

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



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

MÉMOIRE DE MASTER PROFESSIONNEL

En Informatique

Spécialité : Administration et Sécurité des Réseaux

Thème

Développement d'un outil logiciel pour la détection automatique des crises d'épilepsie sur les signaux EEG.

Présenté par : M. MENDIL Adel
M. MESSAOUDI Syphax

Devant le jury composé de :

Examinatrice :	Dr. L. HAMZA	Maître de Conf. A	U. A/Mira Béjaïa.
Examinateur :	Dr. F. KACIMI	Maître de Conf. B	ESTIN C/Amizour, Béjaïa.
Encadrant :	Dr. M. MOHAMMEDI	Maître de Conf. B	U. A/Mira Béjaïa.

Béjaïa, Octobre 2021.

** Remerciements **

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

Nous tenons tout d'abord à remercier Dr Mohamed MOHAMMEDI, pour l'honneur qu'il nous a fait en acceptant de nous encadrer. Ses conseils précieux nous ont permis une bonne orientation dans la réalisation de ce travail.

Nos vifs remerciements vont également aux membres de jury Dr Lamia HAMZA ainsi que Dr Farid KACIMI d'avoir accepté d'évaluer notre travail.

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

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

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

✱ *Dédicaces* ✱

Je dédie ce modeste travail :

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

À notre encadreur Docteur MOHAMMEDI Mohamed qui nous a vraiment motivé
et guidé tout au long de notre travail,

À tous mes frères, mon cousin, et mes amis avec qui j'ai eu de nombreuses et enrichissantes
conversations qui m'ont permis d'élargir l'horizon de cette recherche,

À tous ceux qui m'ont aidé de près ou de loin.

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

À tous ceux qui travaillent pour que cette nation soit meilleure.

ℳ. *MESSAOUDI Sypfax*

※ *Dédicaces* ※

Je dédie ce modeste travail :

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

À notre encadreur Docteur MOHAMMEDI Mohamed qui nous a vraiment motivé
et guidé tout au long de notre travail,

À ma fiancée qui ma vraiment motivé, poussé à travailler et donner de mon meilleur,

À mes frère, mes sœurs,

À tous mes amis, surtout Nourdine et Mouhand avec qui j'ai eu de nombreuses et
enrichissantes conversations qui m'ont permis d'élargir l'horizon de cette recherche,

À tous ceux qui m'ont aidé de près ou de loin,

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

À tous ceux qui travaillent pour que cette nation soit meilleure.

ℳ. *MENDIL Adel*

TABLE DES MATIÈRES

Table des Matières	i
Liste des tableaux	iv
Liste des figures	v
Liste des acronymes	vi
Introduction générale	1
1 Pré-requis théoriques	4
1.1 Introduction	4
1.2 Notions générales sur l'épilepsie	5
1.2.1 Définition	5
1.2.2 Classification des crises épileptiques	5
1.2.3 Causes et symptômes	6
1.2.4 Traitement	7
1.3 L'épilepsie chez les enfants	7
1.3.1 Reconnaître les crises	7
1.3.2 Causes et symptômes	8
1.3.3 Diagnostic	8
1.3.4 Traitement	9
1.4 Pourquoi les enfants?	9
1.5 L'EEG de surface et les crises d'épilepsie	10
1.5.1 Modalité d'enregistrement	10
1.5.2 Type des montages	11

1.5.3	Bandes de fréquences principales des signaux EEG	12
1.5.4	Activités paroxystiques élémentaires	12
1.5.5	Les Perturbations de l'EEG	13
1.6	Structure générale d'un système de détection des crises d'épilepsie dans les signaux EEG	14
1.6.1	Acquisition du signal	14
1.6.2	Prétraitement du signal	14
1.6.3	Extraction de caractéristiques	15
1.6.4	Classification	15
1.7	Conclusion	15
2	État de l'art sur les systèmes de détection des crises d'épilepsie	16
2.1	Introduction	16
2.2	Critères d'évaluation des approches existantes	17
2.2.1	Sensibilité	17
2.2.2	Spécificité	17
2.2.3	Taux de faux négatif	17
2.2.4	Taux de faux positif	18
2.2.5	Exactitude	18
2.3	Taxonomie des travaux examinés	18
2.4	Travaux antérieurs	19
2.4.1	Solutions basées sur deep Learning	19
2.4.2	Solutions basées sur le traitement d'image	20
2.4.3	Solutions basées sur machine Learning	21
2.5	Étude comparative	22
2.6	Synthèse	24
2.7	Conclusion	24
3	CLOUD BASED AUTOMATIC EPILEPTIC SEIZURE DETECTION SYSTEM	26
3.1	Introduction	26
3.2	Motivation	26
3.3	Modèle du système	27
3.4	Notre contribution	29
3.4.1	Acquisition des données EEG	31
3.4.2	Prétraitement	31
3.4.3	Extraction de caractéristiques	33
3.4.4	Classification	34

3.5	Conclusion	35
4	Simulation et évaluation de performances	36
4.1	Introduction	36
4.2	Description de la Base de données EEG	36
4.3	Environnement de simulation	37
4.3.1	Paramètre de simulation	37
4.3.2	Matrice de confusion	38
4.3.3	La courbe ROC	38
4.3.4	Métriques de simulation	39
4.4	Résultats et Discussion	39
4.5	Conclusion	45
	Conclusion générale et perspectives	46
	Bibliographie	48

LISTE DES TABLEAUX

1.1	Principaux rythmes d'un EEG [24].	12
2.1	Étude comparative des différents systèmes analysés.	23
4.1	L'âge des participants à l'expérience.	37
4.2	Matrice de confusion.	38
4.3	Métriques d'évaluation calculées à partir de la matrice de confusion.	40
4.4	Une étude comparative des résultats obtenus par des systèmes de détection des crises d'épilepsies basées sur le signal EEG.	44

TABLE DES FIGURES

1.1	Les crises généralisées et partielles.	6
1.2	Montage 10/20.	10
1.3	Méthodologies d'acquisition du signal.	14
2.1	Classification des systèmes de détection des crises d'épilepsie étudiées.	19
3.1	La position du canal (C3-P3) dans le cerveau humain.	27
3.2	Modèle de système de détection automatique des crises épileptiques basé sur le Cloud.	28
3.3	Organigramme de détection des crises d'épilepsie.	30
4.1	La courbe ROC [13].	39
4.2	La matrice de confusion montrant les différentes prévisions et résultats des tests effectués avec le classificateur SVM.	40
4.3	La courbe ROC avec le classificateur SVM.	41
4.4	Nuages de points avec le classificateur SVM.	42

LISTE DES ACRONYMES

A	AAR	Adaptatifs Auto-régressifs.
	ANN	Artificial Neural Networks.
	AUC	Aire Sous la Courbe.
	AVC	Accident Vasculaire Cérébral.
B	BCI	Brain Computer Interface.
C	CAR	Common Average Referencing.
	CHB	Children's Hospital Boston.
	CNN	Convolutional Neural Network.
	CNGP	Closed Neighbourhood Gradient Pattern.
	CSP	Common Spatial schemes.
	CSSD	Sous-espace Spatial Commun Décomposition.
	CSSP	Common Space-Space models.
	CTP	Combined Texture Pattern.
D	DB4	Daubechies 4.
	DCT	Discrete Cosine Transform.
	DWT	Discrete Wavelet Transform.

E	EDADC	Event-Driven Analog Digital Converter .
	EDF	European data format.
	EEG	Electroencéphalogramme.
	EPCT	Epilepsie Pointes Centro-Temporales.
	EPR	Epilepsie Paroxysmes Rolandiques.
F	FAR	False Acceptance Rate.
	FN	faux négatifs.
	FND	False Negative Detections.
	FP	faux positifs.
	FPD	False Positive Detections.
	FPR	False Positive Rate.
	FRR	False Rejection rate.
G	GA	Genetic Algorithms.
H	Hz	Hertz.
I	ICA	Independent Component Analysis.
	IoT	Internet of Things.
	IRMf	Imagerie par Résonance Magnétique Fonctionnelle.
K	KNN	k-Nearest Neighbors.
L	LAT	Local Average Technique.
	LS-SVM	Least-Squares Support-Vector Machines.
M	MEG	Magnéto-encéphalographie.
	MIT	Massachusetts Institute of Technology.
	MMV	Mean Magnitude Value.
N	NIRS	Near Infrared Spectroscopie.
P	P.Ex	Par Exemple.
	PCA	Principal Component Analysis.
R	ROC	Receiver Operating Characteristic.

	RPR	Relative Power.
S	SL	Surface Laplacien.
	SVD	Single Value Decomposition.
	SVM	Support Vector Machine.
	FFFS	Sequential Forward Floating Selection.
T	TEP	Position Emission Tomography.
	TFP	Taux de faux positif.
	TWSVM	Twin Support Vector Machine.
V	VN	Vrai Négatif.
	VND	Vrai Négatif Détections.
	VP	Vrai Positif.
	VPD	Vrai Positif Détections.
W	WPD	Decomposition of Wavelet Packets.
	WT	Wavelet Transformations.

INTRODUCTION GÉNÉRALE

L'épilepsie est une maladie neurologique caractérisée par des changements soudains et anormaux du comportement du cerveau d'un individu. Ces crises se manifestent sous plusieurs formes, dont des convulsions et des pertes de mémoire. Dans le monde, environ 50 millions de personnes en sont atteintes, ce qui en fait l'une des affections neurologiques les plus fréquentes. De plus le risque de décès prématuré chez les personnes atteintes de cette maladie est près de trois fois plus élevé que dans la population générale [16]. Ce qui laisse les victimes de cette maladie dans une peur constante et leur entourage dans une inquiétude permanente. Pour venir en aide à cette population touchée, la maladie n'a cessé d'être l'objet de recherches dans tous les domaines, aussi bien médicaux que dans le domaine de la statistique et des mathématiques, et plus récemment dans le domaine informatique.

Une grande partie de ces recherches est consacrée à l'identification des causes de cette maladie, et selon une étude 40% des cas détectés sont des facteurs génétiques [17], ce qui fait d'elles le problème le plus important auquel les chercheurs devront répondre afin d'améliorer les traitements proposés aux patients et d'apporter de nouvelles solutions. D'autres causes ont été identifiées comme les causes structurales, métaboliques, inflammatoires. L'origine de certains cas épileptiques reste encore inconnue.

Avant de commencer à travailler sur ce projet, nous avons consultés l'avis des neurologues, des articles publiés, des résultats de certaines recherches effectuées sur cette maladie, et nous avons pu constater qu'il est préférable d'essayer de détecter ces crises chez les enfants en vue des répercussions sévères qu'elles peuvent avoir sur le développement normal de l'enfant, mais aussi parce qu'elles sont plus récurrentes chez eux, ce qui signifie qu'il est plus facile de travailler sur leur cas et de mieux connaître ces crises. Ces conclusions nous les avons eu grâce à des imageries nucléaires, qui nous indiquent que le cerveau humain atteint une activité extrêmement importante à l'enfance, et elle diminue à travers le temps, c'est la phase de son développement, et l'une des grandes originalités des épilepsies de l'enfant est qu'elles surviennent sur un cerveau en plein

développement, parce qu'il existe de nombreuses relations entre cette maladie et la maturation cérébrale. De plus, un enfant reste inconscient des dangers de sa maladie, mais aussi incapable de se protéger, d'où l'intérêt d'un appareil qui alerta son entourage (parent, médecin, etc. . .) en cas de crise.

Depuis des années les recherches n'ont jamais arrêté, et de nombreuses méthodes ont été exploitées afin de trouver des solutions à cette maladie. Avant le développement de la technologie, les médecins utilisent des données cliniques pour diagnostiquer la personne comme étant épileptique ou pas. Avec l'apparition de la technologie, les médecins ont pu compter sur l'aide des données anatomiques et fonctionnelles acquises grâce à des modalités d'imagerie cérébrale (Scanner cérébral, IRMf, TEP), les résultats de ces données sont complémentaires, elles offrent un meilleur diagnostic. Aujourd'hui, le moyen le plus utilisé c'est l'Electroencéphalographie (EEG), elle est considérée comme étant la méthode la plus sûre et indolore qui enregistre l'activité électrique du cerveau. Découverte en 1920 par le neurologue allemand Hans Berger, elle devient en 1950 la technique la plus couramment utilisée, elle offre une bonne résolution temporelle en plus d'être peu coûteuse et non invasive. L'EEG fournit des enregistrements électroencéphalogramme que les médecins pourront examiner à la recherche de preuve de décharges électriques anormales, mais, en raison du temps limité de l'enregistrement, l'EEG peut aussi ne pas en dépister, et l'électroencéphalogramme peut être normal alors que le patient souffre bien d'épilepsie, ce qui conduit forcément à des erreurs lors de l'analyse visuelle. Néanmoins ces ratés restent faibles et peuvent être détectés en répétant les tests.

Ces solutions restent utiles mais pas suffisantes pour l'amélioration de la vie quotidienne des épileptiques, d'où l'introduction des systèmes de détection et de prédiction des crises, leur rôle est d'alerter les patients d'une éventuelle crise un temps avant sa production, ces méthodes utilisent des analyses en temps réel, décryptent les enregistrements électroencéphalogrammes, ainsi que les bandes de fréquences, En se basant sur plusieurs systèmes de détection des crises déjà proposés. Afin d'obtenir des résultats fiables, et efficace en terme de temps de réponse du système par rapport à une crise, le choix des bandes de fréquences à étudier est primordial, il en existe cinq rythmes, et d'après nos recherches et renseignements auprès des pédiatres et neurologues, nous avons défini deux rythmes de fréquences qui caractérisent un départ de crise :

- La décharge rythmique Thêta qui est très facilement reconnaissable par son activité rythmique généralement d'assez grande amplitude par rapport à l'activité de fond.
- La décharge rythmique Alpha est caractérisée par l'état de veille calme, (yeux fermés et repos physiologique et mental), c'est-à-dire que les ondes Alpha sont typiquement présentes lorsqu'un individu est en état de relaxation ou de méditation. Il peut avoir les yeux fermés mais rester attentif aux stimuli extérieurs.

Nous proposons ici une approche résolument orientée sur l'étude des épileptiques afin de détecter les crises à partir d'informations physiologiques (liées à l'activité cérébrale). Le but de ce travail consiste à développer un système de détection de crise en temps réel chez les

victimes de cette maladie à partir de données électroencéphalographiques (décrivant l'activité cérébrale). Cette approche est motivée par le fait que les pédiatres et les neurologues travaillent essentiellement à partir des données cérébrales pour détecter des éventuelles crises. Pour la collecte des signaux cérébraux, un casque sans fil sera utilisé. Cela va assurer la portabilité de notre système, ainsi que le confort du patient.

Le reste de ce document présentera le travail effectué afin d'élaborer un système de détection automatique de crise d'épilepsie chez les enfants à partir des données électroencéphalographiques. Il est organisé en quatre chapitres comme suite :

Chapitre 1 : "Pré-requis théoriques" : Nous abordant ce mémoire avec un premier chapitre Le cadre général du sujet et la problématique médicale (définition, classification, traitement. . .), et les notions de l'épilepsie chez les enfants ainsi que les raisons de notre choix d'étudier la maladie chez cette catégorie. Ensuite, la structure générale d'un système de détection des crises d'épilepsie grâce aux signaux EEG sera évoqué, avec l'essentiel à connaître sur leurs modes de fonctionnement.

Chapitre 2 : "Etat de l'art sur les systèmes de détection des crises épilepsie" : Nous discuterons certains travaux de recherche concernant la détection des crises d'épilepsies, une comparaison de différentes approches par rapport à leurs techniques de détections est ensuite présentée pour mettre en évidence leurs points forts et points faibles en termes de fiabilité, d'efficacité, d'exactitude, ainsi que du faux rejet et fausse acceptation. Puis, nous donnerons une classification des travaux déjà proposés.

Chapitre 3 : "Automatic Epileptic Seizure Detection in EEG Signals" : dans ce chapitre nous présenterons notre contribution pour la détection des crises d'épilepsies à partir des signaux EEG, en détaillant les différentes phases par lesquelles notre protocole passe pour assurer une détection de crises rapide et efficace.

Chapitre 4 : "Simulation et évaluation de performances" :

Dans ce dernier chapitre, nous allons présenter les résultats de notre travail, ainsi qu'une étude comparative de nos résultats avec certaines d'autres recherches. Nous allons terminer ce travail par une conclusion générale.

CHAPITRE 1

PRÉ-REQUIS THÉORIQUES

1.1 Introduction

L'épilepsie est une maladie chronique caractérisée par la répétition de crises épileptiques. La prévalence de l'épilepsie est stable dans le monde et se situe entre 0.5% et 0.8% de la population. L'Algérie compte 400 000 cas d'épilepsie. Selon le professeur Mustapha Sadibelouiz, président de la société algérienne de neurologie et président de la ligue algérienne contre l'épilepsie (2016). Depuis 1981 existe une classification des crises épileptiques qui distingue trois groupes principaux de crises sur la concordance des critères cliniques et EEG, et depuis 1989 une classification des syndromes épileptiques et des épilepsies, permet le regroupement de symptômes et signes apparaissant ensemble d'une manière constante et non fortuite. Les données de l'EEG sont capitales dans cette classification. C'est l'examen le plus performant pour diagnostiquer une épilepsie. Il permet de voir des ondes, ou grapho-éléments, c'est-à-dire à distance d'une crise, et souvent d'enregistrer des crises. Dans la première section de ce chapitre, des notions générales sur l'épilepsie sont rassemblées, dans la deuxième et troisième section, une revue des crises chez les enfants, ainsi que les raisons de notre choix de recherche sur les enfants. Comme ce travail de recherche est consacré au traitement du signal EEG, une description générale sur l'EEG de surface et les crises d'épilepsie est donnée. La dernière partie de ce chapitre expose la structure générale d'un système de détection des crises d'épilepsie dans les signaux EEG. Enfin, une conclusion résumera tous les points cités ci-dessus.

1.2 Notions générales sur l'épilepsie

1.2.1 Définition

Le terme d'épilepsie recouvre plusieurs maladies neurologiques ayant pour point commun la répétition de crises épileptiques spontanées [2]. L'épilepsie est une maladie neurologique qui se caractérise par un fonctionnement anormal de l'activité du cerveau. Elle se traduit par la répétition de crises imprévisibles et souvent très brèves. Elles peuvent avoir lieu soit dans une zone précise du cerveau, soit dans son ensemble. Les crises doivent se répéter pour dire qu'il s'agit d'épilepsie. Ainsi, avoir eu une seule crise de convulsions dans sa vie ne signifie pas que l'on soit épileptique. Une crise survient lorsqu'il y a une activité neuronale anormale. Durant la crise, les neurones s'activent pouvant générer jusqu'à 6 fois plus d'impulsions par seconde qu'en temps normal. Ces crises peuvent prendre différentes formes et varier en intensité [4][1][2][3]. Ces influx nerveux anormaux peuvent se mesurer durant un électro-encéphalogramme (EEG), un examen qui permet d'enregistrer l'activité cérébrale [3].

1.2.2 Classification des crises épileptiques

la classification des épilepsies ne doit pas être seulement pertinente et dynamique selon les changements de pensée, mais aussi robuste et applicable dans toutes les régions du globe. Son but principal est de contribuer au diagnostic des patients, mais elle est également cruciale pour la recherche dans le domaine de l'épilepsie, le développement des thérapies antiépileptiques et la communication entre les professionnels partout dans le monde. Les crises épileptiques sont classées en fonction de la localisation initiale de la décharge épileptique.

Les crises généralisées

L'épilepsie généralisée est caractérisée par des crises épileptiques généralisées (différentes des crises épileptiques partielles). Parmi les crises d'épilepsie généralisées, la plus connue est la crise généralisée tonico-clonique [7]. On peut la diviser en différentes formes :

- **Les crises tonico-cloniques (grand mal)** : La victime perd conscience, ces muscles se raidissent et elle est prise de mouvements incontrôlés.
- **Les crises myocloniques** : se caractérisent par des mouvements des bras et des jambes.
- **Les crises d'absence (petit mal)** : plus communes chez les enfants, elles constituent une perte de contact avec l'extérieur pendant une dizaine de secondes à quelques minutes.
- **Les crises atoniques** : perte de tonus pouvant renverser le patient par terre.

Les crises partielles (ou focales)

C'est une forme de décharges paroxystiques qui se concentre sur une région corticale limitée. La crise partielle peut s'étendre sur d'autres régions du cortex. Une propagation secondaire peut avoir lieu et entraîner des épisodes tonico-cloniques. Il existe aussi des crises simples sans aucune modification de la conscience et des complexes avec altération de la conscience [24].

- **Crises partielles simples** : qui s'étendent sur une ou plusieurs régions du même hémisphère du cortex comme le montre la Figure 1.1. Dans ce cas, le malade ne passe pas par une altération de conscience [36].
- **Crises partielles complexes** : qui s'étendent sur les deux hémisphères du cortex. Cette crise est accompagnée d'une altération de conscience. Dans ce cas on observe une perte de conscience [36].

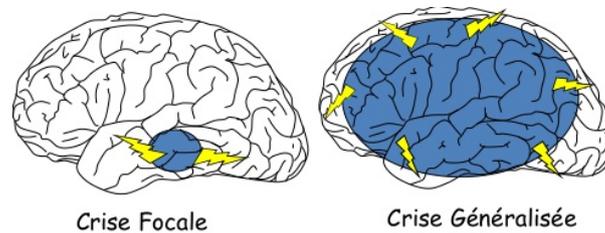


FIGURE 1.1 – Les crises généralisées et partielles.

1.2.3 Causes et symptômes

Les causes de cette maladie peuvent-être :

- Familiales (antécédents familiaux)
- Une tumeur au cerveau
- L'alcoolisme
- Un AVC (Accident Vasculaire Cérébral)
- Une intoxication
- La séquelle d'un traumatisme
- Fièvre élevée chez les jeunes enfants (+ 38,5°)

Les symptômes de cette maladie peuvent-être :

- Absence (maximum 20 minutes)
- Trouble des 5 sens (visuels, auditifs, olfactifs, gustatifs, vertige)
- Des périodes de perte de conscience ou de conscience altérée. Parfois, les yeux restent ouverts, avec un regard fixe.
- Chute brutale de la personne sans raison apparente

- Dans certains cas, des convulsions : des contractions musculaires prolongées et involontaires des bras et des jambes.
- Une respiration bruyante.
- La personne devient effrayée sans raison apparente, elle peut même paniquer ou se mettre en colère.

1.2.4 Traitement

A l'heure actuelle, pour soigner les patients épileptiques, le traitement est d'abord médicamenteux. En cas d'échec de ce traitement, un traitement chirurgical est proposé.

Traitement Pharmacologique

Les médicaments utilisés pour traiter l'épilepsie sont souvent des drogues qui agissent directement sur les mécanismes neuronaux déclenchant les crises. Ces médicaments anti épileptiques permettent de traiter avec succès jusqu'à 70% des enfants et des adultes (c'est-à-dire pouvant obtenir la disparition complète des crises).

Les traitements chirurgicaux

Contrairement au traitement pharmaceutique, le traitement chirurgical de l'épilepsie agit directement sur la zone épileptogène. En effet, dans le cadre des épilepsies partielles généralement dues à des lésions focales, l'exérèse des tissus impliqués dans la génération des crises et de ses voies de propagation immédiate permet souvent de supprimer les crises. Une telle opération n'est toutefois envisagée que si le risque de morbidité est faible et que le patient subit un déficit fonctionnel acceptable. Pour d'autres types d'épilepsie, comme les généralisées, une opération peut aussi être envisagée, mais ces opérations sont alors beaucoup plus lourdes, car elles consistent en la résection partielle ou totale du corps calleux (canaux de communication entre les hémisphères gauche et droit). Ce type d'opération n'est envisagé que dans les cas d'épilepsie généralisée très graves. Après une opération, 60%-70% des patients ne font plus de crises, bien que dans certains cas cette rémission peut intervenir jusqu'à 2 ans après l'opération [33].

1.3 L'épilepsie chez les enfants

1.3.1 Reconnaître les crises

L'épilepsie est une maladie chronique fréquente chez l'enfant. Elle se caractérise par la survenue plus ou moins fréquente et imprévisible de crises qui peuvent durer de quelques secondes à plusieurs minutes. Les crises peuvent se manifester sous différentes formes : absences, convulsions, pertes de connaissance [20]. Comme chez les adultes, on distingue des formes partielles et des

formes généralisées. Chacune de ces deux formes d'épilepsie est elle-même divisée en formes dites « idiopathiques » et en formes dites « non idiopathiques ». De plus, il existe d'autres formes d'épilepsie regroupées sous le terme de « syndromes épileptiques ». À chaque syndrome correspond un certain type de crises, d'anomalies de l'électroencéphalogramme, d'âge d'apparition et, souvent, une même réponse aux traitements et une même évolution [19]. Les épilepsies sont classées en fonction de la cause qui les a provoquées.

1.3.2 Causes et symptômes

Causes

La ligue internationale contre l'épilepsie distingue actuellement quatre grandes causes à cette maladie :

- Les causes génétiques, qui sont les plus fréquentes.
- Les causes structurales, qui sont liées à une anomalie acquise ou constitutionnelle du cortex cérébral.
- Les causes métaboliques.
- Les causes inconnues.

Certaines épilepsies ont certainement des causes inflammatoires [39].

Symptômes

L'épilepsie est marquée par la répétition plus ou moins fréquente et imprévisible de crises qui peuvent provoquer :

- Les crises tonico-cloniques sont les plus impressionnantes. Elles se caractérisent par des contractions intenses de tous les muscles, associées à des convulsions qui peuvent durer plusieurs minutes.
- Les absences sont des crises sans convulsions qui durent quelques secondes. Durant la crise, l'enfant n'est pas conscient il n'interagit pas avec l'entourage. Cette forme de crise est l'une des plus fréquentes chez l'enfant.
- Plusieurs autres formes de crises existent et les symptômes des crises focales sont souvent plus discrets [20].

1.3.3 Diagnostic

Le diagnostic est réalisé après un bilan approfondi par le neuro-pédiatre. Il comprend de façon systématique un électro-encéphalogramme (EEG). L'EEG est un examen indolore qui mesure l'activité du cerveau, via des électrodes posées sur le cuir chevelu. L'imagerie (IRM, tomographie, etc.) permet notamment d'identifier d'éventuelles lésions du cerveau. Définir la forme de la crise épileptique (généralisée ou focale), un interrogatoire de l'entourage et des témoins de la crise est

nécessaire afin d'obtenir des informations essentielles qui vont permettre la classification de la crise [20].

1.3.4 Traitement

Le traitement médicamenteux comporte un traitement de fond quotidien dont l'objectif est de limiter la survenue des crises. Près de 70% des épilepsies sont sensibles aux traitements. La règle générale, lors de la mise en place d'un traitement, est de choisir celui qui a le plus de chance de contrôler l'épilepsie, qui est le mieux toléré, et, chez l'enfant, celui pour lequel le recul est important. Parmi ces traitements on trouve :

- L'éthosuximide utilisé pour l'épilepsie absence de l'enfant.
- Épilepsie à pointes centrotemporales (EPR ou EPCT).
- Épilepsies focales non idiopathiques. Le syndrome de West [39].

1.4 Pourquoi les enfants ?

L'épilepsie est la première maladie neurologique chez l'enfant. Elle est un problème de santé publique au même titre que l'asthme ou le diabète. On compte environ 4000 nouveaux cas d'enfants de moins de dix ans par an. Mais tous les cas n'ont pas la même gravité et n'auront pas le même retentissement sur le cerveau. Certains cas bénins ayant reçu un traitement approprié ne laisseront aucune trace par la suite. D'autres, la moitié environ, peuvent avoir des répercussions sévères sur le développement normal de l'enfant. Pour cause l'une des grandes originalités des épilepsies de l'enfant est qu'elles surviennent sur un cerveau en plein développement. Ce n'est pas le hasard. Il existe en effet de nombreuses relations entre cette maladie et la maturation cérébrale. Car l'immaturation des réseaux neuronaux et leur hyperexcitabilité favorisent l'apparition de l'épilepsie, elles en modifient l'expression, la sévérité, la réponse aux médicaments. Mais inversement l'épilepsie, elle aussi, peut avoir un impact sur le développement cérébral ultérieur et modifier la maturation des réseaux neuronaux. On sait grâce à l'imagerie nucléaire que le cerveau de l'enfant connaît une activité extrêmement importante dans les deux premières années de la vie avec un débit sanguin très élevé, puis, que cette activité passe par un plateau jusque vers huit ans pour diminuer ensuite et atteindre la valeur adulte vers dix-huit ans. Cette dernière reste stable ensuite jusqu'à 60 ans. C'est au cours de ces périodes, dites " périodes critiques ", que les crises peuvent induire des remaniements anormaux dans les réseaux neuronaux et contrecarrer le développement normal de l'enfant. Il faut bien comprendre en effet que ce développement fonctionnel des réseaux cérébraux sert avant tout à la mise en place, au développement et à la bonne marche des différentes fonctions correspondantes, qu'elles soient motrices, sensorielles ou cognitives [20].

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

L'EEG est un examen clinique non invasif. C'est le moyen le plus utilisé pour mettre en évidence l'activité électrique du cerveau, donc l'activité épileptique proprement dite. Comparé aux autres techniques d'investigation, l'EEG fournit des informations en temps réel et avec une très bonne résolution temporelle, de l'ordre de la milliseconde. Il demeure incontournable pour le diagnostic et la classification des épilepsies. L'EEG rassemble les potentiels électriques sur un appareil qui amplifie les signaux et les transcrit pour qu'ils puissent être analysés. Ces signaux sont recueillis grâce à des électrodes posées suivant une norme internationale sur le cuir chevelu et le visage.

1.5.1 Modalité d'enregistrement

L'EEG peut être adapté à chaque patient selon le premier diagnostic du médecin. Les parents sont alors sollicités pour fournir le maximum de précisions sur les crises d'épilepsie ou les troubles passés afin de désigner l'examen le plus adapté. Les différentes modalités de l'EEG sont : l'EEG dit standard, l'EEG avec vidéo de courte durée ou de 24 heures, l'Holter-EEG [36].

L'EEG standard : Montage 10/20

L'EEG standard est généralement réalisé par un technicien chez un neurologue dans un cadre hospitalier. Un casque souple est reposé sur la tête du patient pour y fixer entre 15 et 32 électrodes enduites d'une pâte conductrice. Le montage 10/20 comprend en routine 21 électrodes présentées dans la Figure 1.2. Fp = Fronto-polaire; F = Frontale; T = Temporale; C = Centrale; P = Pariétale; O = Occipitale. Par convention internationale, les chiffres pairs désignent la partie droite du cortex, les chiffres impairs désignent la gauche et la lettre z désigne la ligne médiane (Nasion-Anion).

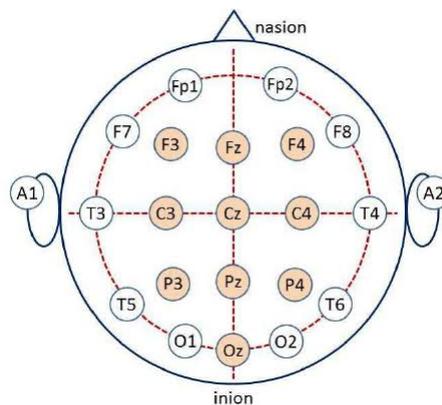


FIGURE 1.2 – Montage 10/20.

Le vidéo-EEG

Il s'agit d'un enregistrement EEG couplé à un enregistrement vidéo. Une caméra vidéo est installée et enregistre votre attitude du patient, en même temps que votre EEG [33]. Le vidéo-EEG peut être prolongé sur une durée d'une heure répétée plusieurs fois par jour à 24 heures

Le Holter-EEG (Montage ambulatoire)

L'EEG en ambulatoire est un enregistrement prolongé de l'EEG sur un enregistreur portable (comme le holter cardiaque). L'EEG est enregistré au moyen de petits capteurs (électrodes) collés sur le cuir chevelu à des endroits précis et reliés par des câbles au boîtier enregistreur [25].

1.5.2 Type des montages

Les montages de l'EEG sont standardisés afin de permettre une meilleure communication entre les différents laboratoires. Un montage vise à couvrir de façon parfaitement symétrique la surface du scalp.

Montage à référence commune

L'EEG mesure la différence de potentiel recueilli entre une électrode active et une référence commune. La référence peut être céphalique comme la Cz et le Fz ou non céphalique comme l'oreille, le nez ou le menton. Une électrode dite électrode terre doit être placée à une distance du scalp, par exemple les épaules. Certains systèmes utilisent la même électrode comme terre et comme référence.

Montage à référence moyenne

La référence moyenne est la somme de l'activité de toutes les voies d'enregistrement divisée par le nombre de voies. Ce montage n'est possible qu'avec un grand nombre d'électrodes.

Montage bipolaire

L'EEG, dans ce cas, enregistre la différence de potentiel entre deux électrodes actives placées sur la surface corticale. Une troisième électrode supplémentaire, dite électrode de masse, est nécessaire pour obtenir une tension différentielle. La configuration minimale pour le canal mono mesure EEG se compose d'une électrode active, une électrode de référence et une électrode de masse. Pour une couverture maximale des zones cérébrales, cette configuration peut fournir 256 chaînes EEG [36].

1.5.3 Bandes de fréquences principales des signaux EEG

Les rythmes cérébraux sont des signaux spontanés, c'est-à-dire qu'ils ne sont pas induits par une stimulation externe. Ces rythmes sont utilisés en neurosciences cognitives afin de classifier les patrons de sommeil, d'identifier des patrons d'activité neuronale atypiques associés à des pathologies (P. Ex. épilepsie, tumeurs cervicales) ou bien à des états de conscience et de vigilance [31]. Les activités électriques cérébrales rythmiques sont classées selon leur fréquence (voir la Table 4.4)

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

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

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

1.5.4 Activités paroxystiques élémentaires

Les activités paroxystiques sont différentes des activités épileptiques. Se sont des anomalies présentes dans l'EEG. Les experts doivent signaler si le patient présente des manifestations cliniques associées à ces anomalies [36]. Électriquement, ces activités paroxystiques sont :

- **L'onde** : elle correspond à toute différence de potentiel entre deux électrodes qui de traduit par un paroxysme EEG [36].
- **La pointe** : paroxysme EEG de brève durée (20 à 70 ms) [36].

- **La pointe lente (onde aigu) :** pointe de grande amplitude d'une durée comprise entre 70 ms et 200 ms ayant ainsi un aspect moins aigu qu'une pointe [36].
 - **Les pointes-ondes :** pointe suivies d'une onde lente de même polarité. Suivant le nombre de cycle (c) par seconde (s) des paroxysmes. On distingue les pontes-onde lentes qui sont à 2.5 c/s ou moins, les pointes-ondes à 3 c/s et les pointes-ondes rapides à 4 c/s [36].
 - **Les poly-pointes :** succession de deux ou plusieurs pointes [36].
 - Les poly-pointes ondes : succession de pointes suivies immédiatement d'une onde lente [36].
 - **L'onde-triphasique :** c'est une onde lente composée d'un ensemble de trois composantes : une composante négative de faible amplitude, une composante positives de grande amplitude et une composante négative de plus faible amplitudes [36].
- L'absence des anomalies EEG typiques ne signifie pas que le diagnostic ne sera pas établi. En revanche elle permette de l'orienter [36].

1.5.5 Les Perturbations de l'EEG

Les signaux EEG recueillis en surface résultent de la sommation de deux types de signaux : d'une part, les signaux électriques cérébraux générés par les populations neuronales en profondeur. D'autre part, les signaux extra-cérébraux appelés artefacts. Ces derniers, souvent d'une énergie importante, peuvent perturber le signal original et détériorer la qualité de l'analyse. Les perturbations détectées sur l'EEG sont classées en deux catégories.

Les bruits

Les bruits sont des signaux aléatoires stationnaires non informatifs affectant les signaux EEG. Ils résultent des instruments de mesures et le l'environnement (interaction électromagnétique).

Les artefacts

Les artefacts sont les signaux d'origines non cérébrales. ils peuvent avoir principalement trois origines (oculaire, musculaire, et mécanique) [18].

- **Les clignements oculaires :** Les clignements des yeux forment un signal lent ($< 4\text{Hz}$) qui correspond à un potentiel électrique généré par le mouvement de l'œil et de la paupière.
- **Les mouvements oculaires :** Les mouvements des yeux forment également un signal lent ($< 4\text{Hz}$) qui correspond au mouvement mécanique des yeux.
- **Les artefacts musculaires :** L'activité musculaire donne des signaux hautes fréquences ($> 13\text{Hz}$), en grande partie supérieur à l'activité EEG mesurable.
- **Les artefacts d'électrode :** Il arrive que des mouvements d'un fil ou d'une électrode créé un artefact basse fréquence ($< 2\text{Hz}$) sur une électrode.

1.6 Structure générale d'un système de détection des crises d'épilepsie dans les signaux EEG

Le BCI peut être classé en trois groupes principaux (Invasif, semi-invasif, non invasif). La classification dépend de la façon dont le signal électrique est obtenu à partir des cellules neuronales dans le cerveau humain [21]. La plupart des pays asiatiques préfèrent l'essence des systèmes BCI non invasives en raison de leur prix abordable et la flexibilité dans la capture des signaux du cerveau [22]. Un système BCI est composé de quatre phases. Qui sont Acquisition du signal, prétraitement du signal, classification du signal et interaction avec l'ordinateur.

1.6.1 Acquisition du signal

L'acquisition des signaux cérébraux est réalisée en utilisant diverses méthodes non invasives comme Electroencéphalographie (EEG), imagerie par résonance magnétique fonctionnelle (IRMf), spectroscopie proche infrarouge (NIRS) et, Magnéto-encéphalographie (MEG) (voir la Figure 1.3).

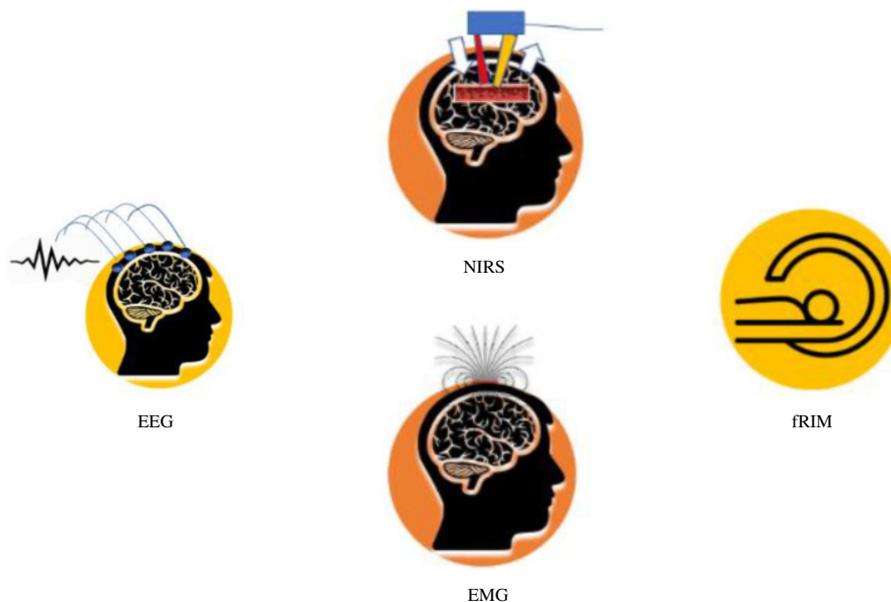


FIGURE 1.3 – Méthodologies d'acquisition du signal.

1.6.2 Prétraitement du signal

Après la phase d'acquisition, les signaux doivent être prétraités et améliorés. En général, les signaux cérébraux acquis sont contaminés par le bruit et les artefacts. Donc, l'élimination de

ces derniers peut se faire en utilisant le référencement moyen en commun (CAR), la Surface Laplacien (SL), Analyse en composantes indépendantes (ICA), Schémas Spatiaux Communs (CSP), Analyse en Composantes Principales (PCA), Décomposition à Valeur Unique (SVD), Modèles Spatio-Spatiaux Communs (CSSP), Normalisation de Fréquence (Freq-Norm), Technique de Moyenne Locale (LAT), Filtrage Kalman Robuste, Décomposition Sous-espace Spatial Communs (CSSD), etc. Les méthodes les plus fréquemment utilisées sont l'ICA, le CAR, le SL, le PCA, le CSP et le filtrage adaptatif [23].

1.6.3 Extraction de caractéristiques

Après avoir obtenu les signaux sans bruit de la phase d'amélioration du signal, les caractéristiques essentielles des signaux du cerveau ont été extraits. Pour l'extraction des caractéristiques des signaux EEG, On peut utiliser des méthodes telles que les paramètres autorégressifs adaptatifs (AAR), AAR bilinéaire, AAR multi variée, Transformations de Fourier rapides (FFT), PCA, ICA, Algorithmes génétiques (GA), ondelettes Transformations (WT), Décomposition de paquets d'ondelettes (WPD) , Parmi celles-ci, ICA, PCA, WT, AR, WPD, Les FFT sont les plus utilisés [37].

1.6.4 Classification

Après l'extraction des caractéristiques, les signaux sont classés en différentes classes à l'aide de divers classificateurs. Les différents types de classificateurs comprennent les classificateurs linéaires, les classificateurs basés sur les réseaux neuronaux artificiels (ANN), les classificateurs bayésiens non linéaires et les classificateurs du plus proche voisin. Parmi ces classificateurs, les classificateurs linéaires et les classificateurs bayésiens non linéaires sont les plus utilisés dans la conception de la BCI [40].

1.7 Conclusion

Au cours de ce premier chapitre, un aperçu sur l'épilepsie et l'épilepsie chez les enfants a été d'abord présenté, suivie d'une description détaillée sur l'électro-encéphalogramme (EEG). Les signaux EEG sont les plus utiles pour la détection d'épilepsie qui vont nous aider à la conception d'un modèle dans le but de détecter et classifier l'épilepsie. Dans le chapitre suivant nous allons proposer certains systèmes connus, que nous allons étudier et comparer, afin de choisir la meilleure solution possible pour l'élaboration de notre système.

CHAPITRE 2

ÉTAT DE L'ART SUR LES SYSTÈMES DE DÉTECTION DES CRISES D'ÉPILEPSIE

2.1 Introduction

Les personnes souffrant de crises ont tendance à avoir davantage de problèmes physiques (par exemple, fractures ou hématomes dus aux crises), et une fréquence plus élevée de troubles psychosociaux, comme l'anxiété ou la dépression. De même, le risque de décès prématuré est jusqu'à trois fois plus élevé chez les personnes atteintes d'épilepsie que dans la population générale. Ajouter à cela le fait que la crise se produit sans aucun signe alertant la personne, cela implique que la personne n'est pas prévenue et qu'elle peut être dans des situation litigieuse (baignade, conduite, etc.) au moment de la crise et les conséquences peuvent être plus fatal que la crise elle-même.

Afin de faciliter leur quotidien et de les prévenir de la survenue d'une crise, le développement d'un protocole de prévention et de détection des crises un temps en avance est plus que nécessaire. Ces protocoles doivent tenir compte des bénéfices sur le plan d'efficacité et un coût de calcul minimal pour assurer une détection rapide et en temps réel. Ainsi qu'à la contrainte des ressources et matérielles limitées.

Dans ce chapitre, une présentation et une étude de quelques solutions récemment proposées sur l'axe de détection des crises épileptiques sera faite. Pour cela, nous définirons les critères d'évaluation sur lesquels nous nous baserons pour évaluer les protocoles étudiés. Suivie par notre propre classification des solutions étudiées en montrant les principales différences et similarités entre eux. Enfin, nous terminerons par une synthèse résumant les points forts et les points faibles des protocoles étudiés.

2.2 Critères d'évaluation des approches existantes

Dans un signal EEG comprenant une période de saisie, il existe toujours une déférence entre les intervalles de crises et de non-crise, les méthodes de détection et de prédiction du domaine temporel tentent de les différencier automatiquement et évaluent leurs performances à l'aide de différentes mesures telles que la sensibilité, la spécificité, l'exactitude et la valeur faussement positive et faussement négative. Lorsqu'il s'agit d'un algorithme de détection, quatre cas peuvent être rencontrés : - Vrai Positif Detections (VPD) : C'est le cas où l'anomalie paroxystique est détectée par l'approche adoptée et par l'expert. - Fausses Négatif Detections (FND) : C'est le cas où l'anomalie paroxystique est détectée par l'expert et non pas par notre approche. - Fausses Positives Detections (FPD) : C'est le cas où l'anomalie paroxystique est détectée par notre approche et non pas par l'expert. - Vrai Négatif Detections (VND) : Ce critère est défini selon les besoins de notre application - Temps : C'est la largeur du temps d'enregistrements. Dans notre application, le temps est de 24 heures pour tous les patients de la base de données CHB-Mit.

Cependant, plusieurs métriques de validation ont été proposées afin d'évaluer les performances de l'approche proposée. Elles sont définies comme suit :

2.2.1 Sensibilité

Elle Correspond au rapport entre les VPD et l'ensemble des crises. C'est la métrique la plus appliquée dans la valorisation des résultats de détections. Elle montre la capacité de l'approche à détecter des crises. La sensibilité est calculée comme suit :

$$\text{Sensibilité} = \frac{VP}{VP + FN} \times 100 \quad (2.1)$$

2.2.2 Spécificité

C'est un critère d'évaluation spécifique aux algorithmes de prédiction et d'anticipation. Ce critère correspond au rapport entre les VND et l'ensemble des VND et les FPD. La spécificité renseigne sur la capacité de l'approche à ne pas détecter des événements qui ne sont pas des vraies crises épileptiques. Elle est définie par l'équation suivante :

$$\text{Spécificité} = \frac{VN}{VN + FP} \times 100 \quad (2.2)$$

2.2.3 Taux de faux négatif

Les Faux négatif correspondent au nombre d'exemple positifs que le modèle a incorrectement classés comme négatifs. La TFN est définie par l'équation suivante :

$$\text{TFN} = \frac{FN}{VP + FN} \times 100 \quad (2.3)$$

2.2.4 Taux de faux positif

Les Faux Positifs (ou les fausses alarmes) correspondent au nombre des alarmes, par une durée de temps, déclarant l'avènement d'une activité épileptique en absence de crise. La TFP est définie par l'équation suivante :

$$\text{TFP} = \frac{\text{FP}}{\text{VN} + \text{FP}} \times 100 \quad (2.4)$$

2.2.5 Exactitude

Généralement utilisé pour les détecteurs d'événements, il s'agit du pourcentage de segments correctement classés, par rapport à l'ensemble des segments soumis au détecteur :

$$\text{Exactitude} = \frac{\text{VP} + \text{VN}}{\text{VN} + \text{FP} + \text{VP} + \text{FN}} \times 100 \quad (2.5)$$

De manière générale, on parle de résultat positif lorsqu'un algorithme réalise une détection. Par conséquent, les "vrais positifs" (VP) traduisent une détection correcte d'attaque épileptique, à l'inverse des "faux positifs" (FP). D'un autre côté, les "vrais négatifs" (VN) réfèrent logiquement aux signaux normaux (hors état de crise) correctement classés, tandis que les "faux négatifs" (FN) désignent les signaux anormaux non-relevés par le détecteur.

2.3 Taxonomie des travaux examinés

Nous présentons une classification des travaux que nous avons analysés en trois catégories. La première catégorie représente les solutions basées sur le deep learning. La deuxième catégorie représente les solutions basées sur le traitement d'image. Enfin, la troisième et dernière catégorie représente les solutions basées sur machine learning. La Figure 2.1, montre notre classification.

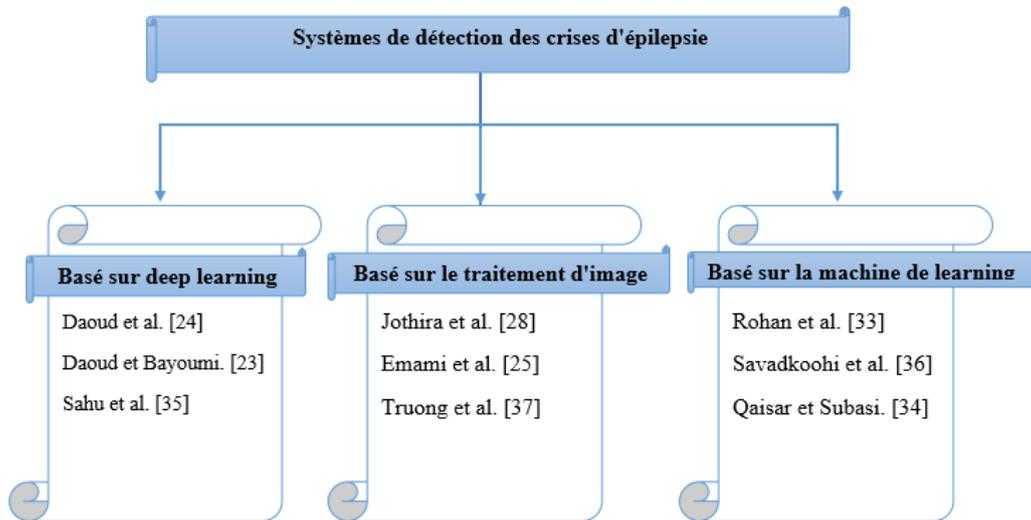


FIGURE 2.1 – Classification des systèmes de détection des crises d'épilepsie étudiées.

2.4 Travaux antérieurs

2.4.1 Solutions basées sur deep Learning

— **IoT based Efficient Epileptic Seizure Prediction System Using Deep Learning.** Daoud et al. [28], ont proposé un Deep Learning basé sur l'IoT pour un système précis de prédiction des crises d'épilepsie. Ce système propose une méthode qui se repose sur l'acquisition de l'EEG du cuir chevelu du patient épileptique et sur le téléchargement de l'enregistrement EEG sur le Cloud pour examen ultérieur par le médecin. De plus, un Edge-IoT est mis en œuvre en analysant l'enregistrement EEG à l'aide d'un algorithme d'apprentissage en profondeur au bord et le résultat positif de la prédiction des crises déclenche une alarme au patient et envoie une notification au médecin et aux autres services d'urgence choisis pour réduire le risque associé avec la crise. Le système de Daoud et al. assure la détection des crises d'épilepsie grâce au deep Learning avec une précision de prédiction élevée de 96,1% avec une complexité moindre et une empreinte mémoire plus petite font du système proposé un bon choix pour un système de santé intelligent afin d'améliorer la qualité de vie des patients épileptiques.

— **Efficient Epileptic Seizure Prediction based on Deep Learning.**

Daoud et Bayoumi. [27], ont proposé une nouvelle méthode de prédiction des crises d'épilepsie spécifique au patient basée sur le Deep Learning. Se système utilisant des données EEG du cuir chevelu à long terme a été proposé. Cette méthode permet d'obtenir une précision de prédiction de 99,6%, une sensibilité de 99,72%, une spécificité de 99,60%, un taux de fausses alarmes de 0,004 par heure et un temps de prédiction d'une heure avant le début de la crise. Le système

de Daoud et Bayoumi assure la détection des crises d'épilepsie grâce au deep Learning. Les résultats expérimentaux de cette méthode démontrent l'efficacité, la fiabilité et l'adaptation de l'application en temps réel à la prédiction des crises.

— **Epileptic Seizure Detection and Anticipation using Deep Learning with Ordered Encoding of Spectrogram Features.**

Sahu et al. [48], Ont proposé une nouvelle méthode d'apprentissage profond basée sur le spectrogramme pour la détection et l'anticipation des crises d'épilepsie à partir de signaux EEG multicanaux. Contrairement à d'autres méthodes, cette méthode propose un nouveau descripteur de caractéristique tout en conservant l'ordre de voisinage des spectrogrammes à la fois en temps et en fréquence, et en réduisant considérablement la dimensionnalité du descripteur de caractéristique. La méthode utilise 18 canaux EEG, et le spectrogramme de chaque canal EEG est construit en divisant chaque signal EEG en 3 blocs de temps et 19 blocs de fréquences, et la valeur moyenne de grandeur de chacun de ces blocs est calculée. Le signal EEG est représenté de manière compacte par un tenseur 3D. Ce descripteur tensoriel est donné en entrée au réseau de neurones à convolution proposé pour l'apprentissage de fonctionnalités de haut niveau. Les évaluations sont effectuées sur un Ensemble de données EEG de 23 patients et les résultats de la méthode proposée sont comparés à 9 autres méthodes existantes. De plus, la classification en cinq classes est effectuée à l'aide de la méthode proposée pour l'anticipation des crises. Cette méthode assure la détection des crises d'épilepsie grâce au deep Learning avec une précision globale de 98,56% dans la détection et 88,65% dans la classification en 5 classes pour l'anticipation des crises d'épilepsie.

2.4.2 Solutions basées sur le traitement d'image

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

Jothira et al. [34], Ont proposé un nouveau système pour détecter automatiquement l'épilepsie à partir des cartes cérébrales d'artefacts. Ces cartes cérébrales sont proposées pour aider les médecins à diagnostiquer les signaux épileptiques sans effort. La principale contribution de ce travail est d'analyser la performance de diverses techniques de traitement d'images dans la classification du cerveau épileptique des cartes à partir de cartes cérébrales d'artefacts. À partir des expériences, il est vérifié que le CNGP proposé pour le pixel voisin 16 bits et le CTP pour le pixel voisin de 8 bits a montré un taux de classification efficace de 94% pour la détection de cartes cérébrales épileptiques à partir de cartes cérébrales d'artefacts. Le système de Jothira et al assure la détection des crises d'épilepsie grâce au traitement d'image avec les techniques CNGP et CTP qui fonctionnent efficacement en tant que descripteurs de motifs de texture et pose une forte représentation de localité menant à un motif de texture amélioré pour une classification efficace des cartes cérébrales épileptiques et artefacts.

— **Seizure detection by convolutional neural network-based analysis of scalp electroencephalography plot images.**

Emami et al. [30], ont émis l'hypothèse que les épéptologues experts peuvent détecter les crises directement en analysant visuellement les images de tracé EEG, contrairement aux méthodes automatisées qui analysent les caractéristiques spectraux-temporelles ou les caractéristiques complexes et non stationnaires de l'EEG signaux. Cela permet à la détection des crises de bénéficier des réseaux de neurones convolutifs (CNN) car leur reconnaissance visuelle est comparable à celle des humains [38]. Le système d'Emami et al assure la détection des crises d'épilepsie grâce au traitement d'image avec l'EEG du cuir chevelu dans laquelle les données EEG ont été converties en une série d'images de tracé, analysées par un épéptologue, puis le CNN a été utilisé pour classer chaque image en état de crise ou non-crise. Ainsi, la reconnaissance visuelle artificielle par les réseaux de neurones convolutifs permet la détection des crises, qui autrement repose actuellement sur une inspection visuelle habile faite par des épéptologues experts lors du diagnostic clinique.

— **A Generalised Seizure Prediction with Convolutional Neural Networks for Intracranial and Scalp Electroencephalogram Data Analysis.**

Truong et al. [51], ont appliqués les réseaux de neurones convolutifs (CNN) sur différents intracrâniens mais aussi sur l'ensemble des données d'électroencéphalogramme (EEG) du cuir chevelu. Ce système propose une prédiction rétrospective généralisée et spécifique au patient. L'utilisation de la transformée de Fourier à court terme (STFT) sur Fenêtres EEG de 30 secondes permet au système d'extraire les informations dans les deux domaines fréquentiel et temporel. Une étape de normalisation est alors appliquée sur les composants STFT sur toute la gamme de fréquences pour éviter que les caractéristiques des hautes fréquences ne soient influencées par celles à fréquences plus basses. Un modèle de réseau de neurones convolutif est aussi utilisé à la fois pour l'extraction de caractéristiques mais aussi pour la classification afin de séparer les segments et les inter-critiques. L'approche proposée atteint une sensibilité de 81,4%, et un taux de fausse prédiction (FPR) de 0,06/h. Cette méthode de prédiction est également statistiquement meilleure qu'une méthode aléatoire non spécifique prédicteur.

2.4.3 Solutions basées sur machine Learning

— **Efficient Approach to Detect Epileptic Seizure using Machine Learning Models for Modern Healthcare System.**

Rohan et al. [47], ont proposé un système pour la multi-classe classification de la crise d'épilepsie. Par détection précoce, le problème peut être guéri. XGBoost et ANN ont donné des résultats prometteurs en conformité avec la précision, mais le SVM a été préférée pour la classification multi classe précise. Ce système assure la détection des crises d'épilepsie grâce à machine Learning mais aussi grâce aux performances de l'apprentissage automatique. Afin de classer les crises

d'épilepsie. Le SVM a obtenu les meilleures performances, en effet, avec une précision de 97.31%, et une exactitude de 95.33%, les résultats obtenus par ce système sont très prometteurs.

— **A machine learning approach to epileptic seizure prediction using Electroencephalogram (EEG) Signal.**

savadkoochi et al. [49], ont exploré le système d'apprentissage automatique pour les diagnostics et la détection des crises d'épilepsie. Cette méthode permet d'analyser le signal EEG dans les domaines temporels et fréquentiels et extrait les caractéristiques de chaque onde EEG. Pour la classification, le K-plus proche voisins (KNN) et le support vecteur machine (SVM) ont été utilisés. Après avoir comparé l'efficacité de chaque fonctionnalité individuellement, une combinaison des fonctionnalités a permis de choisir les meilleures et les plus importantes fonctionnalités. Cette méthode a permis d'avoir une précision de 99.5

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

Qaisar et Subasi. [46], ont proposé un système de détection et de prédiction des crises d'épilepsie basé sur machine Learning. Cette approche utilise une émergence intelligente de l'acquisition et du conditionnement du signal événementiel avec une extraction et une classification robustes des caractéristiques modales. L'objectif est de contribuer au développement d'un système de diagnostic EEG modernes et efficaces en termes de calcul pour une détection efficace des crises d'épilepsie. Le système de Qaisar et Subasi assure la détection des crises d'épilepsie grâce au signal acquis en utilisant un EDADC pour réguler la vitesse d'acquisition du signal en fonction des variations du signal d'entrée [44]. Il diminue l'activité de la chaîne de post-traitement en n'acquérant que les informations pertinentes [45][42][43]. Le système est prometteur et conduit à une électronique frontale compétente avec des données en temps réel.

2.5 Étude comparative

Plusieurs systèmes de détections des crises ont été proposés, certains exploitent les caractéristiques de deep Learning, d'autres le traitement d'image, ou encore machine Learning. Tous ces systèmes permettent la détection des crises avec des temps records, chaque système a ses avantages et ses inconvénients par rapport aux autres systèmes. Afin de mieux comprendre la diversité des systèmes étudiés dans ce chapitre et traitant le problème de la détection des crises épileptiques, la Table 2.1 illustre une étude comparative que nous avons menée sur les différents systèmes analysés précédemment selon les critères d'évaluation discutés en section 2.2.

Solution basée sur	Systèmes	Sensibilité	Spécificité	Taux de faux négatif	Taux de faux positif	Exactitude
Le Deep Learning	Daoud et al. [28]	97.41%	94.8%	Non renseigner	Non renseigner	96.1%
	Daoud et Bayoumi. [27]	99.72%	99.60%	Non renseigner	faible	96.6%
Le traitement d'image	Sahu et al. [48]	95.49%	99.33%	Non renseigner	Non renseigner	98.56%
	Jothira et al. [34]	90.79%	97.52%	Non renseigner	Non renseigner	94.74%
	Emami et al. [30]	Non renseigner	Non renseigner	Non renseigner	Moyen	Non renseigner
machine Learning	Truong et al.[51]	81,4%	Non renseigner	Non renseigner	faible	Non renseigner
	Qaisar et Subasi. [46]	Non renseigner	Non renseigner	Non renseigner	Non renseigner	96.4
	savadkoochi et al. [49]	99%	100%	Non renseigner	Non renseigner	99.5%
	Rohan et al. [47]	Non renseigner	94,00%	Non renseigner	Non renseigner	95,33%

TABLE 2.1 – Étude comparative des différents systèmes analysés.

Les systèmes [28][27][48], sont des solutions avec un taux d'exactitude meilleur pour la détection des crises, et avec un très faible taux de faux positive, la sensibilité et la spécificité restent elles aussi très élevés. Pour les solutions [34][30][51], le problème de l'applicabilité de ses systèmes reste à améliorer car la sensibilité de ces méthodes reste relativement faible par rapport aux autres méthodes, à noter aussi le taux de faux positive moyen pour le protocole [30], est des fausses alertes chaque 5 heure. Et pour ce qui est des solutions [46][49][47], on constate des résultats relativement élevés pour la sensibilité, la spécificité, et l'exactitude, mais ces résultats restent à confirmer vu le nombre de patient limiter pour les tests.

2.6 Synthèse

Les résultats constatés sur la Table 2.1 nous laisse dire que les systèmes [46][49][47], sont de meilleurs qualités par-rapport aux autres. Ces trois systèmes sont tous des solutions basés sur machine Learning. Afin de faire notre choix sur la solution à prendre pour la suite de notre travail, nous avons menés notre petite enquête sur les raisons qui font que les résultats obtenus des systèmes basées sur machine Learning sont meilleurs. Les solutions basées sur le Deep Learning ainsi que sur le traitement d'image, traite des données non structurés, contrairement à machine Learning, qui permet au programmeur de choisir directement et uniquement les données nécessaires pour le fonctionnement de son système. C'est un avantage pour les solutions de Deep Learning et le traitement d'image, parce qu'ils font la distinction entre les données nécessaires au fonctionnement du système sans l'intervention de l'homme, et les récupère automatiquement, ce qui fait qu'ils sont plus indépendant, et bizarrement, c'est la raison pour laquelle les résultats obtenus par ces deux systèmes sont inférieurs aux résultats de machine Learning. En effet, pour avoir un système de qualité basée sur le Deep Learning ou sur le traitement d'image, de long algorithmes sont nécessaire, cela implique le besoin d'utiliser des serveurs très puissant, un ordinateur (même avec des capacités élevées) ne pourra pas dérouler ces algorithmes très complexe.

Pour des solutions moins coûteuses, tous les systèmes proposés ont eu recours à l'utilisation d'un ordinateur, et contrairement aux solutions basées sur machine Learning, les systèmes basés sur le Deep Learning et le traitement d'image ont réduits la profondeur de leurs algorithmes dans la partie du prétraitement et l'extraction des caractéristiques, et c'est la raison pour laquelle les résultats de performance des classificateurs ont diminué. Vu que nous allons nous servir d'un ordinateur pour l'élaboration de notre système, la solution basée sur machine Learning sera logiquement choisit pour la suite de notre travail.

2.7 Conclusion

Plusieurs études montrent que les signaux EEG avaient des modèles différents avant la survenue de la crise, de plus l'épilepsie se manifeste de différentes manière d'un enfant à un autre, d'où

la difficulté de trouver une méthode qui conduit à une prévision rapide et précise des crises. Afin de répondre à ces problèmes, nous avons mené dans ce chapitre une étude sur les approches de détection de crise existantes, on a proposé une catégorisation pour ces approches, avant de terminer par une étude comparative entre ces méthodes grâce aux mesures de performance prédéfinie, qui sont appliquées pour chaque approche. Ces différentes techniques donnent de bons résultats, notamment machine learning, mais nécessitent un apprentissage sur un grand nombre de données afin d'élaborer le modèle de détection de crise. Enfin, nous avons pu identifier quelques méthodes qui nécessitent pas d'apprentissage et s'adaptent sans réglage aux différents cas de crise. Nous pouvons noter la méthode basée sur l'électroencéphalogramme (ou EEG). Ainsi, nous avons pu soulever précisément les problèmes auxquels nous devons faire face pour obtenir une solution qui répond aux critères cités auparavant. Le chapitre suivant sera consacré à la description détaillée de notre contribution.

CHAPITRE 3

CLOUD BASED AUTOMATIC EPILEPTIC SEIZURE DETECTION SYSTEM

3.1 Introduction

À travers l'étude des protocoles de détection des crises d'épilepsies, nous avons déduits que la méthode la plus précise est bien celle qui utilise les données acquises à partir des capteurs physiologiques tels que l'électroencéphalogramme(EEG) dont ses signaux fournissent des informations très utiles pour détecter les crises en temps réel. Bien que les méthodes citées dans le chapitre précédent atteignent une excellente précision dans certains cas, elles ont été jugées insuffisantes pour apprendre et classifier les signaux EEG qui sont complexes et non stationnaires.

Pour remédier aux défaillances des méthodes existantes pour la détection des crises, nous proposons dans ce chapitre un autre système sur lequel repose notre contribution. Nous présentons notre protocole de détection des crises, qui est basé sur les deux bandes de fréquences Alpha et Thêta ainsi que la réduction du nombre de canaux en exploitant seulement le canal C3-P3.

3.2 Motivation

L'épilepsie est l'une des maladies neurologiques les plus répandues et les plus dévastatrices dans le monde. Pour apporter notre aide à ces personnes touchées par cette maladie, Nous avons optés pour une conception d'un système qui pourrait anticiper, très tôt l'arrivée de ces crises avec un certain niveau de fiabilité tout en présentant une complexité minimale. C'est vrai, plusieurs méthodes ont déjà été proposées, avec des résultats très intéressants pour certaines, mais malheureusement aucuns système n'as pu répondre concrètement à tous les problèmes des épileptiques. Notre défi sera alors à la fois médical (détection très rapides des éventuels crises),

et industriel (utilisation d'un casque avec un seul canal).

Augmenter les résultats des mesures de performance fera de notre système de détection des crises d'épilepsies un système très performant. Afin d'avoir ces résultats souhaités, nous avons met en avant l'utilisation du canal (C3-P3). Certaines recherches montres que l'utilisation d'un seul canal s'avère plus efficace pour la détection des crises d'épilepsie [32], ce qui explique notre choix d'utiliser uniquement le canal C3-P3 (voire figure 3.1). Cette réduction de nombre de canaux EEG nous permet aussi d'améliorer le confort du patient. De plus, les crises d'épilepsie étant principalement caractérisées par l'évolution des activités alpha et thêta, nous proposons de nous concentrer sur l'évaluation de l'activité dans ses différentes bandes de fréquences afin de concevoir notre système.

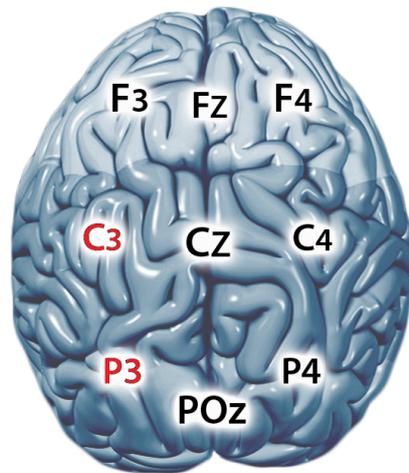


FIGURE 3.1 – La position du canal (C3-P3) dans le cerveau humain.

3.3 Modèle du système

Afin de répondre au problème de la portabilité du système, l'utilisation d'un casque sans fil pour la collecte des données EEG a été choisi. Comme pour le choix du casque, tous les éléments de notre système ont été choisis en tenant compte de certains inconvénients qui pourront être un handicap dans notre système. Ces éléments de base du modèle proposé de système de détection automatique des crises d'épilepsie sont présentés dans la Figure 3.2. Ce modèle proposé se compose d'un casque EEG compatible Bluetooth, d'un téléphone portable, et d'un service de stockage et de calcul. Chaque élément de ce système a sa propre Tâche à effectuer.

La première tâche et l'acquisition des données EEG, elle est effectuée à l'aide d'un module d'acquisition, qui est un casque EEG portable. La fonction du casque EEG est de collecter les

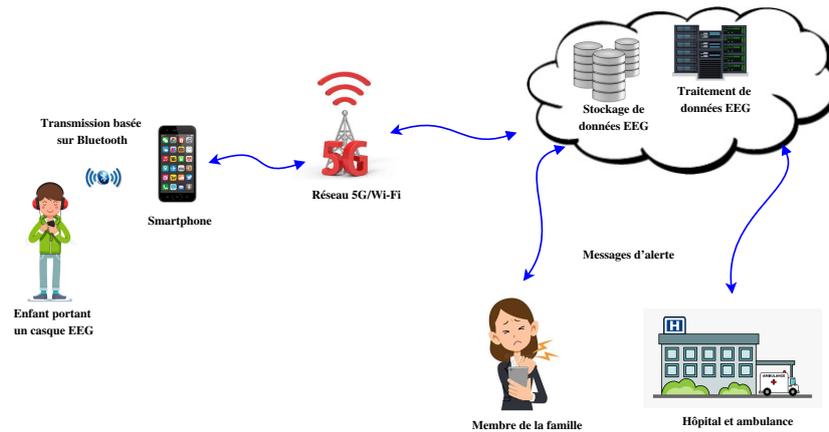


FIGURE 3.2 – Modèle de système de détection automatique des crises épileptiques basé sur le Cloud.

signaux EEG à travers une ou plusieurs électrodes, qui détectent la tension des ondes de courant traversant les neurones du cerveau de différents segments du cerveau humain. Les signaux EEG bruts acquis du casque EEG sont transmis au téléphone portable du patient via Bluetooth.

Les données seront envoyées d'une manière successive avec un intervalle de 2s entre chaque signal. A la réception des données, le téléphone portable supprime les redondances et transmet ensuite les données restantes au serveur basé sur le cloud sur la couche cloud via Wi-Fi ou réseau 5G.

Le serveur effectuera un prétraitement pour chaque signal reçu à l'aide des techniques de traitement du signal pour réduire le bruit et atténuer la plupart des artefacts, cette étape est primordial pour permettre une meilleurs analyse de l'activité cérébrale liée à la stimulation. A la fin de cette étape, le serveur passe à l'extraction des caractéristiques. Cette tâche consiste à calculer la puissance de chaque bande de fréquence, ainsi que la puissance relative de chaque bande par rapport au signal. Grâce aux résultats obtenus de ces deux premières étapes, le classificateur linéaire (SVM) estimera la probabilité d'une éventuelle crise. Le résultat de cette probabilité décidera si oui une alerte sera donné, ou pas. Pour cela, les probabilités affichées seront systématiquement comparer à un seuil particulier, et l'alerte sera déclencher uniquement dans le cas où le résultat de la probabilité est supérieur à ce seuil prédéfini.

Un ou plusieurs membres de la famille du patient seront alertés. Par précaution une autre alerte sera envoyer à l'hôpital afin d'assurer une intervention rapide au cas où les membres de la famille informés sont absents.

3.4 Notre contribution

Ayant comme objectif la conception d'un système très performant, nous avons eu à faire des choix difficiles parmi plusieurs méthodes pour obtenir les meilleurs résultats possibles. Par exemple, pour le choix des bandes de fréquences à utiliser, nous avons optés pour les deux bandes Alpha et Thêta, mais pour exploiter que ces deux bandes une décomposition du signal en sous-bandes et nécessaire, ce qui fait de cette méthode (décomposition du signal en sous-bandes) la base de notre système.

Pour résumer, quatre phases essentielles enchaînées comme suit sont utilisées dans notre processus :

La première phase consiste à collecter les signaux EEG à partir d'un casque et les envoyées par Bluetooth jusqu'au smart-phone, ensuite vient la phase du prétraitement de signal, son rôle c'est le filtrage ainsi que la suppression des artefacts, cette étape est essentiel pour réduire les perturbations du signal, et permettre l'extraction d'un maximum d'informations utiles sur un signal. Ces informations récupérées dans la phase du prétraitement seront utilisées dans la phase d'extraction des caractéristiques du signal EEG pour calculer la probabilité de la survenu d'une crise. Enfin, la dernière phase de notre processus consiste à classifier les résultats obtenus et déclencher une alerte si seulement si la probabilité estimée dépasse un seuil particulier. Afin de mieux comprendre l'organigramme de notre protocole, un schéma fonctionnel du système proposé est illustré à la Figure 3.3.

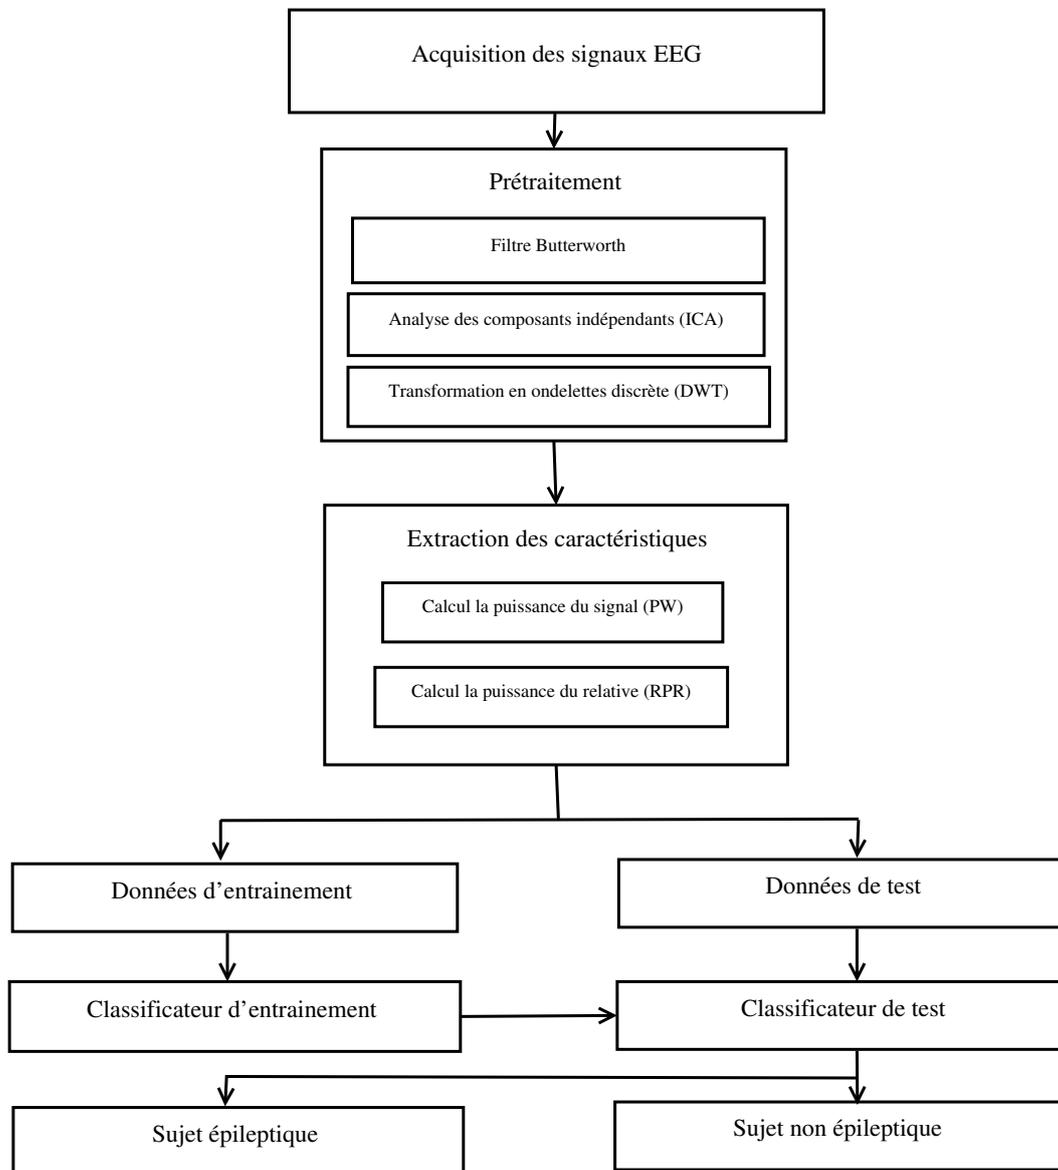


FIGURE 3.3 – Organigramme de détection des crises d'épilepsie.

3.4.1 Acquisition des données EEG.

Malgré que l'électroencéphalographie constitue la modalité la plus fréquente pour la mesure de l'activité électrique cérébrale, il existe un grand manque de données accessibles. Parmi les grandes bases de données capables de soutenir la recherche dans le domaine de l'épilepsie, il existe : «The European Epilepsy Database (<http://epilepsy-database.eu/>) ». Cette base comporte 250 enregistrements de 30 sujets, elle est parfaitement annotée avec des informations supplémentaires des experts (les manifestations cliniques, les instants des évènements intercritiques, etc.). Cependant, l'accès à cette base coûte 3000 euros. D'autres bases de données accessibles comme la « EEG Motor Movement/Imagery Dataset (<http://www.Physionet.org/pn4/eegmidb/>) » comportent plus que 1500 tracés EEG de 109 sujets mais sans aucun renseignement sur l'existence des anomalies épileptiques. Dans ce travail, nous utilisons la CHB-Mit [15] qui est une base de données EEG de 22 patients épileptiques dont 20 patients sur 22 n'ont pas encore atteints 18ans.

3.4.2 Prétraitement

Une fois que les données EEG sont reçues, la phase du prétraitement va commencer. Cette tâche qui consiste à éliminer tous les bruits et les artefacts de l'enregistrement sera réalisée sur deux étapes, la première est d'annuler tous les artefacts pendant l'enregistrement à l'aide d'un filtre Butterworth passe-haut et l'analyse des composants indépendants (ICA). Ensuite, en utilisant la transformation discrète en ondelettes on obtient une échelle de temps-fréquence des informations avec l'ondelette mère Daubechies4 (db4).

Filtrage Butterworth

Un filtre de Butterworth est un type de modèle de filtre linéaire, conçu pour posséder une courbe de réponse très plate à l'origine, et une amplitude régulière en bande passante. Avec des calculs faciles à réaliser, il possède aussi un très bon temps de propagation de groupe.

Pour garder les signaux et réduire les artefacts et les tendances linéaires qui sont sélectionnés par la fréquence de coupure, un filtre passe-bande de Butterworth de deuxième ordre avec une fréquence de coupure ω_c de 0.5 Hz et 30 Hz est appliqué sur les signaux.

Les polynômes normalisés de Butterworth peuvent être utilisés pour déterminer les fonctions de transfert de filtre passe-bas pour toute fréquence de coupure ω_c selon l'équation 3.1 :

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

Avec :

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

(Équation du filtre Butterworth de deuxième ordre) [8][26].

Comme pour l'ensemble des filtres linéaires, le prototype étudié est le filtre passe-bas, qui peut être aisément modifié en filtre passe-haut ou positionné en série pour former des filtres passe-bande ou coupe-bande [8]. La fréquence de coupure a été normalisée à 1 radian par seconde et dont la réponse en fréquence (Gain) est :

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

Où, ω_c est la fréquence angulaire en radians par seconde et n est le nombre de pôles du filtre égal au nombre d'éléments réactifs dans un filtre passif.

Analyse des composantes indépendantes (ICA)

L'analyse en composantes indépendantes (en anglais, Independent Components Analysis (ICA)) est une méthode de séparation aveugle de source qui s'applique à divers problèmes, elle est aussi utilisée pour l'analyse des données qui relève des statistiques, des réseaux de neurones et du traitement du signal. L'utilisation de l'ICA sur les enregistrements EEG nous permettes :

- De séparer le signal cérébral des artefacts.
- L'étude d'activités cérébrales en environnement bruité.
- Le suivi de processus mentaux multiples [9].

Transformation en ondelettes discrète (DWT)

La transformation en ondelettes discrète est utilisée dans plusieurs domaines, l'un de ces domaines est l'analyse automatique des signaux EEG, où elle est utilisée avec efficacité pour l'extraction de paramètres du signal qui est non stationnaire, elle est considérée comme étant la plus adaptée pour effectuer cette analyse vu que les signaux EEG sont des signaux non stationnaires. Le principe de cette méthode est d'analyser le signal à différentes bandes de fréquence avec différentes résolutions en décomposant le signal par une approximation grossière et une information détaillée, car elle utilise une technique multi-résolution pour analyser différentes fréquences avec différentes résolutions. De manière générale, la transformée en ondelettes peut être exprimée avec l'équation suivante [10] :

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

Avec :

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

ψ : représente la fonction de décalage et de détail.

La transformée en ondelettes est une technique mathématique qui peut décomposer un signal en plusieurs niveaux de résolution inférieure en contrôlant les facteurs d'échelle et de décalage

d'une fonction d'ondelette unique (ondelette mère) :

$$\Phi_{\alpha,b}(s) = \phi\left(\frac{s - at_0z_0^b}{z_0^b}\right)\alpha \quad (3.5)$$

Avec :

$$\alpha = \frac{1}{\sqrt{z_0^b}} \quad (3.6)$$

(Équation du DWT) [11].

Il existe différents types d'ondelettes qui diffèrent les unes des autres en termes de forme, de douceur, de compacité, etc... Parmi ces différentes bases d'ondelettes, l'ensemble de transformées en ondelettes discrètes le plus couramment utilisé a été formulé par la mathématicienne belge Ingrid Daubechies en 1988. Cette formulation est basée sur l'utilisation de relations de récurrence pour générer des échantillonnages discrets de plus en plus fins d'une fonction d'ondelette mère implicite ; chaque résolution est le double de celle de l'échelle précédente. Pour la décomposition en ondelettes de l'EEG signal dans ce travail, nous avons employé l'ordre de Daubechies-4 (DB4) ondelette comme base.

3.4.3 Extraction de caractéristiques

La puissance relative qui est considérée comme étant très efficace pour étudier et examiner les relations des changements de puissance à l'heure de stimulus a été choisi pour la suite de notre travail. Et afin d'avoir les meilleurs résultats possible, nous avons concentrés notre travail sur les deux bandes alpha et theta. Cette décomposition représente la forme d'onde qui sera calculée pour obtenir la puissance relative (RPR). Nous définissons le rapport de puissance relative au signal EEG comme le rapport de la puissance d'une forme d'onde (ϵ) du signal filtré, où $(\epsilon_i) \in (\alpha, \theta)$ et la somme de la puissance des deux formes d'onde EEG (ϵ). La puissance du signal EEG est représentée par pW, qui est estimée par la somme de l'intégrale au carré du signal en utilisant environ 2s du signal EEG pour chaque sujet et la taille Hamming de la fenêtre de 256 points de données.

La formule mathématique suivante nous permet le calcul de la puissance pW du signal EEG :

$$pW(\epsilon) = \sum_{i=1}^n \int_{-\infty}^{+\infty} |x(\epsilon_i)|^2 dx \quad (3.7)$$

Avec :

n : nombre d'échantillons de sigla de bande EEG.

x(ϵ) : le carré du signal de bande EEG.

Comme cité avant, nous avons choisit l'utilisation des deux bandes alpha et thêta, ce qui implique le besoin de calculer la fonctionnalité de puissance de bande pour chacune des deux.

— La puissance de la bande Alpha :

$$pW(\alpha) = \sum_{i=1}^n \int_{-\infty}^{+\infty} |x(\alpha_i)|^2 dx \quad (3.8)$$

— La puissance de la bande Thêta :

$$pW(\theta) = \sum_{i=1}^n \int_{-\infty}^{+\infty} |x(\theta_i)|^2 dx \quad (3.9)$$

Le rapport de puissance relative du signal EEG mesuré peut alors être exprimé comme suit :

$$RPR(\epsilon_i) = \frac{pW(\epsilon_i)}{\sum_{i=1}^2 pW(\epsilon_i)} \cdot 100\% \quad (3.10)$$

Le calcul de la valeur de puissance de ces deux bandes ainsi que la puissance pW , nous allons calculé la puissance relative (RPR), qui va nous permettre de former des vecteurs d'entrées pour le classificateur SVM. Voici les fonctionnalités nécessaires pour cela :

— La puissance relative Alpha :

$$RPR(\alpha) = \frac{pW(\alpha)}{pW(\alpha) + pW(\theta)} \cdot 100\% \quad (3.11)$$

— La puissance relative Theta :

$$RPR(\theta) = \frac{pW(\theta)}{pW(\alpha) + pW(\theta)} \cdot 100\% \quad (3.12)$$

Cette étape est très importantes pour la suite. L'extraction de la caractéristique EEG, va aider les classificateurs a classé les signaux.

3.4.4 Classification

Etant donné que notre ensemble de données est subdivisé en deux catégories, la technique de classification va nous permettre de séparer et classer chaque ensemble de données dans sa classe. Plusieurs algorithmes de classification ont été appliqués avec succès à la détection des crises d'épilepsies. Évidemment, le choix des classificateurs utilisé pour la suite de notre travail a été fait par-rapport aux performances de chaque classificateur. La machine à vecteur de support (SVM) est l'algorithme le plus couramment utilisé, il va nous permettre de trouver la meilleure ligne, et l'hyper plan qui a la plus grande distance du plus proche point de données dans les deux classes [6]. Pour démontrer l'efficacité de notre proposition de classement, nous avons aussi choisi d'utiliser le KNN (K-nearest neighbors). Pour ce classificateur, la valeur k a été fixée à trois puis la distance entre chaque échantillon de test avec toutes les données d'apprentissage a été calculée à l'aide de la distance euclidienne fonction [5].

3.5 Conclusion

Dans ce chapitre on a présenté les techniques utilisées dans ce mémoire pour la détection des crises d'épilepsie. Tout d'abord, nous avons décrit notre modèle système sur lequel nous sommes basés pour concevoir notre protocole. Puis, nous avons présenté notre système de détection des crises basé sur les mesures physiologique EEG en exploitant un seul canal C3-P3 et la puissance relative de bande comme caractéristique afin de permettre aux classificateurs SVM et le KNN de classer chaque ensemble de données dans sa classe appropriée. Le chapitre suivant sera consacré à l'évaluation de performances de notre protocole de détection des crises d'épilepsies.

CHAPITRE 4

SIMULATION ET ÉVALUATION DE PERFORMANCES

4.1 Introduction

La détection et la classification des crises épileptiques chez les enfants est l'objectif médical dont nous nous sommes assignés dans ce travail. Dans le chapitre précédent, nous avons présenté notre contribution pour la détection des crises, ainsi que le fonctionnement générale de notre protocole. Pour la dernière partie de notre mémoire, Nous avons commencé par présenter les données EEG utilisées pour les simulations ainsi que l'environnement et les paramètres de simulation considérés pour l'évaluation de performances du protocole proposé. Ensuite, afin de valider les méthodes utilisées et citées au chapitre 3, nous présentons les résultats de simulations des différents cas de la base de données utilisée, ces résultats seront étudiés et comparés avec d'autres protocoles concurrents à l'aide des métriques d'évaluation de performance.

4.2 Description de la Base de données EEG

La base de données étudiée dans ce chapitre comporte des enregistrements EEG crâniens d'enfants souffrant d'épilepsie. Ces enregistrements ont été conçus en partenariat entre l'Hôpital pédiatrique de Boston (Children's Hospital of Boston) et l'Equipe de recherche MIT [50].

Les données CHB-MIT sont disponibles gratuitement en ligne sous format « .edf » (European data format) via le site des données physiologiques «physionet.org ».

Cette base comprend des enregistrements d'EEG provenant de sujets pédiatriques souffrant de crises intractables (pharmaco-résistante). Les sujets ont été suivis pendant plusieurs jours après le retrait des médicaments antiépileptiques afin de caractériser leurs crises et d'évaluer leur candidature à une intervention chirurgicale. Les enregistrements d'EEG qui sont divisés entre 24

cas ont été recueillis chez 22 sujets (5 hommes âgés de 3 à 22 ans et 17 femmes âgés de 1,5 à 19 ans), avec une moyenne d'âge qui ne dépasse pas 10ans. (Un patient a deux séries d'enregistrements EEG.). Le cas 24 a été ajouté à cette collection en décembre 2010 et ne contient aucune donnée sur le patient. Tous les signaux ont été échantillonnés à 256 échantillons par seconde avec une résolution de 16 bits. La plupart des fichiers contiennent 23 signaux EEG (24 ou 26 dans certains cas). Le système international 10-20 des positions et de la nomenclature des électrodes EEG a été utilisé pour ces enregistrements. Les données ont été segmentées en enregistrements d'une heure. Les enregistrements qui ne contiennent pas de crise sont appelés enregistrements sans crise et ceux qui contiennent une ou plusieurs crises sont appelés enregistrements de crises.

Sujet	Sexe	Âge	Sujet	Sexe	Âge
Suj1	F	11	Suj13	F	3
Suj2	M	11	Suj14	F	9
Suj3	F	14	Suj15	M	16
Suj4	M	22	Suj16	F	7
Suj5	F	7	Suj17	F	12
Suj6	F	1.5	Suj18	F	18
Suj7	F	14.5	Suj19	F	19
Suj8	M	3.5	Suj20	F	6
Suj9	F	10	Suj21	F	13
Suj10	M	3	Suj22	F	9
Suj11	F	12	Suj23	F	6
Suj12	F	2			

TABLE 4.1 – L'âge des participants à l'expérience.

4.3 Environnement de simulation

4.3.1 Paramètre de simulation

Pour concevoir notre protocole nous avons fait appel aux filtres Butterworth avec la boîte à outils Signal Processing de Matlab, qui nous a permis d'améliorer la qualité du signal. Ensuite, à l'aide de la DWT incluse dans Matlab, nous avons procédé à la séparation de chaque bande de fréquence d'époque, et c'est en calculant la puissance relative de chaque bande de fréquence EEG par rapport à chaque époque du signal que nous avons pu déterminer la puissance de chaque bande de fréquence. Enfin, nous avons utilisé le classificateur SVM de la boîte à outils de LibSvm pour estimer la probabilité de la survenue d'une éventuelle crise. C'est ainsi que notre système de détections de crises d'épilepsie fut simulé sous l'environnement Matlab-R2019b avec

un ordinateur ayant un processeur AMD A6-5200 APU with Radeon (TM) HD Graphics 2.00 Ghz et une mémoire de 8 Go.

4.3.2 Matrice de confusion

La matrice de confusion ou tableau de contingence est un résumé des résultats de prédictions sur un problème de classification. Les prédictions correctes et incorrectes sont mises en lumière et réparties par classe [12]. Les résultats sont ainsi comparés avec les valeurs réelles. Chaque colonne du tableau contient une classe prédite par l'algorithme et les lignes des classes réelles. Le Tableau 4.2 illustre une matrice de confusion.

		Classe réelle	
		Malade	Saine
Classe prédite	Malade	VP	FN
	Saine	FP	VN

TABLE 4.2 – Matrice de confusion.

4.3.3 La courbe ROC

Les courbes ROC (Receiver Operating Characteristic) ont d'abord été développées pendant la seconde guerre mondiale pour la mise au point de moyens efficaces de détection des avions japonais. Cette méthodologie a ensuite été appliquée de manière plus générale en détection du signal [14]. Ces courbes sont généralement utilisées dans la classification binaire pour étudier la sortie d'un classificateur. Cette courbe trace le taux de vrais positifs en fonction du taux de faux positifs. L'aire sous la courbe (AUC) fournit une mesure agrégée des performances pour tous les seuils de classification possibles. Plus cette région se rapproche de 1, plus le classifieur est performant. La Figure 4.1 illustre l'interprétation de la courbe ROC.

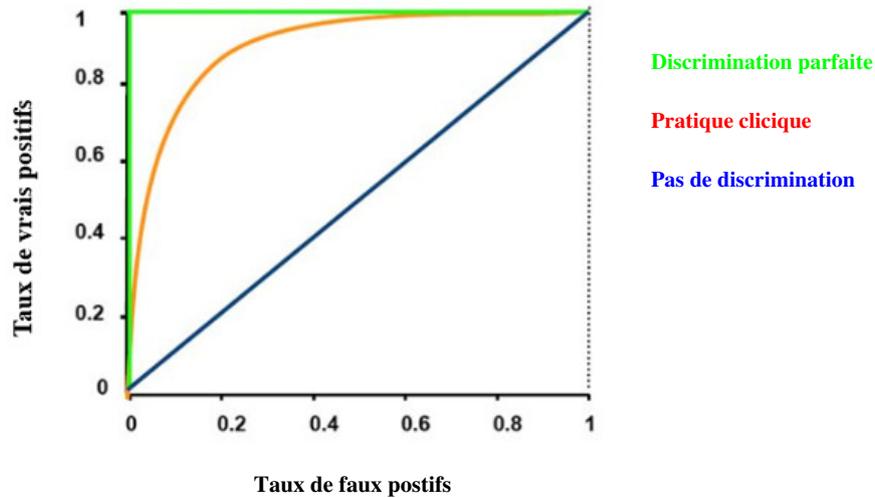


FIGURE 4.1 – La courbe ROC [13].

4.3.4 Métriques de simulation

Les métriques de simulation sont utilisées pour évaluer la qualité d'un algorithme, c'est-à-dire, qu'un algorithme sera jugé avec d'autres algorithmes selon les résultats de calculs des métriques obtenues pour un algorithme donné. Les mesures les plus utilisées comprennent : **(1) Temps de détection de la crise d'épilepsie** : c'est l'intervalle de temps que le système prend pour décider si la personne risque de subir une crise ou non, **(2) Taux d'exactitude** : il s'agit du pourcentage de segments correctement classés, par rapport à l'ensemble des segments soumis au détecteur, **(3) Taux de précision** : c'est le nombre de crises correctement détectées sur le nombre total de crises, **(4) Taux de faux négatif** : c'est la mesure de la probabilité que le système de détection des crises d'épilepsie rejette à tort une bonne détection de crise, **(5) Taux de faux positif** : c'est la mesure de la probabilité que le système de détection des crises d'épilepsie accepte à tort une fausse détection de crise.

4.4 Résultats et Discussion

L'application de notre algorithme de détection des crises sur l'ensemble de la base de données nous a permis d'avoir certains résultats qui nous ont permis d'évaluer les performances de notre système et les comparer à d'autres systèmes similaires au notre.

Parmi ces résultats nous avons la matrice de confusion de notre système obtenue grâce au classificateur SVM Figure 4.2 :

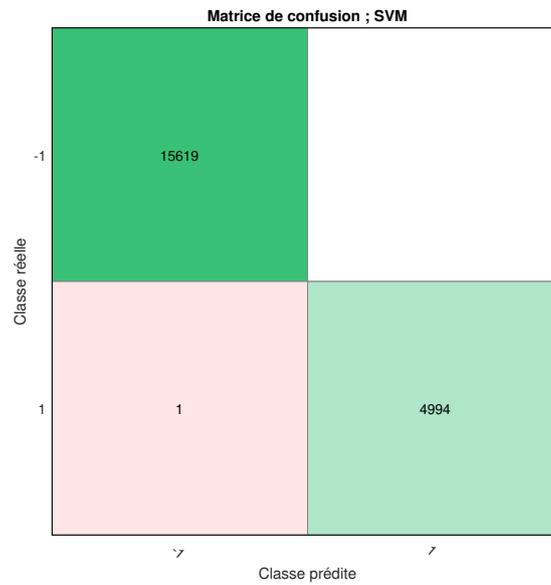


FIGURE 4.2 – La matrice de confusion montrant les différentes prévisions et résultats des tests effectués avec le classificateur SVM.

Cette matrice nous affiche un total de 20613 prédicteurs, un seul prédicteur parmi ces 20613 prédicteur est mal classé, le reste est bien placé. Ce résultat démontre la fiabilité de notre système.

Métriques d'évaluation	Définition %
Exactitude (e)	99.9
Rappel (ψ)	99.9
Précision (σ)	100
Taux du faux négatif	0.006
Taux de faux positif	0.00
Spécificité (ϕ)	100
Sensibilité (γ)	100

TABLE 4.3 – Métriques d'évaluation calculées à partir de la matrice de confusion.

Pour confirmer ce premier résultat obtenu, nous avons représenté la courbe ROC figure 4.3. Grace à cette figure 4.3 nous avons calculé le vrai positif à 100% et le faux positif à 0%.

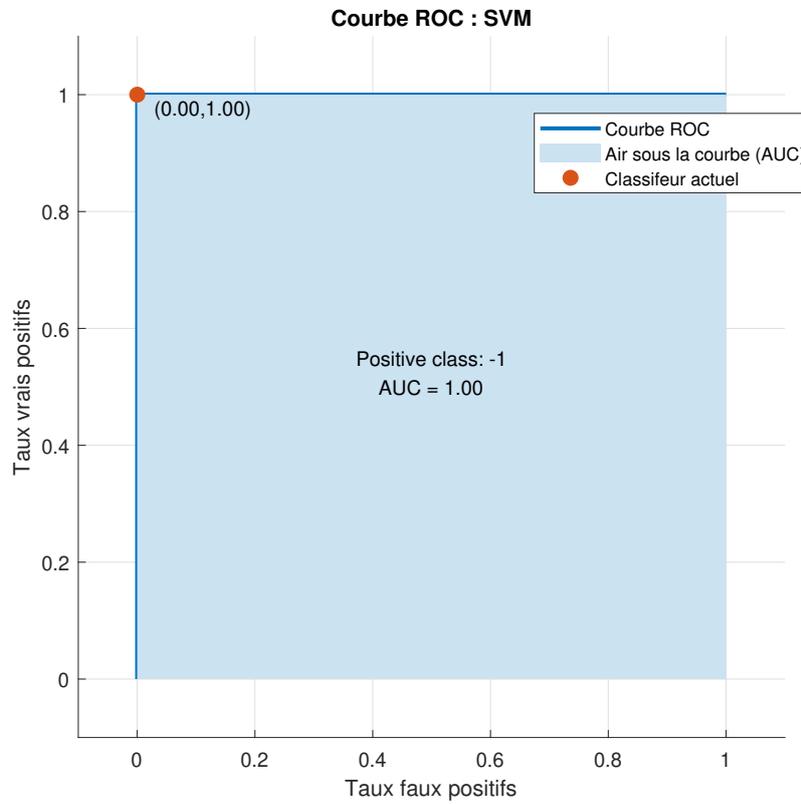


FIGURE 4.3 – La courbe ROC avec le classifieur SVM.

Tandis que la courbe ROC se définit par la présentation des vrais positifs (100%) en fonction des faux positifs on aurait l'indicateur d'évaluation $AUC=1$ qui est l'aire sous la courbe. D'après la figure 4.4 nous pouvons clairement déduire que classifieur SVM est parfait.

Afin d'évaluer encore plus les performances du système proposé, une représentation en nuage de point a été donnée dans la figure 4.4.

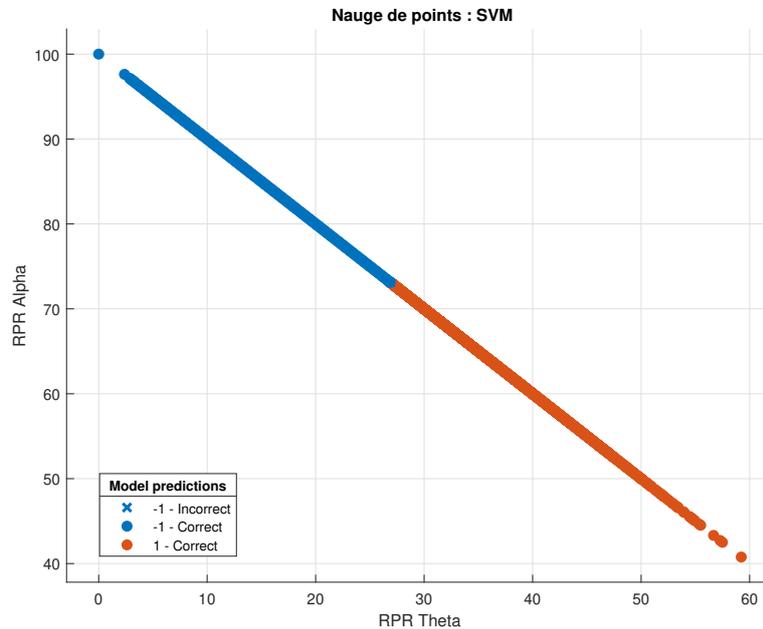


FIGURE 4.4 – Nuages de points avec le classificateur SVM.

Cette figure 4.4 nous permet d'avoir une représentation des points de la puissance relative de la bande de fréquence alpha (RPR_{α}) et la puissance relative de la bande de fréquence theta (RPR_{θ}) selon le classificateur SVM. Avec :

- **La classe (-1)** représenter avec des points bleus désigne les prédictions correctes là ou RPR_{α} est dominante par rapport à RPR_{θ} qui veut dire que le patient est en état de crise.
- **La classe (1)** représenter avec des points rouges désigne les prédictions correctes là ou RPR_{θ} est dominante par rapport à la RPR_{α} qui veut dire que le patient est dans un état stable.
- **La classe (-1)** représenter avec des crois bleu désigne les prédictions incorrectes de l'état de crise.

Contrairement à d'autres systèmes, le nôtre nécessite l'utilisation d'un seul canal (C3-P3), ce qui représenter un grand avantage en terme de coût et de confort. On ce qui concerne les mesures de performances, la matrice de confusion nous permet d'avoir un résumé des résultats obtenus par le système proposé. En effet, grâce à cette matrice nous avons eu les mesures de performance les plus importantes pour permettre l'évaluation du système. Ces performances restent très justes

avec un taux d'exactitude égal à 99.9%, et un temps de réponse inférieur à 1000ms, nous pouvons dire que les résultats sont très satisfaisants, surtout après comparaisons avec d'autres systèmes déjà proposés (voir Table 4.4). Enfin, la pertinence de cette comparaison reste relative car toutes ces techniques ont été testées sur des données différentes.

Systèmes	Notre systèmes	Rohan et al. [47]	Savadkoochi et al. [49]	Qaisar et Subasi. [46]
Base de données EEG	CHB-MIT	UCI	Multi-scale	Non renseigner
Nombres de canaux	1	Non renseigner	Non renseigner	Non renseigner
Pré-traitement	Filtre Butterworth ICA DWT	Non renseigner	Filtre Butterworth	Non renseigner
Extraction	DWT	Non renseigner	TD FD TFD	AR Burg
Nombre de caractéristiques	1	Non renseigner	4	Non renseigner
Classification	SVM	XGboost ANN	SVM KNN	SVM ANN
Temps de détection(MS)	1000	Non renseigner	Non renseigner	Non renseigner
Exactitude (%)	99.9	95,33	99.50	96.40
TVP (%)	100	Non renseigner	Non renseigner	Non renseigner
TVN (%)	99.9	Non renseigner	Non renseigner	Non renseigner
Spécificité (%)	100	94.00	100	Non renseigner
Sensibilité (%)	100	Non renseigner	99.00	Non renseigner
Sampling rate (Hz)	256	Non renseigner	173,61	173,61

TABLE 4.4 – Une étude comparative des résultats obtenus par des systèmes de détection des crises d'épilepsies basées sur le signal EEG.

4.5 Conclusion

Pour conclure ce travail, nous avons commencé dans ce chapitre par présenter les différents résultats obtenus des expérimentations effectuées sur la détection des crises d'épilepsies à l'aide du signal EEG, ainsi que des simulations qui ont été réalisées afin de valider notre système. Chaque système de détection des crises d'épilepsies est jugé selon les résultats des mesures de performances obtenus, pour notre part, ces résultats sont très encourageants. En effet, avec un taux de précision de 100%, un taux d'exactitude de 99.9%, et surtout un temps de réponse inférieur à une seconde, nous pouvons conclure que le système est très performant, mais aussi rapide à réagir ce qui est très important pour le patient. Bien sûr les résultats de notre système ont été comparés à d'autres systèmes basés sur le signal EEG, et nous avons constaté les avantages de notre système par-rapport aux autres.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

Le travail présenté dans ce mémoire avait pour objectif de créer un modèle de détection automatique des crises d'épilepsie chez l'enfant, mais aussi, apporter une contribution aux travaux déjà menés dans ce cadre. Au cours du premier chapitre, nous avons présenté les principales notions de neurophysiologie et d'électroencéphalographie dans le cas de l'épilepsie. Après avoir présenté les critères d'évaluation des systèmes existants, dans le chapitre 2, nous avons cités certains travaux sur la détection des crises d'épilepsie, que nous avons étudié et comparé grâce aux critères d'évaluation qu'on a cités. Pour améliorer la robustesse de l'étape la plus importante dans un système de détection automatique des crises d'épilepsie qui est l'extraction de caractéristiques d'un signal EEG, nous avons présenté dans le chapitre 3, le filtre Butterworth qui a été utilisé pour éliminer les artefacts, afin d'utiliser l'information EEG uniquement lorsqu'elle est de bonne qualité pour réduire le nombre de fausses alarmes. De plus, ce protocole utilise la décomposition en ondelettes discrètes afin de sélectionner uniquement les bandes alpha et thêta et éliminer les bruits dans le but de minimiser le coût de calculs et accélérer la détection en temps réel. La détection EEG est réalisée par le calcul de la puissance relative de chaque bande par rapport au signal qui sera l'entrée du classificateur afin de distinguer les deux classes. Le chapitre 4 a été consacré à la mise en œuvre de l'approche proposée, la présentation, la discussion et l'interprétation des résultats obtenus. À partir des résultats obtenus, nous avons pu constater l'importance du prétraitement qu'on a réalisé. En effet, les résultats du prétraitement des données EEG nous ont aidés à augmenter l'efficacité des étapes d'extraction et la classification, ce qui implique l'obtention d'un système plus performant.

Pour conclure ce document, nous présentons des perspectives qui feront l'objet de nos futures recherches. À commencer d'abord par la réalisation d'une application mobile pour notre système de détection et le connecter aux casques qui sont capable de capter le signal EEG afin de le mettre en œuvre sur des conditions réels. Nous espérons aussi faire une amélioration de notre système de détection, afin qu'il soit bénéfique à tout le monde, c'est-à-dire, toute personne ayant

cette maladie peut utiliser notre système, peut-import son âge.

BIBLIOGRAPHIE

- [1] Définition de l'épilepsie. <https://www.chusj.org/fr/soins-services/E/Epilepsie/Parlons-d-epilepsie/Definition>, (Consulté le 04 février 2021).
- [2] Définition de l'épilepsie. <https://www.chu-toulouse.fr/-definitions-de-l-epilepsie->, (Consulté le 04 février 2021).
- [3] La crise d'épilepsie. https://www.passeportsante.net/fr/Maux/Problemes/Fiche.aspx?doc=epilepsie_pm, (Consulté le 04 février 2021).
- [4] L'épilepsie : définition, symptômes, traitement. https://www.sciencesetavenir.fr/sante/cerveau-et-psy/l-epilepsie-definition-symptomes-traitement_12855, (Consulté le 04 février 2021).
- [5] la courbe roc. <https://springerplus.springeropen.com/articles/10.1186/s40064-016-2941-7>, (Consulté le 1 September 2021).
- [6] signaux eeg à l'aide de svm. <https://ieeexplore.ieee.org/document/7572197>, (Consulté le 1 September 2021).
- [7] Épilepsie généralisée. <https://www.futura-sciences.com/sante/definitions/medecine-epilepsie-generalisee-8088/>, (Consulté le 11 février 2021).
- [8] Filtre de butterworth. http://www.traitement-signal.com/filtre_de_butterworth.php, (Consulté le 13 juin 2021).
- [9] Prétraitement. <http://www.labos.upmc.fr/center-meg/media/meegirmf2003/Pretraitement.pdf>, (Consulté le 13 juin 2021).
- [10] Transformée en ondelettes. <http://gwyddion.net/documentation/user-guide-fr/wavelet-transform.html>, (Consulté le 13 juin 2021).
- [11] Transformée en ondelettes discrète (dwt). <https://www.intechopen.com/books/wavelet-transform-and-complexity/wavelet-transform>, (Consulté le 14 juin 2021).

Bibliographie

- [12] Confusion matrix. <https://www.lebigdata.fr/confusion-matrix-definition>, (Consulté le 18 juin 2021).
- [13] la courb roc. https://slideplayer.fr/slide/9523107/#google_vignette, (Consulté le 18 juin 2021).
- [14] La courbe roc. <https://www.xlstat.com/fr/solutions/fonctionnalites/courbes-roc>, (Consulté le 18 juin 2021).
- [15] Chb-mit scalp eeg database. <https://physionet.org/content/chbmit/1.0.0/>, (Consulté le 20 mars 2021).
- [16] organisation mondiale de la santé. <https://www.who.int/fr/news-room/fact-sheets/detail/epilepsy>, (Consulté le 23 mai 2021).
- [17] Épilepsies de l'enfant et de l'adulte. <https://www.cen-neurologie.fr/deuxieme-cycle/epilepsies-lenfant-ladulte>, (Consulté le 23 mai 2021).
- [18] artefacts. <https://samuelboudet.com/fr/EEG/artefacts.php>, (Consulté le 28 janvier 2021).
- [19] Les formes d'Épilepsie chez les enfants. <https://www.vidal.fr/maladies/systeme-nerveux/epilepsie/formes-chez-enfants.html>, (Consulté le 28 janvier 2021).
- [20] Épilepsie de l'enfant. <https://www.hellomeyko.com/fr/blog/category/epilepsie-de-lenfant>, (Consulté le 30 janvier 2021).
- [21] Eeg. <https://tpemainbionique.weebly.com/le-bci.html>, (Consulté le 31 janvier 2021).
- [22] Les signaux eeg. <https://physionet.org/files/slpdb/1.0.0/slpdb.html>, (Consulté le 31 janvier 2021).
- [23] Ali Bashashati, Mehrdad Fatourehchi, Rabab K Ward, and Gary E Birch. A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals. *Journal of Neural engineering*, 4(2) :R32, 2007.
- [24] Matthieu Caparos. *Analyse automatique des crises d'épilepsie du lobe temporal à partir des EEG de surface*. PhD thesis, Institut National Polytechnique de Lorraine, 2006.
- [25] Allée de Clerlande CHN William Lennox. L'eeg vidéo prolongé (télémétrie) en hospitalisation. pages 11–13, 2014.
- [26] Eric Laciara Correa, Agustina Garcés et Leber. Un détecteur automatique de somnolence basé sur l'analyse spectrale et la décomposition en ondelettes des enregistrements eeg. In *Conférence internationale annuelle 2010 de l'IEEE Engineering in Medicine and Biology*, pages 1405–1408.
- [27] Hisham Daoud and Magdy A Bayoumi. Efficient epileptic seizure prediction based on deep learning. *IEEE transactions on biomedical circuits and systems*, 13(5) :804–813, 2019.

- [28] Hisham Daoud, Phillip Williams, and Magdy Bayoumi. Iot based efficient epileptic seizure prediction system using deep learning. In *2020 IEEE 6th World Forum on Internet of Things (WF-IoT)*, pages 1–6. IEEE, 2020.
- [29] Junzhao et Qi Bingjuan et Huang Huajuan Ding, Shifei et Yu. Un aperçu sur les machines à vecteurs de support jumeau. *Examen d'intelligence artificielle*, 42 :245–252.
- [30] Ali Emami, Naoto Kunii, Takeshi Matsuo, Takashi Shinozaki, Kensuke Kawai, and Hirokazu Takahashi. Seizure detection by convolutional neural network-based analysis of scalp electroencephalography plot images. *NeuroImage : Clinical*, 22 :101684, 2019.
- [31] Centre intégré en neuroimagerie et neurostimulation de Québec. Eeg. <http://www.cinq.ulaval.ca/EEG>, (Consulté le 20 Mai 2021).
- [32] Ali S et Gueye Lamine Issaka, Mahamat Ali et Dabye. Localisation de la crise d'épilepsie avec une approche basée sur le psd avec un modèle autorégressif. *arXiv préimpression arXiv :1506.00947*.
- [33] J Janszky, HW Pannek, I Janszky, R Schulz, F Behne, M Hoppe, and A Ebner. Failed surgery for temporal lobe epilepsy : predictors of long-term seizure-free course. *Epilepsy research*, 64(1-2) :35–44, 2005.
- [34] Sairamya Nanjappan Jothiraj, Thomas George Selvaraj, Balakrishnan Ramasamy, Narain Ponraj Deivendran, and MSP Subathra. Classification of eeg signals for detection of epileptic seizure activities based on feature extraction from brain maps using image processing algorithms. *IET Image Processing*, 12(12) :2153–2162, 2018.
- [35] Suresh et autres Khemchandani, Reshma et Chandra. Machines à vecteurs de support jumelles pour la classification des motifs. *Transactions IEEE sur l'analyse des modèles et l'intelligence artificielle*, 29 :905–910.
- [36] Ibtissem Khouaja. *Imagerie cérébrale : Traitement et Modélisation Embarqués*. PhD thesis, Université Paris-Est, 2017.
- [37] Marcin Kołodziej, Andrzej Majkowski, and Remigiusz J Rak. Linear discriminant analysis as eeg features reduction technique for brain-computer interfaces. *Przegląd Elektrotechniczny*, 88(3 A) :28–30, 2012.
- [38] Thijs et Bejnordi Babak Ehteshami et Setio Arnaud Arindra Adiyoso et Ciompi Francesco et Ghafoorian Mohsen et Van Der Laak Jeroen Awm et Van Ginneken Bram et Sánchez Claire I Litjens, Geert et Kooi. Une enquête sur l'apprentissage en profondeur dans l'analyse d'images médicales. *Analyse d'images médicales*, 42 :60–88.
- [39] M. MILH. Traitement des épilepsies de l'enfant). pages 1–2, 2016.
- [40] M Mohammedi, Juba Mokrani, et al. *Proposition d'un protocole de détection de somnolence au volant pour une conduite sûre*. PhD thesis, université Abderrahmane Mira-Bejaia, 2020.

- [41] Manoranjan Parvez, Mohammad Zavid et Paul. Prédiction de saisie utilisant des caractéristiques globales et locales ondulées. *Transactions IEEE sur le génie biomédical*, 64 :208–217.
- [42] Abdulhamit Qaisar, Saeed Mian et Subasi. Traitement du signal eeg à fréquence adaptative pour la détection des crises d'épilepsie. In *2019 13th International Conference on Sampling Theory and Applications (SampTA)*, pages 1–3.
- [43] Laurent et Renaudin Marc Qaisar, Saeed Mian et Fesquet. Filtrage à débit adaptatif une approche de traitement du signal efficace du point de vue informatique. *Traitement du signal*, 94 :620–630.
- [44] Reda et Gharbi Tijani Qaisar, Saeed Mian et Yahiaoui. Une acquisition de signal efficace avec une conversion a/n à taux adaptatif. In *Conférence internationale IEEE 2013 sur les circuits et systèmes (ICCAS)*, pages 124–129.
- [45] Saeed Mian Qaisar. Une segmentation et un débruitage de signaux eeg efficaces en termes de calcul basés sur une acquisition et un traitement adaptatifs de la fréquence. In *2018 IEEE 3rd International Conference on Signal and Image Processing (ICSIP)*, pages 182–186.
- [46] Saeed Mian Qaisar and Abdulhamit Subasi. Effective epileptic seizure detection based on the event-driven processing and machine learning for mobile healthcare. *Journal of Ambient Intelligence and Humanized Computing*, pages 1–13, 2020.
- [47] Tanbin Islam Rohan, Md Salah Uddin Yusuf, Monira Islam, and Shidhartho Roy. Efficient approach to detect epileptic seizure using machine learning models for modern healthcare system. In *2020 IEEE Region 10 Symposium (TENSYMP)*, pages 1783–1786. IEEE, 2020.
- [48] Sameer Ranjan Sahu, Rama Krishna Sai Subrahmanyam Gorthi, and Subrahmanyam Gorthi. Epileptic seizure detection and anticipation using deep learning with ordered encoding of spectrogram features. In *2020 28th European Signal Processing Conference (EUSIPCO)*, pages 1065–1069, 2021.
- [49] Marzieh Savadkoohi, Timothy Oladunni, and Lara Thompson. A machine learning approach to epileptic seizure prediction using electroencephalogram (eeg) signal. *Biocybernetics and Biomedical Engineering*, 40(3) :1328–1341, 2020.
- [50] Ali Hossam Shoeb. *Application of machine learning to epileptic seizure onset detection and treatment*. PhD thesis, Massachusetts Institute of Technology, 2009.
- [51] Nhan Duy Truong, Anh Duy Nguyen, Levin Kuhlmann, Mohammad Reza Bonyadi, Jia-wei Yang, and Omid Kavehei. A generalised seizure prediction with convolutional neural networks for intracranial and scalp electroencephalogram data analysis. *arXiv preprint arXiv :1707.01976*, 2017.
- [52] Yang Zheng, Gang Wang, Kuo Li, Gang Bao, and Jue Wang. Epileptic seizure prediction using phase synchronization based on bivariate empirical mode decomposition. *Clinical Neurophysiology*, 125(6) :1104–1111, 2014.

RÉSUMÉ

L'épilepsie est une maladie caractérisée par un dysfonctionnement brusque et périodique au niveau du cerveau. La classification des crises d'épilepsie avec des méthodes d'apprentissage automatique est devenue la fameuse solution dans le diagnostic et la détection de l'épilepsie à travers l'utilisation de machine learning ainsi que le cloud computing sur les signaux EEG. Dans ce travail, nous avons proposé un nouveau système de détection automatique de l'avènement des crises d'épilepsie en se basant sur les technologies de communication existantes (machine learning) et le cloud computing. Le système proposé est validé par des expérimentations. Les résultats obtenus montrent que le classificateur SVM fournit des valeurs maximales de précision de classification de 100 %, une exactitude de 99,9 % et une spécificité de 100 %, une erreur quadratique moyenne minimale de 0,006 ainsi qu'un temps d'entraînement optimal de 1000 ms, ce qui rend ce modèle plus compatible en temps réel, faisant ainsi du modèle proposé une technique efficace pour la détection précoce et automatique des crises d'épilepsie en temps réel. Enfin, une comparaison avec d'autres systèmes existants dans la littérature a mis en évidence les avantages de notre système en termes de temps de détection, précision, Taux Vrais Positifs (TVP), Taux Vrais Négatifs (TVN), etc.

Mots clés : Crises d'épilepsie, Signaux EEG, Classificateur SVM, Détection automatique.

ABSTRACT

Epilepsy is a disease characterized by sudden and periodic dysfunction of the brain. The classification of epileptic seizures with machine learning methods has become the famous solution in the diagnosis and detection of epilepsy through the use of machine learning as well as cloud computing on EEG signals. In this work, we proposed a new system for automatic detection of the onset of epileptic seizures based on existing communication technologies in collaboration with machine learning and cloud computing. The proposed system is validated by experiments. The results obtained show that the SVM classifier provides maximum classification precision values of 100 %, an accuracy of 99.9 % and a specificity of 100 %, a minimum mean squared error of 0.006 as well as An optimal training time of 1000 ms, which makes this model more compatible in real time, thus making the proposed model an effective technique for the early and automatic detection of epileptic seizures in real time. Finally, a comparison with other existing systems in the literature highlighted the advantages of the proposed system in terms of detection time, precision, True Positive Rate (TPR), False Positive Rate (FPR), etc.

Key words : Epileptic seizure, EEG signals, SVM classifier, Automatic detection.