une approche basée sur des règles floues, des caractéristiques spécifiques aux sous-bandes et une machine à vecteurs de support à graphe acyclique en couches (LDAG-SVM). Ils ont utilisé deux ensembles de données EEG différents : l'ensemble de données de l'université de Bonn et la base de données EEG du cuir chevelu CHB-MIT. Les signaux EEG ont été décomposés en différentes sous-bandes par transformation en ondelettes, puis des caractéristiques non linéaires telles que l'entropie approximative, l'exposant de Lyapunov et la dimension de corrélation ont été extraites pour chaque sous-bande. Cette approche a permis d'atteindre un taux de classification global de 98% et une sensibilité de 99% en utilisant CHB-MIT, ainsi qu'une précision de 95% et une sensibilité de 97% pour l'ensemble de données de l'université de Bonn.

George *et al.* [131] ont proposé une méthode pour détecter les crises d'épilepsie et leurs types en décomposant les signaux EEG en sous-bandes à l'aide de la transformée en ondelettes à Q variable (TQWT). Ils ont calculé les caractéristiques non linéaires de chaque sous-bande, telles que l'entropie d'énergie logarithmique, l'entropie de Shannon et l'estimation de risque non biaisée de Stein (SURE). Ensuite, ils ont utilisé l'optimisation par essaim de particules (PSO) pour sélectionner les caractéristiques informatives et les introduire dans des réseaux neuronaux artificiels (ANN) pour la classification des signaux EEG. Les bases de données EEG de l'Institut de technologie et de sciences de Karunya (KITS) et de l'hôpital de l'université de Temple (TUH) ont été utilisées pour

évaluer leur méthode. Les résultats ont montré une précision maximale de 100% et 97,4%, respectivement.

Dans une étude supplémentaire, ils ont examiné la classification de divers types de crises en extrayant des caractéristiques de transformée de Fourier rapide (FFT) à partir de montages EEG et en utilisant le classificateur Random forest. Les résultats ont montré une précision de 96% en différenciant trois types de crises épileptiques de l'activité électrique normale du cerveau. Cette étude a été réalisée sur la base de données EEG Corpus de TUH[132].

Camila *et al.* [133] ont développé une méthode basée sur la FFT et l'analyse en composantes principales pour extraire les caractéristiques de signaux EEG à partir de bandes de fréquences afin de détecter quantitativement des motifs diagnostiques chez les patients sains et malades. Ils ont également appliqué une réduction de dimension pour améliorer l'efficacité de la classification. Les résultats ont montré une précision de 0,734, un taux de classification de 0,787 et un score F1 de 0,776 pour la classification par régression logistique.

Ces dernières années, l'apprentissage profond s'est avéré efficace dans le traitement des données EEG pour automatiser la reconnaissance des formes épileptiformes. Yuan *et al.* [134] ont utilisé un modèle d'apprentissage profond multi-vues en générant des spectrogrammes EEG avec la transformée de Fourier à court terme (STFT) et des auto-encodeurs de débruitage clairsemés empilés (SSDA) avec un classificateur softmax. Ils ont obtenu des métriques de performance de 0,9833 pour l'AUC-ROC, 0,9549 pour l'AUC-PR, un F1-score de 96,05% et une précision de 93,82% en utilisant la base de données EEG multicanaux du CHB-MIT.

Cura *et al.* [135] ont utilisé la transformée de synchronisation basée sur Fourier (SST), une représentation de la TF qui réassigne les composantes du signal sur le plan TF pour obtenir des distributions d'énergie TF très localisées, avec les classificateurs SVM, kNN et NBC. En utilisant les données EEG multicanaux de 16 patients épileptiques enregistrés au département de neurologie de la faculté de médecine de l'université Katip Celebi d'Izmir (IKCU), ils ont obtenu des taux d'exactitude et de précision respectifs de 90,6%, 90,2%, 89,3%, 99,97% et 85,99%, 86,48%, 82,32%, 90,85%, avec des AUC de 0,96, 0,96, 0,96 et 0,95.

Ozdemir *et al.* [136] ont utilisé la transformée de synchronisation basée sur Fourier (SST) et uniquement le réseau neuronal convolutif (CNN) en tant qu'étape de classification avec l'ensemble de données IKCU et l'ensemble de données CHB-MIT. Ils ont obtenu des taux d'exactitude et de précision respectifs de 99,06%, 98,99% et 99,81%, 99,63%.

Dans notre étude, nous présentons un algorithme de détection d'activités épileptiformes basé sur des techniques d'analyse temps-fréquence. Nous avons développé de nouvelles caractéristiques à partir de la représentation temps-fréquence (TFR) en utilisant trois méthodes d'analyse temps-fréquence : la distribution pseudo-Wigner-Ville lissée (SPWVD), la distribution de Choi-Williams (CWD) et le spectrogramme (SP). Les caractéristiques extraites ont été utilisées pour assurer l'apprentissage de trois types de classificateurs différents : un classificateur à machine à vecteurs de support (SVM) avec une fonction de noyau RBF, un classificateur des k plus proches voisins (kNN) et un classificateur d'arbre de décision (DT).

4.3 MÉTHODOLOGIE

Le schéma fonctionnel de l'algorithme de détection des crises proposé dans la présente étude comprend quatre étapes. La première consiste à effectuer une analyse temps-fréquence des signaux EEG en utilisant des distributions quadratiques. Ensuite, une étape d'extraction de nouvelles caractéristiques basées sur l'analyse temps-fréquence est réalisée. Enfin, les caractéristiques pertinentes sont sélectionnées, classées à travers plusieurs classifieurs et leurs performances sont évaluées. La Figure 4.2 représente le diagramme méthodologique de l'approche développée.

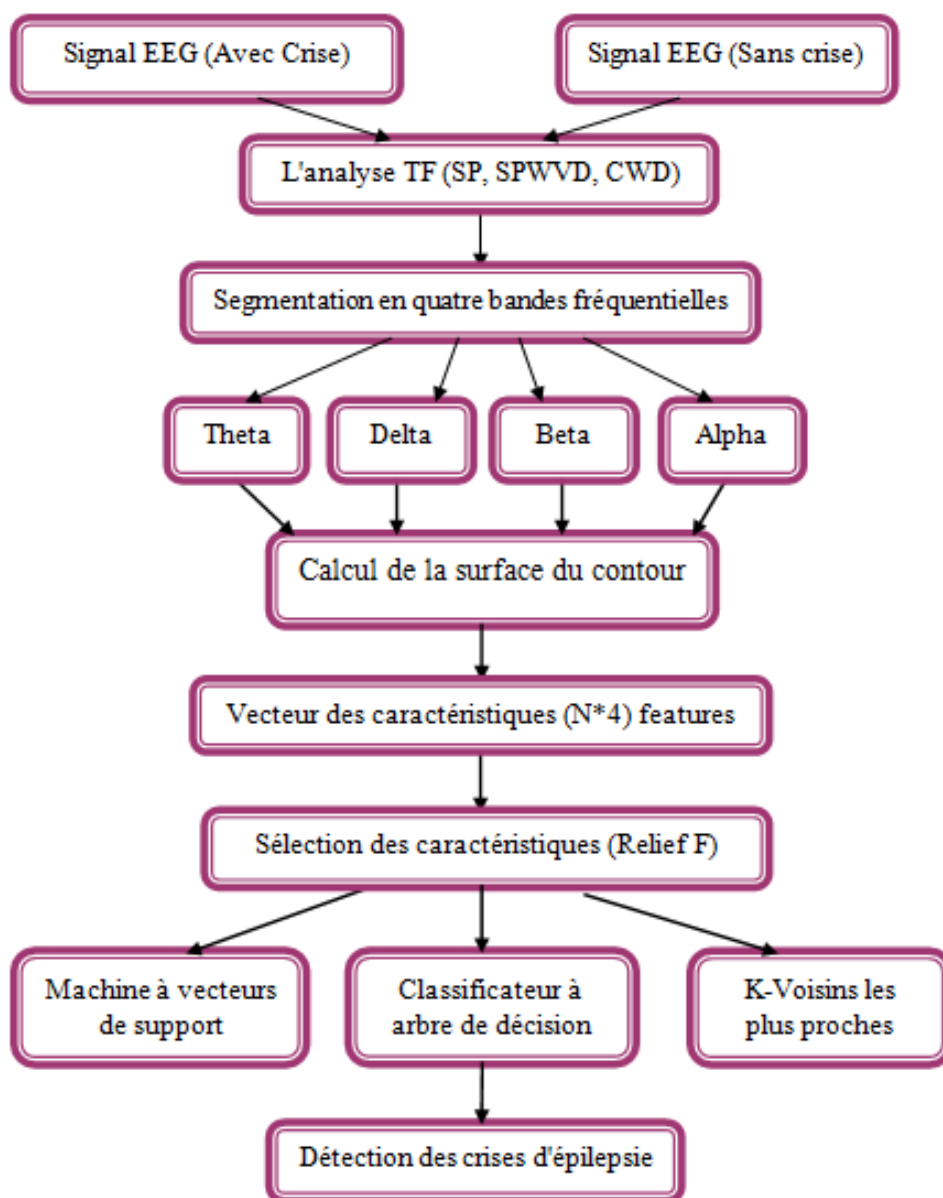


FIGURE 4.2 – Schéma Bloc de l'approche de détection proposée pour chaque TFR

Les caractéristiques sont extraites à partir de la représentation temps-fréquence dérivée de la distribution quadratique temps-fréquence des bandes de fréquences correspondant aux ondes cérébrales dans le signal EEG, à savoir : Delta (0,5 à 4 Hz), thêta (4 à 8 Hz), alpha (8 à 13 Hz) et bêta (13 à 30 Hz). Le vecteur de caractéristiques résultant est ensuite soumis à un processus de sélection de caractéristiques pertinentes pour réduire la

dimensionnalité de l'espace de caractéristiques. Ces caractéristiques sont ensuite considérées comme vecteurs d'entrée pour divers classificateurs qui discriminent les séquences résultantes en deux états cérébraux prédéfinis (ictal, non-ictal). Enfin, les résultats de la classification sont évalués à l'aide de plusieurs mesures de performance.

Dans cette étude, nous avons utilisé plusieurs bases de données provenant de différentes sources, incluant des conditions d'enregistrement, le nombre d'électrodes crâniennes utilisées, le sexe, l'âge des patients, et le type de crises. Les bases de données comprennent le CHB-MIT scalp EEG dataset de l'Hôpital Pédiatrique de Boston et la base de données de l'Hôpital Universitaire de Temple (TUH). Nous avons analysé plus de 350 enregistrements EEG de la base de données CHB-MIT et plus de 200 signaux EEG de la base de données TUH, répartis en deux classes.

4.3.1 L'analyse temps fréquence des signaux EEG

L'étape de l'analyse consiste en une analyse des signaux EEG contenant des phases de crise et de non crise par différents QTFDs dont la fonction principale d'un QTFD est de quantifier, caractériser et visualiser le comportement des signaux non-stationnaires dans le plan temps-fréquence en représentant leur répartition d'énergie et leur variation du contenu fréquentiel dans le domaine temporel. Dans ce travail, nous avons utilisé plusieurs QTFDs notamment le spectrogramme (SP), la distribution de Wigner-Ville (WVD), la distribution Pseudo Wigner-Ville lissée (SPWVD) et la distribution Choi-Williams (CWD) dans le but de comparer la performance de ces distributions pour la détection des crise épileptiques.

Ces QTFD nécessitent des paramètres spécifiques qui doivent être ajustés. Un spectrogramme représentatif a été acquis avec une fenêtre de Hamming de 192 points, une fenêtre de Hamming temporelle de 128 points et une fenêtre de Hamming fréquentielle de 256 points pour une meilleure représentation du SPWVD. Enfin, pour une fréquence d'échantillonnage de 64 Hz, un meilleur lissage de CWD a été obtenu pour des fenêtres de Hamming temporelles et fréquentielles de 256 et 384 points, respectivement. Le paramètre du noyau σ a été défini à 1 pour sa capacité à filtrer les termes croisés sans lissage excessif. Les figures 4.3, 4.4 & 4.5 représentent le tracé du contour et le tracé tridimensionnelle de l'application de SP, SPWVD et CWD aux époques de signal EEG contenant l'épilepsie et non épileptique de l'enregistrement 03 de la base de données CHB-MIT Scalp EEG, respectivement.

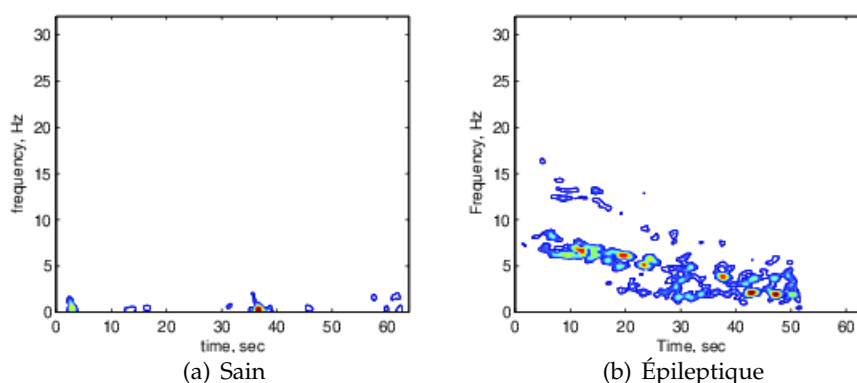


FIGURE 4.3 – Le spectrogramme d'un signal EEG avec et sans crise de l'enregistrement 03 de la base de données CHB-MIT Scalp EEG. (a) Sain (b) Épileptique

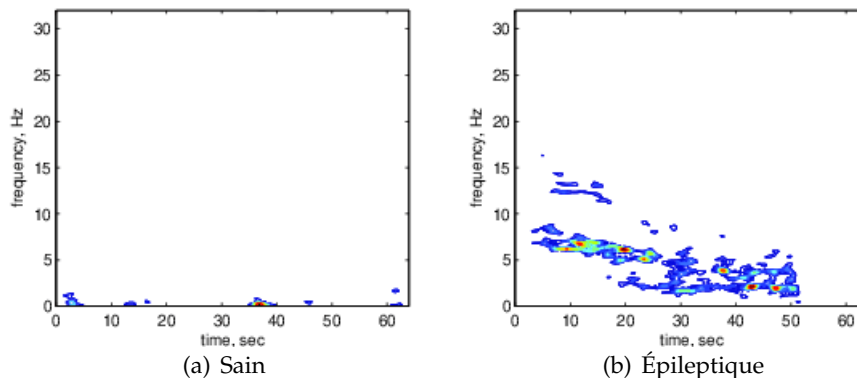


FIGURE 4.4 – La SPWVD d'un signal EEG avec et sans crise de l'enregistrement 03 de la base de données CHB-MIT Scalp EEG. (a) Sain (b) Épileptique

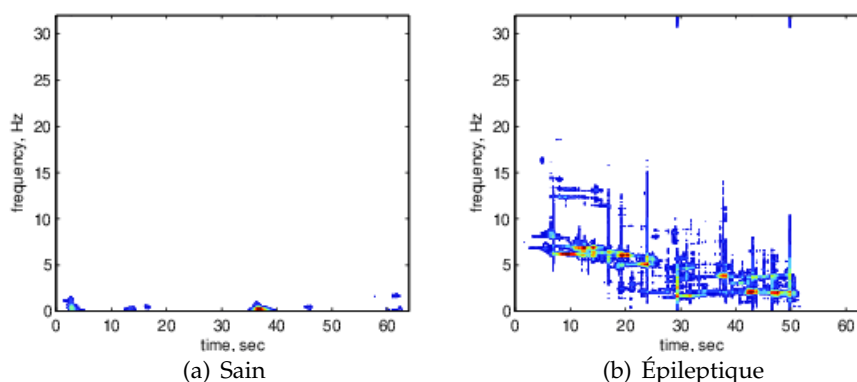
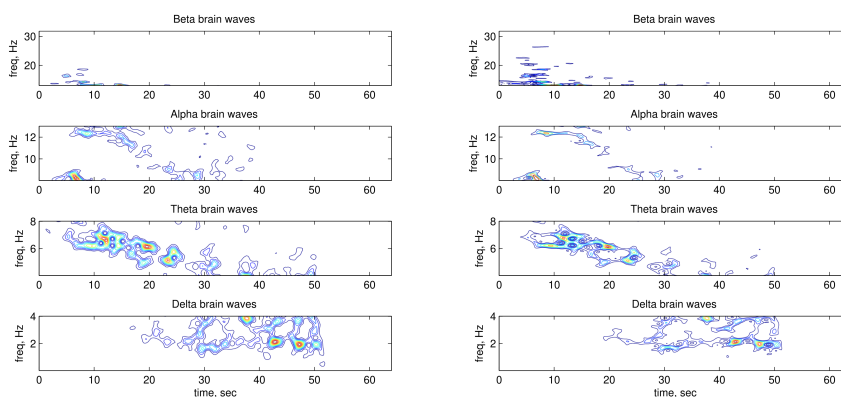


FIGURE 4.5 – La CWD d'un signal EEG avec et sans crise de l'enregistrement 03 de la base de données CHB-MIT Scalp EEG. (a) Sain (b) Épileptique

Les tracés de contours permettent de visualiser les différences entre les signaux EEG normaux et ceux présentant des activités épileptiques. Les signaux normaux montrent une amplitude constante, sans motifs anormaux, concentrés dans la plage des très basses fréquences ne dépassant pas 1 Hz. En revanche, les signaux épileptiques présentent une dispersion d'énergie entre 0 Hz et 10 Hz dans le spectrogramme (SP), avec une distribution d'énergie s'étendant au-delà de 10 Hz dans la distribution de Wigner-Ville (SPWVD) et la distribution Choi-Williams (CWD), avec des pics de fréquence prédominante autour de 15 Hz dans la CWD. De plus, le tracé tridimensionnel de SPWVD est plus lissé que celui de CWD, avec des lignes parallèles dans le sens de la fréquence, ce qui pourrait indiquer la présence d'harmoniques de la fréquence dominante dans la représentation de CWD [137]. En termes de magnitude, il y a une différence quantitative entre l'intensité des signaux EEG normaux et épileptiques, avec une valeur de magnitude d'environ 1,5 pour les signaux normaux et pouvant atteindre 8 pour les signaux épileptiques.

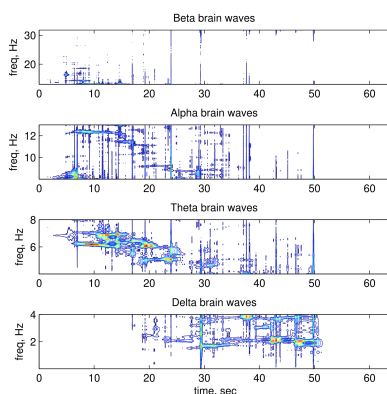
La segmentation des représentations temps-fréquence (TF) est effectuée en quatre sous-bandes fréquentielles distinctes sans chevauchement. Ces sous-bandes couvrent les plages de fréquences associées aux différentes ondes cérébrales présentes dans le signal EEG, à savoir : Delta (0,5 à 4 Hz), Thêta (4 à 8 Hz), Alpha (8 à 13 Hz) et Bêta (13 à 30 Hz). Cette segmentation permet de mettre en avant l'aspect fréquentiel du signal EEG, étant donné que les composantes fréquentielles du signal jouent un rôle essentiel dans

la détection des crises épileptiques. La Figure 4.6 illustre les contours de SP, SPWVD et CWD pour chaque sous-bande fréquentielle des signaux EEG épileptiques.



(a) Spectrogram

(b) SPWVD



(c) CWD

FIGURE 4.6 – Le tracé de contours des quatre bandes fréquentielle, δ (0,5-4 Hz), θ (4-8 Hz), α (8-13 Hz) et β (13-32 Hz), de chaque représentation TF d'un signal EEG épileptique de l'enregistrement 03 de la base de données CHB-MIT Scalp EEG. (a) Spectrogram (b) SPWVD (c) CWD

4.3.2 Caractéristique temps-fréquence développée

Une représentation temps-fréquence (TFR) permet de visualiser un signal qui combine à la fois l'information temporelle et fréquentielle. Elle est obtenue à partir de distributions temps-fréquence quadratiques (QTFD), qui sont des méthodes mathématiques permettant de représenter un signal en trois dimensions, en incluant le temps, la fréquence et la magnitude. Dans cette étude, nous utilisons une nouvelle fonctionnalité qui se base principalement sur cette représentation en calculant la surface du contour d'une TFR à un certain niveau de puissance.

Nous définissons cette caractéristique en divisant les amplitudes maximales de la représentation temps-fréquence (TFR) par un nombre L selon l'équation présentée dans 4.1, ce qui donne $L - 1$ niveaux, plus précisément un ensemble de niveaux est

obtenus à $(\frac{1}{L}, \frac{2}{L}, \frac{3}{L}, \dots, \frac{L-1}{L})$ des amplitudes maximales de la TFR. Cet ensemble de niveaux, nous l'appelons "Nombre de niveaux (NL)".

$$l = \frac{1}{L} * \max(TFR) \quad (4.1)$$

Avec l définit un niveau déterminé.

$$NL = \frac{1}{L}, \frac{2}{L}, \frac{3}{L}, \dots, \frac{L-1}{L} \quad (4.2)$$

Enfin, nous calculons la surface du contour pour chaque niveau en appliquant l'équation 4.3. Nous avons nommé ce paramètre "Time-Frequency Area (TF-area)", comme indiqué dans (4.3);

$$TF_{area}(l) = N(l) * T_{tfr}(1) * F_{tfr}(1) \quad (4.3)$$

Où $N(l)$ est le nombre de points contenus dans une zone de contour d'une TFR déterminée à un certain niveau l , T_{tfr} est les instants du temps d'une TFR et F_{tfr} est le vecteur des fréquences normalisées de la TFR.

Dans la section suivante, nous montrons un exemple de calcul de l'aire temps-fréquence (TF-area), Supposons que nous ayons une représentation TF et fixons le nombre de niveaux L à 4, cela signifie obtenir 3 niveaux, le premier à $1/4$ des magnitudes maximales de la TFR, le second à $2/4$ des magnitudes maximales de la TFR et le troisième à $3/4$ des magnitudes maximales de la TFR. Ensuite, nous calculons la "Aire temps-fréquence (TF-area)" selon l'équation 4.3. Les figures 4.7, 4.8 et 4.9 montrent une représentation tridimensionnelle des étapes suivies.

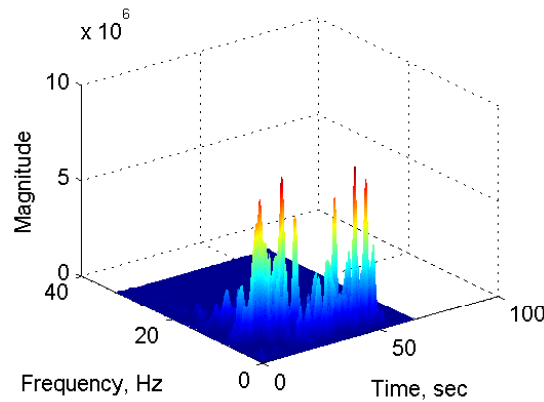


FIGURE 4.7 – Tracé tridimensionnel des SPWVD du signal EEG de l'enregistrement 09 de la base de données CHB MIT scalp EEG.

Dans cette étude, nous avons appliqué ce paramètre élaboré à chaque sous-bandes fréquentielles correspondant aux ondes cérébrales contenues dans le signal EEG, pour finalement former le vecteur de caractéristiques. Nous avons appliqué différentes valeurs du nombres L , variant de 2 à 6. Cela signifie que le nombre de niveaux l variera entre 1 niveau à 5 niveaux. Globalement, nous obtenons $L - 1$ caractéristiques pour chaque sous-bande formant $(L - 1) * 4$ caractéristiques pour chaque représentation TF. Cette procédure est répétée pour tous les canaux de signaux EEG (voir 23 canaux) et tout les fichiers des bases de données CHB-MIT et TUH, y compris les cas épileptiques et sains.

Les Tableaux 4.3, 4.4 & 4.5 montrent les valeur de "Time-Frequency area" (TF-area) des bandes fréquentielles d'un seul canal de signal EEG pour un état normal et un

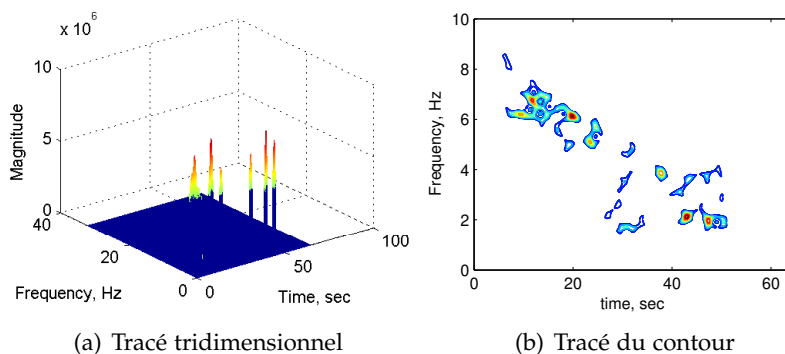


FIGURE 4.8 – La surface du contour à $1/4$ des magnitudes maximales de la SPWVD d'un signal EEG de l'enregistrement 03 de la base de données CHB MIT. (a) Tracé tridimensionnel (b) Tracé de Contour

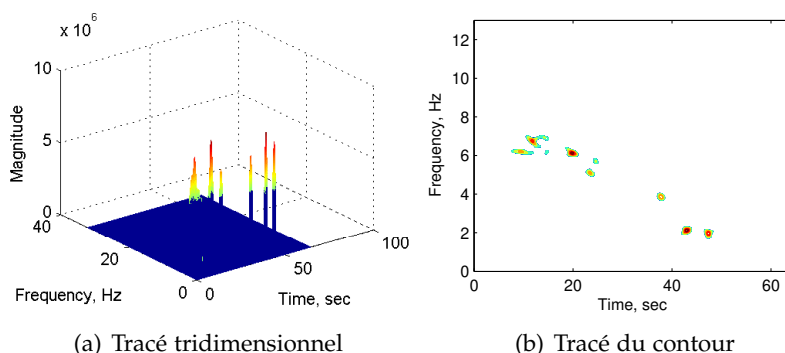


FIGURE 4.9 – La surface du contour à $2/4$ des magnitudes maximales de la SPWVD d'un signal EEG de l'enregistrement 09 de la base de données CHB MIT. (a) Tracé tridimensionnel (b) Tracé de Contour

état épileptique a partir du même enregistrement, et ces valeurs pour chaque nombre de niveau en utilisant la distribution de Choi-Williams (CWD), la SPWVD et la SP, respectivement. Les Figures 4.10, 4.11 & 4.12 représentent l'histogramme de ces valeurs pour les base de données employées. Ces Figures montrent clairement la supériorité des valeurs de la TF-area de l'état épileptique par rapport à celle de l'état normal pour différents nombres de niveaux.

4.3.3 Algorithme d'apprentissage

Algorithme de sélection de caractéristiques

À ce niveau, un algorithme de sélection de caractéristiques est une nécessité pour sélectionner le sous-ensemble de caractéristiques le plus pertinent, ayant les meilleures performances et qui sont plus utiles pour un problème donné. En outre, les caractéristiques redondantes peuvent surcharger le système et produire des résultats sous-optimaux. Son objectif fondamental consiste à atteindre des métriques de haute performances avec un nombre minimal de caractéristiques pour un apprentissage robuste de classificateur [138, 139].

Bien que plusieurs algorithmes aient été proposés dans la littérature, ce travail a été accompli par l'algorithme Relief-F. Il s'agit d'un algorithme d'apprentissage de caractéristiques basé sur le modèle de moyenne-variance qui est considéré comme le critère d'estimation du poids des caractéristiques. Il est basé également sur la sélection d'un sous-échantillon de toutes les instances de signal pour établir des pondérations sur les

Nombre de niveaux	Épileptique				Sain			
	δ	θ	α	β	δ	θ	α	β
Niveau 1 :1 (%)	0,04	4,39	14,70	80,88	0,09	4,83	11,04	84,04
Niveau 2 :1 (%)	0,55	0,31	67,54	31,60	0,90	0,60	58,56	39,93
Niveau 2 :2 (%)	11,59	3,34	63,75	21,32	10,45	4,24	63,16	22,16
Niveau 3 :1 (%)	0,81	0,70	0,22	98,27	1,49	1,40	0,68	96,44
Niveau 3 :2 (%)	14,54	3,20	48,59	33,68	15,81	6,37	42,40	35,43
Niveau 3 :3 (%)	0,98	54,37	37,61	7,04	1,54	53,34	41,20	3,91
Niveau 4 :1 (%)	36,69	32,69	25,37	5,25	32,53	32,05	27,45	7,98
Niveau 4 :2 (%)	38,19	34,31	24,33	3,17	34,53	33,62	26,85	5,00
Niveau 4 :3 (%)	43,24	33,84	20,98	1,94	38,37	36,32	23,54	1,77
Niveau 4 :4 (%)	42,70	33,09	22,02	2,19	37,83	35,91	23,61	2,65
Niveau 5 :1 (%)	30,92	28,08	25,26	15,73	27,53	27,35	26,11	19,01
Niveau 5 :2 (%)	0,03	36,97	33,36	29,65	0,09	34,37	33,93	31,61
Niveau 5 :3 (%)	7,94	0,82	50,30	40,94	10,63	1,51	44,51	43,35
Niveau 5 :4 (%)	10,68	4,44	0,42	84,46	11,56	5,12	0,29	83,02
Niveau 5 :5 (%)	43,34	37,29	18,05	1,32	43,16	37,62	17,69	1,53

TABLE 4.3 – Les résultats de la TF-area appliquée à la CWD pour chaque nombre de niveaux, les résultats obtenus sont pour un seul canal.

Number of levels	Épileptique				Sain			
	δ	θ	α	β	δ	θ	α	β
Niveau 1 :1 (%)	0,03	5,81	14,47	79,68	0,10	6,06	14,57	79,28
Niveau 2 :1 (%)	0,49	0,25	74,48	24,78	1,00	0,67	63,54	34,80
Niveau 2 :2 (%)	12,86	2,45	70,82	13,87	10,60	5,58	63,30	20,53
Niveau 3 :1 (%)	0,66	0,58	0,16	98,60	1,50	1,35	0,59	96,55
Niveau 3 :2 (%)	14,79	3,03	51,83	30,35	15,06	3,45	44,87	36,61
Niveau 3 :3 (%)	0,66	61,74	32,54	5,07	1,90	64,07	32,03	2,01
Niveau 4 :1 (%)	41,77	33,67	21,56	3,00	36,18	34,49	25,70	3,63
Niveau 4 :2 (%)	41,77	33,67	21,56	3,00	36,18	34,49	25,70	3,63
Niveau 4 :3 (%)	47,04	34,63	16,83	1,50	36,09	33,88	24,79	5,25
Niveau 4 :4 (%)	48,74	33,32	15,97	1,98	40,23	36,65	20,30	2,82
Niveau 5 :1 (%)	30,28	28,93	25,96	14,83	27,45	27,28	26,00	19,27
Niveau 5 :2 (%)	0,02	39,06	32,75	28,17	0,10	34,45	33,97	31,48
Niveau 5 :3 (%)	7,01	0,75	51,39	40,86	11,02	2,55	43,63	42,80
Niveau 5 :4 (%)	9,41	3,07	0,35	87,17	11,51	8,31	2,67	77,51
Niveau 5 :5 (%)	49,89	35,40	13,21	1,50	40,39	35,79	20,45	3,38

TABLE 4.4 – Les résultats de la TF-area appliquée à la SPWVD pour chaque nombre de niveaux, les résultats obtenus sont pour un seul canal.

caractéristiques représentatives de la capacité à faire la distinction entre deux classes. L'algorithme estime pour chaque caractéristique $x_i, i = 1, \dots, F$ un poids de qualité $W(i)$ en calculant la différence entre la correspondance la plus proche x_H et l'échec le plus proche x_M pour m vecteurs de caractéristiques sélectionnés aléatoirement [140, 141].

$$W(i) = W(i) - \text{diff}(i, x_k, x_H) / m + \text{diff}(i, x_k, x_M) / m \quad (4.4)$$

Où l'ajustement du poids $W(i)$ est un processus itératif.

L'algorithme de sélection de caractéristiques "Relief F" se caractérise par sa robustesse, son efficacité, sa simplicité et sa capacité à gérer des données bruyantes.

Number of levels	Épileptique				Sain			
	δ	θ	α	β	δ	θ	α	β
Niveau 1 :1 (%)	0,05	6,23	15,39	78,33	0,02	7,79	17,97	74,23
Niveau 2 :1 (%)	0,49	0,31	62,43	36,77	0,41	0,05	66,38	33,16
Niveau 2 :2 (%)	10,84	6,81	58,87	23,48	12,55	5,15	64,67	17,63
Niveau 3 :1 (%)	0,78	0,73	0,21	98,28	0,74	0,19	0,04	99,03
Niveau 3 :2 (%)	15,28	4,92	42,06	37,74	15,31	4,47	44,89	35,33
Niveau 3 :3 (%)	3,02	48,39	40,48	8,11	2,15	57,03	33,84	6,98
Niveau 4 :1 (%)	34,73	33,47	26,29	5,52	37,37	34,76	23,69	4,18
Niveau 4 :2 (%)	34,73	33,47	26,29	5,52	37,37	34,76	23,69	4,18
Niveau 4 :3 (%)	34,24	32,68	26,63	6,45	47,77	36,75	14,48	1,00
Niveau 4 :4 (%)	38,22	35,88	22,86	3,03	57,17	32,27	9,56	1,00
Niveau 5 :1 (%)	28,60	27,76	26,29	17,35	35,06	32,31	22,87	9,76
Niveau 5 :2 (%)	0,02	34,87	34,09	31,02	0,03	36,09	34,46	29,43
Niveau 5 :3 (%)	10,36	1,76	44,51	43,37	8,67	1,43	46,81	43,10
Niveau 5 :4 (%)	12,55	8,65	1,53	77,26	10,10	3,50	0,43	85,97
Niveau 5 :5 (%)	43,61	37,27	17,40	1,72	54,89	34,04	10,26	0,80

TABLE 4.5 – Les résultats de la TF-area appliquée à la SP pour chaque nombre de niveaux, les résultats obtenus sont pour un seul canal de l'enregistrement 02 de la base de données Bonn.

Classification

En fait, la détection des crises est formulée comme un problème de classification binaire pour faire la distinction entre les états EEG "convulsifs" et "non épileptiques". Dans cette étude, les vecteurs de caractéristiques extraits du processus précédent ont été utilisés comme vecteurs d'entrée pour entraîner et tester plusieurs classificateurs, notamment : SVM avec les noyaux RBF, KNN et DT. Notons que nous avons utilisé la stratégie "Train-Test Split", pour diviser aléatoirement la base de données en un ensemble d'apprentissage, contenant 70% des données, et un ensemble de test de 30% de données, afin de valider le modèle de classification et éviter tout ajustement excessif et tout biais des données. Cette technique vise à réduire la charge du calcul et permettre une sélection aléatoire des échantillons d'entraînement et de test, conduisant à des résultats de classification plus transparents et plus précis. Néanmoins, cette évaluation dépend de l'échantillon inclus dans les ensembles de données d'entraînement et de test. Pour évaluer les performances de l'algorithme développé et comparer divers classificateurs, nous avons appliqué sept métriques de performance précédemment définies dans la section 3.4, à savoir : Sensibilité (Sens), Spécificité (Spec), Taux de classification global (Acc), Précision (Prec), Taux de fausses alarmes (FPR), mesure du score F (F1-score) et aire sous la courbe (AUC). Les tableaux 4.6 & 4.7 et 4.8 montrent les résultats de classification de ces mesures pour différents QTFD générés par l'approche développée pour la base de données en utilisant respectivement les classificateurs SVM-RBF, kNN et DT.

La Figures 4.13 montre les résultats de classification en termes de mesures de performances pour différents QTFD produits par l'approche développée pour les bases de données en utilisant les classificateurs SVM-RBF, kNN et DT.

Compte tenu de la complexité de la maladie étudiée et visant à réévaluer la méthode déployée au moyen de plusieurs schémas de validation croisée, toute en gardant à l'esprit les limites de la technique « Train-Test Split », nous avons adopté une méthode alternative de fractionnement de la base de données dite technique « k-fold ». Les tableaux 4.9, 4.10 & 4.11 montrent les résultats de classification en utilisant cette technique avec k étant 10. L'avantage majeur de cette technique est d'assurer que toutes

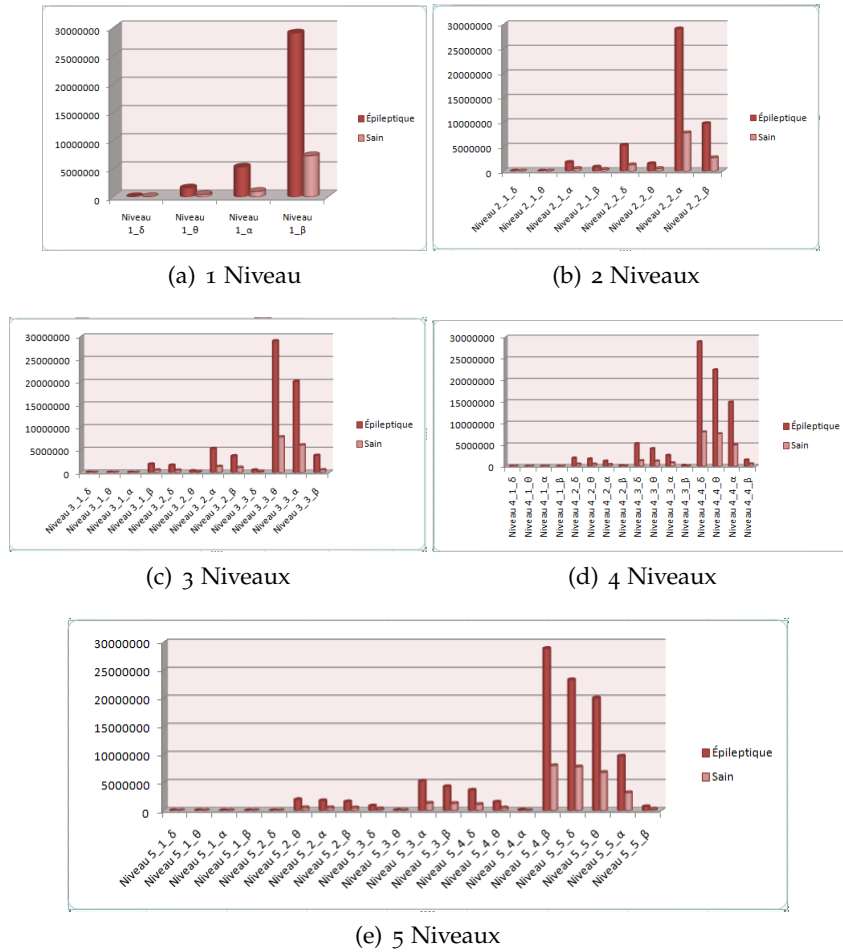


FIGURE 4.10 – L’histogramme des valeurs de TF-area-CWD pour chaque nombre de niveaux appliqué à un seul canal du signal EEG avec et sans crise. (a) 1 niveau (b) 2 niveaux (c) 3 niveaux (d) 4 niveaux (e) 5 niveaux

les échantillons de l’ensemble de données original aient la chance d’apparaître dans l’ensemble d’apprentissage et dans l’ensemble de test.

La figures 4.14 montre les résultats de classification en termes de mesures de performances pour différents QTFD produits par l’approche développée pour les bases de données en utilisant les classificateurs SVM-RBF, kNN et DT.

4.4 NOMBRE OPTIMAL DE NIVEAUX

La section suivante décrit le nombre optimal de niveaux pour chaque bande de fréquence présente dans le signal EEG et ce pour chaque QTFD utilisé dans ce travail, comme illustré dans le Tableau 4.12

Les résultats expérimentaux du tableau 4.12 indiquent que le nombre optimal de niveaux pour les ondes cérébrales de haute fréquence, telles que alpha et bêta, en utilisant SPWVD et CWD est toujours de 5 niveaux, que ce soit le classificateur. Par contre, pour les autres ondes cérébrales de basse fréquence, telles que Delta et Thêta, le nombre optimal oscille entre 4 et 5 niveaux selon le QTFD utilisé.

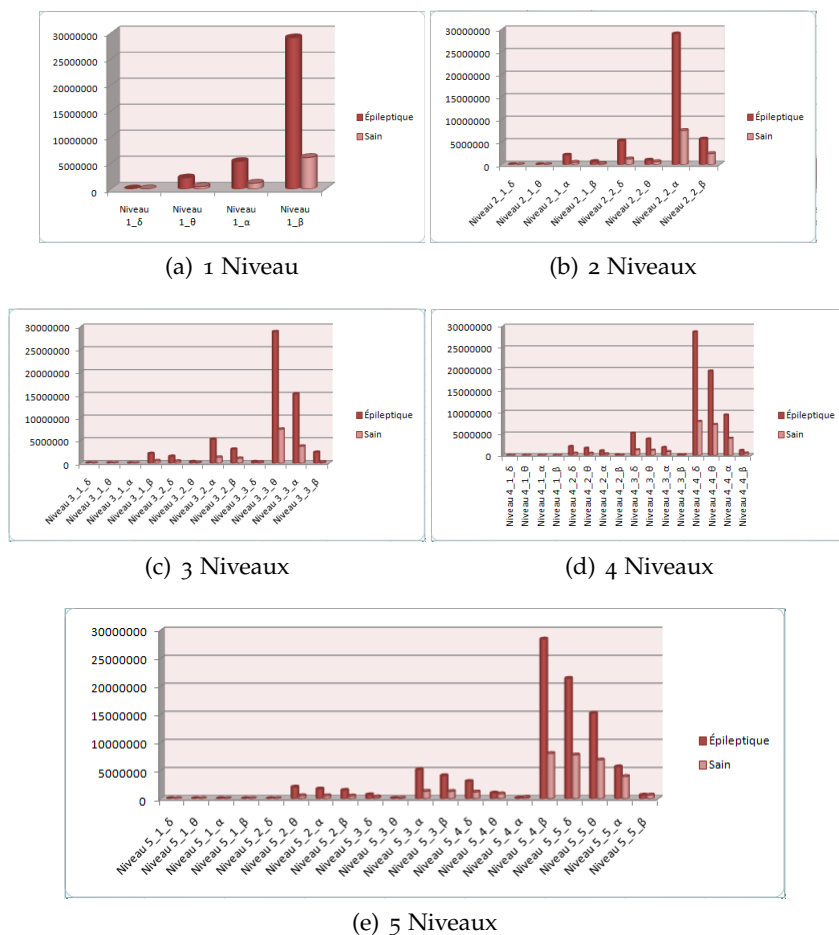


FIGURE 4.11 – L’histogramme des valeurs de TF–area–SPWVD pour chaque nombre de niveaux appliqué à un seul canal du signal EEG avec et sans crise.(a) 1 niveau (b) 2 niveaux (c) 3 niveaux (d) 4 niveaux (e) 5 niveaux

4.5 INTERPRÉTATION DES RÉSULTATS DE CLASSIFICATION

Dans cette section, nous interprétons des résultats de classification sur la performance de l’algorithme développé sur trois représentations temps-fréquence (TFR) de différentes valeurs de niveau à l’aide des classificateurs SVM, kNN et DT. Les résultats montrent des performances faibles de divers classificateurs. Dans la section suivante, nous abordons chaque classification séparément.

Il est important de noter que les résultats de classification des deux méthodes de fractionnement sont très similaires, la méthode «train-test-split» étant légèrement meilleure que la méthode «k-fold».

Dans un premier temps, nous présentons les résultats expérimentaux de l’algorithme développé en utilisant le classificateur SVM. Le tableau 4.6 représente les performances de classification pour cinq niveaux différents en utilisant le SVM : 96,78% et 97,68% pour CWD, 97,12% jusqu’à 97,54% pour SPWVD, et 95,85% à 95,88% pour SP. La représentation CWD a obtenu les meilleures mesures de performance en comparaison avec les autres TFR. Le taux de classification global du CWD a été le plus élevée possible pour 3 niveaux, avec un taux de 97,68%, une sensibilité de 100% et une spécificité de 96,31%. Parallèlement, pour 1 niveau, le taux de classification était le plus bas possible, ne dépassant pas 96,78%. Alors que les résultats des expériences du SPWVD indiquent

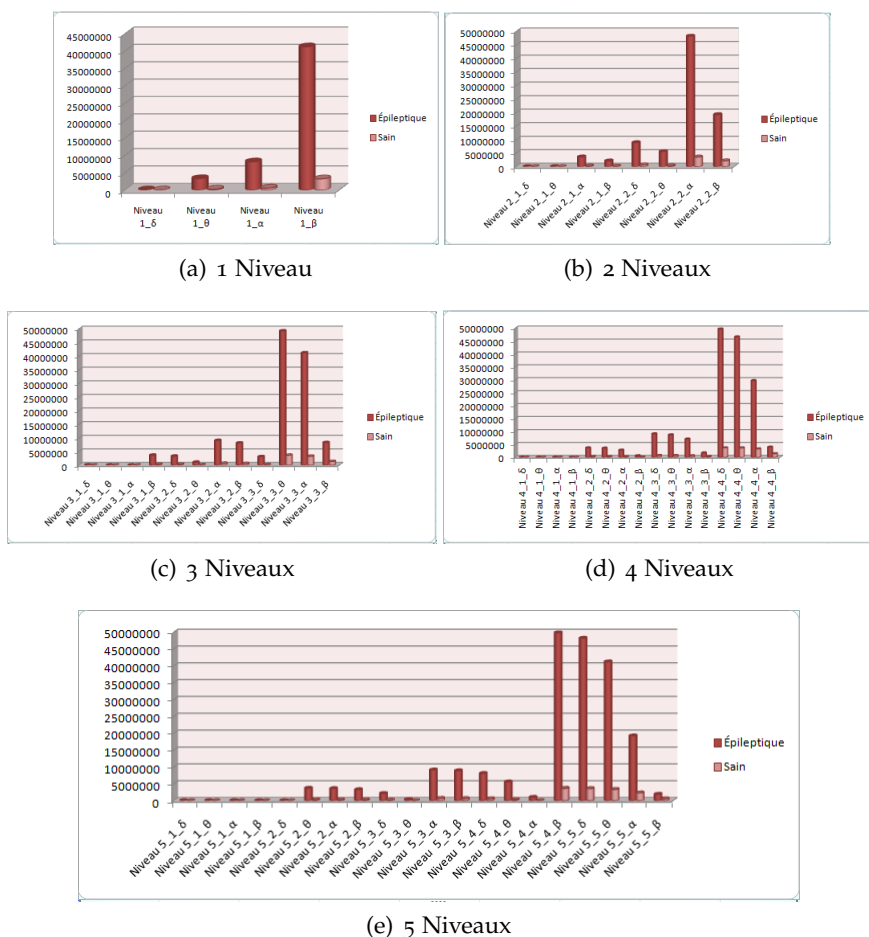


FIGURE 4.12 – L’histogramme des valeurs de TF–area–SP pour chaque nombre de niveaux appliqué a un seul canal du signal EEG avec et sans crise.(a) 1 niveau (b) 2 niveaux (c) 3 niveaux (d) 4 niveaux (e) 5 niveaux

des valeurs inférieures puisque le sommet a été atteint à 2 niveaux avec une taux de classification de 97,54% et la valeur de base est atteinte à 5 niveaux avec un taux de 97,12%. Enfin, SP affiche des performances médiocres. La précision maximale n’a pas dépasser 95,89% avec une sensibilité de 98,97% et une spécificité de 93,83% pour 2 et 5 niveaux, tandis que la précision minimale était de 95,28% pour 1 niveau. De plus, les meilleurs résultats de l’AUC et du F1–score ont été obtenus pour 5, 2 et 3 niveaux pour SP, SPWVD et CWD, respectivement. Le F1–score étant respectivement de 95,09%, 96,83% et 96,95%, tandis que l’AUC était de 0,9542, 0,9693 et 0,9704.

Le tableau 4.8 présente les résultats de classification expérimentaux en utilisant le classificateur DT. Les résultats variaient entre 97,81% et 98,63% pour CWD, 98,05% et 98,93% pour SPWVD et 96,05% à 97,75% pour SP. La représentation SPWVD a obtenu les meilleures mesures de performance avec un meilleur taux de classification global de 98,93% atteinte à 5 niveaux. Parallèlement, pour 1 niveau, le taux de classification était le plus bas possible, ne dépassant pas 98,05%. Alors que les résultats des expériences du CWD indiquent des valeurs inférieures avec un pic de 98,63%, comme taux de classification, atteint à 3 niveaux, et une valeur de base de 97,81% atteinte à 1 niveau. Enfin, SP affiche des performances médiocres avec un taux de classification maximum de 97,75% à 2 et 4 niveaux, tandis que le taux minimale était de 96,05% pour 1 niveau. De plus, les meilleurs résultats de l’AUC et du F1–score ont été obtenus pour 2, 5 et 4 niveaux

QTFD	Niveaux	1 Niveaux	2 Niveaux	3 Niveaux	4 Niveaux	5 Niveaux
CWD	Taux%	96.78	97.41	97.68	97.34	96.97
	Sens%	100	100	100	100	100
	Spec%	94.57	95.87	96.32	95.76	95.22
	Préc%	92.68	93.48	94.09	93.33	92.34
	F1 score%	96.20	96.63	96.95	96.55	96.02
	FPR	0.0543	0.0413	0.0368	0.0424	0.0478
	AUC	0.9634	0.9674	0.9704	0.9667	0.9617
SPWVD	Taux%	97.50	97.54	97.27	97.31	97.12
	Sens%	100	100	100	100	100
	Spec%	95.98	96.06	95.65	95.71	95.45
	Préc%	93.79	93.86	93.15	93.26	92.71
	F1 score%	96.79	96.83	96.45	96.51	96.22
	FPR	0.0402	0.0394	0.0435	0.0429	0.0455
	AUC	0.9689	0.9693	0.9658	0.9663	0.9636
SP	Taux%	95.28	95.89	95.85	95.85	95.89
	Sens%	100	98.50	98.50	98.79	98.97
	Spec%	92.31	94.11	94.06	93.91	93.83
	Préc%	89.12	91.91	91.84	91.49	91.47
	F1 score%	94.25	95.09	95.05	95.00	95.07
	FPR	0.08	0.06	0.06	0.06	0.06
	AUC	0.95	0.95	0.95	0.95	0.95

TABLE 4.6 – Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur SVM

pour SP, SPWVD et CWD, respectivement. Le F1-score étant respectivement de 97,38%, 98,64% et 98,24%, tandis que l'AUC était de 0,9764, 0,9886 et 0,9856.

Finalement, les résultats de classification expérimentales du classifieur kNN démontre une supériorité des résultats de classification par rapport a ceux du SVM et DT, comme indiqué dans le tableau 4.7. Les résultats variaient entre 98,04% et 99,12% pour CWD, 98,27% jusqu'à 99,29% pour SPWVD et 96,81% à 98,53% pour SP. Les mauvais résultats pour SPWVD ont été obtenu à 2 niveaux, et les meilleurs appartiennent à un nombre égal à 5 niveaux, avec un taux de classification plus élevé de 99,29%. Le CWD s'est classé avec un taux de classification de 99,12% pour 5 niveaux et finalement le SP se classe dernier avec un taux de classification de 98,53% pour 3 niveaux. Le taux de classification kNN pour CWD et SPWVD augmentait à mesure que le nombre de niveaux augmentait. Concernant les performances de classification, les meilleurs résultats de l'AUC et du score F1 ont été obtenus pour 5 niveaux avec des valeurs de 0,9911, 99,10% et 0,9891, 98,89% respectivement. Concernant SP, le meilleur F1-score et AUC ont été obtenus pour 3 niveaux avec des valeurs de 0,9831 et 98,28%.

Bien que le classifieur SVM n'a pas eu les meilleures performances en termes de taux global de classification, il a néanmoins présenté les meilleures performances en termes de taux de sensibilité, atteignant 100% pour tout les nombres de niveaux, que ce soit pour la méthode de fractionnement de la base de données "Train-Test Split" ou bien "k-fold" et ceci pour les deux représentations SPWVD et CWD. En outre, le taux de sensibilité du classificateur kNN atteint 100% a partir de 4 et 5 niveaux pour CWD et SPWVD, respectivement. Ces valeurs de sensibilité correspondent à une bonne reconnaissance de tous les signaux EEG contenu la crise épileptique (100 %) grâce à la caractéristique développée conjointement avec CWD et SPWVD. En revanche, les

QTFD	Performance	1 Niveaux	2 Niveaux	3 Niveaux	4 Niveaux	5 Niveaux
CWD	Taux%	98.04	98.73	98.78	99.09	99.13
	Sens%	98.99	99.61	99.92	100	99.92
	Spec%	97.33	98.18	98.08	98.51	98.63
	Préc%	96.53	97.19	96.96	97.73	97.88
	F1 score%	97.75	98.39	98.42	98.85	98.89
	FPR	0.0267	0.0182	0.0192	0.0149	0.0137
	AUC	0.9788	0.9847	0.9846	0.9886	0.9891
SPWVD	Taux%	98.78	98.27	98.79	99.27	99.29
	Sens%	99.23	99.53	99.38	100	100
	Spec%	98.48	97.47	98.40	98.81	98.85
	Préc%	97.73	96.14	97.56	98.18	98.22
	F1 score%	98.47	97.80	98.46	99.08	99.10
	FPR	0.0152	0.0253	0.0160	0.0119	0.0115
	AUC	0.9861	0.9792	0.9858	0.9909	0.9911
SP	Taux%	96.81	98.25	98.53	98.46	98.50
	Sens%	98.24	99.70	100	99.77	99.77
	Spec%	95.79	97.20	97.48	97.52	97.58
	Préc%	94.34	96.25	96.62	96.64	96.76
	F1 score%	96.25	97.94	98.28	98.18	98.25
	FPR	0.0421	0.0280	0.0252	0.0248	0.0242
	AUC	0.9652	0.9801	0.9831	0.9823	0.9830

TABLE 4.7 – Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur kNN

valeurs de spécificité élevées indiquent une défaillance mineure des sujets normaux classés par les classificateurs SVM, kNN et DT. De même, les valeurs modestes du taux de faux positifs (FPR) de 0,0115 par heure, impliquent que des crises mineures ont été identifiées de manière incorrecte.

D'autre part, la base de données utilisée est un ensemble de données déséquilibré, puisque la quantité de données dans la classe saine est plus importante que celle de la classe malade. Par conséquent, le taux de classification global ne peut être utilisée comme critère d'évaluation des performances dans un tel ensemble de données. En outre, la simplicité et la familiarité de la sensibilité et de la spécificité peuvent masquer l'existence d'un certain nombre de complexités qui semblent parfois sous-estimées. Or, le test de dépistage peut présenter des lacunes. Par conséquent, ces paramètres ne doivent pas être considérés comme des attributs fixes et indiscutablement valables pour un test de dépistage. La caractéristique opérationnelle du récepteur (ROC) et l'aire sous la courbe (AUC) sont apparues comme des alternatives populaires et plus convaincantes pour évaluer la performance des classificateurs dans le cas de données déséquilibrées. Dans l'étude en question, les résultats de AUC des trois classificateurs SVM, kNN et DT ont tous été très proches de 1, pour un nombre de niveaux de 3 ou plus, de sorte que la valeur minimale obtenue est de 0,9502, indiquant une haute performance du classificateur. Cependant, le temps d'exécution de CWD est un peu élevé par rapport à celui de SPWVD et SP.

Tous ces résultats rapportés dans l'étude actuelle montrent que "Time-Frequency-Area (TF-area)" peut être mis en œuvre avec succès avec une très grande précision et un taux de fausse détection très faible pour discriminer les crise d'épilepsie à partir des signaux EEG sains. Les résultats des tableaux révèlent la robustesse de notre approche en

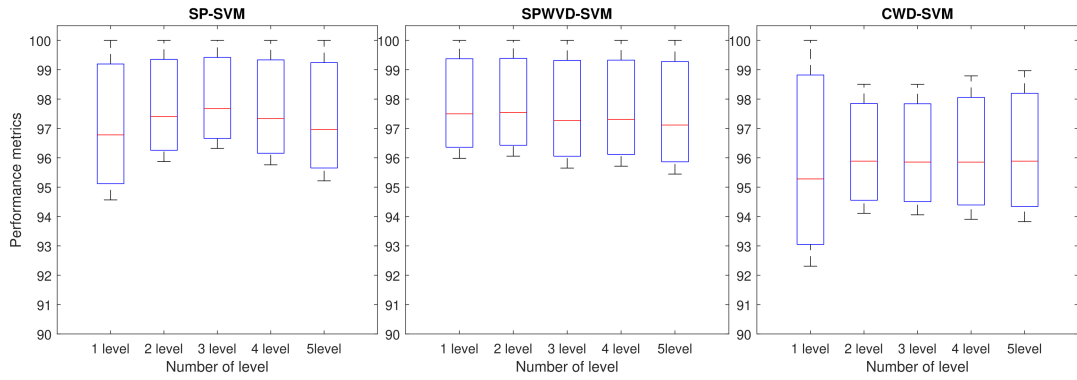
QTFD	Performance	1 Niveaux	2 Niveaux	3 Niveaux	4 Niveaux	5 Niveaux
CWD	Taux%	97.81	97.98	98.63	98.58	98.29
	Sens%	97.99	98.40	98.55	98.99	98.75
	Spec%	97.58	97.35	98.74	97.97	97.58
	Préc%	97.43	97.57	97.74	98.48	98.10
	F1 score%	97.51	97.46	98.24	98.22	97.84
	FPR	0.0201	0.0160	0.0145	0.0101	0.0125
	AUC	0.9777	0.9791	0.9847	0.9856	0.9826
SPWVD	Taux%	98.05	98.24	98.30	98.58	98.93
	Sens%	98.42	98.43	98.63	98.79	99.04
	Spec%	97.50	97.95	97.80	98.26	98.76
	Préc%	97.65	97.65	97.95	98.18	98.53
	F1 score%	97.58	97.80	97.87	98.22	98.64
	FPR	0.0158	0.0157	0.0137	0.0121	0.0096
	AUC	0.9798	0.9814	0.9824	0.9851	0.9886
SP	Taux%	96.05	97.74	97.26	97.75	97.67
	Sens%	96.30	97.65	97.74	97.44	97.92
	Spec%	95.71	97.85	96.63	98.18	97.35
	Préc%	95.15	96.91	97.06	96.56	97.28
	F1 score%	95.43	97.38	96.85	97.36	97.32
	FPR	0.0370	0.0235	0.0226	0.0256	0.0208
	AUC	0.9594	0.9764	0.9723	0.9761	0.9763

TABLE 4.8 – Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur DT


termes de mesures de performances pour SPWVD et CWD en utilisant le classificateur kNN à 4 et 5 niveaux, ce qui surpasse les approches existantes en atteignant plus de 99,29%, 0,0115, 100% et 98,85% en termes de taux totale de classification, FPR, sensibilité et spécificité, respectivement.

De plus, pour s'assurer que le modèle s'adapte aux besoins réels des patients épileptiques, la présente étude a utilisé la sensibilité de détection des crises (Sens) et le taux de fausses détections (FPR) comme principaux paramètres d'évaluation. L'algorithme proposé, dans la plupart des cas, atteint une sensibilité de détection des crises de 100% et un taux de faux positifs (FPR) très faible ne dépassant pas 0,0115, reflétant des événements de crises mineures faussement détectées.


En fin de compte, chaque approche présente des avantages et des inconvénients. Les principaux avantages de la méthode proposée sont la simplicité de mise en œuvre, la faible complexité de calcul, la rapidité d'exécution et la possibilité d'obtenir de meilleurs résultats avec seulement quatre niveaux, soit au moins 16 caractéristiques. De plus, la méthode proposée est applicable aux enregistrements EEG multicanaux et n'est pas limitée à une seule représentation temps-fréquence. De plus, l'approche proposée dans ce travail pourrait être implémentée dans un système en boucle fermée, et compte tenu du temps de traitement de la représentation temps-fréquence quadratique, SPWVD est recommandé à la place de CWD pour éviter les inconvénients majeurs de CWD, qui a un temps de calcul relativement long.



(a) SVM



(b) KNN



(c) DT

FIGURE 4.13 – Les mesures de performances pour chaque QTFD et chaque classifieurs en utilisant la technique "Train-Test Split". (a) SVM (b) kNN (c) DT

4.6 COMPARAISON DES PERFORMANCES AVEC D'AUTRES MÉTHODES

La souffrance des patients atteints d'épilepsie a suscité un intérêt croissant parmi les chercheurs pour l'identification et la prédiction des crises épileptiques à l'aide de l'analyse temps-fréquence des données EEG. Plusieurs approches ont été proposées pour détecter ces crises. Pour démontrer l'efficacité de notre approche, nous avons inclus dans le Tableau 4.13 une synthèse comparative des performances de notre approche par rapport à celles des méthodes existantes utilisant le même ensemble de données, pour une comparaison réaliste en termes de taux de classification, de sensibilité. Nos

QTFD	Niveaux	1 Niveaux	2 Niveaux	3 Niveaux	4 Niveaux	5 Niveaux
CWD	Taux	96.68	97.21	97.70	97.08	96.90
	Sens	100	99.78	100	100	100
	Spec	94.45	95.68	96.35	95.37	95.11
	Prec	92.42	93.24	94.17	92.71	92.22
	F1 score	96.06	96.40	96.99	96.21	95.95
	FPR	0.0555	0.0432	0.0365	0.0463	0.0489
	AUC	0.9621	0.9655	0.9709	0.9636	0.9611
SPWVD	Taux	97.25	97.29	97.07	97.14	97.07
	Sens	100	100	100	100	100
	Spec	95.59	95.67	95.34	95.46	95.37
	Prec	93.19	93.28	92.67	92.87	92.65
	F1 score	96.47	96.52	96.19	96.30	96.18
	FPR	0.0441	0.0433	0.0466	0.0454	0.0463
	AUC	0.9660	0.9664	0.9634	0.9644	0.9633
SP	Taux	94.96	95.73	95.55	95.59	95.46
	Sens	99.83	98.51	98.57	98.54	98.56
	Spec	91.93	93.88	93.55	93.66	93.40
	Prec	88.52	91.55	91.06	91.09	90.84
	F1 score	93.83	94.89	94.66	94.66	94.54
	FPR	0.0807	0.0612	0.0645	0.0634	0.0660
	AUC	0.9420	0.9524	0.9502	0.9504	0.9491

TABLE 4.9 – Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur SVM en utilisant la technique 10-fold

techniques ont présenté le score de précision le plus élevé parmi les études antérieures, ce qui témoigne de leur fiabilité.

QTFD	Performance	1 Niveaux	2 Niveaux	3 Niveaux	4 Niveaux	5 Niveaux
CWD	Taux	97.87	98.75	99.05	99.12	99.14
	Sens	98.88	99.95	99.95	100	99.98
	Spec	97.13	97.99	98.48	98.55	98.61
	Prec	96.22	96.92	97.63	97.81	97.87
	F1 score	97.53	98.41	98.78	98.89	98.91
	FPR	0.0287	0.0201	0.0152	0.0145	0.0139
	AUC	0.9769	0.9845	0.9880	0.9890	0.9893
SPWVD	Taux	98.54	98.23	98.79	99.11	99.10
	Sens	99.22	99.63	99.58	99.93	99.95
	Spec	98.09	97.35	98.28	98.58	98.55
	Prec	97.15	95.97	97.38	97.85	97.78
	F1 score	98.17	97.76	98.47	98.88	98.85
	FPR	0.0191	0.0265	0.0172	0.0142	0.0145
	AUC	0.9831	0.9786	0.9855	0.9890	0.9888
SP	Taux	96.12	98.02	98.25	98.25	98.23
	Sens	97.84	99.63	99.84	99.84	99.86
	Spec	94.91	96.87	97.12	97.13	97.07
	Prec	93.09	95.78	96.11	96.07	96.05
	F1 score	95.40	97.67	97.94	97.92	97.92
	FPR	0.0509	0.0313	0.0288	0.0287	0.0293
	AUC	0.9576	0.9776	0.9800	0.9798	0.9797

TABLE 4.10 – Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur kNN en utilisant la technique 10-fold

4.7 CONCLUSION

La détection automatisée des crises d'épilepsie à partir des signaux EEG à l'aide d'un système de diagnostic assisté par ordinateur est primordiale pour le suivi des patients atteints de cette maladie. Dans cette étude, nous avons développé une approche de détection des crises d'épilepsie en utilisant un schéma innovant pour extraire des caractéristiques basée sur les distributions quadratiques temps-fréquence (QTFD) des données EEG. La base de données CHB-MIT de l'hôpital de Boston et le corpus d'épilepsie EEG TUH collecté à l'hôpital de l'université de Temple ont été utilisés pour créer une configuration expérimentale afin d'évaluer l'approche développée. Nous avons entraîné et testé différents classificateurs, notamment le RBF-SVM, kNN et DT, pour évaluer notre approche proposée. Les meilleures performances ont été obtenue en combinant le classificateur kNN avec SPWVD pour cinq niveaux de contours, avec un taux de classification de 99,29 %, une sensibilité de 100 %, une spécificité de 98,85 %, un taux de fausses alarmes de 0,0115 et un AUC de 0,9911. Ces résultats ont confirmé que les caractéristiques proposées ont permis de représenter efficacement les caractéristiques des crises d'épilepsie à partir des données EEG, et que l'approche "Time-Frequency-Area (TF-area)" peut être mise en œuvre avec succès pour détecter les crises d'épilepsie à partir des signaux EEG sains avec une grande précision et un taux de fausses détections très faible.

QTFD	Niveaux	1 Niveaux	2 Niveaux	3 Niveaux	4 Niveaux	5 Niveaux
CWD	Taux	97.68	98.24	98.41	98.51	98.75
	Sens	97.60	98.42	98.64	98.63	98.85
	Spec	97.80	97.96	98.07	98.35	98.59
	Prec	96.88	97.63	97.91	97.94	98.26
	F1 score	97.33	97.79	97.99	98.14	98.43
	FPR	0.0240	0.0158	0.0136	0.0137	0.0115
	AUC	0.9759	0.9813	0.9833	0.9842	0.9866
SPWVD	Taux	98.18	98.09	98.49	98.51	98.73
	Sens	98.14	98.31	98.73	98.70	98.78
	Spec	98.25	97.76	98.14	98.24	98.66
	Prec	97.24	97.49	98.09	98.05	98.15
	F1 score	97.74	97.62	98.11	98.14	98.40
	FPR	0.0186	0.0169	0.0127	0.0130	0.0122
	AUC	0.9803	0.9799	0.9842	0.9844	0.9863
SP	Taux	95.68	97.37	97.57	97.49	97.45
	Sens	95.82	97.52	97.71	97.70	97.58
	Spec	95.51	97.20	97.38	97.24	97.29
	Prec	94.48	96.73	97.00	96.92	96.82
	F1 score	94.99	96.96	97.19	97.08	97.05
	FPR	0.0418	0.0248	0.0229	0.0230	0.0242
	AUC	0.9554	0.9729	0.9750	0.9742	0.9737

TABLE 4.11 – Les résultats expérimentaux de la classification pour chaque QTFD en utilisant le classificateur DT en utilisant la technique 10-fold

Classifieur	QTFD	Delta	Thêta	Alpha	Bêta
SVM	SP	3 Niveaux	5 Niveaux	3 Niveaux	3 Niveaux
	SPWVD	4 Niveaux	5 Niveaux	2 Niveaux	3 Niveaux
	CWD	4 Niveaux	4 Niveaux	3 Niveaux	3 Niveaux
kNN	SP	4 Niveaux	5 Niveaux	5 Niveaux	5 Niveaux
	SPWVD	4 Niveaux	4 Niveaux	5 Niveaux	5 Niveaux
	CWD	4 Niveaux	5 Niveaux	5 Niveaux	5 Niveaux
DT	SP	3 Niveaux	5 Niveaux	5 Niveaux	5 Niveaux
	SPWVD	4 Niveaux	5 Niveaux	5 Niveaux	5 Niveaux
	CWD	4 Niveaux	5 Niveaux	5 Niveaux	5 Niveaux

TABLE 4.12 – Nombre optimal de niveaux de chaque bande fréquentielle pour chaque QTFD de SVM, kNN et DT

Auteurs	Année	Méthode	Base de données	Classifieur	Accuracy (%)
Tzallas'2007 [116]	2007	Spectrum of the signal	Bonn database	ANN	97.72
Tzallas'2009 [117]	2009	TFD	Bonn database	ANN	99.28
Liang'2010 [122]	2010	Approximate Entropy	Bonn database	RBFsVM and SVM	85.9-98.51
Boubchir'2014 [142]	2014	Relevant Time-Frequency features	Bonn database	SVM	97.14-98.57
Boubchir'2014a [128]	2014	Haralick's texture features	Bonn database	SVM	98.69-99.09
Donos'2015 [129]	2015	Statistical features	Bonn database	Random Forrest	99.28
Khan'2018 [89]	2018	Direction of the energy signal	newborn EEG database	kNN	98.25
Tsipouras'2019 [119]	2019	Spectral features of number of thresholds	Bonn database	Random Forrest	98.80
Ramakrishnan'2019 [130]	2019	Fuzzy-rules sub-band specific features	Bonn, CHB-MIT databases	LDAG-SVM	95-98
Ozdemir'2021 [136]	2021	Fourier-based Synchrosqueezing Transform	IKCU, CHB-MIT databases	CNN	99.06 and 99.81
George'2020 [131]	2020	Log energy entropy and Shannon entropy	TUH, KITS databases	ANN	97.4-100
Basri'2021 [132]	2021	Fast Fourier transform-based features	TUH database	Random forest	96
Camila Guerrero'2021 [133]	2021	Fast Fourier transformation-based features	TUH database	Logistic regression	73.4
This study	2022	Time-Frequency Area (N niveaux)	CHB-MIT and TUH database	SVM-kNN	99.29

TABLE 4.13 – Comparaison des méthodes existantes pour la détection des crises épileptiques.

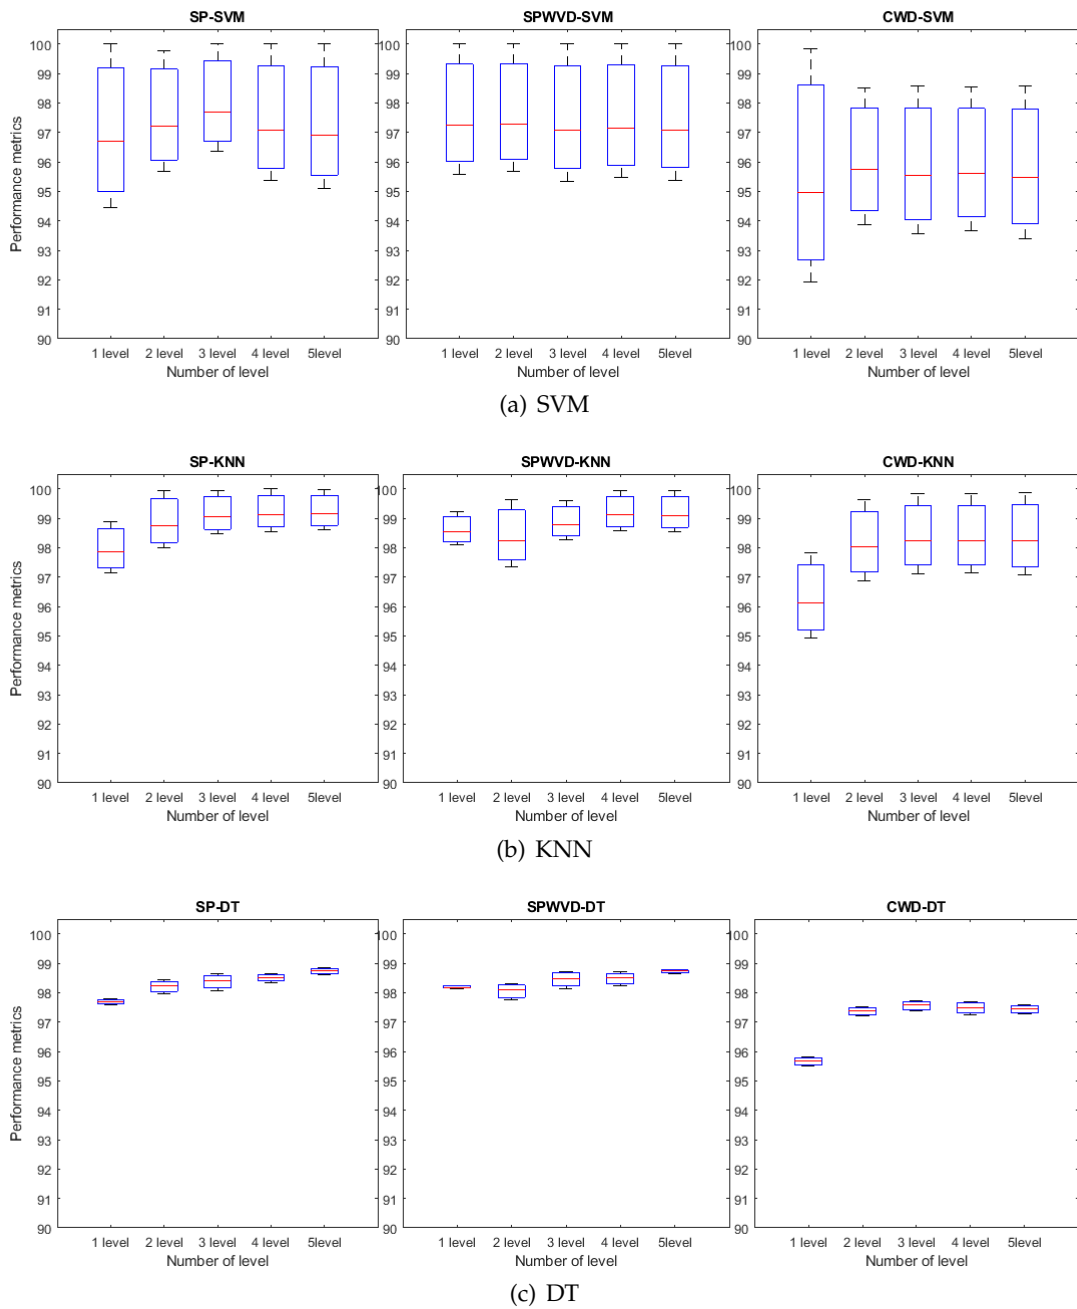


FIGURE 4.14 – Les mesures de performances pour chaque QTFD et chaque classifieurs en utilisant la technique k -fold. (a) SVM (b) kNN (c) DT

PRÉDICTION DES CRISES ÉPILEPTIQUES : RÉSULTATS DE L'ALGORITHME ET INTERPRÉTATION.

5

5.1 INTRODUCTION

L'objectif de cette thèse est de développer un nouvel algorithme de prédiction des crises épileptiques offrant des temps de prédiction plus longs pour permettre au personnel médical et aux patients atteints d'épilepsie de prendre des précautions et prévenir les crises. Dans ce chapitre, nous présentons une méthode novatrice de détection précoce des décharges paroxystiques associées aux crises épileptiques, basée sur l'analyse temps-fréquence et l'entropie de Renyi (RE) étendue. L'objectif est de prédire l'apparition d'une crise d'épilepsie en temps opportun, permettant ainsi aux cliniciens et aux patients d'agir préventivement. Nous présentons également un aperçu concis et non exhaustif des différentes méthodes et algorithmes utilisés pour le traitement, l'analyse et la classification des signaux EEG en vue de prédire l'activité épileptique, en soulignant l'importance de l'analyse temps-fréquence. Nous décrivons ensuite la méthode de prédiction de l'activité épileptique dans les signaux EEG, suivie des résultats obtenus. Enfin, nous effectuons une étude comparative entre les résultats obtenus avec notre méthode et ceux rapportés dans la littérature.

5.2 ÉTAT DE L'ART DES ALGORITHMES DE PRÉDICTION DE CRISES ÉPILEPTIQUES

La prédiction des crises d'épilepsie est une tâche complexe en raison de leur imprévisibilité quant à leur survenue, leur gravité et leur durée, ce qui peut entraîner des blessures graves et des problèmes de sécurité pour les patients. Par conséquent, il est crucial d'identifier les signaux précoces indiquant l'imminence d'une crise afin de prendre des mesures préventives et réduire les dommages. Plusieurs techniques ont été développées au cours des dernières années pour prédire les crises d'épilepsie en analysant les signaux EEG, témoignant de l'importance de cette problématique pour les chercheurs et les professionnels de santé. Das *et al.* [143] ont appliqué plusieurs algorithmes d'extraction de caractéristiques, notamment les maxima actuels, le seuil inférieur, la sélection du point cible et l'appariement de modèles (segments et domaines), ainsi que des caractéristiques de puissance et d'énergie pour le post-traitement des données EEG. Les résultats ont montré une précision et un score F1 de 92,66 % et 94,86 %, respectivement, pour l'identification des crises d'épilepsie dans la période pré-ictale.

Dans l'article [101], Subasi *et al.* ont utilisé diverses techniques d'extraction de caractéristiques pour prédire les crises d'épilepsie à partir de sous-bandes de fréquences obtenues à l'aide de la transformation en ondelettes discrètes (DWT), notamment l'analyse en composantes principales (PCA), l'analyse en composantes indépendantes (ICA) et l'analyse discriminante linéaire (LDA). Ils ont également utilisé la machine à vecteur de support (SVM) comme classificateur. Les résultats ont montré que l'ACP a produit une précision maximale de 98,75%.

Tamanna *et al.* [144] ont proposé une méthode pour prédire les crises d'épilepsie en utilisant un vecteur de caractéristiques, obtenu en extrayant l'énergie, l'entropie et l'écart type des sous-bandes de fréquences obtenues à l'aide de la DWT des données EEG. La précision moyenne de prédiction sur l'ensemble de données CHB-MIT était de 96,38%, avec un taux de faux positifs (FPR) de 0,19.

Dans une autre étude, Cho *et al.* [145] ont détecté les crises d'épilepsie en utilisant la synchronisation de phase collectée à partir de la décomposition en mode empirique multivariée assistée par le bruit (EMD), et ont obtenu une précision de 83,17%.

Yang *et al.* [146] ont développé une approche de prédiction des crises d'épilepsie qui utilise la transformation de Fourier à court terme (STFT) et la mémoire convolutive à long terme (Conv-LSTM) pour minimiser le nombre d'électrodes nécessaires et réduire les fausses alarmes. Ils ont utilisé seulement deux canaux pour produire un taux de 0,17 fausses alarmes par 24 heures pour le défi Neureka 2020 Epilepsy.

Messaoud *et al.* [147] ont proposé une approche pour améliorer la robustesse de l'algorithme de détection des crises d'épilepsie contre les fausses alarmes. Cette approche repose sur le calcul d'une probabilité pour une époque pré-ictale ou inter-ictale spécifique à l'aide du classificateur Random Forest en incorporant un ensemble de caractéristiques. Les résultats ont montré une sensibilité de 82,07% et un taux de faux positifs (FPR) de 0,07 par heure en utilisant la base de données CHB-MIT.

L'entropie est un outil prometteur pour prédire les crises d'épilepsie en raison des propriétés non stationnaires incluses dans les signaux EEG. De nombreux travaux ont étudié l'utilisation de l'entropie pour différencier le comportement régulier, chaotique et aléatoire d'une série temporelle. Zhang *et al.* ont utilisé une approche d'identification de crises basée sur l'entropie approximative pour prédire les crises d'épilepsie en temps réel, atteignant un taux de classification de 94,59% et un taux de fausses prédictions de 0,084 par heure [148]. Acharya *et al.* ont développé une technique pour extraire les formes d'ondes pré-ictales, ictales et normales des données EEG et les ont classées à l'aide de plusieurs classificateurs, notamment SVM, kNN, classificateur flou et classificateur d'arbre de décision, avec quatre types différents de caractéristiques entropiques, tels que l'entropie approximative, l'entropie de l'échantillon, l'entropie de phase 1 (S1) et l'entropie de phase 2 (S2). Le classificateur flou s'est avéré être le plus précis, avec un taux de classification de 98,1% [113]. LoGiudice *et al.* ont utilisé un pipeline d'apprentissage profond pour classifier les enregistrements EEG de sujets souffrant de crises d'épilepsie et de sujets souffrant de crises psychogènes non épileptiques, atteignant un taux de classification moyen de 94,4% à l'aide d'un réseau neuronal convolutionnel [149]. Yang *et al.* ont extrait l'entropie de permutation (PE) à partir des signaux iEEG de 19 patients du centre d'épilepsie de l'hôpital universitaire de Fribourg, en utilisant la machine à vecteur de support (SVM) pour discriminer l'état du cerveau. Les résultats ont montré un horizon de prédiction moyen de 61,93 minutes, avec une sensibilité de 94% et des taux de fausse prédiction de 0,111 par heure [150]. Aung *et al.* ont appliqué l'entropie de distribution modifiée multivariée et multi-échelle comme approche d'extraction de caractéristiques combinée à un réseau neuronal artificiel pour prédire l'état ictal de

l'épilepsie, obtenant des mesures de performance de 98,66% de précision, 91,82% de sensibilité, 99,11% de spécificité, 0,84 de valeur de l'aire sous la courbe (AUC) et un taux de fausses alarmes de 0,014 par heure [151].

De nos jours, l'apprentissage automatique est une technique sophistiquée pour la prédiction de l'épilepsie. Dans l'étude de Daoud et al. [152], les auteurs ont développé des algorithmes d'apprentissage profond sans prétraitement pour extraire automatiquement les caractéristiques les plus importantes des enregistrements EEG bruts en utilisant un perceptron multicouche comme architecture simple de plusieurs couches cachées entraînaibles. De plus, un algorithme de sélection des canaux a été introduit pour choisir les canaux les plus représentatifs de l'enregistrement EEG multicanal. Le modèle proposé a atteint une précision de 99,6%, une sensibilité de 99,72%, une spécificité de 99,60% et un taux de fausses alarmes de 0,004 par heure.

Dans l'étude de Wang et al. [153], plusieurs techniques de préparation de données ont été comparées en utilisant une approche de traitement robuste avec des paramètres d'échantillonnage appropriés et une validation croisée "leave-one-out". Cette technique évite la nécessité de fournir des conditions préalables pour faciliter l'évaluation comparative avec une architecture d'apprentissage profond utilisant un réseau neuronal convolutionnel unidimensionnel et un réseau bidirectionnel de mémoire à long terme pour la prédiction des crises. Le modèle obtient un taux de classification de 77,6%, une sensibilité de 82,7% et une spécificité de 72,4%.

Pour améliorer l'utilisation des informations temporelles, fréquentielles et de canal des signaux EEG, Yan et al. [154] ont proposé un modèle de prédiction des crises basé sur l'extraction des caractéristiques temps-fréquence des signaux EEG en utilisant une transformée de Fourier à court terme (STFT) et un modèle de tour à trois transformateurs pour fusionner et classer les caractéristiques des signaux EEG. Le modèle combine également le mécanisme d'attention des réseaux de transformateurs. Des expériences ont été menées en utilisant la base de données CHB-MIT pour évaluer les performances du modèle, qui ont abouti à une sensibilité de prédiction de 96,01% et un taux de fausses alarmes de 0,047 par heure.

La présente étude présente un algorithme automatique visant à détecter l'activité épileptique pré-ictale dans les signaux EEG pour prédire le début d'une crise épileptique, afin de permettre un temps de traitement adéquat pour prévenir les crises d'épilepsie. Le modèle de prédiction proposé utilise l'entropie de Renyi étendue appliquée sur la distribution de Wigner-Ville pseudo-lissée pour extraire les canaux EEG les plus proches de la zone épileptogène. Les performances de l'algorithme ont été évaluées en termes précision de classification/prédiction (Acc), de sensibilité (Sens), de précision (Prec), de score F1 (F1-score), de rapport de vraisemblance positive (LR), de taux de fausses alarmes (FPR) et de surface sous la courbe (AUC)

5.3 MÉTHODOLOGIE

L'épilepsie se caractérise par l'apparition soudaine de crises résultant d'une transition entre un état stable appelé état intercritique et un état pathologique appelé état critique. Cette transition est associée à des changements dynamiques dans l'activité électrique des neurones, permettant de distinguer quatre phases principales d'une crise : la phase intercritique, la phase précritique, la phase critique et la phase postcritique.

- **Phase inter-critique** : Cette phase est définie comme la période entre deux crises épileptiques. L'EEG montre des anomalies appelées "événements paroxystiques", qui fournissent des informations sur le type de crise et les régions cérébrales

impliquées, y compris les foyers épileptogènes. Pendant cette phase, le patient ne présente aucun symptôme manifeste de la maladie, comme des convulsions ou de l'agitation.

— **Phase pré-critique**

La phase pré-critique est l'étape précédant le début de la crise et peut se manifester par des signes de troubles de comportement tels que l'agitation, l'anxiété ou les tremblements. Elle est caractérisée par l'apparition soudaine de pointes sporadiques isolées et de fortes amplitudes pouvant durer de quelques secondes à une heure.

— **Phase critique** : Une activité critique ou ictale correspond à une crise d'épilepsie, qu'elle soit clinique ou infra-clinique L'EEG est l'examen clinique qui permet d'identifier les signes et symptômes caractéristiques de la crise épileptique en analysant les signaux enregistrés.

— **Phase post-critique** : La phase postcritique (ou post-ictale) fait référence aux activités enregistrées immédiatement après une crise d'épilepsie. Elle est caractérisée par un épuisement total du patient qui peut durer de quelques minutes à quelques jours, en fonction de la gravité et de la nature de la crise. Une somnolence est généralement observée, signalant la fin de la crise.

La Figure 5.1 représente la forme d'onde des différents phases d'un seul canal de chb09 de la base de données EEG CHB-MIT. Elle contient une période inter-critique de 40 minutes, une période pré-critique de 37 minutes, une période critique de 63 secondes.




FIGURE 5.1 – L'état de la crise d'épilepsie. État inter-critique, pré-critique, critique et post-critique d'un seul canal de chb09 de la base de données CHB-MIT.

La tâche de prédiction des crises consistait à se concentrer sur les intervalles pré-ictal et inter-ictal, d'où l'exclusion des segments EEG ictaux et la transformation de la tâche en une classification binaire. Pour ce faire, un algorithme de prédiction de la crise épileptique a été proposé, incluant deux approches différentes de pré-traitement des signaux EEG. Le schéma fonctionnel global de l'approche développée est représenté dans la figure 5.2.

La première approche de pré-traitement a été réalisée en analysant les époques pré-ictales des signaux EEG, en utilisant des données de la base de données CHB-MIT sur une période de 15 à 20 minutes. L'entropie de Renyi a été étendue au domaine temps-fréquence de la distribution Pseudo Wigner-Ville lissée (SPWVD) pour évaluer la complexité des signaux EEG, et les quatre canaux présentant les valeurs les plus élevées ont été sélectionnés.

Dans la deuxième approche, les signaux EEG pré-ictaux ont été traités en utilisant une fenêtre glissante de 50 secondes pour calculer la représentation temps-fréquence à travers la Smoothed Pseudo Wigner-Ville Distribution (SPWVD) de chaque segment, avant de calculer la moyenne de ces représentations pour obtenir une représentation

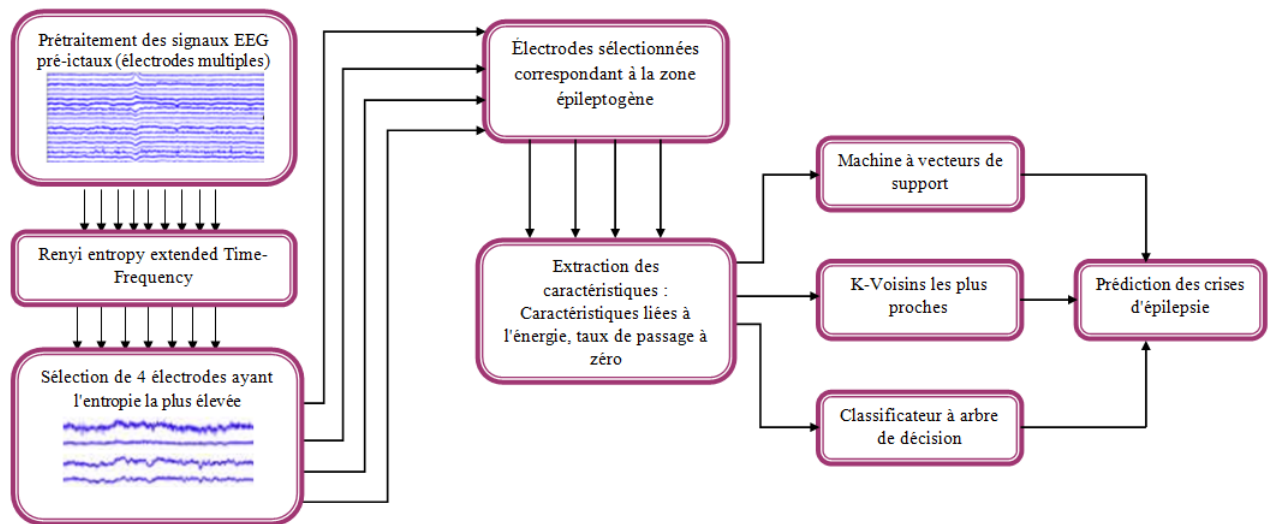


FIGURE 5.2 – Diagramme de l'algorithme développé pour la prédiction des crises d'épilepsie

moyenne représentative de la fenêtre de 5 minutes. L'entropie de Renyi a ensuite été calculée pour sélectionner les quatre canaux EEG les plus complexes associés à la zone épileptogène.

Ensuite, les caractéristiques liées à l'énergie et au taux de passage à zéro (ZCR) ont été extraites des canaux sélectionnés. Une sélection des caractéristiques pertinentes a été effectuée en utilisant l'algorithme Relief-F pour former un vecteur de caractéristiques, qui a été utilisé pour alimenter trois classificateurs différents (SVM, kNN et DT). Les deux méthodologies de pré-traitement sont présentées dans les figures 5.3 & 5.4 .

5.3.1 Distribution Pseudo Wigner-Ville lissée (SPWVD)

Dans notre étude, nous avons examiné les signaux EEG d'état inter-ictal et pré-ictal de 23 canaux. Pour cela, nous avons utilisé la distribution de Pseudo Wigner-Ville lissée (SPWVD) sur des segments pré-ictaux de 60 secondes sur 5 minutes, ainsi que des segments entiers de 5 minutes. Nous avons appliqué une fenêtre de lissage optimale de SPWVD de 128 points temporels de type Hamming et de 256 points fréquentiels. Les signaux EEG étudiés proviennent de sujets de la base de données CHB-MIT. La Figure 5.5 montrent les contours de la SPWVD dans les périodes inter-ictale, pré-ictale et ictale contenues dans le signal EEG, respectivement.

5.3.2 Canaux sélectionnés par l'entropie de Renyi étendue dans le domaine temps-fréquence

L'algorithme décrit dans cette section repose sur l'identification de l'activité épileptiforme dans la phase pré-ictale en analysant la complexité des signaux EEG de chaque canal. Pour ce faire, nous utilisons l'entropie de Renyi étendue au domaine temps-fréquence pour localiser la région épileptogène. Nous sélectionnons les quatre canaux pertinents correspondant aux valeurs de RE les plus élevées, en nous inspirant de la notion que le canal avec la valeur RE la plus élevée indique un état critique [47]. Nous examinons des intervalles de temps allant de 15 à 20 minutes pendant l'état pré-ictal, sous la forme d'époques de 60 secondes, ainsi que sous la forme d'une fenêtre de 5 minutes entière. Pour annuler la structure oscillatoire inter-terme dans la représenta-




FIGURE 5.3 – Schéma fonctionnel global de la première méthode de pré-traitement




FIGURE 5.4 – Schéma fonctionnel global de la deuxième méthode de pré-traitement

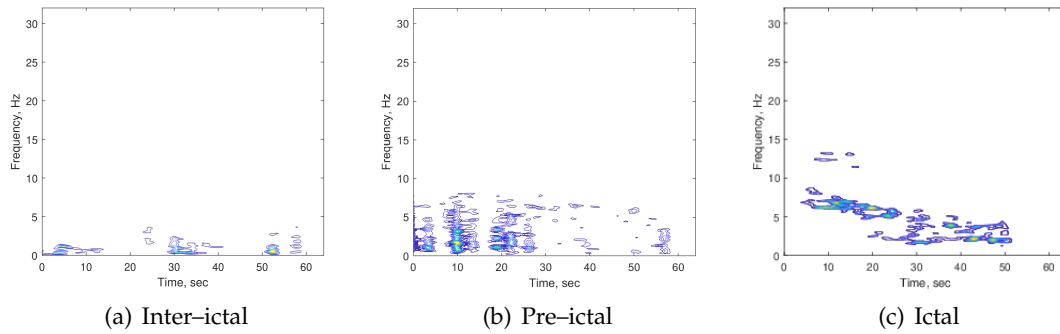


FIGURE 5.5 – Contours des SPWVDs des signaux EEG inter-ictal, pré-ictal et ictal de l'enregistrement 09 de la base de données CHB-MIT. (a) Inter-ictal, (b) Pré-ictal, (c) Ictal

tion, nous fixons le paramètre α à 3 [84]. Les valeurs d'entropie des phases pré-ictale et inter-ictale des signaux EEG de tous les sujets sont présentées dans la Figure 5.6.




FIGURE 5.6 – Variation de l'entropie de Renyi des signaux EEG pré-ictaux et inter-ictaux de la base de données CHB-MIT.

En se concentrant sur l'entropie des phases pré-ictale, inter-ictale et ictale, il est remarqué que les valeurs d'entropie du SPWVD varient significativement entre ces états, avec des valeurs les plus élevées de 12,02 à 15,49 pour les phases pré-ictales, tandis que les phases inter-ictales présentent des valeurs plus faibles allant de 7,82 à 11,98, inférieures à celles observées lors des phases pré-ictale et ictale. Des changements significatifs ont été observés chez tous les patients. Les signaux EEG en phase pré-ictale sont caractérisés par une complexité accrue due à leur dynamique chaotique déterministe, contrairement aux signaux EEG normaux qui ont une dynamique stochastique. L'utilisation de l'entropie de Renyi étendue au domaine temps-fréquence permet de mieux distinguer les trois états des signaux EEG épileptiques.

Il convient de noter que les signaux EEG enregistrés dans la base de données CHB-MIT utilisent le système international de Jasper 10–20 pour le placement des électrodes. Ce système comprend 21 canaux, à savoir Fp1, Fp2, FT9, FT10, F3, F4, F7, F8, C3, C4, T7, T8, P3, P4, P7, P8, O1, O2, Cz, Fz et Pz, qui sont utilisés pour former des signaux EEG bipolaires communs en soustrayant deux signaux pertinents donnant lieu à des canaux EEG différents. Ces signaux sont désignés par des noms tels que FP1-F7, F7-T7, T7-P7,

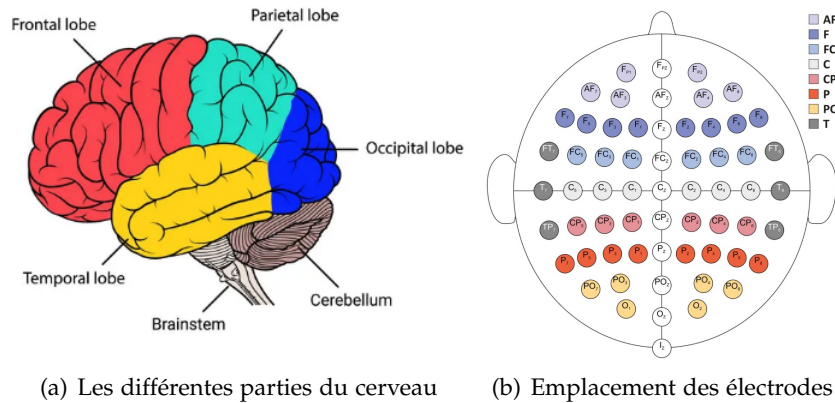


FIGURE 5.7 – Le système international 10–20. (a) Parties du cerveau, (b) Placement des électrodes sur le cuir chevelu

P7-O1, FP1-F3, F3-C3, C3-P3, P3-O1, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8, P8-O2, FZ-CZ, CZ-PZ, P7-T7, T7-FT9, FT9-FT10, FT10-T8 et T8-P8, comme indiqué dans la figure 5.7(b).

Les résultats expérimentaux montrent que l'entropie de Renyi étendue (RE) dans le domaine temps-fréquence de la SPWVD permet de sélectionner des canaux distincts dans l'époque pré-ictale spécifique à chaque patient. Ces canaux sélectionnés sont positionnés dans la même région cervicale correspondant à l'époque ictale, en accord avec le système international 10-20. La valeur de RE est élevée pour l'électrode la plus proche de la zone épileptogène pendant l'époque ictale, et cette même électrode est souvent sélectionnée pendant les phases pré-ictales.

5.3.3 Extraction des caractéristiques

Afin de différencier les variations dans les signaux EEG choisis par RE concernant la zone épileptogène pendant les phases pré-ictales et inter-ictales, plusieurs caractéristiques significatives ont été extraites de ces signaux de canaux EEG. Ces caractéristiques sont liées à l'énergie, incluant l'énergie (E), la puissance moyenne (PM), la moyenne quadratique (RMS) et le taux de passage à zéro (ZCR), dont les équations mathématiques sont définies dans la section 3.2.1.

La plage de valeurs de chaque caractéristique extraite de la SPWVD des phases pré-ictales et inter-ictales, provenant des canaux sélectionnés dans les signaux EEG de tous les sujets, est présentée dans la Figure 5.8.

Les résultats de la Figure 5.8 (d) présentent une augmentation des valeurs ZCR du SPWVD du canal sélectionné pendant la période inter-ictale, avec une valeur maximale de 0,0908 et une valeur minimale de 0,032. Pour la période pré-ictale, la valeur ZCR diminue avec une valeur maximale de 0,0357 et une valeur minimale de 0,0117. Les valeurs de ZCR sont donc ordonnées selon un ordre décroissant pour l'état pré-ictal et croissant pour l'état inter-ictal, indiquant un changement remarquable de cette caractéristique entre les deux périodes. Ces résultats sont similaires pour tous les patients, suggérant que le taux de passage à zéro est une caractéristique considérable pour distinguer les deux états des signaux EEG épileptiques.

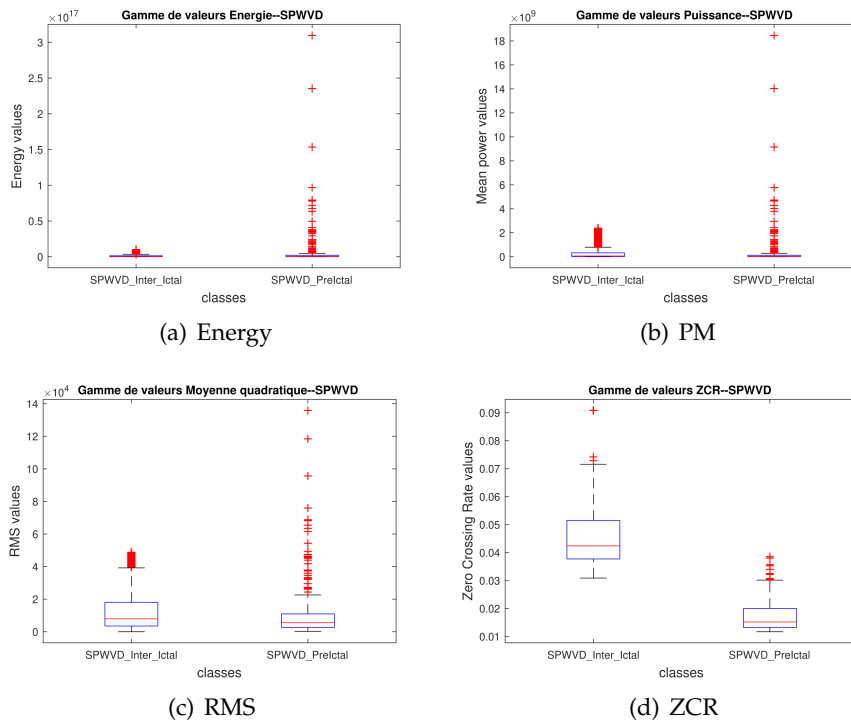


FIGURE 5.8 – La variation de chaque caractéristique extraite du SPWVD des signaux EEG pré-ictaux et inter-ictaux de la base de données CHB-MIT.
 (a) L'énergie (E), (b) Puissance moyenne (PM), (c) Moyenne quadratique (RMS), (d) Taux de passage de zéro (ZCR)

5.3.4 Résultats de la classification

Dans le but d'obtenir des résultats de classification prédictive fiables, nous avons évalué notre méthode en utilisant plusieurs schémas de validation croisée, tels que la méthode "Train-Test Split" avec un ensemble d'apprentissage de 70% des données et un ensemble de test de 30%, ainsi que la méthode de validation croisée K-fold avec $k=10$. Nous avons validé la performance de notre approche de prédiction des crises à l'aide de plusieurs métriques, notamment le taux de classification de prédiction (Acc), la sensibilité (Sens), la précision (Prec), le score F1 (F1-score), le taux de fausses prédictions (FPR), le rapport de vraisemblance positif (LR+), et l'aire sous la courbe (AUC). Les résultats expérimentaux de classification de notre algorithme avec les deux méthodologies de pré-traitement en utilisant la méthode "Train-Test Split" sont présentés dans les tableaux 5.1 et 5.2.

Les tableaux 5.3 et 5.4 présentent les performances des deux méthodologies de pré-traitement en utilisant la technique de validation croisée 5-fold, respectivement.

Les résultats de classification présentés dans les tableaux 5.1, 5.2, 5.3, et 5.4 démontrent la supériorité de la technique de validation croisée 5-fold par rapport à la technique de "Train-Test Split". De plus, la deuxième méthode de pré-traitement est plus performante que la première méthode, que ce soit pour la validation croisée 5-fold ou la technique de "Train-Test Split".

Les résultats de classification obtenus avec la première méthode de prétraitement sont présentés dans les tableaux 5.1 & 5.3. Ces résultats montrent que le classificateur DT a atteint une précision moyenne de prédiction de 96,44%, une sensibilité de 98,97%, et un taux de fausses prédictions de 0,0344 par heure en utilisant la technique "Train-

Classifieurs	Époques	Acc	Sens	Prec	F1-score	FPR	LR+	AUC
SVM	16 minute	94,88	98,72	74,04	84,62	0,0576	17,15	0,8691
	17 minute	95,35	100	72,83	84,28	0,0531	18,84	0,8641
	18 minute	94,61	100	68,48	81,29	0,0611	16,38	0,8424
	19 minute	95,35	100	72,83	84,28	0,0531	18,84	0,8641
	20 minute	94,05	100	65,22	78,95	0,0669	14,94	0,8261
	Moyenne	94,85	99,74	70,68	82,68	0,0583	17,23	0,8532
KNN	16 minute	97,44	97,73	87,76	92,47	0,0261	37,38	0,9365
	17 minute	96,47	97,37	81,32	88,62	0,0368	26,46	0,9044
	18 minute	95,91	93,67	81,32	87,06	0,0370	25,29	0,9010
	19 minute	95,54	93,51	79,12	85,71	0,0412	22,69	0,8900
	20 minute	95,54	93,51	79,12	85,71	0,0412	22,69	0,8900
	Moyenne	96,18	95,16	81,73	87,92	0,0365	26,90	0,9044
DT	16 minute	98,35	98,97	92,31	95,52	0,0178	55,67	0,9604
	17 minute	95,54	93,59	79,35	85,88	0,0413	22,66	0,8911
	18 minute	95,91	91,67	83,70	87,50	0,0330	27,74	0,9106
	19 minute	96,47	97,40	81,52	88,76	0,0369	26,41	0,9054
	20 minute	95,91	97,30	78,26	86,75	0,0431	22,57	0,8891
	Moyenne	96,44	95,79	83,03	88,88	0,0344	31,01	0,9113

TABLE 5.1 – Les résultats expérimentaux de classification pour la première méthodologie de pré-traitement (70/30).

Classifieurs	Acc	Sens	Prec	F1-score	FPR	LR+	AUC
SVM	99,44	100	96,47	98,20	0,0067	149,67	0,9824
kNN	99,25	100	95,24	97,56	0,0089	112,75	0,9762
DT	99,62	100	97,65	98,81	0,0045	224,00	0,9882

TABLE 5.2 – Résultats expérimentaux de classification pour la deuxième méthodologie de pré-traitement (70/30).

Classifieurs	Epochs	Acc	Sens	Prec	F1-score	FPR	LR+	AUC
SVM	16 min	96.21	99.25	79.53	88.19	0.0428	24.45	0.8970
	17 min	96.37	99.20	79.00	87.90	0.0404	25.00	0.8943
	18 min	95.82	98.26	76.33	85.88	0.0454	22.15	0.8803
	19 min	96.10	99.19	77.33	86.84	0.0435	23.27	0.8860
	20 min	95.59	99.08	74.33	84.85	0.0490	21.05	0.8710
	Moyenne	96.02	99.00	77.30	86.73	0.0442	23.18	0.8857
KNN	16 min	95.88	94.94	81.37	87.56	0.0395	25.66	0.9022
	17 min	96.76	99.21	81.33	89.31	0.0361	28.85	0.9060
	18 min	95.65	95.13	78.00	85.64	0.0425	23.48	0.8860
	19 min	95.98	97.49	78.00	86.61	0.0424	23.76	0.8880
	20 min	95.59	95.85	77.00	85.32	0.0443	22.40	0.8817
	Moyenne	95.97	96.53	79.14	86.89	0.0410	24.83	0.8928
DT	16 min	98,74	97,34	95,72	96,45	0,0093	171,40	0,9756
	17 min	97,60	97,17	88,33	92,48	0,0229	46,09	0,9390
	18 min	96,82	93,03	87,67	90,14	0,0243	54,93	0,9316
	19 min	97,44	94,80	89,67	92,11	0,0205	51,80	0,9433
	20 min	97,05	93,29	88,67	90,92	0,0225	49,66	0,9370
	Moyenne	97,53	95,13	90,01	92,42	0,0199	74,78	0,9453

TABLE 5.3 – Les résultats expérimentaux de classification pour la première méthodologie de pré-traitement (5 fold).

Test Split", avec un résultat optimal obtenu à la 16ème minute. Lorsque la méthode de validation croisée 5-fold a été utilisée, le classifieur a atteint une précision moyenne de prédiction de 97,53%, une sensibilité de 95,13%, et un taux de fausses prédictions très

Classifiers	Acc	Sens	Prec	F1-score	FPR	LR+	AUC
SVM	99.32	100	95.64	97.74	0.0079	190.36	0.9782
kNN	99.43	100	96.37	98.12	0.0066	Inf	0.9819
DT	99.71	100	98.18	99.07	0.0033	142.22	0.9909

TABLE 5.4 – Les résultats expérimentaux de classification pour la deuxième méthodologie de pré-traitement (5 fold).

faible de 0,0199 par heure, également avec un résultat optimal à la 16ème minute. Ces résultats indiquent que l'entropie de Renyi étendue au domaine temps-fréquence a correctement sélectionné le nombre de canaux affectés par les signaux ictaux et interictaux.

Les performances du classifieur kNN ont atteint leur apogée à la 17ème minute, avec une précision de prédiction de 96,76%, une sensibilité de 99,21%, et un taux de fausse prédiction de 0,0361 par heure. La précision de prédiction moyenne était de 95,97%, la sensibilité de 96,53%, et le taux de fausse prédiction de 0,0410. Le classificateur SVM a atteint une précision de prédiction moyenne de 96,02%, une sensibilité de 99,00%, et un taux de fausse prédiction de 0,0442%, avec une précision de prédiction maximale de 96,37% à la 17ème minute. L'aire moyenne sous la courbe (AUC) pour le SVM et le kNN est de 0,8857 et 0,8928, respectivement. En revanche, l'AUC pour le DT est de 0,9453, suggérant que le SVM et le kNN ont effectué une tâche de classification aléatoire, tandis que le DT a correctement prédit les cas vrais/faux.

Les Tableaux 5.2 & 5.4 présentent les performances du deuxième modèle de pré-traitement pour la prédiction des crises. Les résultats expérimentaux montrent une nette amélioration par rapport au premier modèle. En utilisant le classifieur à arbre de décision (DT), la classification de l'état ictal par rapport à l'état inter-ictal a atteint une précision, une sensibilité et un taux de fausse prédiction (FPR) de 99,71%, 100% et 0,0033 par heure, respectivement. En utilisant les k-Nearest Neighbors (kNN), ces mesures ont atteint respectivement 99,43%, 100% et 0,0066 par heure, et enfin, avec la machine à vecteurs de support (SVM), elles ont atteint 99,32%, 100% et 0,0079 par heure. Les valeurs AUC étaient élevées pour tous les classificateurs, atteignant 0,9909, 0,9819 et 0,9782 pour DT, kNN et SVM respectivement. Les classifieurs kNN et SVM ont tous deux atteint une sensibilité de 100%, indiquant que le classificateur DT a correctement classé tous les segments EEG pré-ictaux. Dans toutes les expériences, le DT a surpassé le SVM et le kNN, bien que la différence de performance entre SVM et kNN ait été légère.

Dans la section suivante, nous présentons les résultats de la prédiction des crises d'épilepsie pour chaque patient de la base de données CHB-MIT en utilisant deux méthodes de pré-traitement proposées, comme indiqué dans le Tableau 5.5. Les performances de prédiction ont été évaluées à l'aide du taux de classification prédictive et du FPR. De plus, les résultats de la validation croisée 5-fold ont également été rapportés pour permettre la comparaison des performances des deux méthodes de pré-traitement.

Les performances des deux méthodes de pré-traitement sont comparées en utilisant le taux de classification prédictive et le FPR, qui sont tous deux rapportés dans le Tableau 5.5.

Les résultats du Tableau 5.5 montrent clairement que la deuxième méthode de prédiction proposée a produit de meilleurs résultats que la première pour tous les patients de la base de données CHB-MIT. La plupart des patients ont atteint un taux de classification prédictive de 100% avec notre deuxième méthode. Pour le classificateur DT, 13 patients, à savoir chb02, chb06, chb09, chb11, chb12, chb13, chb14, chb18, chb20, chb21, chb22 et chb23, ont obtenu un taux de classification prédictive de 100%. Le kNN a obtenu un taux de 100% pour 8 patients, à savoir chb03, chb09, chb11, chb13, chb14, chb20,

Classifieurs	SVM				kNN				DT			
	1 ère		2 ème		1 ère		2 ème		1 ère		2 ème	
Méthode	Acc	FPR	Acc	FPR	Acc	FPR	Acc	FPR	Acc	FPR	Acc	FPR
Chb 01	94,89	0,0419	98,64	0,0205	94,91	0,0454	98,64	0,0205	92,50	0,0720	97,24	0,0118
Chb 02	97,50	0,0333	100	0	99,50	0,0067	97,5	0,0333	98,50	0,0133	100	0
Chb 03	98,93	0,0140	100	0	98,12	0,0242	100	0	97,63	0,0228	99,39	0
Chb 04	88,60	0,1384	100	0	87,81	0,1383	97,14	0,04	95,71	0,0493	97,14	0,04
Chb 06	97,55	0,0159	98,67	0,0111	98,10	0,0104	99,33	0	97,42	0,0123	100	0
Chb 09	99,48	0,0076	100	0	98,40	0,0073	100	0	99,75	0,0036	100	0
Chb 10	93,90	0,0103	97,31	0,0200	93,77	0,0397	98,64	0,0105	97,42	0,0239	97,31	0,0100
Chb 11	98,26	0,0227	100	0	96,86	0,0347	100	0	100	0	100	0
Chb 12	97,81	0,0397	99,62	0,0061	98,05	0,0345	99,62	0,0061	98,24	0,0202	100	0
Chb 13	88,65	0,1107	100	0	88,98	0,1102	100	0	91,85	0,0674	100	0
Chb 14	99,57	0,0065	100	0	100	0,0000	100	0	100	0	100	0
Chb 15	99,75	0,0036	100	0	99,50	0,0076	97,33	0,0382	100	0	98,67	0,0182
Chb 16	98,23	0,0123	97,69	0,0118	97,43	0,0309	97,69	0,0118	95,68	0,0220	95,50	0,03
Chb 18	99,32	0,0083	100	0	99,05	0,0145	97,26	0	99,32	0,0062	100	0
Chb 20	97,30	0,0306	100	0	97,62	0,0292	100	0	97,41	0,0207	100	0
Chb 21	97,28	0,0220	99,09	0	97,28	0,0328	99,09	0	98,55	0,0192	100	0
Chb 22	96,83	0,0413	97,5	0,0333	97,33	0,0347	100	0	97,33	0,0213	100	0
Chb 23	99,45	0,0080	100	0	99,45	0,0080	100	0	99,43	0,0040	100	0
Chb 24	93,68	0,0548	98,67	0,0123	93,89	0,0488	99	0,0121	96,75	0,0318	100	0
Moyenne	96,68	0,0327	99,33	0,0061	96,63	0,0346	99,01	0,0091	97,55	0,0216	99,22	0,0058


TABLE 5.5 – Taux de classification de la prédiction et taux de faux positifs (FPR) des deux méthodes proposées pour chaque patient.

chb22 et chb23, tandis que le SVM a atteint un taux de 100% pour 11 patients, à savoir chb02, chb03, chb04, chb09, chb11, chb13, chb14, chb15, chb18, chb20 et chb23, avec un FPR de 0 par heure. En moyenne, le taux de classification prédictive pour tous les patients était respectivement de 99,33%, 99,01% et 99,22% pour SVM, kNN et DT, avec un FPR moyen de 0,0061/h, 0,0091/h et 0,0058/h.


Après avoir appliqué la première méthode de prétraitement, nous avons observé que le classificateur DT a atteint un taux de classification prédictive de 100% pour seulement trois patients : chb11, chb14 et chb15. Pour le classificateur kNN, seul chb14 a obtenu un taux de classification prédictive de 100%, tandis que pour le SVM, aucun patient n'a atteint ce taux. En ce qui concerne la précision moyenne de prédiction pour tous les patients, nous avons noté des taux respectifs de 96,68%, 96,63% et 97,55% pour les SVM, kNN et DT, avec des FPR moyens de 0,0327/h, 0,0346/h et 0,0216/h, respectivement.

Le taux de précision de prédiction du classifieur SVM variait considérablement d'un patient à l'autre, allant de 99,75% pour le patient 15 à 88,60% pour le patient 04. De même, pour le classifieur kNN, la précision variait également entre les patients, allant de 99,50% pour le patient 02 à 87,81% pour le patient 04. Pour le classifieur DT, la précision minimale atteinte était de 91,85% pour le patient 13, avec un taux maximal de faux positifs (FPR) de 0,0674 par heure. Les valeurs de performance pour tous les patients des 24 sujets pour les deux approches sont présentées dans les figures 5.9, 5.10 & 5.11.

Tous les résultats expérimentaux présentés dans les tableaux 5.1, 5.2, 5.3 & 5.4 suggèrent que la seconde approche de prétraitement pour les canaux sélectionnés englobe des caractéristiques significatives pour l'ensemble de la durée du traitement des données EEG pré-critiques étudiées, par rapport à la première approche. Cela implique que la méthode proposée est fiable pour la prédiction des crises en sélectionnant les canaux pertinents pour la classification.




(a) Taux de classification




(b) Taux de fausse prédiction

FIGURE 5.9 – Les valeurs de performance de tous les sujets de la base de données CHB-MIT pour la première approche utilisant le classificateur SVM. (a) Taux de classification, (b) Taux de fausse prédiction




(a) Taux de classification




(b) Taux de fausse prédiction

FIGURE 5.10 – Les valeurs de performance de tous les sujets de la base de données CHB-MIT pour la première approche utilisant le classificateur kNN. (a) Taux de classification, (b) Taux de fausse prédiction



(a) Taux de classification



(b) Taux de fausse prédiction

FIGURE 5.11 – Les valeurs de performance de tous les sujets de la base de données CHB-MIT pour la première approche utilisant le classificateur DT. (a) Taux de classification, (b) Taux de fausse prédiction

Les résultats expérimentaux rapportés dans les tableaux 5.1, 5.2, 5.3 et 5.4 suggèrent que l'utilisation de la Rényi entropy (RE) pour sélectionner les canaux pertinents correspondant à la zone épileptogène, ainsi que le taux de passage par zéro comme caractéristique pertinente pour extraire des informations de ces canaux, combiné avec la classification par l'arbre de décision (DT), pourrait constituer une technique prometteuse pour la prédiction des crises épileptiques et la sélection des canaux pertinents. Cette méthode assure la prédiction clinique des crises épileptiques en anticipant leur apparition à 20 minutes, ce qui offre un délai de 15 minutes pour une intervention médicale ou un traitement approprié.

5.4 COMPARAISON DES PERFORMANCES AVEC D'AUTRES MÉTHODES

La prédiction des crises d'épilepsie suscite un intérêt croissant de la part des chercheurs en raison de l'impact grave de cette pathologie sur la qualité de vie des patients épileptiques. Diverses approches ont été proposées pour prédire ces crises. Pour évaluer l'efficacité de notre approche, nous avons comparé ses performances avec celles d'autres méthodes utilisant le même ensemble de données, en termes de taux de classification, de sensibilité et de FPR. Les résultats, présentés dans le tableau 5.6, montrent que notre approche a le taux de classification le plus élevé parmi ces études antérieures, ce qui témoigne de sa fiabilité.

Auteurs	Méthode	Acc (%)	FPR
Williamson et al. [155]	Corrélation spatio-temporelle	85.0	0.03
Alotaiby et al. [156]	Modèle spatial commun	89.0	0.39
Park et al. [157]	Puissance spectrale	94.4	0.20
Tamanna et al. [144]	DWT	96.38	0.19
Yang et al. [146]	Spectrogramme	-	0.17
Messaoud et al. [147]	Classificateur Random Forest	-	0.07
Cette étude	Entropie de Renyi étendue de la TF moyenne	99.71	0.0033

TABLE 5.6 – Comparaison des méthodes existantes pour la prédiction des crises épileptiques.

5.5 CONCLUSION

L'épilepsie est une maladie cérébrale chronique qui provoque des changements anormaux et soudains dans les ondes cérébrales, affectant ainsi l'ensemble du système nerveux. Ce chapitre se concentre sur la prédictibilité des crises épileptiques en utilisant le signal EEG capté 20 minutes avant leur apparition. Nous avons développé un algorithme utilisant deux méthodes de prétraitement différentes pour détecter les anomalies du signal EEG à partir des signaux cérébraux. Nous avons également développé un modèle de prédiction basé sur les caractéristiques temps-fréquence d'énergie de l'EEG et le taux de passage à zéro.

De plus, les méthodes proposées permettent de réduire efficacement le nombre d'électrodes EEG nécessaires pour prédire les crises épileptiques liées à la source épileptogène. L'algorithme proposé a montré des résultats prometteurs dans la prédiction des crises, avec une précision de prédiction de 99,71% et un taux de fausse prédiction (FPR) de 0,0033 par heure en utilisant un traitement complet de 5 minutes dans l'état pré-ictal et en utilisant le classificateur DT comme étape de classification. Ces résultats confirment la fiabilité de la méthode proposée pour prédire les crises d'épilepsie.

CONCLUSION GÉNÉRALE

L'épilepsie est une neuropathologie chronique non transmissible qui résulte de lésions cérébrales. Elle se manifeste principalement par des comportements cliniques paroxystiques transitoires provoqués par une activité électrique anormale, excessive et synchronisée dans une population de neurones cérébraux, appelés crises d'épilepsie. Ces crises peuvent également avoir un impact moteur ou sensoriel, parfois accompagné d'une altération de la conscience. Elles ont des conséquences sociales, psychologiques, cognitives et neurobiologiques importantes, et touchent largement les jeunes et les personnes âgées des deux sexes. Les crises d'épilepsie peuvent être classées en deux types : les crises partielles, qui se produisent lorsque seule une partie spécifique du cerveau est soumise à une décharge électrique excessive et synchronisée, et les crises généralisées, qui affectent l'ensemble du cerveau.

L'EEG est une technique de mesure des signaux électriques du cerveau utilisée pour diagnostiquer l'épilepsie en fournissant des informations en temps réel sur l'activité électrophysiologique des structures cérébrales, y compris l'activité épileptique. Les médecins s'appuient sur l'analyse de ces enregistrements pour établir un diagnostic précis et sélectionner le traitement le plus approprié pour les patients atteints d'épilepsie. Cependant, l'analyse de ces signaux est complexe en raison de leur nature non linéaire, dynamique et non stationnaire. Pour y remédier, des techniques de traitement de signal plus avancées et puissantes doivent être utilisées pour analyser simultanément les informations temporelles et fréquentielles. Les techniques d'analyse temps-fréquence sont particulièrement utiles dans ce contexte, car elles permettent de localiser plus précisément les différentes composantes spectrales des signaux EEG et offrent une technique plus adaptée à la reconnaissance des crises d'épilepsie.

La communauté scientifique s'est toujours intéressée à la détection des crises épileptiques. Pour cela, des chercheurs ont exploré différentes techniques d'analyse des signaux EEG dans les domaines temporel, fréquentiel ou temps-fréquence (TF) afin d'identifier les crises et de développer des systèmes d'aide au diagnostic médical. Cette thèse avait pour but de proposer et d'évaluer des modèles mathématiques basés sur l'analyse temps-fréquence pour améliorer l'interprétation des signaux électrophysiologiques par les neurologues. Dans la première partie, de nouvelles caractéristiques ont été extraites du signal EEG dans le domaine temps-fréquence pour améliorer la détection de l'activité électrique associée à l'événement de l'épilepsie dans la phase ictale des signaux EEG de manière plus précise, efficace et fiable. Dans la deuxième partie, des méthodes de traitement de signal automatisées basées sur l'analyse temps-fréquence ont été mises en œuvre pour détecter les crises d'épilepsie de manière précoce, en utilisant des techniques avancées d'analyse de signal pour repérer les activités épileptiformes dans la phase pré-ictale des signaux EEG. Cette approche pourrait permettre aux neurologues d'intervenir plus rapidement et d'améliorer les résultats cliniques pour les patients.

Dans le premier chapitre, nous avons contextualisé la neurophysiologie et l'électroencéphalographie dans le domaine de l'épilepsie. Nous avons expliqué le fonctionnement du cerveau et du système nerveux, et nous avons examiné les différentes formes

d'épilepsies, qu'elles soient focales ou généralisées et causées par divers facteurs. Nous avons également abordé les divers symptômes et syndromes qui peuvent survenir en cas d'épilepsie.

Le deuxième chapitre de notre étude a été consacré aux concepts fondamentaux et aux bases théoriques des représentations temps-fréquence, y compris les représentations linéaires et les distributions temps-fréquence quadratiques (QTFDs). Nous avons détaillé leur formulation mathématique ainsi que leurs propriétés distinctives.

Au cours du troisième chapitre, nous avons exploré diverses méthodes pour extraire les informations pertinentes des signaux EEG en identifiant les caractéristiques significatives. Nous avons également étudié les systèmes de classification utilisés pour classer les crises épileptiques.

Le quatrième et le cinquième chapitre ont été dédiés à l'exposé de l'approche développée pour la détection et la prédiction des crises épileptiques, respectivement. Nous avons également examiné et analysé les résultats obtenus dans ces deux chapitres.

L'algorithme développé dans cette étude a été évalué en utilisant plusieurs mesures d'évaluation sur des enregistrements EEG provenant de deux bases de données différentes. La première base de données, appelée CHB-MIT de l'hôpital de Boston, contient des enregistrements de 24 patients âgés de 1,5 à 22 ans présentant différents types de crises, notamment des crises partielles simples (SP), des crises partielles complexes (CP) et des crises tonico-cloniques généralisées (GTC). La deuxième base de données, appelée corpus EEG TUH, est composée de données de 100 personnes atteintes d'épilepsie et 100 sujets témoins présentant différents types de crises, tels que des crises partielles simples (SPSZ), des crises partielles complexes (CPSZ), des crises focales (FNSZ), des crises généralisées (GNSZ), des crises d'absence (ABSZ), des crises toniques (TNSZ), des crises cloniques (CNSZ) et des crises tonico-cloniques (TCSZ). Les résultats de l'évaluation de l'algorithme sont très convaincants, démontrant son efficacité avec une grande précision, une sensibilité totale et un faible taux de fausses alertes, indiquant la capacité des méthodes présentées à identifier et prédire les crises d'épilepsie à partir des signaux EEG.

PUBLICATIONS

Les contributions présentées dans cette thèse apparaissent dans les publications et les communications suivantes :

Revues Internationales

Fayza Ghembaza, Abdelghani Djebbari, Novel quadratic time–frequency features in EEG signals for robust detection of epileptic seizure. *Research on Biomedical Engineering*, pages 1–23, mar 2023. ISSN 24464740.

<https://link.springer.com/article/10.1007/s42600-022-00256-6/metrics>

Conférences Internationales

Fayza Ghembaza, Abdelghani Djebbari, Epileptic Seizure Detection by time–frequency Renyi entropy applied to Choi Williams Distribution of normal and abnormal Electroencephalograms, La 9 ème édition du colloque Tendances dans les Applications Mathématiques en Tunisie Algérie Maroc (TAMTAM'2019), Tlemcen 23–27 Février 2019.

Fayza Ghembaza, Abdelghani Djebbari, Epileptic Seizure Detection by Quadratic Time-Frequency Distributions of Electroencephalogram signals, International Conference on Advanced Electrical Engineering (ICAEE'2019), Alger 19–22 nov 2019.

Fayza Ghembaza, Abdelghani Djebbari, A Robust Dynamic EEG Channel Selection using Time–Frequency Extended Renyi Entropy, 7th International Conference on Image and Signal Processing and their Applications (ISPA'2022), Mostaganem 8–9 Mai 2022.

Conférences Nationales

Fayza Ghembaza, Abdelghani Djebbari, Detection of cerebral disorders by spectral and time–frequency analysis of EEG signals, 7 ème journée de la Maintenance Bio Médical de l'hôpital central de l'armée (JMB7), ALGER 4 Octobre 2018.

Fayza Ghembaza, Abdelghani Djebbari, Epileptic Seizure Detection by Quadratic Time Frequency Distributions for Normal and Abnormal Electroencephalograms (EEG), 8 ème journée de la Maintenance Bio Médical de l'hôpital central de l'armée (JMB8). ALGER 10 Octobre 2019.

Fayza Ghembaza, Abdelghani Djebbari, Electroencephalogram Time–Frequency Analysis : Application in neuromarketing, Colloque National Virtuel sur l'apport des Neurosciences dans le Marketing-Management. TLEMEN 11 Juin 2022.

Journées Doctorales

Fayza Ghembaza, Abdelghani Djebbari, Detection of cerebral disorders by spectral and time–frequency analysis of EEG signals, 8 ème journée doctorale en Génie Bio Médical (JD'GBM 2018), TLEMEN 10 Mai 2018.

Fayza Ghembaza, Abdelghani Djebbari, «Epileptic Seizure Detection by Quadratic Time Frequency Distributions applied on Electroencephalograms (EEG)”, 9 ème journée doctorale en Génie Bio Médical (JD’GBM 2019), TLEMCEN 13 Juin 2019.

BIBLIOGRAPHIE

- [1] Z. You, *Etude de la morphologie et de la distribution des neurones dans le cerveau de macaque par microscopie optique*. PhD thesis, Université Pierre et Marie Curie-Paris VI, 2017.
- [2] S. S. Cash, E. Halgren, N. Dehghani, A. O. Rossetti, T. Thesen, C. M. Wang, O. Devinsky, R. Kuzniecky, W. Doyle, J. R. Madsen, E. Bromfield, L. Eross, P. Halász, G. Karmos, R. Csercsa, L. Wittner, and I. Ulbert, "The human K-complex represents an isolated cortical down-state," *Science*, vol. 324, pp. 1084–1087, may 2009.
- [3] I. E. Maâchi, "Algorithmes de détection des maladies neurodégénératives à partir de la démarche d'un individu," Master's thesis, École Polytechnique de Montréal, décembre 2018.
- [4] J. Gotman, "A few thoughts on "What is a seizure?"," *Epilepsy and Behavior*, vol. 22, no. SUPPL. 1, p. S2, 2011.
- [5] R. B. Yaffe, P. Borger, P. Megevand, D. M. Groppe, M. A. Kramer, C. J. Chu, S. Santaniello, C. Meisel, A. D. Mehta, and S. V. Sarma, "Physiology of functional and effective networks in epilepsy," *Clinical Neurophysiology*, vol. 126, pp. 227–236, feb 2015.
- [6] D. Ehrens, F. Assaf, N. J. Cowan, S. V. Sarma, and Y. Schiller, "Ultra Broad Band Neural Activity Portends Seizure Onset in a Rat Model of Epilepsy," in *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, vol. 2018, pp. 2276–2279, IEEE, jul 2018.
- [7] A. Sharma, J. K. Rai, and R. P. Tewari, "Epileptic seizure anticipation and localization of epileptogenic region using EEG signals," *Journal of Medical Engineering & Technology*, vol. 42, pp. 203–216, apr 2018.
- [8] G. H. Klem, H. O. Lüders, H. H. Jasper, and C. Elger, "The ten-twenty electrode system of the International Federation. The International Federation of Clinical Neurophysiology," *Electroencephalography and clinical neurophysiology. Supplement*, vol. 52, pp. 3–6, 1999.
- [9] M. T. Salam, J. L. Perez Velazquez, and R. Genov, "Seizure Suppression Efficacy of Closed-Loop Versus Open-Loop Deep Brain Stimulation in a Rodent Model of Epilepsy," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 24, pp. 710–719, jun 2016.
- [10] B. Boashash, N. A. Khan, and T. Ben-Jabeur, "Time-frequency features for pattern recognition using high-resolution TFDs : A tutorial review," *Digital Signal Processing : A Review Journal*, vol. 40, pp. 1–30, may 2015.

- [11] F. A. Azevedo, L. R. Carvalho, L. T. Grinberg, J. M. Farfel, R. E. Ferretti, R. E. Leite, W. J. Filho, R. Lent, and S. Herculano-Houzel, "Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain," *Journal of Comparative Neurology*, vol. 513, pp. 532–541, apr 2009.
- [12] O. Akinyokun, "Neuro-fuzzy expert system for evaluation of human resource performance," *First Bank of Nigeria PLC Endowment Fund Lecture Series*, vol. 1, 2002.
- [13] H. Berger, "Über das Elektrenkephalogramm des Menschen," *Archiv für Psychiatrie und Nervenkrankheiten*, vol. 87, pp. 527–570, dec 1929.
- [14] J. Bourien, *Analyse de distributions spatio-temporelles de transitoires dans des signaux vectoriels. Application à la détection-classification d'activités paroxystiques intercritiques dans des observations EEG*. PhD thesis, Université Rennes 1, 2003.
- [15] B. J. Fisch and R. Spehlmann, *Fisch and Spehlmann's EEG primer : basic principles of digital and analog EEG*. Amsterdam ; New York : Elsevier, 1999.
- [16] R. S. Fisher, W. v. E. Boas, W. Blume, C. Elger, P. Genton, P. Lee, and J. Engel, "Epileptic Seizures and Epilepsy : Definitions Proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE)," *Epilepsia*, vol. 46, pp. 470–472, apr 2005.
- [17] I. E. Scheffer, S. Berkovic, G. Capovilla, M. B. Connolly, J. French, L. Guilhoto, E. Hirsch, S. Jain, G. W. Mathern, S. L. Moshé, *et al.*, "Ilae classification of the epilepsies : Position paper of the ilae commission for classification and terminology," *Epilepsia*, vol. 58, no. 4, pp. 512–521, 2017.
- [18] A. Shoeb, H. Edwards, J. Connolly, B. Bourgeois, S. Ted Treves, and J. Guttag, "Patient-specific seizure onset detection," *Epilepsy and Behavior*, vol. 5, pp. 483–498, aug 2004.
- [19] I. Obeid and J. Picone, "The temple university hospital EEG data corpus," *Frontiers in Neuroscience*, vol. 10, no. MAY, p. 196, 2016.
- [20] S. Ouelha, "Représentation et reconnaissance des signaux acoustiques sous-marins," <http://www.theses.fr>, dec 2014.
- [21] W. Klonowski, "Everything you wanted to ask about EEG but were afraid to get the right answer," *Nonlinear Biomedical Physics*, vol. 3, p. 2, may 2009.
- [22] W. Klonowski, "Application of nonlinear dynamics in biosignal analysis," in *Topical Problems of Nonlinear Wave Physics*, vol. 5975, pp. 335–344, SPIE, 2006.
- [23] F. Hlawatsch and G. F. Boudreaux-Bartels, "Linear and quadratic time-frequency signal representations," *IEEE Signal Processing Magazine*, vol. 9, no. 2, pp. 21–67, 1992.
- [24] A. Papandreou-Suppappola and G. F. Boudreaux-Bartels, "Exponential class and generalized time-shift covariant quadratic time-frequency representations," in *Proceedings of the IEEE-SP International Symposium on Time-Frequency and Time-Scale Analysis*, pp. 429–432, IEEE, 1996.

- [25] R. G. Baraniuk, "Warped perspectives in time-frequency analysis," in *Proceedings of IEEE-SP International Symposium on Time-Frequency and Time-Scale Analysis*, pp. 528–531, IEEE, 1994.
- [26] A. Quinquis, "Polynomial phase signal processing via warped high-order ambiguity function," *Eur. Conf. on Signal Processing* . . . , jan 2004.
- [27] H. M. Ozaktas, M. A. Kutay, and Z. Zalevsky, *The fractional Fourier transform with applications in optics and signal processing*. Wiley, 2001.
- [28] P. Flandrin, "B.EscudiéC.GazanhesH.TachoireV.TorraDes Cordes aux Ondettes2001Publ. de l'Univ. de Provence," *European Journal of Mechanics Series B Fluids*, vol. 25, no. 6, pp. 1022–1022, 2006.
- [29] D. C. Cassidy, "Answer to Question 62. When did the indeterminacy principle become the uncertainty principle?," *American Journal of Physics*, vol. 66, pp. 278–279, apr 1998.
- [30] S. Kadambe and G. F. Boudreaux-Bartels, "A Comparison of the Existence of "Cross Terms" in the Wigner Distribution and the Squared Magnitude of the Wavelet Transform and the Short Time Fourier Transform," *IEEE Transactions on Signal Processing*, vol. 40, no. 10, pp. 2498–2517, 1992.
- [31] P. Gibbins, "A Note on Quantum Logic and the Uncertainty Principle," *Philosophy of Science*, vol. 48, pp. 122–126, mar 1981.
- [32] L. Cohen, "Time-Frequency Distributions-A Review," 1989.
- [33] B. Barkat and B. Boashash, "A high-resolution quadratic time-frequency distribution for multicomponent signals analysis," *IEEE Transactions on Signal Processing*, vol. 49, pp. 2232–2239, oct 2001.
- [34] B. Boashash, "Note on the Use of the Wigner Distribution for Time-Frequency Signal Analysis," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 36, no. 9, pp. 1518–1521, 1988.
- [35] T. Claasen, "The wigner distribution-a tool for time-frequency signal analysis," *Philips J. Res.*, vol. 35, pp. 217–250, 1980.
- [36] A. Janssen, "On the locus and spread of pseudo-density functions in the time-frequency plane," *Philips Journal of Research*, vol. 37, no. 3, pp. 79–110, 1982.
- [37] D. L. Jones and T. W. Parks, "Resolution comparison of several time-frequency representations," *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, vol. 4, pp. 2222–2225, 1989.
- [38] J. ROTHSTEIN, "Probability and Information Theory, with Applications to Radar. P. M. Woodward. McGraw-Hill, New York; Pergamon Press, London, 1953. 128 pp. Illus. 4.50," *Science*, vol. 119, pp. 874–874, jun 1954.
- [39] E. F. Velez and R. G. Absher, "Transient analysis of speech signals using the Wigner time-frequency representation," *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, vol. 4, pp. 2242–2245, 1989.

- [40] H.-I. Choi and W. Williams, "Improved time-frequency representation of multicomponent signals using exponential kernels," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 37, pp. 862–871, jun 1989.
- [41] D. T. Barry, "Fast Calculation of the Choi-Williams Time-Frequency Distribution," *IEEE Transactions on Signal Processing*, vol. 40, no. 2, pp. 450–455, 1992.
- [42] H. F., "SPWVD, CWD, and CKR : ambiguity-domain analysis and experimental comparison," *Signal Processing*, vol. 43, no. 2, pp. 149–168, 1995.
- [43] Y. Zhao, L. E. Atlas, and R. J. Marks, "The Use of Cone-Shaped Kernels for Generalized Time-Frequency Representations of Nonstationary Signals," *IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 38, no. 7, pp. 1084–1091, 1990.
- [44] I. Kayikcioglu, C. Kose, and T. Kayikcioglu, "ECG ST segment change detection using Born-Jordan Time-Frequency Transform and Artificial Neural Networks," *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018*, pp. 1–4, jul 2018.
- [45] W. J. Williams, "Reduced Interference Time-Frequency Distributions : Applications to Acoustic Transients," 1990.
- [46] B. Boashash and L. Boubchir, "On the Selection of Time-Frequency Features for Improving the Detection and Classification of Newborn EEG Seizure Signals and Other Abnormalities," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 7666 LNCS, pp. 634–643, nov 2012.
- [47] B. Boashash, *Time-frequency signal analysis and processing : a comprehensive reference*. Academic Press, 2015.
- [48] P. Boonyakitanont, A. Lek-uthai, K. Chomtho, and J. Songsiri, "A review of feature extraction and performance evaluation in epileptic seizure detection using EEG," *Biomedical Signal Processing and Control*, vol. 57, p. 101702, mar 2020.
- [49] J. F. Kaiser, "On a simple algorithm to calculate the 'energy' of a signal," *undefined*, vol. 1, pp. 381–384, 1990.
- [50] C. C. Osuagwu, "FAULT DETECTION USING THE ZERO CROSSING RATE," *Nigerian Journal of Technology*, vol. 13, no. 1, pp. 16–25, 1989.
- [51] S. Sanei and J. Chambers, *EEG signal processing*. John Wiley & Sons, 2007.
- [52] N. Kannathal, U. R. Acharya, C. M. Lim, and P. K. Sadasivan, "Characterization of EEG - A comparative study," *Computer Methods and Programs in Biomedicine*, vol. 80, pp. 17–23, oct 2005.
- [53] S. M. Pincus, "Approximate entropy as a measure of system complexity.," *Proceedings of the National Academy of Sciences*, vol. 88, pp. 2297–2301, mar 1991.
- [54] C. E. Shannon, "Communication Theory of Secrecy Systems*," *Bell System Technical Journal*, vol. 28, pp. 656–715, oct 1949.

- [55] B. Tellenbach, M. Burkhart, D. Sornette, and T. Maillart, "Beyond Shannon : Characterizing Internet Traffic with Generalized Entropy Metrics," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 5448, pp. 239–248, 2009.
- [56] E. J. Heikkilä and L. Hu, "Adjusting Spatial-Entropy Measures for Scale and Resolution Effects :," <https://doi.org/10.1068/b31126>, vol. 33, pp. 845–861, nov 2016.
- [57] D. P. Feldman and J. P. Crutchfield, "Measures of statistical complexity : Why?," *Physics Letters A*, vol. 238, pp. 244–252, feb 1998.
- [58] A. Rényi, "On measures of entropy and information," in *Proceedings of the Fourth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1 : Contributions to the Theory of Statistics*, (Berkeley, Calif.), pp. 547–561, University of California Press, 1961.
- [59] C. Cachin, "Smooth Entropy and Rényi Entropy," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 1233, pp. 193–208, 1997.
- [60] G. Sonnino, G. Steinbrecher, and A. Sonnino, "The Rényi entropy of Levy distribution," *arXiv preprint arXiv:1402.5909*, 2014.
- [61] L. Campbell, "On measures of information and their characterizations (j. aczél and z. daróczy)," *SIAM Review*, vol. 19, no. 3, pp. 577–579, 1977.
- [62] A. Bezerianos, S. Tong, and N. Thakor, "Time-dependent entropy estimation of EEG rhythm changes following brain ischemia," *Annals of biomedical engineering*, vol. 31, no. 2, pp. 221–232, 2003.
- [63] S. Tong, A. Bezerianos, A. Malhotra, Y. Zhu, and N. Thakor, "Parameterized entropy analysis of EEG following hypoxic-ischemic brain injury," *Physics Letters, Section A : General, Atomic and Solid State Physics*, vol. 314, pp. 354–361, aug 2003.
- [64] A. Capurro, L. Diambra, D. Lorenzo, O. Macadar, M. T. Martin, C. Mostaccio, A. Plastino, J. Pérez, E. Rofman, M. E. Torres, and J. Velluti, "Human brain dynamics : the analysis of EEG signals with Tsallis information measure," *Physica A : Statistical Mechanics and its Applications*, vol. 265, no. 1, pp. 235–254, 1999.
- [65] P. S. Rodrigues and G. A. Giraldo, "Computing the q-index for tsallis nonextensive image segmentation," *Proceedings of SIBGRAPI 2009 - 22nd Brazilian Symposium on Computer Graphics and Image Processing*, pp. 232–237, 2009.
- [66] A. J. Seely and P. T. MacKlem, "Complex systems and the technology of variability analysis," *Critical Care*, vol. 8, p. R367, dec 2004.
- [67] S. Pincus, "Approximate entropy (ApEn) as a complexity measure," *Chaos : An Interdisciplinary Journal of Nonlinear Science*, vol. 5, p. 110, aug 1998.
- [68] J. S. Richman and J. R. Moorman, "Physiological time-series analysis using approximate and sample entropy," *American Journal of Physiology - Heart and Circulatory Physiology*, vol. 278, no. 6, pp. 2039–2049, 2000.
- [69] I. Veisi, N. Pariz, and A. Karimpour, "Fast and Robust Detection of Epilepsy in Noisy EEG Signals Using Permutation Entropy," *undefined*, pp. 200–203, 2007.

- [70] C. Bandt and B. Pompe, "Permutation Entropy : A Natural Complexity Measure for Time Series," *Physical Review Letters*, vol. 88, p. 174102, apr 2002.
- [71] Y. Cao, W. wen Tung, J. B. Gao, V. A. Protopopescu, and L. M. Hively, "Detecting dynamical changes in time series using the permutation entropy," *Physical Review E - Statistical Physics, Plasmas, Fluids, and Related Interdisciplinary Topics*, vol. 70, p. 7, oct 2004.
- [72] X. Li, G. Ouyang, and D. A. Richards, "Predictability analysis of absence seizures with permutation entropy," *Epilepsy Research*, vol. 77, pp. 70–74, oct 2007.
- [73] M. Zanin, L. Zunino, O. A. Rosso, and D. Papo, "Permutation Entropy and Its Main Biomedical and Econophysics Applications : A Review," *Entropy 2012, Vol. 14, Pages 1553-1577*, vol. 14, pp. 1553–1577, aug 2012.
- [74] B. Fadlallah, B. Chen, A. Keil, and J. Príncipe, "Weighted-permutation entropy : A complexity measure for time series incorporating amplitude information," *Physical Review E - Statistical, Nonlinear, and Soft Matter Physics*, vol. 87, p. 022911, feb 2013.
- [75] W. Weiting Chen, Z. Zhizhong Wang, H. Hongbo Xie, and W. Wangxin Yu, "Characterization of Surface EMG Signal Based on Fuzzy Entropy," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 15, pp. 266–272, jun 2007.
- [76] P. Li, C. Liu, K. Li, D. Zheng, C. Liu, and Y. Hou, "Assessing the complexity of short-term heartbeat interval series by distribution entropy," *Medical & biological engineering & computing*, vol. 53, pp. 77–87, jan 2015.
- [77] B. R. Greene, S. Faul, W. P. Marnane, G. Lightbody, I. Korotchikova, and G. B. Boylan, "A comparison of quantitative EEG features for neonatal seizure detection," *Clinical Neurophysiology*, vol. 119, pp. 1248–1261, jun 2008.
- [78] F. Ghembaza and A. Djebbari, "Epileptic Seizure Detection by Quadratic Time-Frequency Distributions of Electroencephalogram signals," *2019 International Conference on Advanced Electrical Engineering, ICAEE 2019*, nov 2019.
- [79] F. Ghembaza and A. Djebbari, "A Robust Dynamic EEG Channel Selection using Time-Frequency Extended Renyi Entropy," *2022 7th International Conference on Image and Signal Processing and their Applications, ISPA 2022 - Proceedings, 2022*.
- [80] L. Guo, D. Rivero, and A. Pazos, "Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks," *Journal of Neuroscience Methods*, vol. 193, pp. 156–163, oct 2010.
- [81] W. Liu, Y. Jiang, and Y. Xu, "A Super Fast Algorithm for Estimating Sample Entropy," *Entropy 2022, Vol. 24, Page 524*, vol. 24, p. 524, apr 2022.
- [82] N. S. Tawfik, S. M. Youssef, and M. Kholief, "A hybrid automated detection of epileptic seizures in EEG records," *Computers & Electrical Engineering*, vol. 53, pp. 177–190, jul 2016.
- [83] R. G. Baraniuk, P. Flandrin, A. J. Janssen, and O. J. Michel, "Measuring time-frequency information content using the rényi entropies," *IEEE Transactions on Information Theory*, vol. 47, no. 4, pp. 1391–1409, 2001.

- [84] R. Baraniuk, P. Flandrin, A. Janssen, and O. Michel, "Measuring time-frequency information content using the Renyi entropies," *IEEE Transactions on Information Theory*, vol. 47, pp. 1391–1409, may 2001.
- [85] B. Boashash, "Part I : A The time-frequency tutorial," *Time-Frequency Signal Analysis and Processing*, pp. 3–137, 2016.
- [86] L. Tang and G. Liu, "The novel approach of temporal dependency complexity analysis of heart rate variability in obstructive sleep apnea," *Computers in Biology and Medicine*, vol. 135, p. 104632, aug 2021.
- [87] H. Azami, J. Escudero, and A. Humeau-Heurtier, "Bidimensional Distribution Entropy to Analyze the Irregularity of Small-Sized Textures," *IEEE Signal Processing Letters*, vol. 24, pp. 1338–1342, sep 2017.
- [88] L. Stankovi, "A measure of some time–frequency distributions concentration," *Signal Processing*, vol. 81, pp. 621–631, mar 2001.
- [89] N. A. Khan and S. Ali, "A new feature for the classification of non-stationary signals based on the direction of signal energy in the time–frequency domain," *Computers in Biology and Medicine*, vol. 100, pp. 10–16, sep 2018.
- [90] R. Zemouri, *Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance*. PhD thesis, Université de Franche-Comté, 2003.
- [91] K. Yamazaki, V.-K. Vo-Ho, D. Bulsara, and N. Le, "Spiking neural networks and their applications : A review," *Brain Sciences*, vol. 12, no. 7, p. 863, 2022.
- [92] O. Nerrand, P. Roussel-Ragot, L. Personnaz, G. Dreyfus, and S. Marcos, "Neural Networks and Nonlinear Adaptive Filtering : Unifying Concepts and New Algorithms," *Neural Computation*, vol. 5, pp. 165–199, mar 1993.
- [93] S. V. Chakravarthy and J. Ghosh, "Scale-based clustering using the radial basis function network," *IEEE Transactions on Neural Networks*, vol. 7, no. 5, pp. 1250–1261, 1996.
- [94] C. Dumitru and V. Maria, "Advantages and Disadvantages of Using Neural Networks for Predictions," *Ovidius University Annals : Economic Sciences Series*, 2013.
- [95] K. I. Qazi, H. Lam, B. Xiao, G. Ouyang, and X. Yin, "Classification of epilepsy using computational intelligence techniques," *CAAI Transactions on Intelligence Technology*, vol. 1, pp. 137–149, apr 2016.
- [96] Z. Zainuddin, L. K. Huong, and O. Pauline, "On the Use of Wavelet Neural Networks in the Task of Epileptic Seizure Detection from Electroencephalography Signals," *Procedia Computer Science*, vol. 11, pp. 149–159, 2012.
- [97] R. Rojas and R. Rojas, "The backpropagation algorithm," *Neural networks : a systematic introduction*, pp. 149–182, 1996.
- [98] R. Chellappa and K. Etemad, "Discriminant analysis for recognition of human face images," *JOSA A, Vol. 14, Issue 8, pp. 1724-1733*, vol. 14, pp. 1724–1733, aug 1997.

- [99] C. Deacon, S. Wiebe, W. T. Blume, R. S. McLachlan, G. B. Young, and S. Matievic, "Seizure identification by clinical description in temporal lobe epilepsy," *Neurology*, vol. 61, pp. 1686–1689, dec 2003.
- [100] V. Vapnik, *The Nature of Statistical Learning Theory*. Information Science and Statistics, Springer New York, 2013.
- [101] A. Subasi and M. I. GURSOY, "EEG signal classification using PCA, ICA, LDA and support vector machines," *Expert Systems with Applications*, vol. 37, pp. 8659–8666, dec 2010.
- [102] F. A. Afsar, M. U. Akram, M. Arif, and J. Khurshid, "A pruned fuzzy k-Nearest neighbor classifier with application to electrocardiogram based cardiac arrhythmia recognition," *IEEE INMIC 2008 : 12th IEEE International Multitopic Conference - Conference Proceedings*, pp. 143–148, 2008.
- [103] L. Y. Hu, M. W. Huang, S. W. Ke, and C. F. Tsai, "The distance function effect on k-nearest neighbor classification for medical datasets," *SpringerPlus*, vol. 5, pp. 1–9, dec 2016.
- [104] A. H. Fielding, *Cluster and classification techniques for the biosciences*. Cambridge University Press, 2006.
- [105] S. R. Safavian and D. Landgrebe, "A Survey of Decision Tree Classifier Methodology," *IEEE Transactions on Systems, Man and Cybernetics*, vol. 21, no. 3, pp. 660–674, 1991.
- [106] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, vol. 21, pp. 1–13, jan 2020.
- [107] J. Gotman, "Automatic seizure detection : improvements and evaluation," *Electroencephalography and Clinical Neurophysiology*, vol. 76, pp. 317–324, oct 1990.
- [108] G. Widman, T. Schreiber, B. Rehberg, A. Hoeft, and C. E. Elger, "Quantification of depth of anesthesia by nonlinear time series analysis of brain electrical activity," *Physical Review E - Statistical Physics, Plasmas, Fluids, and Related Interdisciplinary Topics*, vol. 62, pp. 4898–4903, oct 2000.
- [109] K. Fu, J. Qu, Y. Chai, and T. Zou, "Hilbert marginal spectrum analysis for automatic seizure detection in EEG signals," *Biomedical Signal Processing and Control*, vol. 18, pp. 179–185, apr 2015.
- [110] P. A. M. Kanda, L. R. Trambaiolli, A. C. Lorena, F. J. Fraga, L. F. I. Basile, R. Nitrini, and R. Anghinah, "Clinician's road map to wavelet EEG as an Alzheimer's disease biomarker," *Clinical EEG and Neuroscience*, vol. 45, no. 2, pp. 104–112, 2014.
- [111] S. Altunay, Z. Telatar, and O. Erogul, "Epileptic EEG detection using the linear prediction error energy," *Expert Systems with Applications*, vol. 37, pp. 5661–5665, aug 2010.
- [112] N. Kannathal, M. L. Choo, U. R. Acharya, and P. Sadasivan, "Entropies for detection of epilepsy in eeg," *Computer methods and programs in biomedicine*, vol. 80, no. 3, pp. 187–194, 2005.

- [113] U. R. Acharya, F. Molinari, S. V. Sree, S. Chattopadhyay, K. H. Ng, and J. S. Suri, "Automated diagnosis of epileptic EEG using entropies," *Biomedical Signal Processing and Control*, vol. 7, pp. 401–408, jul 2012.
- [114] H. Ocak, "Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy," *Expert Systems with Applications*, vol. 36, no. 2 PART 1, pp. 2027–2036, 2009.
- [115] S. H. Lee, J. S. Lim, J. K. Kim, J. Yang, and Y. Lee, "Classification of normal and epileptic seizure EEG signals using wavelet transform, phase-space reconstruction, and Euclidean distance," *Computer Methods and Programs in Biomedicine*, vol. 116, pp. 10–25, aug 2014.
- [116] A. T. Tzallas, M. G. Tsipouras, and D. I. Fotiadis, "Automatic seizure detection based on time-frequency analysis and artificial neural networks," *Computational Intelligence and Neuroscience*, vol. 2007, 2007.
- [117] A. T. Tzallas, M. G. Tsipouras, and D. I. Fotiadis, "Epileptic seizure detection in EEGs using time-frequency analysis," *IEEE Transactions on Information Technology in Biomedicine*, vol. 13, pp. 703–710, sep 2009.
- [118] M. Fani, G. Azemi, and B. Boashash, "EEG-based automatic epilepsy diagnosis using the instantaneous frequency with sub-band energies," in *7th International Workshop on Systems, Signal Processing and their Applications, WoSSPA 2011*, pp. 187–190, 2011.
- [119] M. G. Tsipouras, "Spectral information of EEG signals with respect to epilepsy classification," *Eurasip Journal on Advances in Signal Processing*, vol. 2019, pp. 1–17, dec 2019.
- [120] X. Zhang, L. Yao, M. Dong, Z. Liu, Y. Zhang, and Y. Li, "Adversarial representation learning for robust patient-independent epileptic seizure detection," *IEEE journal of biomedical and health informatics*, vol. 24, no. 10, pp. 2852–2859, 2020.
- [121] C. Guerrero-Mosquera, A. Malanda Trigueros, J. Iriarte Franco, and Á. Navia-Vázquez, "New feature extraction approach for epileptic EEG signal detection using time-frequency distributions," *Medical & Biological Engineering & Computing*, vol. 48, pp. 321–330, apr 2010.
- [122] S. F. Liang, H. C. Wang, and W. L. Chang, "Combination of EEG complexity and spectral analysis for epilepsy diagnosis and seizure detection," *Eurasip Journal on Advances in Signal Processing*, vol. 2010, p. 15, may 2010.
- [123] N. Arunkumar, K. R. Kumar, and V. Venkataraman, "Automatic Detection of Epileptic Seizures Using New Entropy Measures," *Journal of Medical Imaging and Health Informatics*, vol. 6, pp. 724–730, jun 2016.
- [124] A. Ridouh, D. Boutana, and M. Benidir, "Comparative study of time frequency analysis application on abnormal eeg signals," in *Recent Advances in Electrical Engineering and Control Applications*, pp. 355–368, Springer, 2017.
- [125] A. Aarabi, F. Wallois, and R. Grebe, "Automated neonatal seizure detection : A multistage classification system through feature selection based on relevance and redundancy analysis," *Clinical Neurophysiology*, vol. 117, pp. 328–340, feb 2006.

- [126] J. Löfhede, M. Thordstein, N. Löfgren, A. Flisberg, M. Rosa-Zurera, I. Kjellmer, and K. Lindcrantz, "Automatic classification of background EEG activity in healthy and sick neonates," *Journal of Neural Engineering*, vol. 7, p. 016007, jan 2010.
- [127] J. Mitra, J. R. Glover, P. Y. Ktonas, A. T. Kumar, A. Mukherjee, N. B. Karayiannis, J. James D. Frost, R. A. Hrachovy, and E. M. Mizrahi, "A Multi-stage System for the Automated Detection of Epileptic Seizures in Neonatal EEG," *Journal of clinical neurophysiology : official publication of the American Electroencephalographic Society*, vol. 26, no. 4, p. 218, 2009.
- [128] L. Boubchir, S. Al-Maadeed, and A. Bouridane, "Haralick feature extraction from time-frequency images for epileptic seizure detection and classification of EEG data," *Proceedings of the International Conference on Microelectronics, ICM*, vol. 2015-March, pp. 32–35, 2014.
- [129] L. Boubchir, S. Al-Maadeed, A. Bouridane, and A. A. Cherif, "Classification of EEG signals for detection of epileptic seizure activities based on LBP descriptor of time-frequency images," *Proceedings - International Conference on Image Processing, ICIP*, vol. 2015-Decem, pp. 3758–3762, dec 2015.
- [130] S. Ramakrishnan and A. S. Muthanantha Murugavel, "Epileptic seizure detection using fuzzy-rules-based sub-band specific features and layered multi-class SVM," *Pattern Analysis and Applications*, vol. 22, pp. 1161–1176, aug 2019.
- [131] S. T. George, M. S. Subathra, N. J. Sairamya, L. Susmitha, and M. Joel Premkumar, "Classification of epileptic EEG signals using PSO based artificial neural network and tunable-Q wavelet transform," *Biocybernetics and Biomedical Engineering*, vol. Vol. 40, pp. 709–728, apr 2020.
- [132] A. Basri and M. Arif, "Classification of Seizure Types Using Random Forest Classifier," *Advances in Science and Technology. Research Journal*, vol. 15, pp. 167–178, sep 2021.
- [133] M. C. Guerrero, J. S. Parada, and H. E. Espitia, "Principal components analysis of eeg signals for epileptic patient identification," *Computation*, vol. 9, no. 12, p. 133, 2021.
- [134] Y. Yuan, K. Jia, G. Xun, and A. Zhang, "A multi-view deep learning method for epileptic seizure Detection using short-time Fourier transform," *ACM-BCB 2017 - Proceedings of the 8th ACM International Conference on Bioinformatics, Computational Biology, and Health Informatics*, pp. 213–222, aug 2017.
- [135] O. K. Cura, M. A. Ozdemir, and A. Akan, "Epileptic EEG classification using synchrosqueezing transform with machine and deep learning techniques," *European Signal Processing Conference*, vol. 2021-Janua, pp. 1210–1214, jan 2021.
- [136] M. A. Ozdemir, O. K. Cura, and A. Akan, "Epileptic EEG Classification by Using Time-Frequency Images for Deep Learning," *International Journal of Neural Systems*, vol. 31, aug 2021.
- [137] S. Khoshnoud and M. Shamsi, "Epilepsy classification framework utilizing joint time-frequency signal analysis and processing," *Applied Medical Informatics*, vol. 36, no. 2, pp. 1–8, 2015.

- [138] A. Subasi, "Automatic detection of epileptic seizure using dynamic fuzzy neural networks," *Expert Systems with Applications*, vol. 31, pp. 320–328, aug 2006.
- [139] T. Kumar Gandhi, P. Chakraborty, G. Ghosh Roy, and B. Ketan Panigrahi, "Discrete harmony search based expert model for epileptic seizure detection in electroencephalography," *Expert Systems With Applications*, vol. 39, pp. 4055–4062, 2012.
- [140] D. E. Hernández, L. Trujillo, E. Z-Flores, O. M. Villanueva, and O. Romo-Fewell, "Detecting Epilepsy in EEG Signals Using Time, Frequency and Time-Frequency Domain Features," in *Studies in Systems, Decision and Control*, vol. 143, pp. 167–182, Springer International Publishing, 2018.
- [141] E. Z-Flores, L. Trujillo, A. Sotelo, P. Legrand, and L. N. Coria, "Regularity and Matching Pursuit feature extraction for the detection of epileptic seizures," *Journal of Neuroscience Methods*, vol. 266, pp. 107–125, jun 2016.
- [142] L. Boubchir, S. Al-Maadeed, and A. Bouridane, "Effectiveness of combined time-frequency image and signal-based features for improving the detection and classification of epileptic seizure activities in EEG signals," *Proceedings - 2014 International Conference on Control, Decision and Information Technologies, CoDIT 2014*, pp. 673–678, dec 2014.
- [143] K. Das, D. Daschakladar, P. P. Roy, A. Chatterjee, and S. P. Saha, "Epileptic seizure prediction by the detection of seizure waveform from the pre-ictal phase of EEG signal," *Biomedical Signal Processing and Control*, vol. 57, p. 101720, mar 2020.
- [144] T. Tamanna, M. A. Rahman, S. Sultana, M. H. Haque, and M. Z. Parvez, "Predicting seizure onset based on time-frequency analysis of EEG signals," *Chaos, Solitons and Fractals*, vol. 145, apr 2021.
- [145] D. Cho, B. Min, J. Kim, and B. Lee, "EEG-Based Prediction of Epileptic Seizures Using Phase Synchronization Elicited from Noise-Assisted Multivariate Empirical Mode Decomposition," *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, vol. 25, pp. 1309–1318, aug 2017.
- [146] Y. Yang, N. D. Truong, C. Maher, A. Nikpour, and O. Kavehei, "Two-channel epileptic seizure detection with blended multi-time segments electroencephalography spectrogram," *IEEE SPMB 2020*, 2020.
- [147] R. Ben Messaoud and M. Chavez, "Random forest classifier for eeg-based seizure prediction," *arXiv e-prints*, pp. arXiv–2106, 2021.
- [148] Z. Zhang, Z. Chen, Y. Zhou, S. Du, Y. Zhang, T. Mei, and X. Tian, "Construction of rules for seizure prediction based on approximate entropy," *Clinical Neurophysiology*, vol. 125, pp. 1959–1966, oct 2014.
- [149] M. Lo Giudice, G. Varone, C. Ieracitano, N. Mammone, G. G. Tripodi, E. Ferlazzo, S. Gasparini, U. Aguglia, and F. C. Morabito, "Permutation Entropy-Based Interpretability of Convolutional Neural Network Models for Interictal EEG Discrimination of Subjects with Epileptic Seizures vs. Psychogenic Non-Epileptic Seizures," *Entropy 2022, Vol. 24, Page 102*, vol. 24, p. 102, jan 2022.

- [150] Y. Yang, M. Zhou, Y. Niu, C. Li, R. Cao, B. Wang, P. Yan, Y. Ma, and J. Xiang, "Epileptic Seizure Prediction Based on Permutation Entropy," *Frontiers in Computational Neuroscience*, vol. 12, p. 55, 2018.
- [151] S. T. Aung and Y. Wongsawat, "Modified-distribution entropy as the features for the detection of epileptic seizures," *Frontiers in physiology*, vol. 11, p. 607, 2020.
- [152] H. Daoud and M. A. Bayoumi, "Efficient Epileptic Seizure Prediction Based on Deep Learning," *IEEE Transactions on Biomedical Circuits and Systems*, vol. 13, pp. 804–813, oct 2019.
- [153] Z. Wang, J. Yang, H. Wu, J. Zhu, and M. Sawan, "Power efficient refined seizure prediction algorithm based on an enhanced benchmarking," *Scientific Reports 2021 11 :1*, vol. 11, pp. 1–9, dec 2021.
- [154] J. Yan, J. Li, H. Xu, Y. Yu, and T. Xu, "Seizure Prediction Based on Transformer Using Scalp Electroencephalogram," *Applied Sciences (Switzerland)*, vol. 12, may 2022.
- [155] J. R. Williamson, D. W. Bliss, D. W. Browne, and J. T. Narayanan, "Seizure prediction using EEG spatiotemporal correlation structure," *Epilepsy & Behavior*, vol. 25, pp. 230–238, oct 2012.
- [156] T. N. Alotaiby, S. A. Alshebeili, F. M. Alotaibi, and S. R. Alrshoud, "Epileptic seizure prediction using CSP and LDA for scalp EEG signals," *Computational Intelligence and Neuroscience*, vol. 2017, 2017.
- [157] Y. Park, L. Luo, K. K. Parhi, and T. Netoff, "Seizure prediction with spectral power of EEG using cost-sensitive support vector machines," *Epilepsia*, vol. 52, pp. 1761–1770, oct 2011.