

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



Université IBN Khaldoun – Tiaret

Faculté des Mathématiques et de l'Informatique

Département d'Informatique

Laboratoire Informatique et Mathématiques (LIM)

Thèse présentée par

Sabrina AMMAR

Pour l'obtention du diplôme de

Doctorat LMD

Spécialité : Génie Informatique

Option : Systèmes Embarqués et Temps Réel

Sujet :

Analyse et Diagnostic des Données Médicales

Interprétation des Données issues de

l'EEG

Membres du jury :

M. SENOUCI Abdelkader	Université de Tiaret	Professeur	Président du jury
M. BENYAMINA Abou el Hassan	Université d'Oran	Professeur	Examineur
M. BELARBI Mostefa	Université de Tiaret	M.C.A	Examineur
M. SENOUCI Mohamed	Université d'Oran	Professeur	Rapporteur

2018/2019

REMERCIEMENTS

Le travail que nous présentons dans ce rapport de thèse de doctorat a été effectué dans le laboratoire de recherche "LIM" Laboratoire Informatique et Mathématiques de l'université de Tiaret.

J'adresse l'expression de ma très grande reconnaissance à mon directeur de thèse, Monsieur **Mohamed SENOUCI**, professeur à l'Université d'Oran, pour la confiance qu'il m'a accordée en acceptant d'encadrer et diriger mes travaux, pour ses conseils judicieux et pour l'attention qu'il a bien apportée à ce travail à divers stades de son élaboration.

Je tiens à exprimer mon profond respect à Monsieur **Abdelkader SENOUCI**, professeur à l'Université de Tiaret et directeur du laboratoire (LIM), qui m'a fait l'honneur d'accepter la présidence du jury.

Je tiens également à remercier Monsieur **Abou el Hassan BENYAMINA**, professeur à l'Université d'Oran, d'avoir accepté d'examiner et juger cette thèse.

Mes vifs remerciements s'adressent également et en particulier à Monsieur **Mostefa BELARBI**, MCA à l'Université de Tiaret, d'avoir accepté d'examiner cette thèse, pour son aide, sa coopération et ses conseil très valables, qui m'ont permis d'achever et de mener à bien ce rapport.

Effectuer une thèse de doctorat est un travail qui comporte de bons côtés comme l'apprentissage de nouveaux concepts, la découverte permanente, mais aussi des moments plus difficiles. Afin de surmonter ces derniers, le soutien des personnes qui vous entourent est indispensable. J'ai eu la chance d'avoir bénéficié de cet appui et c'est avec gratitude que je m'adresse à Monsieur **Omar TRIGUI SULTANE**, MA à l'Ecole Nationale d'Ingénieurs de Sfax, pour le remercier pour son encouragement et son aide précieuse sur le plan professionnel et personnel.

J'adresse également des expressions de reconnaissances aux membres de notre équipe de recherche LIM, ainsi qu'à tout le personnel du département informatique de l'université de Tiaret pour leurs encouragements, leurs aides, leur soutien, ainsi que leur disponibilité.

Merci à tous les membres de ma famille pour leur soutien sans limite et leurs encouragements.

Dédicace

A toute ma famille ...

A mes chers parents

A mes princes Faical, Mohamed et Sid Ahmed.

A mes princesses Maria, Hind, Rimasse et Amira.

Table des matières

Introduction générale.....	1
----------------------------	---

Chapitre 1: La technique Electroencéphalographique EEG

1.1.Introduction.....	6
1.2.Neurophysiologie.....	7
1.2.1.Structure du cerveau.....	7
1.2.2.Structure des neurones.....	9
1.2.3.Fonctionnement des neurones.....	11
1.3.Notions de base de l'EEG.....	14
1.3.1.Montages EEG.....	17
1.3.1.1.Montages bipolaires.....	17
1.3.1.2.Montage en référence commune.....	18
1.3.1.3.Montage en référence moyenne.....	18
1.3.1.4.Montage en référence moyenne pondérée ou Laplacien.....	18
1.3.2.Les rythmes corticaux.....	19
1.3.3.Les perturbations.....	21
1.3.3.1.Les artefacts.....	21
1.3.3.2.Le bruit.....	23
1.4.Structure générale d'un système automatique de détection des crises épileptiques.....	23
1.4.1.Prétraitements.....	24
1.4.2.Extraction des caractéristiques.....	25
1.4.3.Classification.....	26
1.5.Conclusion.....	27

Chapitre 2 : Généralité sur L'épilepsie

2.1.Introduction.....	29
2.2.Définition.....	30
2.3.Aperçu historique.....	30
2.4.Epidémiologie.....	32
2.4.1.Incidence.....	32
2.4.2.Prévalence.....	32
2.4.3.Mortalité.....	33

Table des matières

2.5.Pathogénie (mécanisme	33
2.6.Les multi-modalités pour le diagnostic d'épilepsie	34
2.6.1.Données cliniques	35
2.6.2.Données anatomiques et fonctionnelles (L'imagerie médicale).....	35
2.6.2.1.Tomographie par Emission de Positons (TEP)	36
2.6.2.2.Tomographie par Emission Monophotonique (TEMP)	37
2.6.2.3.Imagerie par Résonance Magnétique (IRM).....	38
2.6.2.4.Imagerie par Résonance Magnétique fonctionnelle (IRMf)	38
2.6.2.5.Tomodensitométrie	39
2.6.3.Données électrophysiologiques	40
2.6.3.1.Méthodes non invasives	40
2.6.3.2.Méthodes invasives.....	44
2.6.3.3.Conclusion sur les modalités d'exploration cérébrale	46
2.7.Causes de l'épilepsie.....	48
2.8.Classification internationale d'épilepsie	49
2.8.1.Classification de l'épilepsie	49
2.8.1.1.Les crises partielles	50
2.8.1.2.Les crises généralisées	51
2.8.1.3.Les crises inclassables.....	52
2.8.2.Classification des épilepsies et des syndromes épileptiques	52
2.8.2.1.Les épilepsies idiopathiques.....	52
2.8.2.2.Les épilepsies cryptogéniques	52
2.8.2.3.Les épilepsies symptomatiques	52
2.8.3.Révision terminologique et conceptuelle	53
2.9.Prise en charge.....	55
2.9.1.Pharmacologique (médicamenteux	55
2.9.2.Chirurgie	55
2.9.3.Stimulation du nerf vague.....	56
2.9.4.Le gamma knife (GK.....	56
2.10.Conclusion.....	57

Chapitre 3 : Etude des systèmes de détection automatique des crises épileptiques

3.1.Introduction.....	59
3.2.Etat de l'art en méthodes de détection automatique des crises épileptiques.....	60

3.3.Détection des crises épileptiques avec l'EEG monocanal en utilisant l'ELM et le SVM ..62	
3.3.1.Extraction des caractéristiques avec la transformée en ondelette	63
3.3.1.1.Transformée en ondelettes	65
3.3.1.2.Analyse multi résolution	68
3.3.2.Extraction des caractéristiques.....	69
3.3.2.1.Méthode de Burg pour l'estimation de la densité spectrale de puissance.....	69
3.3.2.2.Variance et écart type.....	71
3.3.2.3.Skewness	72
3.3.2.4.Kurtosis	73
3.3.3.Classification.....	74
3.3.3.1.Séparateur à vaste marge.....	75
3.3.3.2.Réseau de neurones.....	78
3.4.Résultats d'évaluation de la méthode proposée	87
3.4.1.Base de données	87
3.4.2.Résultats.....	90
3.5.Conclusion.....	92
Chapitre 4: Méthode auto-adaptative proposée pour la détection des crises épileptiques	
4.1.Introduction	94
4.2.Etat de l'art en méthodes spécifiques au patient de détection automatique des crises épileptiques	95
4.3.Nouvelle approche proposée	96
4.3.1.Bloc de traitement	97
4.3.1.1.Prétraitement.....	99
4.3.1.2.Extraction des caractéristiques	105
4.3.1.3.Classification avec l'analyse discriminante linéaire	109
4.3.2.Bloc d'adaptation des paramètres	110
4.3.2.1.Algorithme génétique.....	112
4.4.Modélisation UML	113
4.4.1.Les diagrammes UML.....	114
4.4.2.Identification des cas d'utilisation	115
4.4.2.1.Définition du diagramme de cas d'utilisation	115
4.4.2.2.Les packages de cas d'utilisation.....	115
4.4.3.Le diagramme de classes	119

Table des matières

4.4.4.Le diagramme de Séquence	122
4.4.5.Le diagramme d'activité	125
4.4.5.1.Diagramme d'activité « recherche des paramètres optimaux	125
4.4.5.2.Diagramme d'activité « détection automatique des classes et calcul des performances du système	126
4.5.Résultats d'évaluation de la méthode proposée	127
4.5.1.Résultat du processus de tamisage	127
4.5.2.Comparaison entre l'EMD et l'EEMD.....	129
4.5.3.Optimisation des paramètres du système	131
4.5.4.Etude de la complexité de la méthode proposée.....	135
4.5.5.Evaluation de la méthode proposée.....	136
4.6.Conclusion.....	140
Conclusion et perspectives.....	142
Références.....	145

Liste des figures

Figure 1.1: Architecture du cerveau humain.....	7
Figure 1.2: Organisation somatotopique du cortex moteur primaire	9
Figure 1.3: Structure d'un neurone	10
Figure 1.4: Structure de la membrane cellulaire	10
Figure 1.5: Génération d'un potentiel d'action d'un neurone	12
Figure 1.6: Cellule pyramidale créant un dipôle de courant.....	13
Figure 1.7: Premier enregistrement des signaux EEG réalisés par Hans Berger, (a) Hans Berger (1873-1941), (b) Enregistrements d'EEG réalisés par Berger et (c) Patient de Berger 14	
Figure 1.8: Vue sagittale du positionnement des électrodes selon le système international 10-20.....	16
Figure 1.9: Vue axiale du positionnement des électrodes selon le système international 10-20.....	16
Figure 1.10: Exemple des différents rythmes corticaux du signal EEG à l'ordre du micro volt par rapport au temps (1 seconde) chez un être humain	20
Figure 1.11: EEG normal d'un adulte	21
Figure 1.12: Signal EEG contaminé avec l'artefact de tremblements de visage.....	22
Figure 1.13: Blocs fonctionnels d'un système automatique de détection des crises épileptiques	24
Figure 1.14: Exemples de deux crises épileptiques de la base de données CHB-MIT. Quatre canaux d'enregistrement EEG de crise épileptique du Patient 1, (a) fichier chb01-04 et (b) fichier chb01-15	26
Figure 2.1: Equilibre entre les événements excitateurs et inhibiteurs au niveau synaptique ...	34
Figure 2.2: Tomographie par Emission de Positons.....	36
Figure 2.3 : Tomographie par émission monophotonique.....	37
Figure 2.4: Résultats d'IRM d'un patient épileptique	38

Liste des figures

Figure 2.5: La mesure des réponses cérébrales au moyen de l'imagerie par résonance	39
Figure 2.6: La technique Tomodensimétrie TDM	40
Figure 2.7: L'Electroencéphalographie (EEG)	41
Figure 2.8: Exemple de motifs épileptiques	42
Figure 2.9: Exemple de crises épileptiques. Les flèches marquées sur la figure indiquent les points du déclenchement des crises	42
Figure 2.10: Différence entre l'EEG épileptique et l'EEG non-épileptique.....	43
Figure 2.11: Technique de mesure MEG.....	44
Figure 2.12: Stéréo-Electroencéphalogramme, (a) l'électrode SEEG et (b) Implantation d'électrodes SEEG	45
Figure 2.13: Grille d'électrodes placée sur le cortex d'un patient	46
Figure 2.14: Schéma comparatif des résolutions temporelles et spatiales et du caractère invasif des différentes techniques d'exploration de l'activité cérébrale	47
Figure 2.15: Classification par saisie selon ILAE.....	50
Figure 2.16: Classification des crises épileptiques.....	54
Figure 2.17: Stimulation du nerf vague	56
Figure 2.18: Le gamma knife	57
Figure 3.1: Schéma de principe de la méthode proposée	63
Figure 3.2: Exemple d'ondelettes extraites d'un signal de durée de 2 s.....	64
Figure 3.3: Niveaux de décomposition du signal EEG échantillonné à 256 Hz.....	64
Figure 3.4: Principe de l'algorithme de Mallat.....	68
Figure 3.5: Décomposition par ondelettes	69
Figure 3.6: Types de Skewness	73
Figure 3.7: Variation du Kurtosis suivant la fonction de densité de probabilité	74
Figure 3.8: Séparation entre deux nuages de points par l'hyperplan H.....	75
Figure 3.9: Les vecteurs de support.....	76

Liste des figures

Figure 3.10: Hyperplan de marge maximale pour l'SVM.....	76
Figure 3.11: Création de l'espace de re-description pour la séparation des classes. (a) nuages de points de classes non-linéairement séparables, (b) transformation des points vers un espace de plus grande dimension pour la division des classes par un hyperplan avec la plus grande marge et (c) en revenant dans l'espace de départ, la frontière de décision est non-linéaire	77
Figure 3.12: Structure d'un neurone à une seule entrée	79
Figure 3.13: Structure d'un neurone à plusieurs entrées	80
Figure 3.14: Un Perceptron multicouche.....	83
Figure 3.15: Positions des canaux et des électrodes utilisés	88
Figure 4.1: Schéma de principe de la méthode proposée	97
Figure 4.2: Schéma de principe du bloc de traitement	98
Figure 4.3: Exemple d'extraction d'IMF.....	102
Figure 4.4: Organigramme de l'EMD	103
Figure 4.5: Décomposition du signal original en un nombre finie d'IMF et un résidu.....	104
Figure 4.6: Démonstration schématique de l'estimation de l'entropie.....	108
Figure 4.7: Méthode de sélection des paramètres	111
Figure 4.8: Mécanisme d'algorithmes génétiques	113
Figure 4.9: Les 4+1 vues d'un système	114
Figure 4.10: Package cas d'utilisation.....	115
Figure 4.11: Les cas d'utilisation du package de détection automatique des crises épileptiques	116
Figure 4.12: Diagramme de classes.....	120
Figure 4.13: Diagramme de séquence « choix des données d'apprentissage et de test1».....	122
Figure 4.14: Diagramme de séquence « recherche des paramètres optimaux»	123
Figure 4.15: Diagramme de séquence « détection automatique des crises épileptiques»	124
Figure 4.16: Diagramme de séquence « calculer des performances du système»	124

Liste des figures

Figure 4.17: Diagramme d'activité de la recherche des paramètres optimaux.....	125
Figure 4.18: Diagramme d'activité de la détection automatique des classes et calcul des performances du système.....	126
Figure 4.19: Résultats du processus de tamisage de l'IMF1 à l'IMF5 (2048 échantillons)...	128
Figure 4.20: Résultats du processus de tamisage de l'IMF6 au résidu (2048 échantillons)...	129
Figure 4.21: Décomposition du signal d'origine en un ensemble d'IMF et un résidu (a) avec la méthode EMD et (b) avec la méthode EEMD	130
Figure 4.22: Spectre temps-fréquence: (a) en utilisant l'EMD (b) en utilisant l'EEMD	130
Figure 4.23: Composition du chromosome.....	132

Liste des tableaux

Tableau 1.1: Signification des lettres utilisées dans la nomenclature des électrodes.....	17
Tableau 2.1: Comparaison entre les différentes techniques d'exploration cérébrale pour le diagnostic des épilepsies.	48
Tableau 3.1: Bondes d'ondelettes utilisées dans la détection des crises	65
Tableau 3.2: Exemple de noyaux utilisés pour la création de l'espace de re-description	78
Tableau 3.3 : Détails des patients	89
Tableau 3.4: Évaluation de la méthode basée sur la transformé en ondelettes	90
Tableau 4.1: Caractéristiques utilisées pour la quantification de la crise épileptique.....	106
Tableau 4.2: Documentation du cas d'utilisation diviser les données en apprentissage, test1 et test2.....	117
Tableau 4.3: Documentation du cas d'utilisation rechercher les paramètres optimaux	118
Tableau 4.4: Documentation du cas d'utilisation détecter automatiquement les classes des segments.....	118
Tableau 4.5: Documentation du cas d'utilisation calculer les performances du système	119
Tableau 4.6: Les classes et leurs rôles	121
Tableau 4.7: Sélection des meilleurs paramètres : Longueur de la période, nombre de segments, le taux de chevauchement, Caractéristiques extraites et canaux (Chb 01-Chb 14)	133
Tableau 4.8: Sélection des meilleurs paramètres : Longueur de la période, nombre de segments, le taux de chevauchement, Caractéristiques extraites et canaux (Chb 15- Chb 23) ...	134
Tableau 4.9: Temps de calcul nécessaire pour l'adaptation des paramètres de tous les patients	136

Liste des tableaux

Tableau 4.10: Performances du système proposé	137
Tableau 4.11: Évaluation des méthodes	138

Liste d'abréviations

AdaLiNe :	Adaptative Linear Neuron
ADN:	Acide Désoxyribonucléique
Ag/AgCl :	Argent/Chlorure d'argent
ApEn :	Approximate Entropy
AR:	Autoregressive
Cl ⁻ :	Chlorure
CP :	Conditional Probability
CT-scan :	Computerized Tomography Scan
DF :	Dimension Fractal
DWT :	Discret Wavelet Transform
ECG :	Electrocardiogramme
ECoG :	Electrocorticographie
EEG:	Electroencéphalographies
EEMD :	Ensemble Empirical Mode Decomposition
ELM :	Extrême Learning Machine
EMD:	Empirical Mode Mecomposition
EMG :	Electromyogramme
EOG :	Electro-oculogramme
FFRE :	Fondation Française pour la Recherche sur l'Épilepsie
GA :	Genetic Algorithm
GK :	Gamma knife
GPU:	Graphical Processing Unit
H :	Habitants
ILAE:	International League Against Epilepsy
IMF:	Intrinsic Mode Functions
IRM :	Imagerie par Résonance Magnétique
IRMf :	Imagerie par Résonance Magnétique Fonctionnelle

List d'abréviations

K+ :	Potassium
LDA :	linear Discriminant Analysis
LICE :	ligue Internationale Contre l'Epilepsie
MEG :	Magnétoencéphalographie
MLP :	Multilayer Perceptron
Na+ :	Sodium
NN :	Neural Networks
OMS :	Organisation Mondiale de la Santé
PCA :	Principal Component Analysis
PED :	Pays En Développement
PPSE :	Potentiel Postsynaptique Excitateur
PPSI :	Potentiel Postsynaptique Inhibiteur
PSD :	Power Spectral Density
PSE :	Personnes Souffrant d'Epilepsie
RBF :	Radial Basis Function
RFR :	Réseau à Fonctions de base Radiales
SD :	Standard Deviation
SEEG :	Stéréo-Electroencéphalogramme
SLFN :	Single Hidden Layer Feedforward Neural Network
SNC :	Signal to Noise Ratio
SPECT :	Single Photon Emission Computed Tomography
SVM :	Séparateur à Vaste marge / Support Vector Machine
TDM :	Tomodensitométrie
TEMP :	Tomographie par Emission Monophotonique
TEP :	Tomographie par Emission de Positrons
TO :	Transformée en Ondelette
TOD :	Transformée en Ondelettes Discrètes
UML :	Unified Modeling Language
ZE :	Zone Epileptogène

Résumé

La compréhension du fonctionnement du cerveau est l'un des défis majeurs des neurosciences. Pour appréhender cet organe in vivo, de nombreux dispositifs se sont développés, parmi lesquels on trouve l'électroencéphalographie (EEG). Elle mesure directement d'une manière non invasive les signaux du cerveau avec une haute résolution temporelle et fait le suivi de l'activité cérébrale pendant une tâche spécifique.

Cette thèse s'inscrit dans le contexte de l'analyse et de la classification des signaux EEG. En particulier, nous nous intéressons à la détection automatique des crises épileptiques. La problématique principale ici est de garantir le plus haut taux de sensibilité.

L'étude bibliographique et l'implémentation de la méthode basée sur la transformée en ondelettes menées ont permis de mieux comprendre le système de détection des crises et ses différents blocs. Elles ont notamment mis en évidence l'avantage d'utiliser une méthode spécifique au patient. Étant donné que les signaux EEG des crises d'un patient peuvent ressembler largement aux signaux EEG normaux d'un autre patient, une méthode spécifique au patient permet d'atteindre de meilleures performances que celles d'une méthode non spécifique au patient.

Sur la base de ces constatations, nous avons proposé une nouvelle méthode spécifique au patient qui permet de choisir et de calibrer le nombre maximum de paramètres pour chaque patient. Le signal EEG observé est tout d'abord décomposé en une somme de fonctions de mode intrinsèque (IMF) par la décomposition en mode empirique (EMD). Cette technique joue le rôle d'un filtre non linéaire qui sépare les IMF pertinentes des IMF contenant le bruit et les artefacts. Ainsi, seules les IMF contenant des informations utiles pour la séparation entre les classes seront utilisées pour le reste du système. Dans la phase suivante, 14 caractéristiques sont utilisées comme représentation plus facile à interpréter du signal. L'analyse discriminante linéaire, qui a prouvé son efficacité dans la littérature, a été utilisée pour séparer les segments épileptiques des segments sans crises. Finalement, l'algorithme génétique a été utilisé pour la phase de calibrage des paramètres du système suivant le patient.

Les résultats trouvés avec des données EEG réelles montrent que notre méthode proposée a surpassé plusieurs méthodes de la littérature.

Résumé

Mots clefs : Signaux Electroencéphalogrammes, Crise Epileptique, Méthode Spécifique au Patient, Transformée en Ondelettes, Décomposition en Mode Empirique, Apprentissage Machine Extrême, Analyse Discriminante Linéaire, Algorithme Génétique.

Abstract

Understanding how the brain works is one of the major challenges of neuroscience. To figure out this organ in vivo, many devices are developed such as the electroencephalography (EEG). It is a direct and a non-invasive approach to measure the brain signals with high temporal resolution and to monitor the cerebral activity during a specific task.

This thesis is a part of many research works aiming to analyse and classify the EEG signal. In particular, we are interested in the automatic seizure detection. The main problem here is to ensure the highest sensitivity.

The bibliographic study and the implementation of the method based on the wavelet transform led to a better understood of the crisis detection system and its different blocks. Actually, they highlighted the advantage of using a patient-specific method. Since the EEG signals of one patient's seizures may be largely similar to the normal EEG signals of another patient, a patient-specific method achieves better performance than a non-patient-specific one.

On the basis of these statements, we proposed a new patient-specific method that allows the choice and the calibration of the maximum number of parameters for each patient. The observed EEG signal is firstly decomposed into a number of Intrinsic Mode Functions (IMF) by the Empirical Mode Decomposition (EMD). This technique acts as a nonlinear filter that separates the relevant IMFs from the noise and the artifacts. Thus, only the IMFs that contain useful information for the classification will be used in the next system steps. 14 features are used as a signal representation easier to interpret. Then, the linear discriminant analysis, which was found effective in the literature, is used to separate seizure from seizure-free segments. Finally, the genetic algorithm is used for the calibration phase of the system parameters according to each patient.

Results found with real EEG data show that our method surpassed several methods of the literature.

Key words: Electroencephalogram Signals, Epileptic Seizure, Patient Specific Method, wavelet Transform, Empirical Mode Decomposition, Extreme Machine Learning, Linear Discriminant Analysis, Genetic Algorithm.

Introduction générale

Introduction générale

Un système de détection automatique des crises épileptiques est un système qui permet d'analyser les signaux cérébraux émis par le cerveau de façon automatique afin de discerner si des crises existent. Il crée un nouveau moyen d'investigation automatique d'heures d'enregistrements EEG pour générer un rapport qui indique le début et la fin de chaque crise rencontrée. Cette approche limite l'investigation visuelle indispensable par le neurologue aux segments de données classés automatiquement comme représentatifs de la crise épileptique. Le système doit donc utiliser les propriétés spatiales (la zone cérébrale impliquée), temporelle et fréquentielle de la séquence des états mentaux qui forment les crises pour distinguer les différentes classes (crise/normal). L'objectif est d'atteindre la sensibilité du système la plus élevée avec une spécificité acceptable puisque le neurologue inspectera les périodes épileptiques et non pas les périodes sans crises.

La détection automatique des crises épileptiques à partir des signaux EEG est un sujet d'actualité de plus en plus intégré dans le traitement de cette maladie. Ce domaine de recherche est en croissance continue aussi bien dans la compréhension de la maladie et de son effet sur les caractéristiques du cerveau et des signaux qu'il génère que dans le développement de nouvelles techniques de traitement du signal qui respectent mieux les propriétés des signaux cérébraux. Durant ces dernières années, les techniques utilisées pour la conception de ces systèmes se sont largement développées. Ainsi, des nouvelles méthodes de traitement du signal apparaissent régulièrement dans le but d'améliorer les performances des systèmes pour consolider les résultats finaux trouvés par le neurologue. Cependant, malgré les développements technologiques, il existe de nombreux obstacles devant la construction d'un système efficace. En effet, la contamination de ces signaux EEG par des artefacts physiologiques et non physiologiques rend leur interprétation une tâche ardue et difficile. D'autre part, les crises épileptiques se développent comme les résultats de différents troubles, ce qui provoque des variations significatives des types de crises chez les patients (variabilité inter-patient). En plus, de nombreuses similitudes entre les segments épileptiques et les segments non-épileptiques ainsi que des fortes variations au sein de chaque type peuvent être rencontrées. Ceci affaiblit la capacité de discrimination des caractéristiques extraites, et rend leur choix une tâche délicate. Également, la variation des régions du cerveau où les crises sont apparues ajoute un autre degré de complexité. D'autre part, le cerveau est un organe

complexe qui délivre des signaux non linéaires et non stationnaires qu'il faut tenir en compte lors de la conception du système. Toutes ces problématiques peuvent affaiblir la précision et l'efficacité du système. Dans la littérature, il est courant de mesurer les performances des systèmes en fonction de la sensibilité, qui reflète la capacité du système à détecter les segments épileptiques, et en fonction de la spécificité, qui reflète sa capacité à détecter les périodes sans crises. Les systèmes efficaces qui garantissent les interprétations des experts les plus précises possèdent une sensibilité élevée. Ainsi, l'avenir de la technologie de détection automatique des crises épileptiques repose sur l'amélioration des taux de sensibilité.

Les travaux dans cette thèse sont concentrés sur l'aspect de traitement du signal EEG relatif à la conception d'un système de détection automatique des crises épileptiques. Ils s'inscrivent dans l'ensemble des travaux visant à fournir de nouvelles méthodes pour améliorer la sensibilité. Les objectifs de cette thèse sont tous clairement inscrits dans une problématique biomédicale. Il s'agit de concevoir des méthodes et des outils de traitement des signaux physiologiques à des fins diagnostics des crises épileptiques. Ainsi, le but est de mieux définir et localiser le plus précisément possible les segments de crises dans le signal EEG afin de garantir des meilleures performances du système. Pour atteindre ces objectifs, il est nécessaire d'exploiter au mieux le signal EEG en tenant compte de ses propriétés et des différents facteurs qui l'affaiblissent. Ainsi, nous avons commencé par étudier le processus d'acquisition de données, les caractéristiques des signaux électroencéphalographies (EEG) qui pourraient être exploitées pour implémenter le système et les méthodologies de traitement du signal pour l'extraction et la classification des caractéristiques. L'étude des systèmes disponibles dans la littérature montre que les systèmes spécifiques au patient présentent les meilleures performances. Ainsi, une grande partie de ce travail est consacrée à la proposition d'une nouvelle méthode spécifique au patient avec des performances plus élevées.

La méthodologie de recherche, suivie dans la réalisation des objectifs spécifiés, est conforme avec la méthodologie générale de la recherche, à savoir :

- Etude des différentes approches/méthodes existantes pour la détection des crises épileptiques pour l'évaluation de leurs performances ainsi que leurs limites;
- Evaluation de la pertinence d'élaborer une approche/méthode basée sur celles qui existent déjà et qui correspondent au niveau d'avancement actuel dans le domaine des systèmes de détection automatiques des crises épileptiques;
- Proposition de nouvelles approches/méthodes de détection;
- Test et validation des méthodes proposées en utilisant des données réelles.

Contribution de la thèse

Le but de la thèse est de concevoir un système de détection automatique des crises épileptiques efficace visant une meilleure sensibilité que les systèmes présents dans la littérature. Le premier objectif est de proposer un système efficace et satisfaisant en termes de taux de précision et du taux de sensibilité qui sont les premiers soucis dans la réalisation d'une application crédible.

Pour atteindre ces objectifs, nous avons commencé par étudier les méthodes proposées dans la littérature afin de comprendre leurs limites. Nous avons ensuite étudié les méthodes qui respectent la non-linéarité et la non-stationnarité des signaux cérébraux. Ces algorithmes doivent être adaptés pour l'utilisation dans le domaine de détection des crises épileptiques.

Ainsi, nous avons implémenté et testé la méthode basée sur la transformée en ondelettes qui est considérée comme l'une des méthodes les plus prometteuses dans la littérature.

Vu le grand succès des méthodes spécifiques au sujet, nous nous sommes intéressés à ce type de systèmes. Nous avons commencé par étudier leurs avantages et leurs inconvénients.

Nous avons ainsi examiné les paramètres qui peuvent agir sur les performances des systèmes voire le nombre de segments par période analysée, la longueur du segment, le taux de chevauchement entre les segments et les canaux et caractéristiques intervenant dans le traitement de l'EEG. Ensuite, nous avons proposé une nouvelle méthode spécifique au sujet qui utilise la décomposition en mode empirique pour le prétraitement, 14 caractéristiques des domaines temporels et fréquentiels pour la représentation du phénomène étudié, l'analyse discriminante linéaire pour la classification et l'algorithme génétique pour la sélection des paramètres du système les plus adéquats pour chaque patient.

Organisation du document

Le rapport de la thèse est organisé en quatre chapitres :

Dans un premier chapitre, les compétences et les connaissances nécessaires à la conception d'un système de détection automatique des crises épileptiques seront expliquées et détaillées. Le deuxième chapitre présentera l'épilepsie et les principales connaissances nécessaires pour comprendre cette maladie.

Dans le troisième chapitre, nous exposerons un état de l'art sur les systèmes de détection les plus connus. Ensuite, nous présenterons en détail la méthode basée sur la transformée en

Introduction générale

ondelettes et les résultats de l'implémentation de cette méthode avec des signaux EEG réels. Nous allons nous intéresser dans le quatrième chapitre aux systèmes spécifiques au patient. Ainsi, nous allons commencer par présenter le principe de ces méthodes en suite nous passerons à la nouvelle méthode que nous avons proposée.

Une conclusion générale résumera l'ensemble de nos contributions ainsi que quelques perspectives ouvrant le chemin pour de futurs travaux.

Chapitre 1

La technique Electroencéphalographique EEG

Chapitre 1: La technique Electroencéphalographique EEG

1.1. Introduction

1.2. Neurophysiologie

1.3. Notions de base de l'EEG

1.4. Structure générale d'un système automatique de détection des crises épileptique

1.5. Conclusion

1.1. Introduction

Le principe d'un système automatique de détection des crises épileptiques est de détecter l'activité cérébrale et de la convertir en classes qui expriment la présence ou l'absence de la crise dans le segment de données analysées. Ce vecteur de classes sera envoyé vers le neurologue sous forme d'un rapport qui indique le début et la fin de chaque crise.

La transcription des activités cérébrales vers ce rapport n'est pas un travail aisé et nécessite des compétences variées. Le développeur d'un tel système doit avoir des connaissances en neurophysiologie pour comprendre l'origine et les caractéristiques des différentes activités cérébrales étudiées. Par exemple, quelles sont les propriétés des signaux EEG recherchés et les artefacts qui peuvent les contaminer. De même, des connaissances en matière de technologies de mesure des données électrophysiologiques sont primordiales afin de comprendre la nature du signal traité et la façon dans laquelle il reflète les informations du phénomène étudié. Après l'acquisition des signaux, des connaissances profondes des méthodes de traitement du signal sont nécessaires pour concevoir un système de détection de hautes performances.

Ce chapitre sera dédié à l'introduction et à la description de ces thématiques. La première partie a pour objectif de mettre en évidence la source des activités cérébrales et plus particulièrement le mécanisme de la création des signaux électrochimiques. La seconde partie montre la principale technologie utilisée pour quantifier les activités épileptiques. La dernière partie présente la structure générale d'un système de détection automatique des crises épileptiques.

1.2. Neurophysiologie

La neurophysiologie est la science qui s'intéresse à l'étude de l'anatomie et au fonctionnement du système nerveux (niveau moléculaire jusqu'aux réseaux neuronaux).

Le système nerveux humain est composé, comme tous les vertébrés, d'un système nerveux central (encéphale et moelle épinière) et d'un système nerveux périphérique (nerfs). Il est responsable de l'envoi, la réception et le traitement des influx nerveux. Anatomiquement, l'encéphale peut être divisé en trois parties principales : le cerveau, le tronc cérébral et le cervelet [Gra2002], comme l'illustre la figure 1.1.

Le cerveau est le système biologique le plus complexe du corps humain. Sa protection est assurée essentiellement à l'aide de la boîte crânienne. Il remplit les fonctions de régulations des autres organes, mais également les fonctions cognitives permettant de ressentir l'environnement, de penser et d'y réagir [Rom2010].

1.2.1. Structure du cerveau

La figure 1.1 illustre la topologie générale du cerveau humain.




Figure 1.1: Architecture du cerveau humain [Tri2017].

Le cerveau se compose de deux hémisphères, droit et gauche, quasi-symétriques [Art2012]. Le cortex cérébral est la couche externe du cerveau. Il comprend une écorce de plusieurs couches de cellules et il possède une surface fortement plissée présentant des scissures et des

sillons. Le cortex peut être divisé en quatre zones ou lobes selon les fonctions cognitives [Bes2007].

- **Le lobe frontal :** C'est la partie avant du cerveau. Il est responsable du contrôle des mouvements volontaires. De même, il intervient dans les fonctions liées à la planification et au langage;
- **Le lobe pariétal :** C'est la partie située derrière le lobe frontal dans la partie supérieure du cerveau. Il est responsable essentiellement des fonctions somato-sensoriel qui assurent le traitement des informations en provenance de la peau comme la chaleur et la texture;
- **Le lobe occipital :** C'est la partie arrière du cerveau. Il est responsable des fonctions liées à la vision;
- **Le lobe temporal :** C'est la partie qui se situe entre l'arcade auxiliaire et l'oreille. Il intervient dans certaines fonctions sensorielles, émotionnelles, de mémorisation et de compréhension.

Le cortex cérébral est divisé en plusieurs aires fonctionnelles dont chacune assure une fonction cognitive précise. Les aires motrices (cortex moteur) sont situées dans la partie postérieure du lobe frontal, contigu le sillon central. L'aire motrice primaire ou cortex moteur primaire, également appelée M1, est le centre de la commande motrice. Son activité est à l'origine de la planification, du contrôle et de l'exécution des mouvements volontaires [Bio2005]. Chaque organe moteur est relié à une région spécifique comme illustré dans la figure 1.2.

Le système nerveux est essentiellement constitué par les neurones. Il existe plus de 100 milliards de neurones dans le système nerveux humain, dont un peu moins de 20 milliards dans le cortex [Aze2009].




Figure 1.2: Organisation somatotopique du cortex moteur primaire [Bio2005].

Afin de comprendre la source des activités cérébrales, il faut d'abord comprendre la structure des neurones.

1.2.2. Structure des neurones

Un neurone est divisé en trois éléments principaux comme illustré dans la figure 1.3 [Cos2009]:

- **Corps cellulaire :** Cette partie dispose de tous les éléments essentiels qui constituent une cellule, tels que le noyau qui contient de l'ADN (Acide Désoxyribonucléique);
- **Les axones :** Cette partie sous forme de câble mince et long transporte les messages électrochimiques tout au long de la cellule. Les axones des neurones sensoriels et moteurs sont recouverts d'une fine couche de myéline, comme un fil électrique isolé. La myéline est faite de matières grasses, et elle permet d'accélérer la transmission d'une impulsion nerveuse vers le bas d'un long axone;
- **Les dendrites ou les terminaisons nerveuses :** Cette partie permet d'établir une connexion avec d'autres cellules voisines [Alb2016].




Figure 1.3: Structure d'un neurone.

La membrane plasmique neuronale délimite le contour de la cellule et assure la séparation entre le compartiment extra cellulaire du compartiment intra cellulaire. Elle est constituée de lipides et de protéines. Les phospholipides sont des lipides complexes qui interviennent dans la création et la transmission des messages électrochimiques [Cos2009].




Figure 1.4: Structure de la membrane cellulaire.

Chaque phospholipide a une tête collée à l'eau et deux terminaisons qui ne doivent jamais être en contact avec l'eau. Les têtes et les queues forment une barrière entre l'intérieur et l'extérieur de la cellule comme représenté dans la figure 1.4 [Cos2009]. Cela interdit le mouvement des particules hydrosolubles ou chargées électriquement comme les ions à travers la membrane neuronale. Cependant, la membrane de la cellule dispose de petits tunnels ou canaux (des protéines spécialisées) à travers lesquels les ions qui sont hydrosolubles et chargés peuvent se déplacer.

1.2.3. Fonctionnement des neurones

Chaque canal est spécifique pour un seul type d'ion. Il existe en particulier des canaux spécifiques pour les ions de sodium (Na^+), les ions de potassium (K^+) et les ions de chlorure (Cl^-). Ces canaux rendent la membrane cellulaire sélectivement perméable pour divers ions et autres substances (comme le glucose) [Kir2009]. Ceci permet d'avoir une différence entre la composition de ce qui est à l'intérieur et à l'extérieur. Par exemple, le fluide extracellulaire est riche en sodium, une concentration environ 10 fois supérieure à celle du fluide à l'intérieur. Par contre, le fluide intracellulaire est riche en potassium avec une concentration environ 20 fois plus élevée que celle à l'extérieur. Il y a aussi une grande quantité de protéines chargées négativement à l'intérieur de la cellule et qui sont trop grosses pour passer à travers la membrane. Cette inégalité des ions de part et d'autre de la membrane plasmique crée à l'intérieur de la cellule une charge électrique négative par rapport à la charge de l'extérieur ce qui donne naissance au potentiel membranaire. Le potentiel de repos est d'environ -70 à -80 millivolts (mV). Certains canaux restent toujours ouverts afin de contribuer à l'établissement de ce potentiel [Cos2009].

Les stimuli (thermiques, mécaniques, chimiques ou électriques...) peuvent déclencher le passage de l'influx nerveux en causant l'ouverture de quelques canaux de sodium. La charge positive des ions de sodium qui traversent les canaux sodiques jusqu'à l'intérieur de la cellule affaiblit sa charge négative (dépolarise la cellule). Lorsque la dépolarisation atteint une certaine valeur de seuil, beaucoup de canaux sodiques additionnels s'ouvrent. Sous l'effet de ce flux de sodium un potentiel d'action va naître. L'entrée des ions de sodium inverse la valeur du potentiel membranaire (rendant l'intérieur positif et l'extérieur négatif).

Lorsque ce potentiel atteint environ +30 mV, les canaux de sodium se ferment et les canaux de potassium s'ouvrent. Donc les ions de potassium sortent de l'intérieur de la cellule. Cette émigration des ions positifs fait de l'intérieur de la cellule plus négative et rétablit l'état du potentiel de repos. A ce moment, les canaux de potassium se ferment. Finalement, l'équilibre ionique se rétablit [Cos2009].

Cette séquence d'événements se produit dans une zone locale de la membrane en suite ces changements sont transmis à la prochaine zone, puis à l'autre, et ainsi de suite sur toute la longueur de l'axone. La figure 1.5 présente les différentes étapes de la création du potentiel d'action.




Figure 1.5: Génération d'un potentiel d'action d'un neurone.

Une petite période de repos est nécessaire avant qu'une zone puisse répéter cette séquence d'événement (période réfractaire). Cette période réfractaire empêche le potentiel d'action de se déplacer vers l'arrière et garde une seule direction de déplacement. Ainsi, le potentiel d'action (impulsion nerveuse ou signal nerveux) se propage de la dendrite vers le corps cellulaire puis vers l'axone jusqu'à la synapse qui est une zone qui sépare deux neurones et qui permet un contact indirect entre eux. A ce niveau, des messages chimiques (neurotransmetteurs) vont être libérés dans la synapse puis activent un récepteur dans la dendrite du neurone post-synaptique (cellule réceptrice) de l'autre côté de la synapse et créent un nouveau courant électrique. Des milliers de courants post-synaptiques des dendrites d'un seul neurone seront additionnés pour provoquer la génération du potentiel d'action dont ce neurone. Cette relation entre ces deux neurones est générale pour tous les neurones adjacents.

Les neurones pyramidaux est une classe commune de neurones trouvée dans le cortex cérébral. Ils sont également fréquents dans les structures sous-corticales telles que l'hippocampe et l'amygdale. Les cellules pyramidales corticales sont responsables de la génération des activités cérébrales mesurables. En effet, avec leurs longues dendrites apicales ces neurones sont semblables aux "dipôles de courant" dont l'activité peut être détectée par des électrodes placées à des distances relativement petites. De cette façon, le phénomène de dépolarisation membranaire local crée une différence de potentiel entre le sommet de l'arbre dendritique et le pied de la cellule comme illustré dans la figure 1.6.

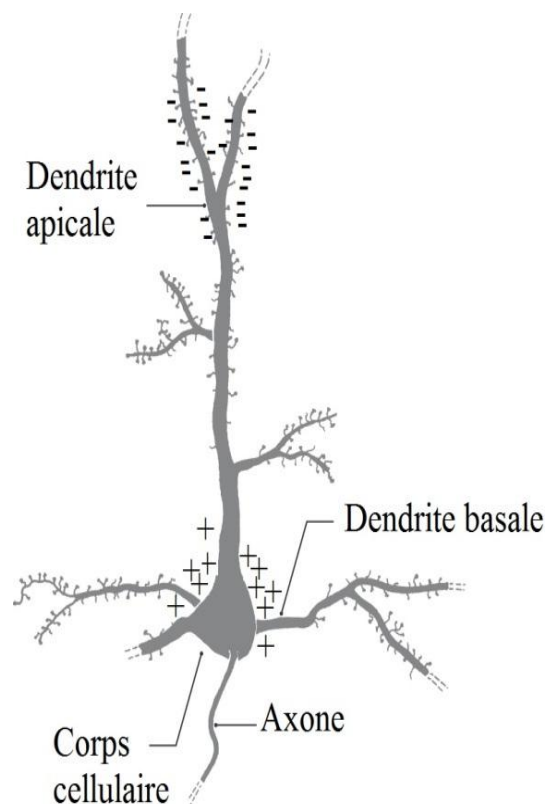


Figure 1.6: Cellule pyramidale créant un dipôle de courant.

Comme représenté dans cette figure, une cellule pyramidale est constituée essentiellement de [Bes2007]:

- Un corps cellulaire à la forme d'une pyramide;
- Les dendrites apicales qui sont des dendrites longues qui émergent de l'extrémité pointue du soma;
- Les dendrites basales qui sont des dendrites courtes qui émergent de l'extrémité arrondie.

1.3. Notions de base de l'EEG

Le premier EEG humain a été enregistré par Hans Berger dans les années 1920 (figure 1.7). En tant qu'un pionnier dans le domaine, c'est lui qui a inventé le terme électroencéphalogramme. Son travail était basé sur les études initiales de la fonction du cerveau animal réalisées par Richard Caton au 19ème siècle. Caton et Berger ont décrit plusieurs modèles d'EEG normaux et anormaux, parmi lesquels les ondes α et β [Bi2013]. Dans le domaine de la détection des crises épileptiques, les premières études ont été réalisées dans les années 1930 lorsque Fisher et Lowenback ont décrit des pointes épileptiformes [Che2010]. Tout au long de la seconde moitié du XXe siècle, avec l'aube des techniques d'enregistrement numérique et de la puissance informatique largement accessible, nous avons vu une poussée d'études décrivant à la fois les origines de l'EEG et ce que les cliniciens et les chercheurs peuvent en déduire. Aujourd'hui, l'EEG est largement accepté comme une technique de mesure standard.

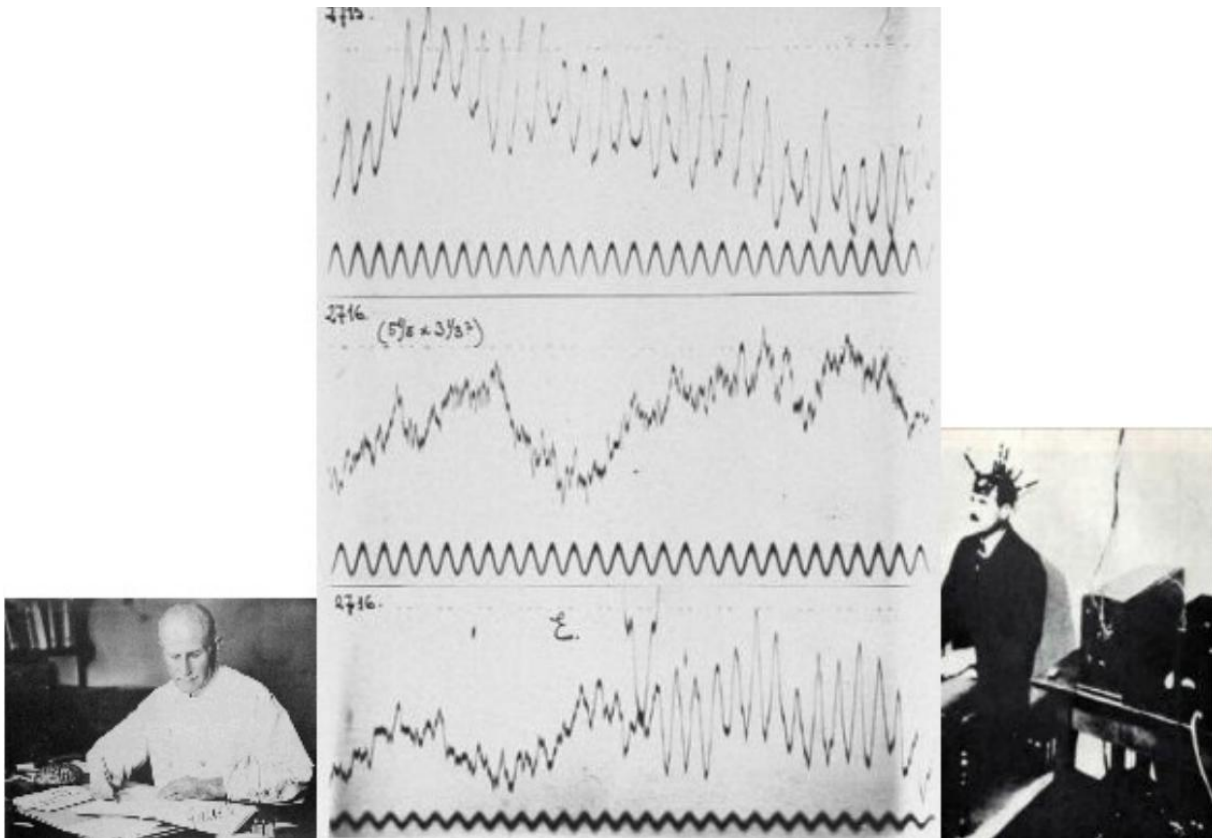


Figure 1. 7 (a)

Figure 1. 7 (b)

Figure 1. 7 (c)

Figure 1.7: Premier enregistrement des signaux EEG réalisés par Hans Berger, (a) Hans Berger (1873-1941), (b) Enregistrements d'EEG réalisés par Berger et (c) Patient de Berger [Ber1929].

Naturellement les neurones du cerveau émettent une activité électrique, comme nous venons d'expliquer dans la partie précédente. La concentration de millions de neurones forme un dipôle de courant. Ces courants se propagent dans les dendrites et les axones du cerveau jusqu'au crâne puis le cuir chevelu où ils sont mesurables comme une différence de potentiels électriques engendrée entre deux électrodes [Wol2006].

L'électroencéphalographie (EEG) est basée sur la mesure des variations de ces champs électriques. Cette technique a été utilisée dans plusieurs études chez des sujets sains [Bar2012] et des patients. A la différence de la MEG, L'EEG capture préférentiellement les activités électriques extracellulaires des assemblées de neurones pyramidaux formant un dipôle perpendiculaire à la surface du crâne. Les valeurs mesurées reflètent le niveau de l'activité cérébrale [Kir2009].

Un appareil EEG moderne se compose d'un ensemble d'électrodes, d'un amplificateur, d'une unité de stockage de données et d'une unité d'affichage. Les capteurs EEG sont des électrodes Ag/AgCl (Argent/Chlorure d'argent) d'un rayon d'environ 5 mm. Ils sont fixés sur le cuir chevelu du sujet et un gel conducteur est généralement appliqué entre eux. Les positions de l'électrode peuvent être choisies selon des informations préalables sur l'étiologie du patient ou selon le système standard 10-20 [Kol2015]. Ce système définit de façon proportionnelle l'emplacement des électrodes par rapport à des repères d'os fixes, telles que le nasion (jonction entre l'arête du nez et le front), l'inion (point défini sur l'occiput) et les deux points pré-auriculaires droit et gauche. Ensuite, les électrodes sont placées à des intervalles de 10 % ou 20 % par rapport à ces repères (figure 1.8 et figure 1.9).




Figure 1.8: Vue sagittale du positionnement des électrodes selon le système international 10-20. Modifié de la figure originale par Malmivuo et al. [Mal1995].




Figure 1.9: Vue axiale du positionnement des électrodes selon le système international 10-20. Modifié de la figure originale par Malmivuo et al. [Mal1995].

Les électrodes impaires sont situées à la gauche du crâne tandis que les électrodes paires sont sur la droite. Les lettres contenues dans les noms des électrodes correspondent aux zones cérébrales sont données dans le tableau 1.1 [Mal1995].

Tableau 1. 1: Signification des lettres utilisées dans la nomenclature des électrodes.

Lettre	C	F	AF	T	P	O
zone	Centrale	Frontale	Antérieure Frontale	Temporale	Pariétale	Occipitale

Les électrodes utilisées en EEG sont caractérisées par leur faible coût, leur faible impédance de contact et leur bonne stabilité. Il faut environ 10^4 neurones, dans quelques millimètres cube du cortex prêt du crâne, orientés dans le même sens et fonctionnant de manière synchrone pour que le potentiel post-synaptique engendré puisse être observable au niveau du scalp à l'aide des capteurs EEG.

1.3.1. Montages EEG

Tous les signaux EEG sont des enregistrements bipolaires c'est à dire des différences entre des potentiels électriques scalaire appliqués sure l'entrée d'un amplificateur. Les enregistrements multivoies (multicanaux) sont utilisés pour déterminer la distribution des changements de potentiels sur le scalp. Lors des enregistrements, les signaux recueillis sont mesurés par rapport à une ou plusieurs références. Selon plusieurs études, il est impossible de trouver une référence de potentiels céphalique qui soit complètement nulle [Die1998, Fis1999, Yao2001, Hu2007]. Pour pallier à ce problème, mais également pour faciliter l'interprétation du clinicien et/ou appliquer des méthodes particulières de traitement du signal (estimation de synchronicité, déférence de phases instantanées entre les électrodes...), plusieurs combinaisons de montages sont possibles. On peut distinguer principalement 4 types de montages : le montage en référence commune, le montage en référence moyenne, le montage bipolaire et le montage en référence moyenne pondérée ou Laplacien [Fis1999].

1.3.1.1. Montages bipolaires

Généralement, chaque paire d'électrodes constitue un canal. Chaque canal représente la différence de potentiel entre deux électrodes adjacentes selon le système 10-20 [Nid2005,

[Fis1999]. Par exemple, le canal "Fp1-F3" représente la différence de potentielle entre l'électrode Fp1 et l'électrode F3. Le prochain canal dans le montage, "F3-C3", représente la différence de potentielle entre F3 et C3, et ainsi de suite, tout au long l'ensemble des électrodes. On distingue 3 types de montages bipolaires : le longitudinal (sens antéro - postérieur), le transversal ou coronal (sens gauche - droite) et le circonférentiel (autour de la tête) [Deu2002].

1.3.1.2. Montage en référence commune

Chaque canal représente la différence entre une électrode spécifique et une électrode de référence distincte [Nid2005, Fis1999]. Il n'y a pas une position de référence standard. Cependant, l'électrode de référence est située dans une position déférente des positions des électrodes d'enregistrement. Les positions de ligne médiane (Mid Line), FZ, CZ et PZ, sont souvent utilisées parce qu'elles n'amplifient pas le signal d'un hémisphère par rapport à l'autre. Une autre référence très utilisée est "les oreilles liées", qui est une moyenne des électrodes attachées aux oreilles et aux mastoïdes. On peut distinguer deux catégories : les références céphaliques (référence auriculaire) ou non-céphaliques (référence cou-poitrine).

1.3.1.3. Montage en référence moyenne

Malgré l'absence d'une référence totalement nulle, il est possible d'envisager une référence "virtuelle" inactive. Ce montage prend comme référence la moyenne de l'ensemble des potentiels mesurés [Gol1950, Off1950]. Dans l'hypothèse où la tête est quasiment isolée électriquement du reste du corps, la moyenne des mesures équiréparties sur la surface de la tête, devrait être nulle. Les mesures du montage en référence moyenne sont obtenues donc en soustrayant la moyenne des mesures en référence commune de chaque mesure de canal [Fis1999].

1.3.1.4. Montage en référence moyenne pondérée ou Laplacien

C'est une variété du montage en référence moyenne. Proposé par Hjorth [Hjo1975], il considère une référence moyenne locale, c'est-à-dire que chaque canal représente la différence entre une électrode et la moyenne pondérée des électrodes qu'il entoure [Fis1999]. Avec les équipements modernes d'enregistrement EEG, tous les signaux sont numérisés et stockés suivant un montage particulier. Puisque chaque montage peut être construit

mathématiquement à partir d'un autre, les signaux EEG peuvent être visualisés et utilisés avec n'importe quel montage.

1.3.2. Les rythmes corticaux

Les neurones du cerveau produisent un ensemble de signaux rythmiques qui est constamment présent [Art2012]. Les ondes EEG sont généralement classées en fonction de leur fréquence, amplitude et forme, ainsi que des positions sur le cuir chevelu sur lesquels elles sont enregistrées. La classification la plus connue utilise la bande fréquentielle (Alpha, Bêta, Thêta, Gamma et Delta) [Nie2004].

- **Rythme Delta :** Les ondes EEG inférieures à 4 Hz (habituellement 0,1-3,5 Hz) appartiennent aux ondes Delta. Elles sont observées chez l'adulte pendant le sommeil profond ;
- **Rythme Thêta :** Les ondes Thêta se situent entre 4 et 8 Hz. Elles caractérisent certains états de somnolence ou d'hypnose ainsi que des processus émotionnels et cognitifs;
- **Rythme Alpha :** Les bandes Alpha sont des "rythme basique" qui contiennent les fréquences entre 8 Hz et 13 Hz. Elles sont les premières ondes remarquables observées grâce à leurs fortes amplitudes. Ce rythme est détecté lorsque le sujet est éveillé et a les yeux fermés. Les ondes Alpha sont observées le mieux dans la zone pariéto-occipitale. On les surnomme aussi Mu (≈ 10 Hz) lorsqu'elles sont enregistrées au niveau du cortex sensorimoteur : dans ce cas elles apparaissent lors de la préparation d'un mouvement moteur;
- **Rythme Bêta :** Toute activité rythmique dans la bande de fréquence de 13 à 30 Hz peut être considérée comme un rythme Bêta. Il est observé chez l'adulte éveillé et surtout dans l'exécution ou l'imagination des mouvements, principalement sur la région frontale et centrale;
- **Rythme Gamma :** Centrée autour de 40 Hz, il est pratiquement invisible en EEG. Ces ondes sont liées à des activités complexes du cerveau.

La figure 1.10 présente un exemple sur l'allure des différents rythmes du signal EEG [Grn2012].




Figure 1.10: Exemple des différents rythmes corticaux du signal EEG à l'ordre du micro volt par rapport au temps (1 seconde) chez un être humain.

Plusieurs critères font de l'EEG la technique la plus adéquate en détection automatique des crises épileptiques. Le critère le plus important est la résolution temporelle très fine qui permet d'obtenir les latences les plus faibles et assure le respect de la contrainte temps réel. De même, le faible coût et la simplicité d'utilisation par rapport aux autres techniques d'imagerie fait de l'EEG une technologie de choix. De plus, le faible poids et taille du casque EEG et la possibilité de se connecter sans fil à un ordinateur rendent le système EEG plus adapté à des multitudes d'applications qui nécessitent une tolérance relativement bonne pour le déplacement spatial. Aussi la mise en place facile et non invasive offre la possibilité d'étudier l'activité sur des sujets valides et non valides sans aucune intervention chirurgicale. Encore, un système EEG est silencieux ce qui permet d'étudier les réponses à des stimuli sonore.

Malgré la limitation significative de la résolution spatiale, l'EEG reste la technique la plus appropriée aux applications des systèmes de détection automatiques des crises épileptiques.

La figure 1.11 montre un exemple d'enregistrement EEG d'un adulte sain.

On peut constater qu'il est difficile, voire impossible, d'interpréter le signal directement à partir de ses séries temporelles sauf pour un expert.




Figure 1.11: EEG normal d'un adulte [Wil2006].

1.3.3. Les perturbations

Dans l'analyse de l'EEG, il est important de reconnaître les modèles des signaux qui ne sont pas générés par le cerveau pour éviter les mauvaises interprétations. Les signaux EEG de surface résultent d'une combinaison des signaux cérébraux et des perturbations. Ces perturbations peuvent faire l'objet d'énergies importantes qui peuvent perturber considérablement l'interprétation clinique ou l'analyse automatique. Les signaux EEG sont très sensibles à toutes sortes de perturbations qui peuvent être classés en artefacts et bruit.

1.3.3.1. Les artefacts

Les artefacts EEG sont d'origine physiologique tandis que le bruit est d'origine non physiologique. Les artefacts sont généralement dus aux clignotements et aux mouvements des yeux, aux mouvements musculaires et à l'électrocardiogramme. Les artefacts oculaires dus aux mouvements des yeux sont causés par la différence de potentiel de quelques millivolts entre la cornée et la rétine. Lorsque les yeux se déplacent, la différence dans le champ électrique provoquée par le mouvement est captée par des électrodes à proximité [Cor2007]. De même, Les potentiels musculaires peuvent être localisés sur le cuir chevelu en provoquant

diverses formes d'artefacts dans une seule ou plusieurs zones. Dans de nombreux cas, les artefacts peuvent être reconnus s'il existe des potentiels de moyenne ou haute amplitude qui ne se produisent que dans une seule électrode ou une activité rythmique ou irrégulière qui apparaisse simultanément dans des régions du cerveau indépendantes [Dur2003]. Par exemple les mouvements du visage et de la mâchoire sont observés dans le signal comme des rafales qui sont synchronisées avec le mouvement et qui sont superposées à des formes d'onde plus lentes [Cor2007]. La figure 1.12 illustre un exemple d'artefact d'un tremblement de visage.




Figure 1.12: Signal EEG contaminé avec l'artefact de tremblements de visage.

Les artefacts de l'électrocardiogramme proviennent du champ électrique associé à l'action cardiaque. Ce champ électrique peut être capté sur le signal EEG, mais peut également provoquer un mouvement des électrodes à proximité des artères en raison de l'onde de pression d'impulsion qu'il produit dans le système artériel [Cor2007]. Les artefacts peuvent être réduits par la relaxation du patient, le changement de sa posture ou, si nécessaire, avec des algorithmes de filtrage. La difficulté dans l'élimination des artefacts est que les artefacts physiologiques sont des signaux qui peuvent être extrêmement informatifs sur l'état du patient. En plus, les méthodes d'élimination des artefacts, telles que le filtrage, peuvent affecter les caractéristiques fréquentielles du signal [Zou2008].

1.3.3.2. *Le bruit*

Le bruit est causé par les interférences électriques et la déformation du signal causée par les électrodes et l'instrument d'enregistrement. L'interférence est causée principalement par les champs électriques et magnétiques du réseau électrique. De même, lorsque le contact de l'électrode est imparfait, il provoque un affaiblissement du courant entre l'électrode et le tissu. Aussi, les câbles d'électrode donnent lieu à des bruits lorsqu'ils se déplacent ou vibrent.

1.4. Structure générale d'un système automatique de détection des crises épileptiques

Un système automatique de détection des crises épileptiques est une chaîne de traitement temps réel de l'activité cérébrale (figure 1.13). Les signaux enregistrés par le dispositif d'acquisition subissent plusieurs phases de traitements numériques: la phase de prétraitement permet d'améliorer la qualité du signal, la phase d'extraction des caractéristiques transforme les signaux EEG vers une nouvelle représentation plus facile à interpréter et la phase de classification permet de distinguer la classe du segment analysé à partir des caractéristiques afin de générer un rapport qui indique le début et la fin de chaque période de crise. Cependant, le système peut ne pas inclure toutes ces phases ou grouper plusieurs phases en une seule.

A chaque instant, seuls les échantillons d'une période de temps bien spécifique, en provenance d'une fenêtre temporelle fixe, sont traités pour vérifier s'ils représentent un état de crise.

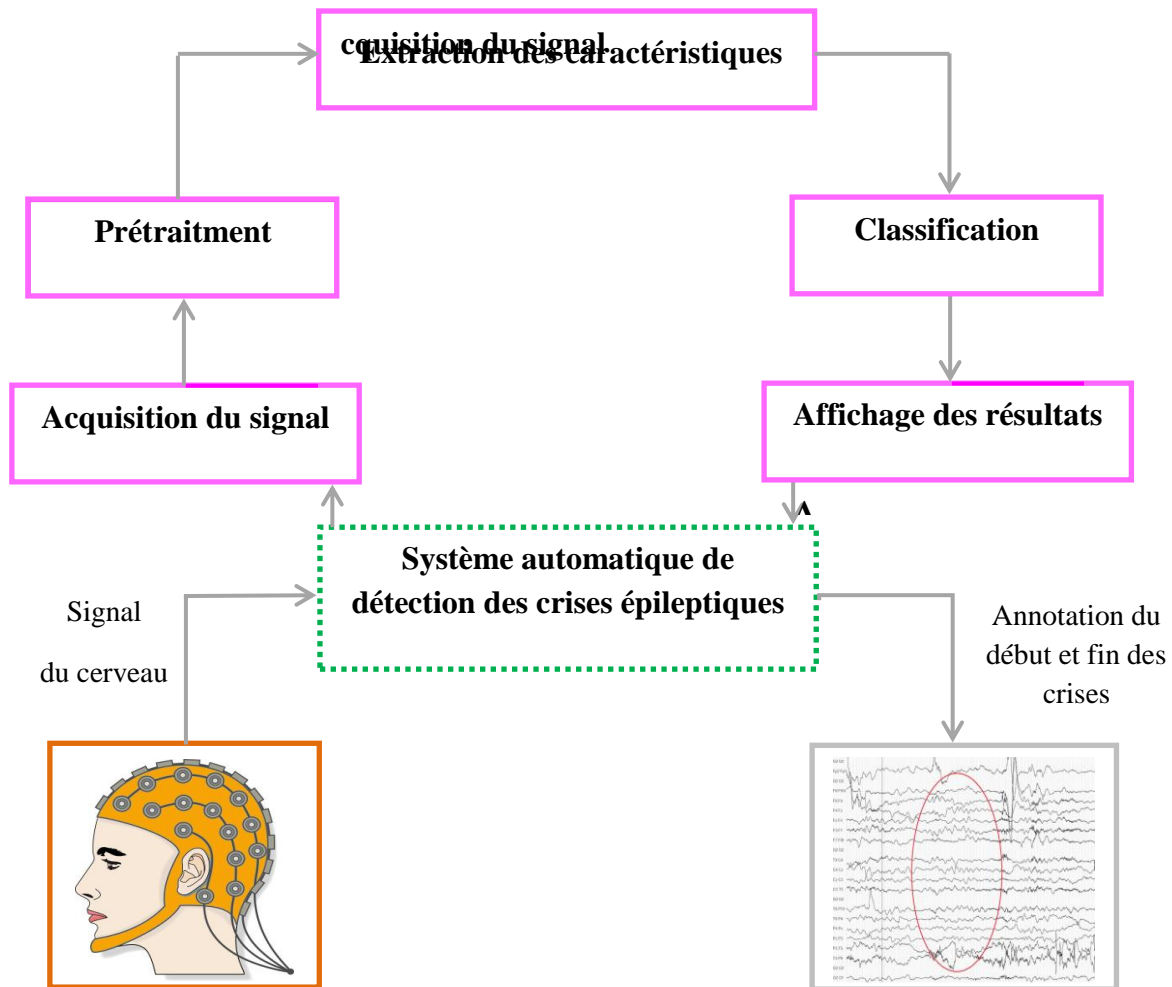


Figure 1.13: Blocs fonctionnels d'un système automatique de détection des crises épileptiques.

1.4.1. Prétraitement

Le prétraitement améliore la qualité du signal cérébral par l'élimination du bruit, comme le signal de la ligne d'alimentation 50 Hz et des artefacts comme l'électromyogramme (EMG), l'électrocardiogramme (ECG), l'électro-oculogramme (EOG) et les artefacts dus aux mouvements du corps. Cette étape permet de ne conserver que les signaux pertinents les plus représentatifs de l'activité cérébrale cherchée. En plus, elle veille à ce que le système ne soit pas contrôlé par des signaux de nature artéfactuelle et non cérébrale.

Les méthodes de prétraitement les plus utilisées sont :

- **Le filtrage fréquentiel :** Il consiste à utiliser les filtres ordinaires passe bas, passe haut, passe bande et coupe bande pour éliminer les bandes fréquentielles susceptibles d'inclure les artefacts et le bruit. Il s'agit de la méthode de prétraitement la plus facile à

implémenter. Cependant, sa réussite nécessite que les signaux non utiles et les signaux utiles soient localisés dans des bandes de fréquences différentes. En cas de chevauchement entre les deux types de signaux, le filtrage va atténuer ces derniers de toute la bande des fréquences sans distinction et indépendamment de leurs impacts, ce qui mène à perdre une grande quantité de données pertinentes;

- **Le filtrage spatial** : C'est une technique plus sophistiquée et plus prometteuse. Elle consiste à créer de nouveaux vecteurs de données en combinant les signaux EEG des différentes électrodes de telle sorte que la puissance du bruit et des artefacts seront réduites. Un poids est attribué à chaque électrode pour indiquer la puissance de ses signaux dans le nouvel ensemble de données. L'une des méthodes les plus connues est la PCA qui permet de réduire la dimension des données en minimisant la redondance des signaux.

1.4.2. Extraction des caractéristiques

Après l'étape du prétraitement le système doit extraire les caractéristiques qui permettent de distinguer les différentes classes. La figure 1.14 illustre 100 secondes du signal EEG à partir de 4 électrodes, qui incluent une crise épileptique. Dans la figure 1.14 (a) il est facile de distinguer les différents états avec une investigation visuelle tandis que dans la figure 1.14 (b) la crise épileptique peut passer inaperçue avec un examen rapide par un neurologue.




Figure 1.14 (a)




Figure 1.14 (b)

Figure 1.14: Exemples de deux crises épileptiques de la base de données CHB-MIT. Quatre canaux d'enregistrement EEG de crise épileptique du Patient 1, (a) fichier chb01-04 et (b) fichier chb01-15. Les lignes rouges indiquent les limites de temps d'une crise annotée par un expert.

Il est donc nécessaire de trouver des caractéristiques telles que l'amplitude, la durée et la fréquence qui permettent de distinguer une crise épileptique des signaux de l'arrière-plan. Cependant, l'inspection visuelle des modifications de ces caractéristiques et de la morphologie des ondes est difficile, subjective et nécessite une longue durée. Le développement d'outils automatiques pour la détection de crise à partir d'enregistrements EEG avec l'utilisation de caractéristiques plus pertinentes est donc indispensable.

1.4.3. Classification

Les systèmes de détection automatique des crises épileptiques utilisent des algorithmes de classifications pour distinguer entre les différentes classes. Le classifieur va apprendre dans une première étape à séparer les différentes classes en utilisant les informations contenues dans l'espace des caractéristiques. Puis, dans une deuxième étape il va désigner les classes des nouvelles données en se basant sur les règles conçues durant l'apprentissage.

Les méthodes de classification les plus utilisées sont : l'Analyse discriminante et les Séparateurs à Vaste Marge (SVM). Considérant la complexité de l'apprentissage, le vecteur des caractéristiques doit avoir une taille raisonnable.

1.5. Conclusion

Ce chapitre s'intéresse aux principes fondamentaux des systèmes de détection automatique des crises épileptiques.

Tout d'abord, nous avons présenté les notions de base de la neurophysiologie afin de comprendre l'origine et les caractéristiques des activités cérébrales. Puis, nous avons mis l'accent sur la technologie de détection des données EEG qui est la technique de mesure de l'activité cérébrale la plus utilisée pour concevoir ce système. Ensuite, nous avons décrit les différents blocs fonctionnels du système comme étant une chaîne de traitement en temps réel de l'activité cérébrale.

Dans le chapitre suivant, nous étudierons les crises épileptiques en donnant toutes les informations nécessaires pour mieux comprendre cette maladie.

Chapitre 2

Généralité sur L'épilepsie

Chapitre 2 : Généralité sur L'épilepsie

2.1. Introduction

2.2. Définition

2.3. Aperçus historique

2.4. Epidémiologie

2.5. Pathogénie (mécanisme)

2.6. Les multi-modalités pour le diagnostic d'épilepsie

2.7. Cause de l'épilepsie

2.8. Classification internationale de l'épilepsie

2.9. Prise en charge

2.10. Conclusion

2.1. Introduction

L'épilepsie est une affection neurologique fréquente. Il s'agit d'une maladie sévère posant un problème majeur de santé publique de par les conséquences médicales, sociales, culturelles et économiques qu'elle engendre, à la fois pour les patients mais également pour la société.

Toutefois, l'épilepsie n'est pas une entité clinique unique et différents types d'épilepsies peuvent être distingués.

Au cours de la première partie de ce chapitre, un bref retour historique sur la découverte de cette maladie cérébrale sera présenté avec un bilan des origines de l'épilepsie et de son impact social. Dans le contexte qui nous préoccupe, notamment l'épilepsie, nous aborderons les différentes modalités de mesure appliquées pour l'aide au diagnostic et nous détaillerons les classifications internationales présentes jusqu'à ce jour (classification des épilepsies et des syndromes épileptiques). Enfin, une fois que le diagnostic est posé, plusieurs traitements sont envisageables.

2.2. Définition

L'épilepsie est un désordre neurologique chronique caractérisé par des crises récurrentes. Un fonctionnement anormal qui transforme un réseau neuronal normal en un réseau hyperexcitable, aigu et transitoire de l'activité électrique d'une zone cérébrale qui se traduit par des crises épileptiques, et par les conséquences neurobiologiques, cognitives, psychologiques et sociales de cette affection.

Fisher et al. [Fih2005] ont proposé en 2005 une définition conceptuelle de la crise d'épilepsie : « une crise épileptique est définie par la présence transitoire des signes et/ou symptômes due à une activité neuronale anormale excessive ou syndrome dans le cerveau ».

Fisher et al. [Fie2014] ont proposé en 2014 une définition clinique opérationnelle (pratique) de l'épilepsie : « l'épilepsie est une maladie cérébrale définie par une quelconque des manifestations suivantes :

- Au moins deux crises provoquées (ou reflexes) espacées de plus de 24 heures;
- Une crise non provoquée (ou reflexe) et une probabilité de survenue ultérieure au cours des dix années suivantes similaire au risque général de récurrence (au moins 60 %) observé après deux crises non provoquées;
- Un diagnostic de syndrome épileptique».

L'épilepsie est considérée comme ayant disparu chez les patients qui présentaient un syndrome épileptique âge-dépendant et qui ont désormais dépassé l'âge correspondant et chez ceux qui n'ont pas eu de crise au cours des dix dernières années sans avoir pris de traitement antiépileptique depuis au moins 5 ans [Fie2014].

Cette décharge épileptique est objectivée par l'enregistrement de l'électroencéphalogramme (EEG) s'il est réalisé au cours de la crise.

2.3. Aperçu historique

Contrairement à ce qu'on pense parfois, l'épilepsie n'est pas une maladie nouvellement découverte. Son histoire remonte à quelques millénaires.

Terminologie : son nom dérive du mot latin " *epilepsia* " qui provient lui-même du verbe grec " *επιλαμβάνειν* " signifiant " *attaquer par surprise, saisir, ou possession* ". Souvent les peuples attribuaient les crises aux démons.

Les premières recherches sur les descriptions de la pathologie datent de quelques millénaires, entre 4500 et 1500 avant Jésus-Christ, en Inde. Au début, l'épilepsie était caractérisée uniquement par les crises tonico-cloniques, qu'on pensait être la seule manifestation de la pathologie.

La découverte d'une série de tablettes qui datent de plus de 2000 ans av. J.-C. prouve que l'épilepsie était déjà connue des Babyloniens dans le "*Code d'Hammurabi*" sous la dénomination de "*benu*".

Les babyloniens traitent l'épilepsie de façon détaillée, en discernant notamment les différents types de crises qu'ils avaient pu observer. Chaque type de crise est associé au nom d'un esprit ou d'un dieu, le plus souvent malfaisant.

Hippocrate (V à IVème siècle av. J.-C.) a donné les premières descriptions de l'épilepsie comme une "*maladie sacrée*" ayant pour étiologie un dérèglement cérébral. Il a écrit: « *rien de plus divin ni de plus sacré que les autres maladies, ni dans sa nature, ni dans sa source* ».

La pathologie a souvent été associée à la religion, durant le Moyen-Age l'épilepsie fut considérée comme le reflet d'une possession démoniaque, empêchant toute progression significative dans la compréhension scientifique de la maladie. L'épilepsie est apparue dans la langue française en 1503.

En 1770, Samuel Auguste David Tissot, publie son traité de l'épilepsie, avec une des premières approches scientifiques de la pathologie, qui ouvrira la porte à de nombreuses avancées dans le domaine.

La piste du dérèglement cérébral reprend au XIXe siècle, avec les débuts de la neurologie, par les aliénistes français. Ces derniers ont commencé à considérer l'épilepsie comme une maladie mentale grave aboutissant à la démence. Vers la fin de ce siècle, grâce à l'essor des technologies médicales, des avancées majeures dans les connaissances des épilepsies ont été réalisées.

Ainsi, on peut dire que nous sommes entrés dans l'ère moderne du traitement chirurgical de l'épilepsie avec Sir Victor Horsley qui a réussi une résection de la zone épileptogène de trois patients présentant des crises partielles en 1886 [Eng1998].

Des avancées diagnostics ont vu le jour vers 1920 permettant un meilleur traitement et analyse de la maladie.

L'introduction de l'ElectroEncéphaloGrammes (EEG), par Hans Berger ouvre le chemin devant la naissance d'une invention qui va révolutionner l'étude de l'épilepsie. Ces avancées ont servi à détecter un signal d'activité cérébrale en 1929.

Aujourd'hui, la question se porte de plus en plus sur la qualité de vie des personnes épileptiques, sur leur intégration en société et sur l'ostracisme dont elles peuvent être victimes. Cependant, pour beaucoup, cette maladie reste un tabou, que ce soit dans les pays développés ou dans les pays en développement.

2.4. Epidémiologie

Affection fréquente, la deuxième après les céphalées, sans limites géographiques ni sociales, touchant environ 50 millions de personnes dans le monde [Ita2016] et 400 000 personnes en Algérie [Sad2016], avec une prévalence mondiale de 0,5 à 1%.

Pas de prédominance sexuelle, peut survenir à tout âge, mais plus particulièrement pendant la petite enfance, l'enfance, l'adolescence et la vieillesse.

2.4.1. Incidence

L'incidence est la mesure de la fréquence d'apparition d'une pathologie dans une population, déterminée par le nombre de nouveaux cas d'épilepsie apparaissant dans une population donnée, au cours d'une période de temps, généralement une année.

Selon l'OMS, l'incidence annuelle de l'épilepsie dans les pays développés se situerait autour de 50 cas pour 100 000 pour l'ensemble de la population, toutefois, les études sur l'incidence de l'épilepsie dans les pays en développement (PED) sont peu nombreuses à cause de l'absence des moyens nécessaires pour la réalisation d'une statistique crédible [Tra2008]. Certaines études réclament que ce chiffre serait proche de 100 épileptiques pour chaque 100 000 habitant [Cha2007].

- Pays développés: 40-70/100 000 H;
- Pays en voie de développement: 100-190/100 000 H;
- En Afrique 30-80/100 000 H;
- En Algérie 20-50/100 000 H [Sad2016].

2.4.2. Prévalence

La prévalence est la mesure à la fois de la chronicité et de la sévérité de l'épilepsie dans une population. Elle est déterminée par le nombre de sujets souffrant dans une population à un moment donné dans le temps.

Selon l'OMS, l'Organisation Mondiale de la Santé, il existerait environ 50 millions de personnes souffrant d'épilepsie (PSE) dans le monde et sa prévalence moyenne se situerait autour de 8,2‰ dans l'ensemble de la population. La répartition de cette affection est inégale et le nombre de PSE est beaucoup plus important dans les PED près de 80%.

- Pays développés: 6 à 8 pour 1000 H;
- Pays en voie de développement: 23 à 50 pour 1000 H;
- En Algérie: 10 à 30 pour 1000 H [Sad2016].

2.4.3. Mortalité

Peu de données dans la littérature. Elle représente le rapport du nombre d'épileptiques décédés par rapport au nombre total d'épileptiques, dans une population donnée, par unité de temps (généralement une année).

Dans les PED : Les études ont révélé que la mortalité associée à cette maladie se révèle être trois à cinq fois supérieure à celle de la population générale (31,6‰), ce qui a suscité un regain d'intérêt de la part de la communauté scientifique et des associations de malades [Hou2013].

2.5. Pathogénie (mécanisme)

Une crise d'épilepsie est consécutive à une hyperexcitabilité cellulaire et synaptique au niveau neuronal.

A l'état normal, les concentrations électrolytiques (Na^+ , K^+), de part et d'autre de la membrane neuronale, définissent un potentiel de repos et les influences excitatrices ou inhibitrices qui agissent sur chaque neurone se somment algébriquement pour maintenir un certain état d'équilibre (figure 2.1).

Si les afférences excitatrices l'emportent, une dépolarisation de la membrane se produit avec apparition d'un potentiel d'action lorsqu'un certain seuil critique est atteint, ce dernier variant en fonction des sujets et des structures cérébrales. La survenue d'un déséquilibre entre les processus excitateurs et inhibiteurs en faveur des premiers est un élément déterminant dans l'apparition d'une crise d'épilepsie.

L'hyperexcitabilité d'un groupe neuronal peut être le fait de plusieurs facteurs:

- Altération de la membrane neuronale ou des systèmes enzymatiques qui régissent les répartitions ioniques intra et extracellulaires (Na-K-ATPase membranaire);
- Une hyperactivité des afférences excitatrices dont le neuromédiateur est principalement le glutamate;
- Une déficience des afférences inhibitrices qui dépendent surtout de l'acide gamma-amino-butyrique (GABA), soit le rôle modulateur joué par d'autres substances comme l'acétylcholine, les catécholamines, la sérotonine et de nombreux neuropeptides.

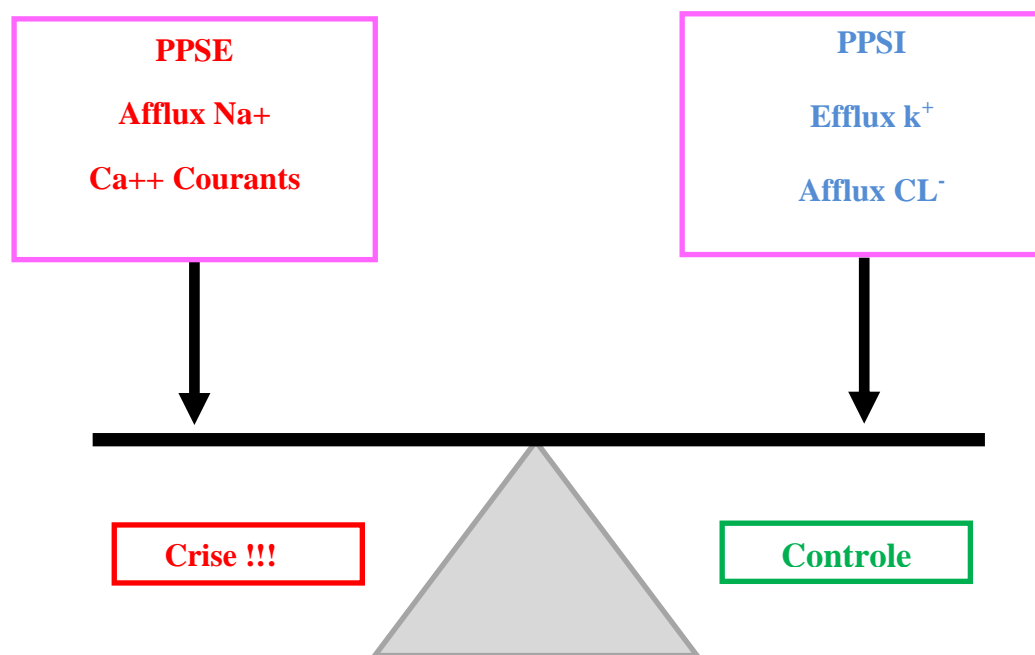


Figure 2.1: Equilibre entre les événements excitateurs et inhibiteurs au niveau synaptique.

2.6. Les multi-modalités pour le diagnostic d'épilepsie

Il est important de poser un diagnostic car d'autres pathologies peuvent présenter des manifestations qui font penser à des crises d'épilepsie. A partir du moment où le diagnostic d'épilepsie est posé, un traitement adapté peut être entamé.

Dans le cadre de ce bilan, une batterie d'examens est effectuée pour tenter de déterminer, le plus précisément possible, la zone cérébrale responsable du déclenchement des crises d'épilepsie. Cette batterie d'examens comporte des données cliniques, des données anatomiques et d'imagerie cérébrale (IRM morphologique et fonctionnelle, TEP, TEMP) et enfin des données électrophysiologiques (enregistrements d'EEG).

Pour certains patients, la ZE n'est pas toujours localisée avec ces examens et il n'y a pas une lésion apparente ou évidente. Les neurologues passent à l'exploration chirurgicale. Des méthodes plus invasives comme SEEG et ECoG. Ce bilan est long, lourd et coûteux.

2.6.1. Données cliniques

Les données cliniques sont les premières informations recueillies lorsqu'un patient se présente chez son médecin. Elles regroupent les résultats d'un ensemble de tests et de questions permettant de donner rapidement des pistes sur le type d'épilepsie ou au moins de privilégier certains axes de recherche des causes de la maladie [Mah2006].

- **L'historique de la maladie du patient** : Le neurologue essaye, en interrogeant le patient et sa famille, de déterminer les origines éventuelles de la maladie (âge d'apparition des premiers symptômes, traumatismes crâniens, chutes, antécédents familiaux, etc...);
- **Signes fonctionnels** : Le patient et son entourage tentent de décrire le déroulement des crises : spasmes, absences, chutes, convulsions, ...;
- **L'examen neurologique** : Réalisé par un neurologue afin de rechercher des anomalies du système nerveux et dans certains cas, de suspecter un diagnostic. Il est très long si on veut explorer toutes les fonctions commandées ou supervisées par le cerveau. L'examen neurologique consiste en une batterie de tests qui servent à déterminer les déficits éventuels dans les fonctions neurologiques du patient. Les fonctions testées sont principalement les fonctions motrices, cognitives et sensorielles;
- **L'examen neuropsychologique** : Axé sur le test les fonctions supérieures (Langage, Attention, Organisation/ Planification, Perception, Lecture, Ecriture, Capacités visuelles et spatiales, Fonctions exécutives et principalement mémoire). Des déficits dans l'une ou l'autre de ces fonctions permettent d'émettre un diagnostic quant à la zone hémisphérique dans laquelle se situe le siège des crises.

2.6.2. Données anatomiques et fonctionnelles (L'imagerie médicale)

Les données anatomiques et fonctionnelles sont l'ensemble des techniques permettant de visualiser, de façon non invasive, des processus biologiques sur des organismes vivants. Les données récoltées sont utilisées pour le diagnostic et le traitement des pathologies. Elle a toute son importance dans la recherche étiologique.

- Les données anatomiques sont indiquées avant toute épilepsie focale à l'exception de l'épilepsie à pointes centro-temporales typiques. Elles permettent de mettre en

évidence l'existence ou non de structures cérébrales endommagées, les dysplasies corticales, les lésions acquises à la suite d'un traumatisme ou d'une infection, les lésions cérébrales d'un syndrome neurocutané et donc de connaître le foyer lésionnel susceptible de générer les crises d'épilepsie. Ces données sont enregistrées grâce à plusieurs modalités d'imagerie cérébrale telles que les images radiologiques, les scanners (PETscan, CT-scan), La plus utilisée de ces techniques est l'Imagerie par Résonance Magnétique (IRM);

- Les données fonctionnelles fournissent des images de l'activité cérébrale à un moment précis en identifiant des zones fonctionnelles actives et apprécient son retentissement. Ces modalités ne fournissent pas le même type d'information. Des exemples de ces techniques sont la Tomographie par Emission de Positons (TEP), Tomographie par Emission Monophotonique (TEMP) et l'IRM fonctionnelle (IRMf).

2.6.2.1. Tomographie par Emission de Positons (TEP)

La **TEP** (Tomographie par Emission de Positons ou PETscan) est une technique d'imagerie utilisée pour mettre en évidence des zones d'hypométabolismes en relation avec la ZE responsable du déclenchement de la crise. Le principe de fonctionnement de la TEP est basé sur la détection externe d'un élément radioactif traceur du glucose.

Ce traceur (généralement incorporé dans une molécule impliquée dans le métabolisme glucidique ou de la consommation en oxygène) est injecté au patient [Sal2012]. Grâce aux émissions gamma radioactives il est possible de détecter ce traceur et sa concentration dans les tissus explorés grâce à une caméra spéciale comme montré dans la figure 2.2.




Figure 2.2: Tomographie par Emission de Positons [Dav2017].

2.6.2.2. Tomographie par Emission Monophotonique (TEMP)

La **TEMP** (Tomographie par Emission Monophotonique) est une méthode tomographique d'imagerie médicale nucléaire qui permet de réaliser des reconstructions d'images dans trois dimensions d'organes et leur métabolisme, au moyen d'un certain nombre de caméras gamma qui fait une rotation coaxiale autour du patient (figure 2.3).

Elle est aussi connue comme **SPECT**, (Single Photon Emission Computed Tomography), basée sur l'émission de particules radioactives, qui se caractérise par la détection de photons γ résultant directement ou indirectement de la désintégration d'un radionucléide.

Le principe de SPECT est proche de celui du PET. Les deux techniques sont complémentaires de l'IRM et participent au bilan pré chirurgical des patients souffrant d'une épilepsie partielle pharmaco-résistante [Sem2007, Pan2008].

La principale différence est que chez PET, on détecte une paire de photons qui permet de simplifier l'évaluation pré chirurgicale des patients, en facilitant la latéralisation, particulièrement dans le cas des épilepsies du lobe temporal, tandis que dans SPECT, on détecte un photon, utilisée dans la localisation de la ZE et l'étude de la dynamique des crises. Les images SPECT sont moins précises, mais elles ne nécessitent pas que le traceur émette des positons. SPECT peut donc être utilisée avec des traceurs dont la désintégration est plus lente et qui peut être transportée et stockée beaucoup plus facilement.



Figure 2.3 : Tomographie par émission monophotonique.

2.6.2.3. *Imagerie par Résonance Magnétique (IRM)*

L'IRM (Imagerie par Résonance Magnétique) est l'une des techniques d'imagerie médicale les plus récentes. Fiable et précise, elle est très souvent utilisée pour détecter une anomalie morphologique qui peut être la cause de l'épilepsie chez certains patients [Hof2013].

L'IRM basée sur l'exploitation d'une propriété que possèdent certains noyaux atomiques : le spin, le moment cinétique intrinsèque des particules quantiques placées dans un champ magnétique [Sal2012]. Elle permet de visualiser avec une grande précision les organes et tissus mous, dans différents plans de l'espace en deux et en trois dimensions de l'intérieur du corps.

Les images obtenues par résonance magnétique sont le résultat de l'interaction entre un champ magnétique créé par la machine et les atomes d'hydrogène contenus dans l'organisme du patient à un temps d'acquisition long (figure 2.4). Ces images peuvent être segmentées pour distinguer chacun des milieux.




Figure 2.4: Résultats d'IRM d'un patient épileptique.

2.6.2.4. *Imagerie par Résonance Magnétique fonctionnelle (IRMf)*

L'IRMf (Imagerie par Résonance Magnétique Fonctionnelle) est actuellement en plein essor vu les perspectives qu'elle offre dans l'étude du fonctionnement du cerveau. Cette technique non-invasive a été proposée dans les années 1990. Chaque activité cérébrale provoque une consommation d'oxygène dans la zone cérébrale respective. Par la suite elle provoque une transformation de l'hémoglobine en désoxyhémoglobine qui possède deux propriétés magnétiques différentes. L'IRMf exploite cette différence pour mesurer de manière indirecte le niveau d'oxygénation du sang dans le cerveau. La haute résolution spatiale de cette

technologie permet de créer des cartes d'activation des voxels du cerveau d'une résolution très fine [Gm2012]. Cependant, la résolution temporelle est très faible. En effet, l'activité cérébrale n'est détectée qu'après environ 1 s. En effet, cette technique de mesure nécessite l'utilisation d'une machine très couteuse qui n'est absolument pas portable pour une utilisation en dehors du laboratoire (figure 2.5).



Figure 2.5: La mesure des réponses cérébrales au moyen de l'imagerie par résonance.

2.6.2.5. Tomodensitométrie

La **TDM** ou **CT-scan** (Computerized Tomography) est une méthode diagnostic d'imagerie médicale qui mesure l'absorption des rayons X (figure 2.6) par les tissus et peut être exploitée dans le cas d'une prise en charge immédiate de la première crise épileptique.

Elle est basée sur le principe de l'acquisition d'images scanner incrémentale : plusieurs coupes successives sont obtenues à des niveaux anatomiques différents.

Avant chaque coupe, la table d'examen est déplacée d'un incrément prédéfini. La distance séparant deux coupes est donc exacte pour les structures anatomiques immobiles mais elle reste très affectée par les mouvements du patient [Mah2006].




Figure 2.6: La technique Tomodensimétrie TDM.

2.6.3. Données électrophysiologiques

De façon générale, les techniques d'imagerie apportent des informations structurelles insuffisantes par rapport aux échelles des processus étudiés. Les grandeurs électrophysiologiques fournissent des données directement liées à l'activité électrique cérébrale. Malgré les grands développements technologiques de l'imagerie médicale, l'enregistrement des données électroencéphalographiques est l'unique moyen de mettre en évidence l'activité épileptique, garde encore une place importante pour la localisation de la ZE et la compréhension du déroulement de la propagation des crises [Vel2010]. Dans cette thèse nous nous limiterons à l'épilepsie qui représente un des plus grands champs de publication de l'EEG.

2.6.3.1. Méthodes non invasives

La méthode non-invasive la plus fréquente est l'enregistrement EEG, les capteurs sont placés à la surface par conséquent aucune lésion n'est nécessaire sur l'organisme du sujet ce qui rend l'utilisation beaucoup moins contraignante. Toutefois, les signaux captés sont plus sensibles au bruit et aux artefacts qui peuvent changer ces propriétés.

a) L'Electroencéphalographie (EEG)

L'EEG est la méthode de référence et la plus ancienne concernant l'enregistrement de l'activité électrique du cerveau au moyen d'électrodes posées à la surface de la tête au niveau du scalp (on parle d'EEG de surface ou d'EEG de scalp).

Ces électrodes sont positionnées sur des zones bien définies du crâne. Ils transmettent les signaux électriques à un appareil où ils sont amplifiés et affichés sous forme de courbes. Ces

courbes, représentatives de leurs évolutions, constituent l'électroencéphalogramme (EEG) [Vel2010].

C'est un examen indolore et non-invasif avec une résolution spatiale des quelques millimètres et une résolution temporelle de l'ordre de la ms (figure 2.7).

Le signal électrique enregistré est la résultante de la somme des potentiels d'action post-synaptiques synchrones et simultanée d'un grand nombre de neurones environ 100 millions et un milliard d'une certaine région [Nun2006].

L'électroencéphalographie est l'un des principaux outils de diagnostic de la neurologie clinique, mais la grande majorité de l'EEG est obtenue dans le cadre de l'évaluation de crises d'épilepsie provoque des mouvements non coordonnés qui sont en relation avec le dysfonctionnement électrophysiologique cérébral du corps de patient.

Pour étudier les crises d'épilepsie, l'EEG peut être couplé à des enregistrements vidéo.

Ces enregistrements sont simultanés et synchronisés de l'EEG et du comportement du patient. Grâce à son utilisation, l'étude du mouvement des patients met en relation la topographie de la décharge avec les symptômes des crises, donnant accès à l'origine anatomique des crises.




Figure 2.7: L'Electroencéphalographie (EEG).

Les crises d'épilepsie sont des manifestations de l'épilepsie, qui sont dues au développement soudain de la décharge neuronale synchrone dans le cortex cérébral. Ces activités électriques cérébrales sont enregistrées et mesurées en utilisant l'EEG. Les crises d'épilepsie peuvent survenir localement dans le cerveau (crises partielles), qui ne sont visibles que dans quelques

canaux de l'enregistrement EEG, ou impliquant le cerveau entier (crises généralisées), qui sont observées dans tous les canaux de l'enregistrement EEG [Zab2015]. La principale difficulté dans la détection des crises réside dans la grande variété des motifs "pattern" EEG pouvant caractériser les activités cérébrales anormales, tels que:

Les spikes rythmiques, les polyspikes rythmiques, les polyspikes continus, les spikes et ondes, la désynchronisation de faible amplitude et les ondes rythmiques à une grande variété de fréquences et d'amplitudes [Zab2015], comme illustrer dans les figures (2.8 et 2.9).




Figure 2.8: Exemple de motifs épileptiques [Gon1999].




Figure 2.9: Exemple de crises épileptiques [Gon1999]. Les flèches marquées sur la figure indiquent les points du déclenchement des crises.

Plusieurs caractéristiques ont été proposées dans la littérature pour décrire cette multitude de motifs épileptiques comme les caractéristiques temporelles, spectrales ou d'ondelettes.

La figure 2.10 présente des exemples de segments EEG prisent pour différent patients durant des états normaux et durant des états de crises.




Figure 2.10: Différence entre l'EEG épileptique et l'EEG non-épileptique [Zab2015].

Le grand degré de similitude entre l'EEG normal d'un patient et l'EEG épileptique d'un autre patient rend la discrimination entre ces deux états une tâche difficile.

b) La Magnétoencéphalographie (MEG)

La magnétoencéphalographie (MEG) a été développée en 1972 par David Cohen qui a procédé aux premiers enregistrements de champs magnétiques cérébraux [Bai1999].

La réussite de cette expérience est due aux avancements dans les technologies des capteurs supraconducteurs extrêmement précis. La MEG est une technique d'imagerie non-invasive basée sur la mesure des variations du champ magnétique à la surface du crâne, provoquées par l'activation électrique intracellulaire des neurones pyramidaux formant un dipôle parallèle à la surface du crâne. Les capteurs utilisés permettent de mesurer des variations infinitésimales du champ magnétique de l'ordre de 10^{-15} Tesla [Gm2012].

La MEG présente une moyenne résolution spatiale ainsi qu'une excellente résolution temporelle qui permet de réaliser des applications en temps réel. Cependant, le coût élevé et la grande taille de l'appareil ainsi que la nécessité de refroidir les capteurs avec de l'hélium liquide. La figure 2.11 illustre l'appareil utilisé pour la mesure de la MEG.



Figure 2.11: *Technique de mesure MEG.*

2.6.3.2. Méthodes invasives

Les techniques invasives nécessitent une intervention chirurgicale pour placer les capteurs sous le crâne. Ceci permet d'augmenter l'amplitude du signal et de diminuer le bruit mais le coût élevé et la possibilité de provoquer des complications graves à la santé du sujet restent deux limites majeures.

a) Stéréo-Electroencéphalogramme (SEEG)

SEEG est l'une des techniques d'enregistrement pour les activités électrophysiologiques intracrâniennes avec une très bonne résolution spatiale de l'ordre de 2 mm [Ban1973, Tal1974]. Évidemment, ces électrodes doivent être insérées chirurgicalement par des neurologues (le processus d'implantation de l'électrode SEEG est montré dans figure 2.12). Elle est utilisée pour la localisation des sources dans le cadre de l'épilepsie partielle résistante aux médicaments.

Les enregistrements de SEEG mesurent donc l'activité épileptique d'une façon focale bien que les signaux présentent des intensités très faibles. Son grand avantage est qu'elle fournit des signaux non ou peu perturbés par le bruit [Ada2000].




Figure 2.12 (a)




Figure 2.12 (b)

Figure 2.12: Stéréo-Electroencéphalogramme, (a) l'électrode SEEG et (b) Implantation d'électrodes SEEG.

b) L'Electrocorticographie (ECoG)

ECoG est une technique d'imagerie cérébrale invasive. Depuis son invention par W. Penfield et H. Jasper dans les années 1950, elle reste utilisée jusqu'à maintenant [Fel2007, Hui1999, Leu2004, Sci2008].

L'ECoG est basée sur la mesure du potentiel d'action dans les neurones pyramidaux corticaux. Cette technique nécessite une opération chirurgicale pour implanter une grille d'électrodes,

sur/sous la dure-mère, entre l'os du crâne et la surface du cortex comme montré dans la figure 2.13. Ainsi, les amplitudes des signaux électriques acquis sont au maximum (50-100 μV) puisqu'ils ne seront pas conduits à travers le crâne qui diminue leurs potentiels en raison de la faible conductivité de l'os. Cela entraîne une augmentation de la résolution spatiale de l'ECOG par rapport à l'EEG (dizaines de millimètres par rapport aux centimètres) et de la bande passante des fréquences des signaux (supérieure à 300 Hz). En plus, les enregistrements ECoG sont moins influencés par les artefacts [Leu2004]. Il est fréquemment utilisé dans les pays anglo-saxons.




Figure 2.13: Grille d'électrodes placée sur le cortex d'un patient [Mil2007a].

2.6.3.3. Conclusion sur les modalités d'exploration cérébrale

En conclusion, on résume les principales propriétés des techniques d'exploration cérébrale présentées dans cette section (figure 2.14). On peut remarquer que chaque méthode a sa propre résolution spatiale et temporelle. La résolution spatiale indique la capacité de la technique à distinguer ou séparer deux ou plusieurs activités cérébrales spatialement proches. Tandis que la résolution temporelle indique sa sensibilité aux changements rapides dans le traitement neuronal. On concentrera au cours de ce travail notre attention sur l'EEG de surface, méthode autour de laquelle ces travaux se sont développés. Cette méthode apporte une excellente résolution temporelle (de l'ordre de la milliseconde) cependant sa résolution spatiale reste inférieure à celle des méthodes d'imagerie. Malgré cet inconvénient, cet examen est incontournable pour le diagnostic et la classification des épilepsies étant donné qu'il

permet d'enregistrer des informations en temps réel et d'une manière directe l'activité électrique du cerveau.

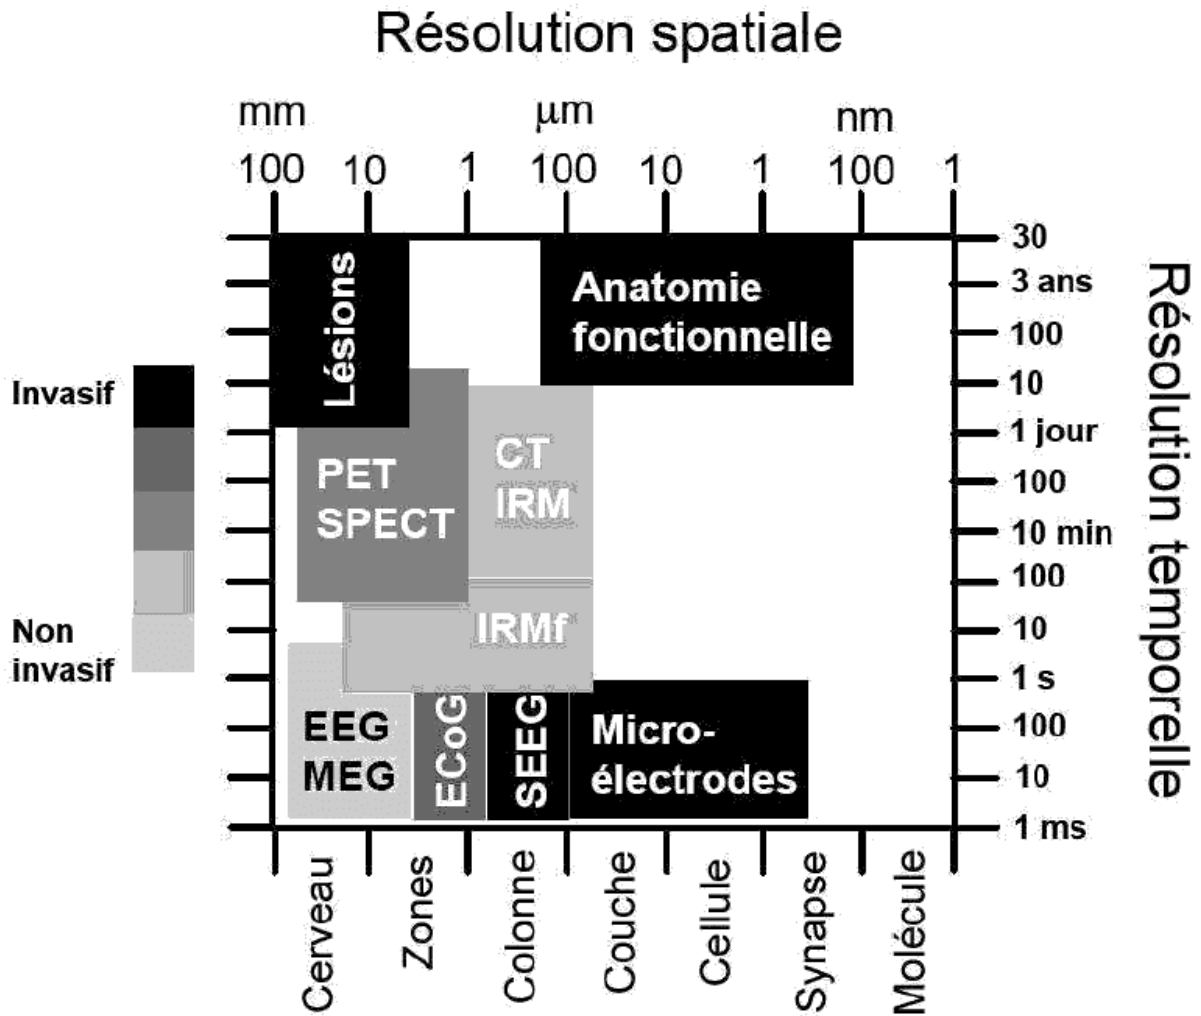


Figure 2.14: Schéma comparatif des résolutions temporelles et spatiales et du caractère invasif des différentes techniques d'exploration de l'activité cérébrale [Bra1968].

Le tableau 2.1 qui suit montre les principales propriétés des techniques d'exploration cérébrale les plus utilisées pour le diagnostic des épilepsies.

Tableau 2.1: Comparaison entre les différentes techniques d'exploration cérébrale pour le diagnostic des épilepsies. Source : Nicolas-Alonso et al. [Alo2012].

Technique de mesure	Nature du signal	Résolution spatiale	Résolution temporelle	Invasivité	Portabilité
ECoG	Electrique	1 mm	30 ms	Oui	Oui
IRMf	Métabolique	5 mm	1 s	Non	Non
MEG	Magnétique	5 mm	50 ms	Non	Non
EEG	Electrique	1 cm	50 ms	Non	Oui
SEEG	Electrique	2 mm	10 ms	Oui	Non
IRM	Métabolique	5 mm	–	Non	Non

2.7. Causes de l'épilepsie

Les différentes causes responsables de l'apparition de la pathologie sont observées à différents âges :

- **Une cause connue :** Liée par exemple à une lésion ou à un trouble du métabolisme, dite symptomatique;
- **Une cause non-déterminée :** Parfois les causes des convulsions sont non déterministes mais liées à une anomalie du cerveau, dite cryptogénique;
- **Une cause inconnue :** Qui constitue plus de la moitié des cas, dite idiopathique;
- **Une cause déterminée :** C'est la principale cause de crise épileptique et les troubles génétiques comme les accidents vasculaires cérébraux, les tumeurs cérébrales, trauma de tout type (plus la lésion est grave, plus le risque de développement de l'épilepsie est grand), altération du développement du cerveau du fœtus, blessure cérébrale lors de l'accouchement, manque d'oxygène chez les nouveau-nés, les infections chez les enfants et les nourrissons, séquelle d'infection (méningite, encéphalite) et intoxication (drogues, alcool).

Différents facteurs ont été décrits comme pouvant déclencher des crises chez les sujets prédisposés. Citons le stress, la mauvaise alimentation, un non-suivi du traitement, la

stimulation lumineuse intermittente (stroboscopique), un horaire de repas irrégulier, un état fébrile, un manque de sommeil et les émotions fortes.

2.8. Classification internationale de l'épilepsie

L'intérêt de la classification est de déterminer le type de maladie épileptique afin de répondre à ces questions :

- Quelle décision thérapeutique face à une telle manifestation ?, faut-il traiter ou non ? et avec quoi ?
- Fixer le pronostic à long terme, déterminer la durée du traitement, savoir si son arrêt est possible ou non ?
- Quelles sont les conséquences socioprofessionnelles ? l'orientation scolaire qui va déterminer l'activité professionnelle ?

2.8.1. Classification de l'épilepsie

Les manifestations de cette maladie sont très variées, c'est pourquoi, la ligue internationale contre l'épilepsie (ILAE : International League Against Epilepsy) a proposé une classification des épilepsies initialement publiée en 1960 et mise à jour en 1989 [Hen2015], afin que tous les professionnels de la santé parlent le même langage.

Cette classification est basée uniquement sur les descriptions cliniques qui sont :

- Le type de crises;
- Le contexte clinique dans lequel s'inscrit l'épilepsie : âge du début, antécédents familiaux et personnels, histoire clinique;
- Les manifestations neurologiques et extra-neurologiques associées à l'épilepsie;
- Les données de l'électroencéphalogramme critiques (durant les crises) et inter critiques (entre les crises);
- Les données de l'imagerie.

La première classification des crises épileptiques a été réalisée par Gastaut [Ben2014]. Cette classification a été révisée en 1981 (Commission on Classification and Terminology). Elle était alors basée uniquement sur des éléments cliniques et électroencéphalographiques des différents types de crises. L'originalité de cette classification était de séparer les crises partielles en crises simples et complexes selon qu'il existait ou non une altération de la

conscience [Hon2014]. Cette classification comporte trois groupes (les crises généralisées, les crises partielles, les crises inclassables) comme illustrée dans la figure 2.15.

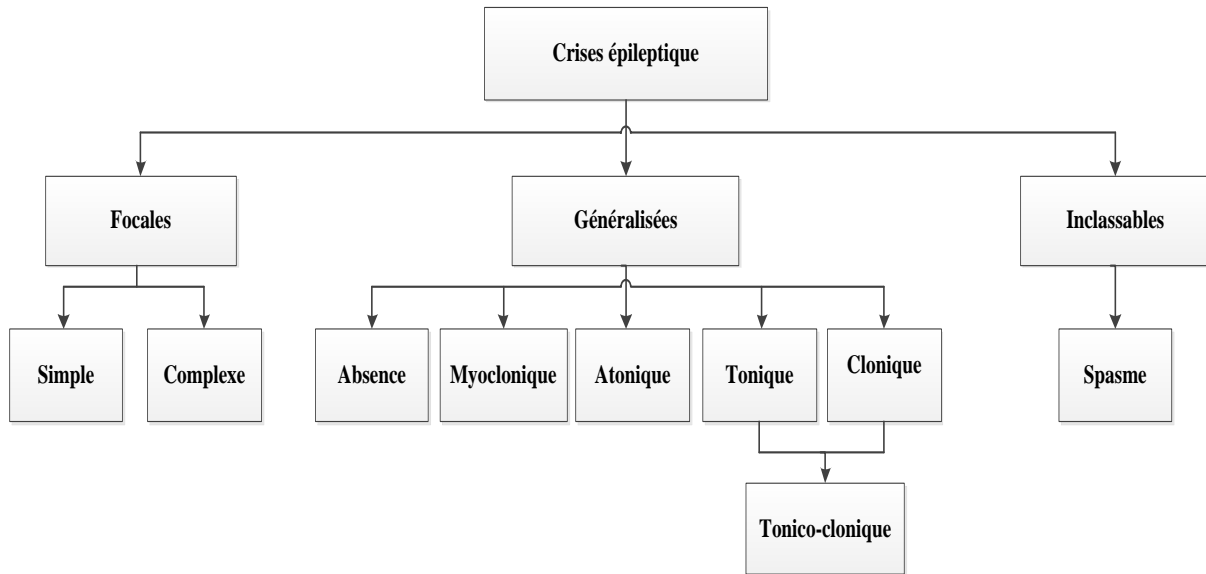


Figure 2.15: Classification par saisie selon ILAE [Jet2015].

2.8.1.1. Les crises partielles

Les crises partielles sont localisées dans une seule région du cerveau, appelée origine focale. Dans ce cas l'analyse du signal EEG et les premières manifestations cliniques montrent qu'un réseau cérébral limité à une partie d'un hémisphère cérébral est affecté [Hen2015].

Globalement, la proportion des crises généralisées est de 40% face à 60% pour les crises partielles [Mah2006, Kot2002].

Les crises partielles sont subdivisées en 2 grands groupes: partielles simples et partielles complexes. On distingue ces 2 types selon qu'il existait ou non une altération de la conscience.

a) Les crises partielles simples

Les crises partielles qui n'agissent pas sur la conscience sont appelées crises partielles simples. Elles étaient appelées autrefois "crises focales", car elles ne sont localisées que dans une petite région du cerveau (le siège focal). Durant ce type de crise, la personne est consciente de ce qui se passe et elle est habituellement de courte durée. Ce type de crises est également connu sous le nom de "aura" parce qu'il sert souvent d'indice annonciateur qu'une convulsion plus grave est imminente.

b) Les crises partielles complexes

Les crises partielles complexes touchent des structures centrales profondes du cerveau qui régissent la conscience, entraînant donc des altérations ou une perte de la conscience. La personne qui fait une crise partielle complexe regarde dans le vide et fait des gestes automatiques répétés dont elle n'a pas conscience, comme claquer des lèvres, tirer sur ses vêtements, marcher au hasard avec un air désorienté et confus. Elles étaient autrefois appelées crises psychomotrices ou du lobe temporal, car elles sont souvent localisées au niveau des lobes temporal ou frontal. Les fonctions cérébrales localisées dans ces lobes sont aussi complexes que les crises qui les affectent.

2.8.1.2. *Les crises généralisées*

Les crises généralisées, qui sont caractérisées par une activité électrique anormale, touchent la totalité du cerveau, sans origine focale apparente ou signal d'avertissement. Dans ces cas les premières manifestations cliniques et EEG des crises indiquent l'implication des deux hémisphères cérébraux. Ces crises mènent dans la plupart des cas à une perte de connaissance. Elles peuvent se manifester de différentes façons.

Les crises généralisées sont divisées en six types généraux :

- a) **Les absences** : Ce sont des convulsions où les patients deviennent absents [Mil2015b]. Ils peuvent être divisés en deux sous-types. Les absences typiques (ou petit mal, suspension de l'activité en cours et une perte de conscience de quelques secondes). Les absences atypiques (similaires aux absences typiques mais accompagnées de quelques contractions musculaires) [Vel2010];
- b) **Crises myocloniques** : Elles se manifestent par des torsions d'une ou plusieurs parties du corps qui durent plus de 100 millisecondes. Ceux-ci sont causés par une activité synchrone des unités motrices. La myoclonie peut se produire seule ou dans des séquences, où la conscience est habituellement préservée. Souvent, les séquences produisent des crampes généralisées [Jet2015];
- c) **Crises cloniques** : Sont des contractions musculaires rythmiques des membres. Normalement, elles se répètent environ 2 à 5 fois par seconde;
- d) **Crises toniques** : Ce sont caractérisées par une augmentation universelle du tonus dans le corps et les extrémités d'environ 5-10 secondes avec une perte de conscience;

- e) **Crises tonico-cloniques (ou grand mal) :** Elles possèdent deux phases séquentielles: la phase tonique (10-20 secondes) suivie d'une phase clonique (1/2-2 minutes) [Mil2015b];
- f) **Crises atoniques / crises astatiques :** C'est une perte extrêmement courte du tonus musculaire.

2.8.1.3. *Les crises inclassables*

Les crises inclassables sont celles sur lesquelles on dispose de moins de renseignements cliniques [Tho2003], car elles sont peu fréquentes.

2.8.2. Classification des épilepsies et des syndromes épileptiques

En 1989, La LICE a proposé une classification des syndromes épileptiques (Commission on Classification and Terminology, ILAE, 1989), très liée à celle de 1981 puisqu'elle conservait la distinction entre épilepsies généralisées et partielles mais proposait une terminologie spécifique en fonction de l'étiologie. Cette classification permettait de distinguer :

2.8.2.1. *Les épilepsies idiopathiques*

Ce type d'épilepsies appelées primaires dans la classification de 1970, définies par leurs caractères électro-cliniques, habituellement âge-dépendantes, sans aucune lésion cérébrale détectée et sans cause organique, répondant à un facteur génétique plus ou moins évident. Ceci fait suspecter une lésion invisible en imagerie cérébrale et engendre tout de même un dysfonctionnement transitoire du cerveau. Les épilepsies idiopathiques de l'adulte sont toujours généralisées. Ce sont essentiellement des épilepsies, datant de l'enfance ou de l'adolescence, n'ayant pas guéri mais le plus souvent elles sont en rémission durable sous traitement. Elles disparaissent vers la puberté ou à l'âge adulte.

2.8.2.2. *Les épilepsies cryptogéniques*

Ces épilepsies représentent environ 30% des cas mais ce chiffre est en constante diminution du fait de l'évolution permanente des nouvelles techniques d'exploration. On parle d'épilepsie cryptogénique lorsqu'une crise est suspectée, mais ne répond à aucune cause explicable par les antécédents et/ou décelable par les moyens diagnostics actuels.

2.8.2.3. *Les épilepsies symptomatiques*

Elles sont dues à une lésion cérébrale identifiée ou suspectée, fixée ou évolutive ou secondaire à des troubles métaboliques: malformation congénitale, encéphalite, séquelles d'une souffrance natale, traumatisme crânien, accident cérébro-vasculaires, tumeurs, infections du

SNC, maladies neurologiques évolutives, anomalies des chromosomes et malformations cérébrales... Elles peuvent se présenter sous la forme : d'épilepsies partielles, du syndrome de West, du syndrome de Lennox-Gastaut ou d'une épilepsie multifocale. Selon la Fondation Française pour la Recherche sur l'Épilepsie (FFRE), 40% des épilepsies sont d'origine symptomatique [Ffr2009].

Quant aux épilepsies symptomatiques ou cryptogéniques, elles sont le plus souvent partielles. Elles représentent près de 70% des épilepsies de l'adulte [Ffr2009].

2.8.3. Révision terminologique et conceptuelle

En 2010, Berg et al. ont proposé une révision terminologique et conceptuelle de l'organisation des différentes formes des crises épileptiques et des épilepsies (Commission on Classification and Terminology, ILAE, 2010). Cette proposition a voulu tenir compte des avancées obtenues dans les domaines des neurosciences en intégrant les apports cliniques, génétiques, neurobiologiques et ceux de la neuroimagerie [Beg2010]. Cette classification a maintenu la liste des syndromes déjà connus en proposant des changements de terminologie et de concept.

- a) Le terme "**idiopathique**" a été remplacé par le terme "**génétique**". Définis par leurs caractères électrocliniques, habituellement âge-dépendantes, ces sujets sans aucune lésion cérébrale détectée et sans cause organique [Vel2010]. Une épilepsie génétique étant la conséquence d'une anomalie génétique connue ou présumée dont les crises sont la principale manifestation. La nature génétique d'un trouble n'exclut pas la possibilité d'une contribution de facteurs environnementaux même si à l'heure actuelle, il n'existe pas de données qui montrent l'influence spécifique de ces derniers dans les épilepsies génétiques [Eul2015];
- b) Le terme "**symptomatique**" a été remplacé par le terme "**structurelle/métabolique**". La nouvelle désignation met en avant l'existence d'une cause dont le rapport avec l'épilepsie n'est pas forcément direct;
- c) Le terme "**cryptogénique**" a laissé la place au terme "**cause inconnue**"; celui-ci semble mieux indiqué que la nature de la cause sous-jacente demeure jusque-là inconnue.

La figure 2.16 présente la proposition de la LICE pour une révision de la terminologie et de l'organisation des crises et des épilepsies 2010.

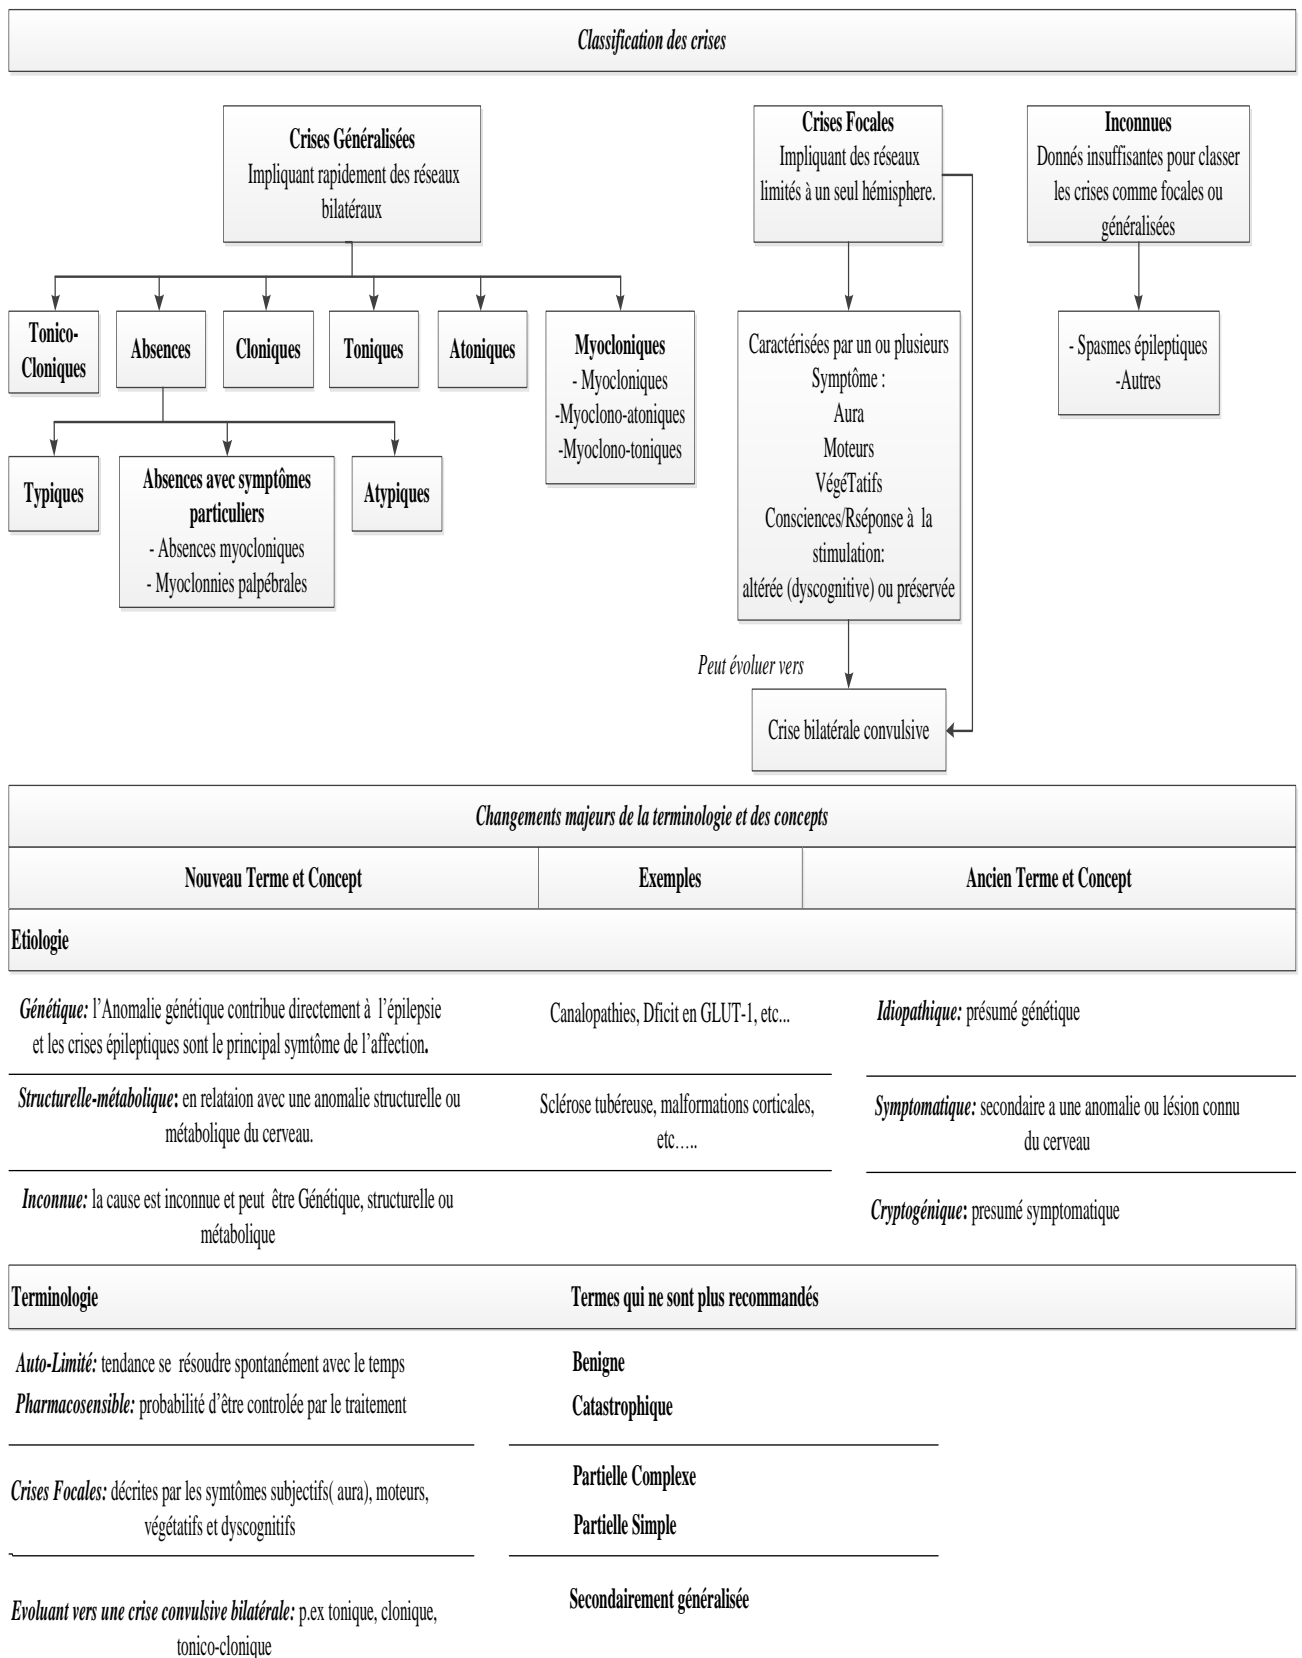


Figure 2.16: Classification des crises épileptiques [Beg2010].

2.9. Prise en charge

L'épilepsie est une maladie très handicapante, les crises peuvent être évitées grâce à un traitement adapté. Pas de prise en charge universelle. A chaque patient, une solution.

2.9.1. Pharmacologique (médicamenteux)

Pour contrôler les convulsions, les traitements médicamenteux sont souvent utiles, la plupart des épilepsies peuvent être traitées médicalement. Aujourd'hui, de 7 à 8 malades sur 10 ne sont suivis qu'avec un seul médicament. En cas d'échec, un autre médicament peut être proposé, (entre 17 et 30% des cas de succès) [Fer2009]. En cas d'un deuxième échec, on pense à l'association de plusieurs médicaments. Toutefois, si les traitements médicamenteux ne seront pas suffisants, l'alternative chez les patients pharmacorésistants est le recours à la chirurgie. En effet, 5 à 10% d'entre eux pourront bénéficier d'une intervention chirurgicale.

2.9.2. Chirurgie

En cas de crises partielles et que la médication n'apporte pas de résultats tangibles, il est parfois possible de procéder à une chirurgie.

La chirurgie du cerveau consiste à sectionner la région du cerveau où les décharges épileptiques sont produites par les neurones (origine focale), lorsqu'il est possible de déterminer la zone épileptogène (ZE) où les crises débutent et d'en faire l'ablation de façon sécuritaire.

Trois types d'intervention sont actuellement pratiqués suivant une neurochirurgie classique [Vel2010]:

- **La cortectomie :** Elle est limitée à la résection de la zone où la ZE a été individualisée;
- **La callosotomie :** Elle est indiquée dans certaines épilepsies généralisées graves et consiste à la résection du corps calleux qui relie les deux hémisphères cérébraux;
- **L'hémisphérotomie :** Elle est l'isolation des hémisphères l'un de l'autre.

Comme pour toute intervention chirurgicale, la chirurgie du cerveau comporte des risques. Néanmoins, chez les patients dont le foyer d'origine a été localisé, le taux de succès de la chirurgie s'élève à 80 %.

2.9.3. Stimulation du nerf vague

C'est une technique pour maîtriser les crises difficiles à traiter et qui ne répondent pas à la chirurgie ou à la médication. Il s'agit d'un petit dispositif (5 cm de diamètre) ressemblant à un stimulateur cardiaque, contenant un fil conducteur (électrode) que l'on enroule autour du nerf vague situé dans le cou. Il est implanté chirurgicalement sous la clavicule gauche (figure 2.17). Les impulsions électriques qu'il génère vont atteindre les différentes régions cérébrales et agir sur les foyers de l'épilepsie.

Jusqu'à présent, les recherches ont démontré que la stimulation du nerf vague peut réduire la fréquence des crises de 50 % ou plus chez environ la moitié des sujets.

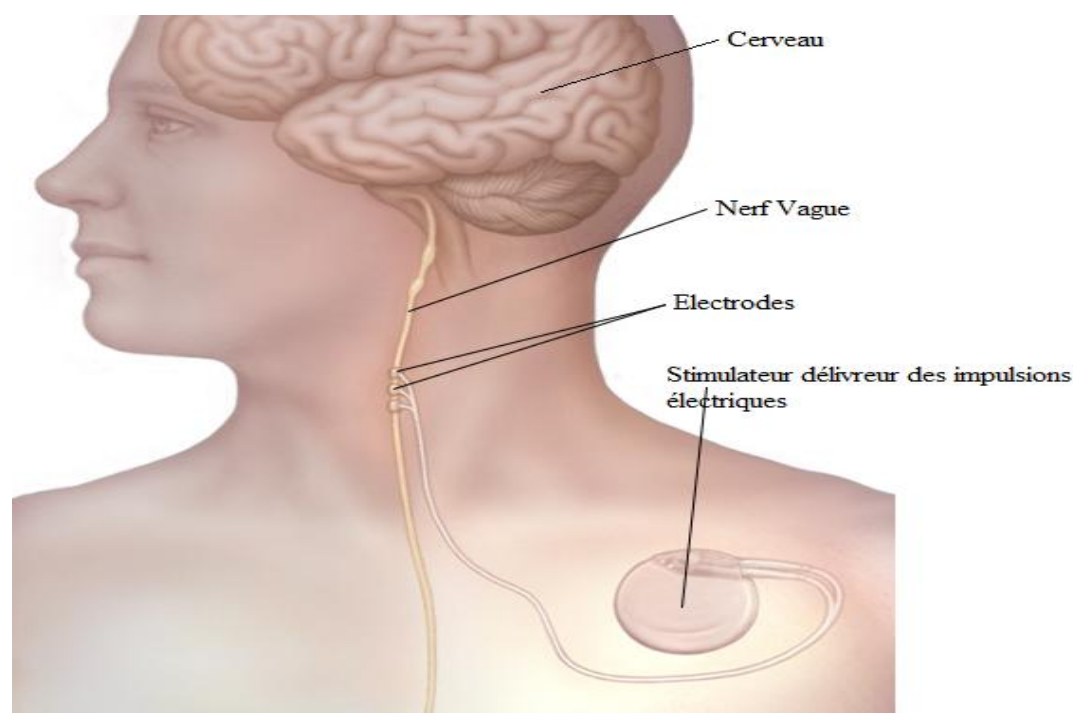


Figure 2.17: *Stimulation du nerf vague.*

2.9.4. Le gamma knife (GK)

GK est une radio-chirurgie encore expérimentale pour l'épilepsie. Cette méthode consiste à irradier la zone causant l'épilepsie par des faisceaux convergents en utilisant une puissance de radiation très élevée (figure 2.18). La radio-chirurgie a l'avantage d'être non invasive et de ne détruire que les cellules défectueuses. Elle peut être employée seulement pour traiter des lésions cérébrales de petite taille (moins de 3 cm de diamètre) situés dans des structures profondes inopérables par la chirurgie classique.




Figure 2.18: *Le gamma knife.*

2.10. Conclusion

L'enjeu des investigations actuelles en neuropsychologie de l'épilepsie repose sur l'identification des marqueurs neurobiologiques des troubles cognitifs classiquement décrits. L'épilepsie est appelée comme un groupe de conditions, principalement, plus d'une crise non provoquée dans un temps limité en raison de l'activité électrique irrégulière des neurones du cerveau.

Ce chapitre présente, dans une première section, un aperçu détaillé de l'épilepsie et les différents types des crises épileptiques. Ensuite, toute une partie est consacrée au diagnostic de celle-ci. Parmi ces méthodes de diagnostic, un certain nombre s'appuient sur l'enregistrement direct de l'activité électrophysiologique du cerveau. En routine clinique, la technique la plus couramment utilisée est l'EEG, car elle permet de recueillir un grand nombre d'informations dynamiques au cours de la crise (inter-critique proche et critique) épileptique de façon rapide et totalement non-invasive.

Le chapitre suivant présente les méthodes de traitement du signal les plus utilisées dans la conception des systèmes automatiques de détection des crises épileptiques. Ainsi, une méthode basée sur la transformée en ondelettes est présentée en détaille avec les résultats d'évaluation.

Chapitre 3

*Etude des systèmes de détection
automatique des crises épileptiques*

Chapitre 3 : Etude des systèmes de détection automatique des crises épileptiques

3.1. Introduction

3.2. Etat de l'art en méthodes de détection automatique des crises épileptiques

3.3. Détection des crises épileptiques avec l'EEG monocanal en utilisant l'ELM et le SVM

3.4. Résultats de l'évaluation de la méthode proposée

3.5. Conclusion

3.1. Introduction

Le système de détection automatique des crises épileptiques basé sur le signal EEG semble être assez simple dans son principe mais un certain nombre de problèmes doit être résolu, afin d'aboutir à des résultats satisfaisants. Au cours de la mise en œuvre du système, on doit prendre en considération plusieurs facteurs liés à la nature du signal traité (faible rapport signal sur bruit, artefacts de haute amplitude...) et à la variabilité entre les sujets. De ce fait, l'acquisition du signal EEG doit être réalisée dans les meilleures conditions afin d'améliorer sa qualité. D'autre part, les techniques de traitement du signal doivent être adéquates aux différentes caractéristiques du signal EEG.

De nombreuses méthodes de traitement du signal ont été proposées pour l'amélioration de la qualité des signaux par l'élimination des artefacts et la réduction du bruit. Aussi plusieurs travaux ont été menés afin d'optimiser les paramètres du système et de sélectionner les caractéristiques les plus pertinentes.

Ce chapitre présente les meilleures méthodes de la reconnaissance des crises épileptiques qui sont présentes dans la littérature. De même, il présente et détaille l'une des méthodes les plus utilisées. Les résultats de l'implémentation de cette méthode avec trois sujets de la base de données CHB-MIT sont examinés afin d'évaluer les performances du système.

3.2. Etat de l'art en méthodes de détection automatique des crises épileptiques

Plusieurs algorithmes ont été conçus pour la détection automatique des crises dans le but de surveiller l'épilepsie chez les patients. En effet, La détection des crises a été abordée comme un problème d'apprentissage automatique (machine-learning) qui se constitue de deux étapes principales: la génération des caractéristiques et la conception et le choix du classifieur. De ce fait, de nombreuses approches ont été expérimentées afin de produire des caractéristiques EEG spécifiques aux crises et suffisamment sensibles et génériques pour capturer la majorité d'entre elles. Les premières méthodes proposées ne visaient pas réellement la détection des crises, mais la compression des données et la mise en évidence des événements du signal EEG pour faciliter l'examen du neurologue. Ces systèmes de détection semi-automatique peuvent accélérer le processus d'évaluation, mais ils imposent un retard à l'intervention. Il existe plusieurs rapports décrivant des outils de compression largement utilisés tels que le réseau spectral compressé, le réseau de densité spectral, le spectrogramme et l'opérateur d'énergie non linéaire [Sch2002, Aga2001, Sce2004, Sha2006].

Dans le passé, la technique la plus largement appliquée était d'analyser le contenu fréquentiel du signal en appliquant quelques variantes de la transformée de Fourier [Pol2007]. Ceci permet d'avoir un compromis considérable entre les résolutions fréquentielles et temporelles. Cependant, si le spectre est évalué dans des courtes fenêtres, la résolution temporelle devient satisfaisante, mais la résolution fréquentielle devient médiocre. Par contre, si une fenêtre plus longue est utilisée, la résolution fréquentielle augmente, mais l'information est moins concentrée dans le temps.

Une approche plus moderne consiste à utiliser la transformation en ondelettes [Ade2003]. Cette méthode est présentée plus en détail dans la section suivante. La décomposition en ondelettes permet de représenter les propriétés du signal avec différentes échelles. De cette façon, les composantes temporelles et fréquentielles peuvent être évaluées avec une résolution relativement bonne.

D'autres travaux se sont intéressés aux caractéristiques extraites directement à partir du signal EEG. Les caractéristiques les plus couramment utilisées sont la puissance du signal et les nombres de passage par zéro. Ces techniques ont une très faible complexité de calcul, ce qui constitue un avantage lors de la conception d'un algorithme temps réel [Oso2017]. Après la

génération des caractéristiques, il reste à concevoir une méthode de prise de décision. Ceci est un problème typique d'apprentissage supervisé. Étant donné un ensemble de données avec les résultats souhaités connus, il faut concevoir un système de décision qui fonctionne bien avec ces données de même qu'avec un ensemble de données préalablement inconnues.

Les méthodes d'apprentissage automatiques qui ont été appliquées dans ce domaine comprennent les systèmes experts, les arbres de décision, les algorithmes de clustering, la carte auto-organisatrice ou carte de Kohonen et une variété de configurations de réseaux de neurones artificiels.

Certains algorithmes de détection des crises ont été mis en disposition par des neurologistes. Chaque méthode développée nécessite une validation, avec des expériences sur des données réelles. Nous présentons ici quelques exemples des systèmes les plus performants.

Gotman a été impliqué dans le domaine de la surveillance de l'EEG et de la détection des crises depuis les années 1970. Ses algorithmes sont distribués par Stellate. Les premiers algorithmes ont utilisé une décomposition de l'EEG en ondes élémentaires puis une inspection de leurs propriétés [Got1982, Gom1990]. Un autre module a été ajouté pour exclure les causes communes des faux positives [Goa1993]. H. Qu, et J. Gotman. ont proposé une classification spécifique au patient qui utilise cinq caractéristiques extraites des domaines temporel et fréquentielle [Qu1997]. Les caractéristiques utilisées pour chaque segment et pour chaque canal EEG sont: l'amplitude moyenne de l'onde, la durée moyenne des ondes, le coefficient de variation de la durée de l'onde, la fréquence dominante et la puissance moyenne dans une zone d'énergie principale. Les trois premières caractéristiques proviennent de la méthode de décomposition d'onde de Gotman et les deux autres représentent des caractéristiques importantes de l'EEG dans le domaine fréquentiel. Un classifieur des plus proches voisins modifiés a été utilisé. Cette méthode était validée avec 47 crises de 12 patients. La valeur de sensibilité était de 100%. M. E. Saab et J. Gotman ont conçu un système basé sur la décomposition en ondelettes pour l'extraction des caractéristiques à partir des segments afin de calculer les probabilités a priori requises pour la formulation bayésienne utilisée dans l'apprentissage, le test et le fonctionnement normal du système [Saa2004]. Cette méthode a été testée avec 652 heures d'EEG, incluant 126 crises chez 28 patients pour la phase d'apprentissage et 360 heures d'EEG, dont 69 crises chez 16 patients pour la phase de test. La valeur de sensibilité était de 77.9%. Scott B Wilson et al. ont créé l'algorithme Reveal qui utilise trois nouvelles méthodes dans leur application à la détection des crises: l'algorithme itératif "matching pursuit", petites règles de réseau de neurones et nouvel algorithme de

"clustering" hiérarchique d'objet connecté (connected-object hierarchical clustering algorithm) [Sco2004]. La méthode a été testée avec 672 crises chez 426 patients atteints d'épilepsie. La valeur de sensibilité était de 76%. D'autre part, A. Shoeb et al. ont proposé une méthode qui utilise une décomposition en ondelettes pour construire un vecteur de caractéristiques qui reflète la morphologie et la répartition spatiale d'une période de données électroencéphalographique, puis détermine si ce vecteur est représentatif d'une crise ou non à l'aide de l'algorithme de classification machines à vecteurs de support [Sho2004]. Cette méthode a été testée sur des électroencéphalogrammes non invasifs de 36 sujets pédiatriques souffrant d'une variété de types de crises. La valeur de sensibilité était de 94%. G.E. Polchronaki et al. ont conçu un algorithme qui utilise la dimension fractal (DF) comme mesure naturelle de l'irrégularité d'une courbe puis compare deux méthodologies: l'Algorithme de Katz et l'Algorithme de plus proches voisins [Poy2010]. Si la valeur (DF) d'une fenêtre donnée est inférieure à la valeur du seuil, cette fenêtre est considérée comme le début d'une crise. Cette méthode était testée avec 244,9 heures d'enregistrements EEG du cuir chevelu, dont 16 crises chez 3 patients. La valeur de sensibilité était de 100%. Le travail de Y. U. Khan et al. décrivent une méthode basée sur deux caractéristiques statistiques: le skewness et la kurtosis avec une caractéristique basée sur les ondelettes: le coefficient de variation normalisé [Kha2012]. La différenciation entre la crise et les signaux EEG normaux a été effectuée en utilisant un classifieur linéaire simple. La crise est identifiée si elle était présente dans au moins 60% des canaux. Ce système a été évalué avec 55 crises d'une durée de 10646 secondes en provenance de 10 patients. La valeur de sensibilité était de 100%.

3.3. Détection des crises épileptiques avec l'EEG monocanal en utilisant l'ELM et le SVM

Nous allons présenter dans un premier exemple un système de reconnaissance de crise basé sur la transformée en ondelettes et les classifieurs ELM et SVM.

Le processus de reconnaissance des crises épileptiques utilisé dans cette méthode peut être divisé en quatre étapes. Les signaux EEG acquis à partir du canal FT10-T8 (en se basant sur le travail de Maragakis et al. [Mar2015]) sont d'abord divisés en plusieurs segments qui seront traités séparément. Ensuite, une transformée en ondelettes appliquée à chaque segment contribue dans l'étape de prétraitement et l'étape d'extraction de caractéristiques. En effet, seulement les niveaux de décomposition ou les bandes représentatives des deux états (avec et sans crise) seront prises en considération. Les bandes ondelettes non pertinentes seront

ignorées. Cette technique est utilisée comme étant la phase de prétraitement qui diminue le niveau de bruit et des artefacts. Des caractéristiques fréquentielles et temporelles seront extraites à partir des bandes pertinentes. Finalement, nous avons adopté les classifieurs de machine d'apprentissage extrême et de machines à vecteurs de support pour décider si une crise est détectée ou non dans le segment de données examiné.

La figure 3.1 représente les différentes étapes impliquées dans le processus de classification.

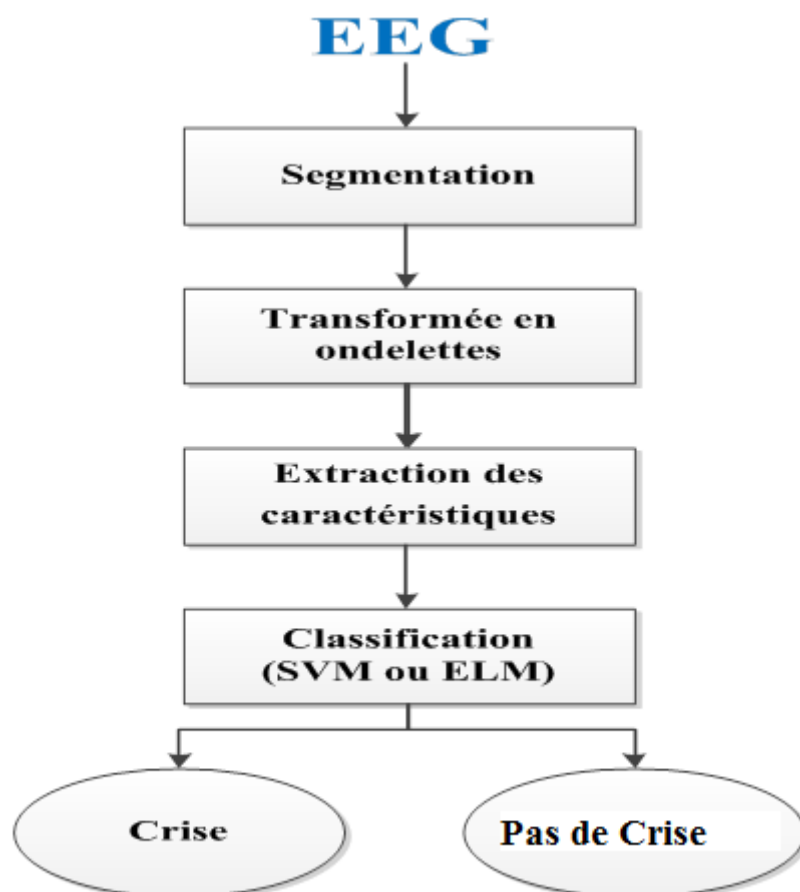


Figure 3.1: Schéma de principe de la méthode proposée.

3.3.1. Extraction des caractéristiques avec la transformée en ondelettes

La Transformée en Ondelette (TO) décompose le signal temporel en le transformant vers le plan temps-échelle [Ors2016]. Elle conduit à extraire plusieurs bandes de sous-fréquence des segments EEG à l'aide de différentes fonctions d'ondelettes. La sélection de la fonction d'ondelettes et le nombre de niveaux de décomposition appropriés permettent d'avoir des caractéristiques pertinentes. Nous avons utilisé dans cette méthode la fonction d'ondelettes Daubechies d'ordre 6 avec 6 niveaux de décomposition en se référant au travail présenté dans [Jin2009]. Le choix du niveau de décomposition tient en considération les rythmes cérébraux

intéressants. La TO a été calculée pour chaque segment de 2 s et six niveaux de décomposition (D_i avec i est le nombre de niveaux) ont été trouvés comme illustré dans la figure 3.2 et la figure 3.3.




Figure 3.2: Exemple d'ondelettes extraites d'un signal de durée de 2 s.

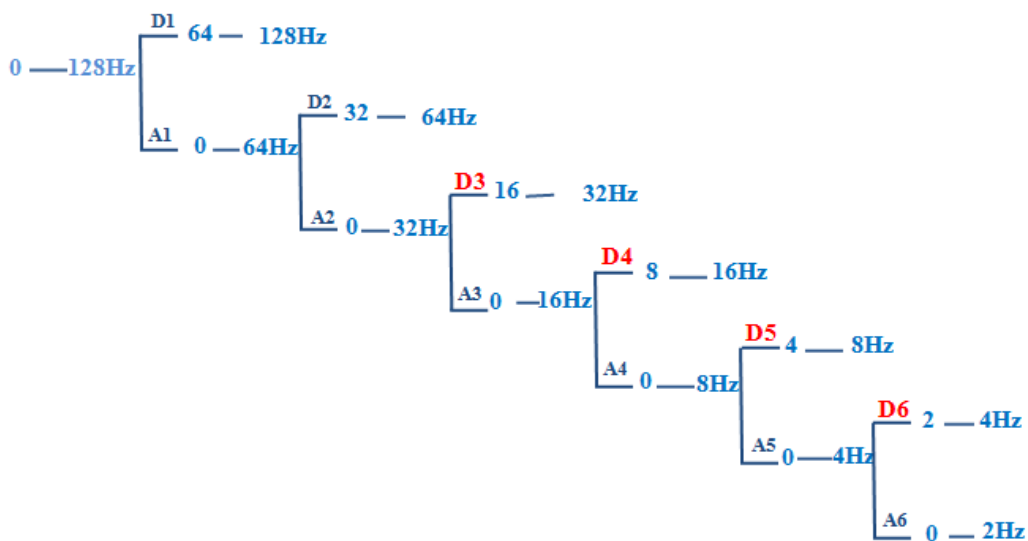


Figure 3.3: Niveaux de décomposition du signal EEG échantillonné à 256 Hz.

Quatre bandes TO peuvent être considérées comme pertinentes car elles se situent approximativement sur les mêmes bandes de fréquence que les rythmes cérébraux: β entre 13 et 30 Hz, α entre 8 et 13 Hz, θ entre 4 et 8 Hz et δ entre 0,5 et 4 Hz [Mar2015]. Ensuite, pour chaque bande, les caractéristiques temporelles et spectrales ont été déterminées.

Le tableau 3.1 illustre les bandes passantes des filtres d'ondelettes D3, D4, D5 et D6.

Tableau 3.1: Bondes d'ondelettes utilisées dans la détection des crises [Amm2016].

Niveau de décomposition	Largeur de bande (Hz)	Rythmes cérébrales
D3	16-32 Hz	β
D4	8-16 Hz	α
D5	4-8 Hz	θ
D6	2-4 Hz	δ

3.3.1.1. Transformée en ondelettes

La transformée en ondelettes [Lou1997] réalise la décomposition du signal sur une base de fonctions correspondant à des petites oscillations, aussi appelées ondelettes, qui gardent la même forme et ne diffèrent que par leurs tailles. Elle utilise une fenêtre dont la longueur est dilatée ou contractée. Le signal traité sera donc représenté comme une somme pondérée de ces petites ondes translatées ou dilatées. Une ondelette est une fonction de carré sommable de l'espace de Hilbert $\psi \in L^2(\mathbb{R})$ de moyenne nulle :

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (3.1)$$

Elle est normalisée à $\|\psi\|=1$. Une famille d'atomes temps-fréquence s'obtient en dilatant l'ondelette ψ par un facteur s , et en la translatant par u :

$$\psi_{us}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) \quad (3.2)$$

Ces atomes restent de norme 1 : $\|\psi_{us}\|=1$. La transformée en ondelettes continue du signal $f(t)$ est le produit de convolution du signal par l'ondelette $\psi(t)$ dilatée de s et translatée de u [Pat2009]:

$$wf(u, s) = \langle f, \psi_{us} \rangle = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi^* \left(\frac{t-u}{s} \right) dt \quad (3.3)$$

Où le symbole $*$ désigne le conjugué complexe.

Cette expression donne une représentation du signal $f(t)$ avec différentes échelles (multi-échelle) et pour tout instant u pour explorer le signal dans le plan temporel. Le paramètre s opère la dilatation de l'ondelette : plus s est petit plus le support de l'ondelette est réduit et inversement.

La transformée en ondelettes continue peut s'écrire comme un produit de convolution :

$$wf(u, s) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi^* \left(\frac{t-u}{s} \right) dt = f * \overline{\psi_s}(u) \quad (3.4)$$

u Coefficient de translation

s Coefficient de dilatation

ψ^* Fonction mère

$f(t)$ Signal original

Avec

$$\overline{\psi_s}(u) = \frac{1}{\sqrt{s}} \psi^* \left(\frac{-t}{s} \right) \quad (3.5)$$

Supposant que la fonction ondelette mère est définie dans l'espace de Haar, Daubechies,... une approximation $f[n]$ d'un signal discret peut être écrite dans $l^2(\mathbb{Z})$ sous la forme :

$$f[n] = \frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi[j, k] \psi_{j, k}[n] \quad (3.6)$$

Ici, $f[n]$, $\phi_{j_0, k}[n]$ et $\psi_{j, k}[n]$ sont des fonctions discrètes définies sur $[0, M-1]$ ou M est le nombre total des points. Ainsi, puisque $\{\phi_{j_0, k}[n]\}_{k \in \mathbb{Z}}$ et $\{\psi_{j, k}[n]\}_{(j, k) \in \mathbb{Z}^2, j \geq j_0}$ sont orthogonaux, on peut utiliser le produit de convolution pour trouver les coefficients d'ondelette.

$$W_\phi[j_0, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \phi_{j_0, k}[n] \quad (3.7)$$

$$W_\psi[j, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \psi_{j, k}[n] \quad (3.8)$$

$$j \geq j_0$$

L'équation 3.7 sont les coefficients d'approximation tandis que l'équation 3.8 sont les coefficients du détail.

Avec

$$\phi_{j, k}(t) = 2^{j/2} \phi(2^j t - k) \quad (3.9)$$

$$\psi_{j, k}(t) = 2^{2j} \psi(2^j t - k) \quad (3.10)$$

Où j est le paramètre de dilatation, k est le paramètre lié à la position, ϕ est la fonction de mise à l'échelle et ψ est la fonction ondelette mère.

Plusieurs algorithmes pour la décomposition du signal en sous-bandes de fréquence étaient proposés. Cette décomposition est ajustable ce qui offre une grande souplesse pour l'utilisateur et lui permet de s'adapter au signal à analyser. En effet, les algorithmes permettent de trouver l'approximation et les détails à la résolution immédiatement inférieure, ce qui par itérations successives conduit à l'analyse du signal pour toutes les résolutions inférieures à celle de départ.

L'algorithme de Mallat pour la transformée en ondelettes discrète, qui est un système classique de banque de filtres décompose le signal en différentes échelles qui peuvent être considérées comme des bandes de fréquences différentes. Nous pouvons donc obtenir une représentation à plusieurs résolutions (multi-échelle) de la fonction échantillonnée sur un nombre fini d'échelles de la plus fine à la plus dilatée. En alimentant successivement le signal

ou (les coefficients d'approximation) dans le schéma, cette transformée décompose le signal en coefficients avec des résolutions différentielles de temps et de fréquence.

La transformation d'ondelettes est donc une technique multi-résolution qui permet de traiter le signal en différents intervalles de temps et bandes de fréquences. L'application de cette technique sur un signal transforme ses échantillons situés dans le domaine temporel vers des coefficients discrets dans le domaine de l'ondelette.

3.3.1.2. Analyse multi résolution

En 1988, S. Mallat [Maa2000] a proposé un algorithme rapide pour calculer les coefficients d'ondelettes. Cet algorithme a été fortement inspiré de l'algorithme pyramidal introduit dans les années 70. La théorie de la multi-résolution conçoit la transformée en ondelettes discrètes (TOD) comme une séquence d'application de filtres [Maa2000]. Le signal est constitué de composantes basses fréquences: appelées approximations et de composantes hautes fréquences : appelées détails. Selon Mallat, nous pouvons séparer les détails et les approximations en faisant appel à une paire de filtre H et G, appelées aussi filtres à miroirs quadratique, qui sont un filtre passe bas et un filtre passe haut complémentaires (ils ont la même fréquence de coupure) et dont les réponses impulsionnelles doivent satisfaire certaines conditions.

Le processus de cet algorithme de Mallat à son premier niveau est illustré dans la figure 3.4.

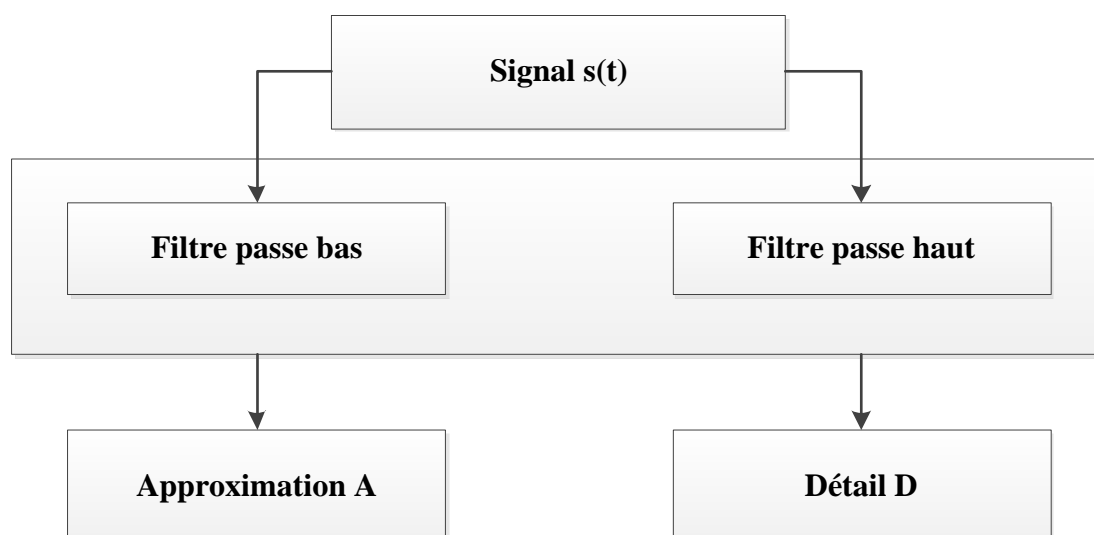


Figure 3.4: Principe de l'algorithme de Mallat.

Pour passer au niveau suivant de la décomposition, on applique la même opération à l'approximation A. le processus est par la suite itéré à chaque fois qu'on obtient une approximation (figure 3.5).

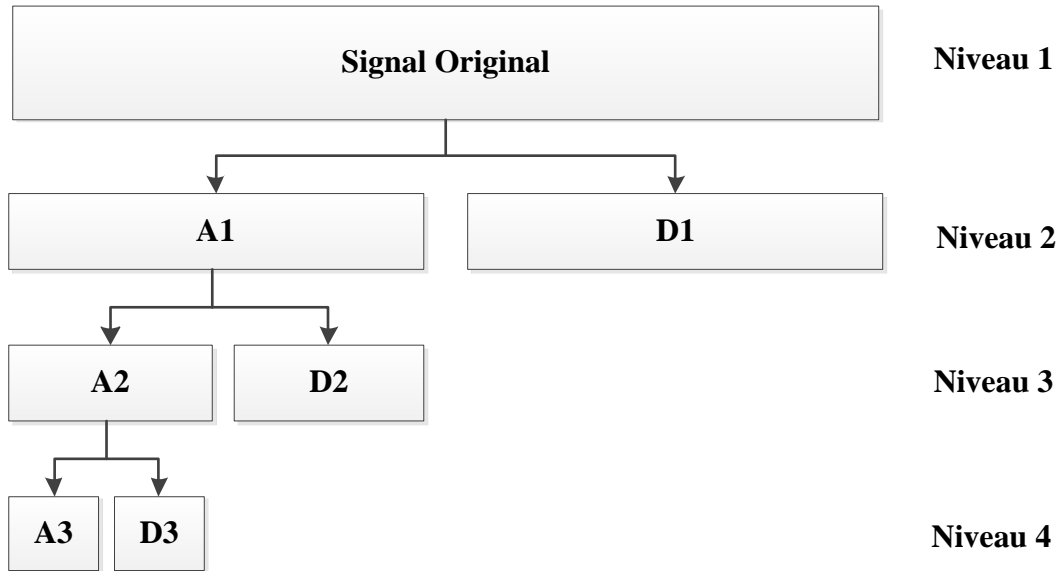


Figure 3.5: Décomposition par ondelettes.

Le calcul des coefficients se fait donc de manière itérative et hiérarchique. La différence entre une approximation b_i et l'approximation qui la suit A_{n+1} représente le détail D_{n+1} .

3.3.2. Extraction des caractéristiques

Après la décomposition, plusieurs caractéristiques ont été extraites à partir des niveaux (D3, D4, D5 et D6). La densité spectrale de puissance basée sur la méthode de Burg a été utilisée dans le calcul de toutes les caractéristiques spectrales. La fréquence du pic et la fréquence moyenne du PSD sont considérées comme des caractéristiques. Les caractéristiques temporelles utilisées dans cette méthode sont: la valeur moyenne, le taux de variance (NCOV), l'écart type, le skewness et le kurtosis [Tza2007]. Ainsi, nous avons obtenu 8 caractéristiques spectrales (4 niveaux d'ondelettes * 2 types de caractéristiques) et 20 caractéristiques temporelles (4 niveaux d'ondelettes * 5 types de caractéristiques).

3.3.2.1. Méthode de Burg pour l'estimation de la densité spectrale de puissance

L'estimation paramétrique du spectre est basée sur une hypothèse et un modèle des données ayant des connaissances antérieures. La réponse fréquentielle du modèle génère l'estimation de la densité spectrale de puissance. Cette approche surmonte les limitations causées par la

segmentation et elle a donc une meilleure résolution que les méthodes non paramétriques. L'approche paramétrique la plus fréquemment utilisée est le modèle autorégressif qui fait partie des modèles communs de processus aléatoires pour prédire les phénomènes naturels [Gal2008]. Les formules de prédiction linéaire prédisent la sortie d'un système basé sur l'entrée. Le modèle suppose que les données observées ont été générées par un système dont l'équation est donnée par :

$$x[n] = -\sum_{k=1}^p a_k x[n-k] + e[n] \quad (3.11)$$

Où $x[n]$ est le signal modélisé (sortie observée du système), a_k sont les coefficients du modèle et $e[n]$ est une séquence d'erreur de modélisation. Si l'ordre du modèle est correct, $e[n]$ s'avère être un processus de bruit blanc avec une variance σ^2 . Le modèle est abrégé en $AR(p)$ avec p est l'ordre du système. Le PSD du processus est donné par [Sri2007, Ors2016] :

$$PSD_{AR}(f) = \frac{\sigma^2}{\left|1 + \sum_{k=1}^p a_k \exp(-j2\pi fk)\right|^2} \quad (3.12)$$

Ainsi, pour obtenir le $PSD_{AR}(f)$, il faut estimer les coefficients du AR et la variance σ^2 . Le modèle AR est largement utilisé car il représente le spectre avec des pics étroits.

Les coefficients du AR peuvent directement être estimés avec la méthode Burg en minimisant la somme des erreurs des moindres carrés des prédictions avant et arrière en respectant les coefficients de réflexion pour la stabilité du modèle.

Pour une donnée $x(n), n = 0, 1, \dots, N-1$ l'estimation de la prédiction linéaire avant d'ordre m est donnée par :

$$x(n) = -\sum_{k=1}^m a_m(k) x(n-k) \quad (3.13)$$

$$x(n-m) = -\sum_{k=1}^m a_m(k)x(n+k-m) \quad (3.14)$$

Avec $a_m(k)$ sont les coefficients de prédiction, $0 \leq k \leq m-1$ et $m=1,2,\dots,p$

Les erreurs avant et arrière correspondantes sont définies par :

$$f_m(n) = x(n) - x(n) \quad (3.15)$$

$$b_m(n) = x(n-m) - x(n-m) \quad (3.16)$$

L'erreur des moindres carrés est donnée par :

$$f_m = \min \sum_{n=m}^{k-1} \left[|f_m(n)|^2 + |b_m(n)|^2 \right] \quad (3.17)$$

L'erreur est minimisée en sélectionnant les coefficients de prédiction

$$a_m(k) = a_{m-1}(k) + \lambda_m a_{m-1}^*(m-k) \quad (3.18)$$

Avec $\lambda_m = a_m(m)$ est le coefficient de réflexion numéro m .

En réduisant au minimum l'erreur des moindres carrés ξ_m par rapport à la fonction à valeur complexe λ_m , on obtient :

$$\lambda_m = \frac{-\sum_{n=m}^{N-1} f_{m-1}(n)b_{m-1}^*(n)}{\left(\frac{1}{2}\right) \sum_{n=m}^{N-1} \left[|f_{m-1}(n)|^2 + |b_{m-1}(n)|^2 \right]} \quad (3.19)$$

Étant donné que le fenêtrage n'est pas appliqué aux données, les estimations de l'AR sont supposées être plus précises. Elles évitent le calcul de la fonction d'autocorrélation [Erk1998, Zak2005]. En plus elles offrent une haute résolution pour les enregistrements de données courts et produisent un modèle stable.

3.3.2.2. Variance et écart type

La variance et l'écart type permettent de mesurer la dispersion des valeurs d'une série statistique x (variable aléatoire discrète) qui prend les valeurs $\{x_1, \dots, x_k\}$. Si les valeurs de la série possèdent une unité, l'écart type s'exprime dans la même unité.

La variance de x (si elle existe) est :

$$Var(x) = E\{x - E(x)\}^2 = E(x^2) - \{E(x)\}^2 \quad (3.20)$$

Tel que $E(x)$ est l'espérance de x :

$$E(x) = \sum_{i=1}^k x_i p(x = x_i) \quad (3.21)$$

La racine carrée de la variance $\sigma = \sqrt{Var(x)}$ est l'écart type de cette série.

3.3.2.3. Skewness

Le Skewness caractérise le degré d'asymétrie d'une distribution autour de sa valeur moyenne. Bien que la moyenne, l'écart-type et l'écart moyen soient des quantités dimensionnelles, c'est-à-dire qu'elles ont les mêmes unités que les quantités mesurées x_i , le Skewness est défini de manière qui le rend non dimensionnel. Il s'agit d'un nombre pur qui ne caractérise que la forme de la distribution. Il est défini généralement par :

$$Skew(x_1 \dots x_n) = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{\sigma} \right)^3 \quad (3.22)$$

Où N est le nombre d'éléments de x_i , σ est l'écart type de la distribution et \bar{x} est la valeur moyenne de x_i .

Si la distribution à une queue asymétrique à droite (s'étendant vers un x plus positif), le Skewness est positif, Si la queue est sur la gauche (s'étendant vers un x plus négatif), alors le Skewness est négatif (figure 3.6).




Figure 3.6: Types de Skewness.

3.3.2.4. Kurtosis

Le Kurtosis est un paramètre qui décrit la forme de la distribution de probabilité d'une variable aléatoire. Il mesure la répartition de la distribution. Par exemple le kurtosis de la distribution normale est de 3.

Le kurtosis d'une distribution est définie par :

$$Ku = \frac{E(x - \mu)^4}{\sigma^4} \quad (3.23)$$

où μ est la moyenne de x et σ est l'écart type de x .

La figure 3.7 illustre la notion de kurtosis. La fonction de densité de probabilité à droite a une kurtosis plus élevée que la fonction de densité de probabilité à gauche car elle est plus élevée au centre.

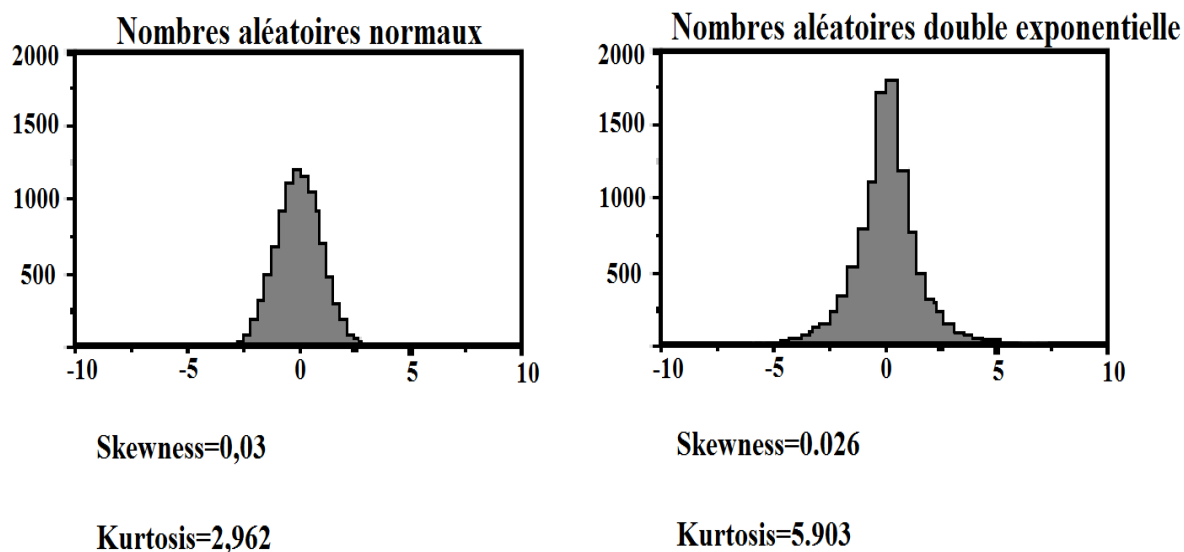


Figure 3.7: Variation du Kurtosis suivant la fonction de densité de probabilité.

3.3.3. Classification

Une fois l'étape d'extraction des caractéristiques, à partir des bandes d'ondelettes les plus intéressantes, est terminée, la technique de classification doit être correctement choisie. Nous exposons dans ce paragraphe une brève présentation des techniques de classification que nous avons utilisées dans la conception du système. Les résultats expérimentaux permettront de comparer l'SVM et l'ELM qui appartient à la famille des réseaux de neurones, afin d'évaluer les performances de notre système proposé.

Souvent, les techniques de classification sont divisées en deux familles:

- **La classification non supervisée:** Ce type de classification consiste à regrouper des éléments, qui possèdent un aspect identique dans des classes inconnues au préalable. L'ensemble d'apprentissage n'est pas connue dans ce type de classification;
- **La classification supervisée:** La connaissance a priori d'un ensemble d'apprentissage et d'un ensemble de classement est nécessaire dans ce type de classification. La phase d'apprentissage consiste à couper tout d'abord l'espace des éléments à classer, ensuite à attribuer à chaque partie de l'espace découpé une des classes définies a priori. La phase de classement consiste à classer les éléments en fonction de leur position dans l'espace.

Dans le cadre de ce travail, nous avons utilisé la classification supervisée.

3.3.3.1. Séparateur à vaste marge

Les machines à vecteurs de support souvent appelées séparateurs à vaste marge (SVM) sont une classe d'algorithmes d'apprentissage initialement définis pour la discrimination binaire, c'est-à-dire la séparation entre deux nuages de points représentant deux classes différentes. Elles sont basées sur la recherche de l'hyperplan de marge optimale qui classe ou sépare correctement les données. Cet hyperplan doit être le plus éloigné possible de toutes les observations [Wan2005]. L'idée principale des SVM consiste à projeter les données dans un espace de plus grande dimension appelé, espace de caractéristiques, afin que les données non linéairement séparables dans l'espace de départ deviennent linéairement séparables dans l'espace de caractéristiques. Après la création de l'hyperplan optimal, on obtient une fonction de classification qui dépend d'un produit scalaire des images des données de l'espace d'entrée dans l'espace des caractéristiques. Ce produit scalaire peut être exprimé, sous certaines conditions, par des fonctions définies dans l'espace d'entrée, qu'on appelle les noyaux. Ainsi, l'SVM repose sur la notion de marge maximale, et la notion de fonction noyau.

a) Notion de marge maximale

La figure 3.8 illustre un exemple de classification binaire. L'hyperplan sépare les deux classes ou les deux nuages de points. En particulier il sépare leurs points d'apprentissage.




Figure 3.8: Séparation entre deux nuages de points par l'hyperplan H .

Afin de déterminer l'hyperplan seulement les points les plus proches (les points de la frontière entre les deux classes de données) parmi l'ensemble total des points d'apprentissage sont utilisés, ces points sont appelés vecteurs de support comme représenté dans la figure 3.9.




Figure 3.9: Les vecteurs de support.

Il existe une infinité d'hyperplans capables de séparer parfaitement les deux classes. Le principe de l'SVM est de choisir celui qui va maximiser la distance entre l'hyperplan et les exemples d'apprentissage (la distance entre l'hyperplan et les vecteurs de support), cette distance est appelée la marge comme le montre la figure 3.10.

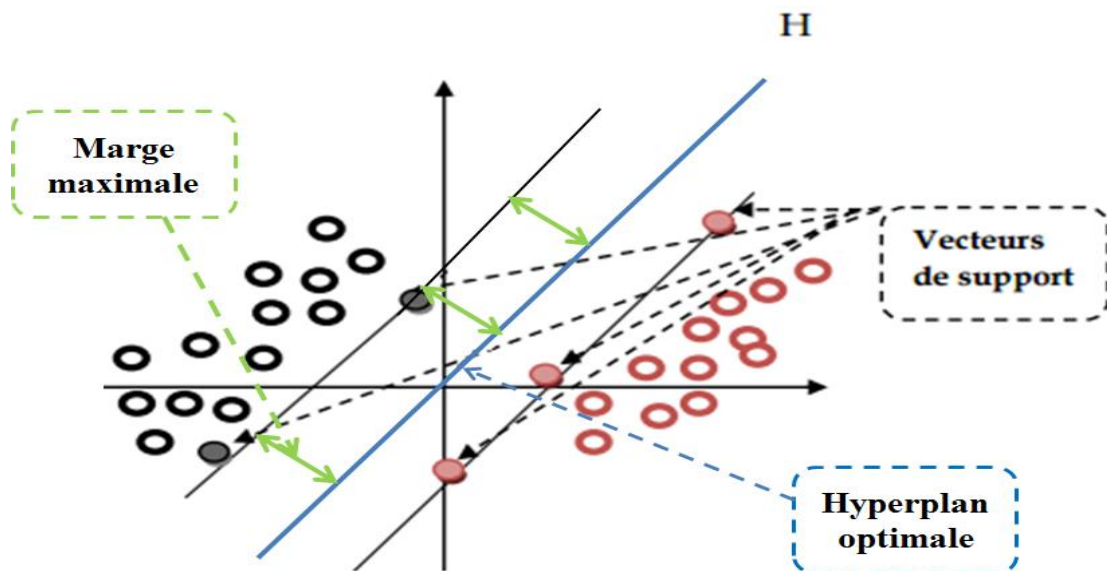


Figure 3.10: Hyperplan de marge maximale pour l'SVM.

Intuitivement, le fait d'avoir une marge plus large procure plus de sécurité lorsqu'on classe un nouveau point. De plus, si l'on trouve le classifieur qui se comporte le mieux vis-à-vis des

données d'apprentissage, il est clair qu'il sera aussi celui qui permettra au mieux de classer les nouveaux exemples.

b) Linéarité et non linéarité

Selon la distribution des nuages de points des deux classes, on peut distinguer deux types de problématiques : le cas des classes linéairement séparables et le cas des classes non linéairement séparables. Le premier est naturellement plus simple puisqu'il est plus facile de trouver le classifieur linéaire. Cependant, il est rare de rencontrer cette situation dans des problèmes réels où la distribution des données est plus compliquée. Pour s'adapter à la deuxième situation, l'SVM utilise le changement de l'espace des données. Une transformation non linéaire des données peut servir à séparer linéairement les classes dans un nouvel espace de dimension supérieur appelé "espace de re-description".

La figure 3.11 illustre un exemple de cas non linéairement séparable. Les points du premier groupe sont représentés en rouge tandis que ceux du deuxième groupe sont représentés en bleu.

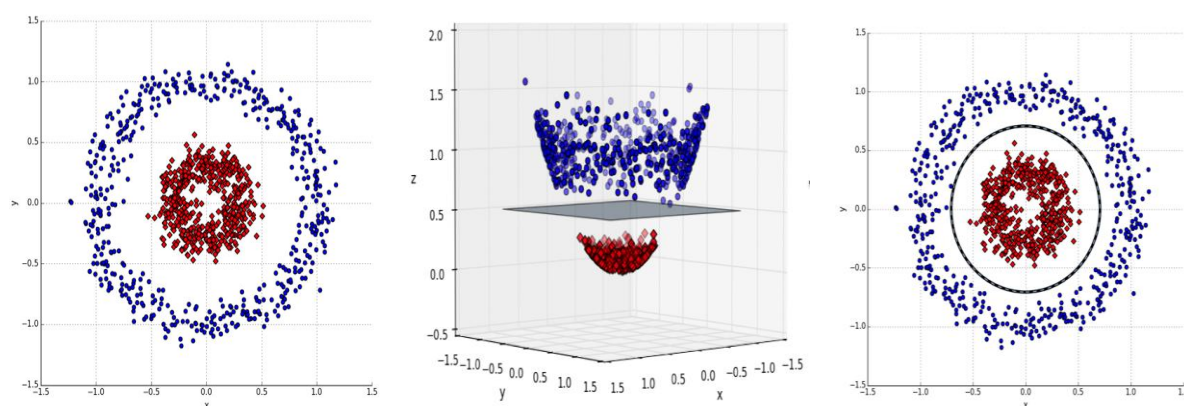


Figure 3.11 (a)

Figure 3.11 (b)

Figure 3.11 (c)

Figure 3.11: *Création de l'espace de re-description pour la séparation des classes. (a) nuages de points de classes non-linéairement séparables, (b) transformation des points vers un espace de plus grande dimension pour la division des classes par un hyperplan avec la plus grande marge et (c) en revenant dans l'espace de départ, la frontière de décision est non-linéaire.*

Clairement, il est impossible de séparer les deux groupes dans l'espace de départ 2D en utilisant une droite. Après le passage du plan 2D vers l'espace 3D la séparation devient possible au moyen du plan présenté en vert. Ce plan correspond à un cercle dans l'espace de

départ. Par conséquent, le passage vers un espace de dimension supérieur engendre un classifieur SVM non linéaire.

La transformation non linéaire de l'espace de départ vers l'espace de re-description est réalisée via une fonction noyau. On peut citer les exemples de noyaux suivants : polynomial, gaussien, sigmoïde et laplacien (tableau 3.2).

Tableau 3.2: Exemple de noyaux utilisés pour la création de l'espace de re-description.

Type de noyau	Expression
Noyau linéaire	$K(x, z) = x.z$
Noyau laplacien	$K(x, z) = \exp\left(-\frac{\ x-z\ }{\sigma}\right)$
Noyau polynomial	$K(x, z) = (a * \langle x, z \rangle + b)^d$
Noyau Gaussien (Radial Basis Function, RBF)	$K(x, z) = e^{\left(-\frac{\ x-z\ ^2}{2\sigma^2}\right)}$

3.3.3.2. Réseau de neurones

Les physiologistes McCulloch et Pitts ont introduit le premier modèle d'un neurone en 1943 [Cul1943]. Ce modèle possède deux entrées et une seule sortie. Le principe de ce modèle consiste à calculer la somme pondérée des entrées reçues, ensuite à appliquer à cette valeur une fonction d'activation, finalement la sortie est la valeur finale obtenue. Aujourd'hui, ce modèle de neurone est connu comme un circuit logique. Rosenblatt a développé le Perceptron comme second modèle du neurone en 1957 [Ros1957]. Il a interconnecté au hasard les Perceptrons, et utilisé des essais et des erreurs pour changer aléatoirement les poids afin de réaliser "l'apprentissage". En 1958, Selfridge a apporté l'idée de l'espace de poids au Perceptron. Il a ajusté les poids en choisissant au hasard un vecteur de direction. Si la performance n'est pas améliorée, les poids ont été retournés à leurs valeurs précédentes, et un nouveau vecteur de direction aléatoire a été choisi.

En 1960, B. Widrow et T.Hoff ont développé un modèle AdaLiNe (Adaptative Linear Neuron) qui ressemble au Perceptron, mais il diffère dans la loi d'apprentissage. Leur algorithme d'apprentissage est basé sur la minimisation des erreurs quadratiques. En 1969, M. Minsky et S. Papert publient leur livre intitulé "Perceptrons" dans lequel ils montrent que les Perceptrons ne pourraient résoudre que les problèmes linéaires.

Une théorie du fonctionnement et des possibilités des réseaux de neurones a été présentée par J.J.Hopfield en 1982 [Hop1982]. En 1986, Rumelhart et McClelland ont développé l'algorithme de rétro-propagation qui est adapté au Perceptron Multi Couches [Rum1986]. Vers ces années, il été possible de réaliser une fonction non linéaire d'entrée/sortie sur un réseau de neurone en décomposant cette fonction en une suite d'étapes linéaire. Finalement, en 1989 Moody et Darken ont proposé le Réseau à Fonctions de base Radiales (RFR), qui se diffère des autres types de réseaux de neurones par sa représentation locale.

a) Neurone et modèle mathématique

Le réseau de neurones de perception multicouche est construit à partir de composants simples. La figure 3.12 présente un neurone à une seule entrée

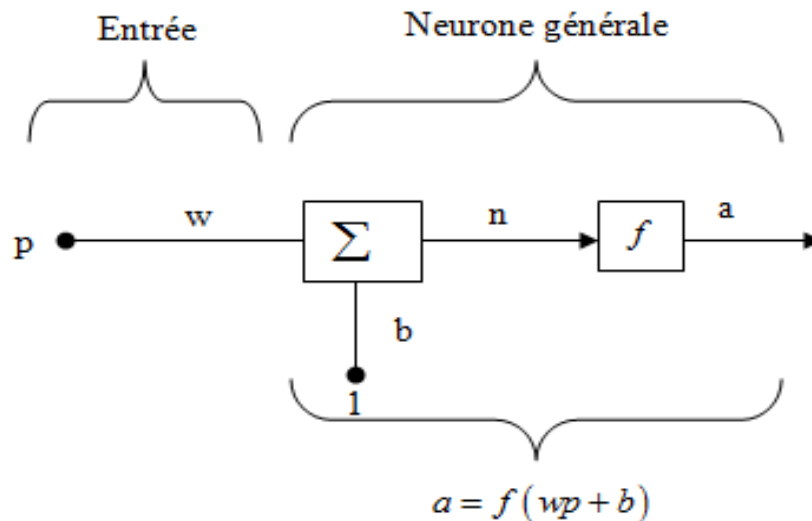


Figure 3.12: Structure d'un neurone à une seule entrée.

L'entrée scalaire p est multiplié par le poids w . L'autre entrée, 1 , est multiplié par un biais b . La sortie " n " de la somme est désignée comme une entrée de la fonction d'activation f qui produit la sortie d'un neurone. w et b sont les deux paramètres réglables du neurone. La fonction d'activation f peut-être une fonction linéaire ou non-linéaire. Cette fonction est choisie pour satisfaire une certaine spécification du problème que le neurone essaye à résoudre. Généralement, un neurone a plus d'une entrée. Un neurone avec R entrées est représenté sur la figure 3.13.

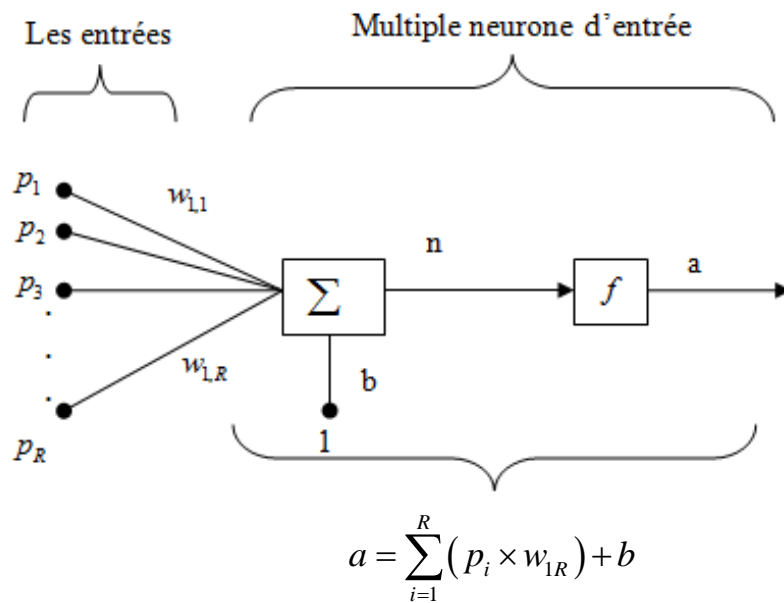


Figure 3.13: Structure d'un neurone à plusieurs entrées.

Les entrées p_1, p_2, \dots, p_R sont chacune pondérée par des éléments correspondant w_1, w_2, \dots, w_R de la matrice de poids w . Le neurone a un biais b , qui est additionné avec les entrées de poids pour former l'entrée n :

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (3.24)$$

Cette expression peut être écrite sous forme matricielle:

$$n = wp + b \quad (3.25)$$

Donc la sortie du neurone peut être écrite comme :

$$a = f(wp + b) \quad (3.26)$$

b) Structure des réseaux de neurone

Un réseau neural artificiel est un modèle de traitement d'informations qui est inspiré par la façon du fonctionnement des systèmes nerveux biologiques. L'élément-clé de ce modèle est la nouvelle structure du système de traitement d'informations qui est composé d'un grand nombre d'éléments de traitement fortement connectés qui sont les neurones. Un réseau neural artificiel est configuré pour une application spécifique, comme la reconnaissance de formes ou la classification de données, par un processus d'apprentissage. L'apprentissage dans des

systèmes biologiques implique des rajustements aux connexions synaptiques qui existent entre les neurones.

Il existe deux grandes familles de réseaux de neurones artificiels: les réseaux bouclés et les réseaux non bouclés.

- **Les réseaux de neurones non bouclés "Feedforward"** : Dans ce réseau la propagation d'information se fait vers l'avant à partir des neurones d'entrée, à travers les neurones cachés, et jusqu'aux nœuds de sortie. Il n'y a aucun retour d'information, donc la sortie de n'importe quelle couche n'affecte pas cette même couche. Ces types de réseaux ont tendance à être des réseaux simples qui associent des entrées avec des sorties. Ils sont largement utilisés dans la reconnaissance de formes;
- **Les réseaux de neurones bouclés "Récurent"** : L'information dans ce type de réseaux se propage dans les deux directions en présentant des boucles dans le réseau. Les réseaux de neurones bouclés sont très puissants et peuvent être extrêmement compliqués. Ils sont dynamiques car leurs états changent continuellement jusqu'à ce qu'ils atteignent un point d'équilibre. Ils restent au point d'équilibre jusqu'à ce que les changements d'entrée se reproduisent et un nouvel équilibre doit être trouvé. Les architectures de réseaux bouclés sont aussi mentionnées comme interactives ou récurrentes, bien que le dernier terme soit souvent utilisé pour dénoter des connexions de retour d'information dans des organisations d'une seule couche.

Dans notre travail, nous nous limitons au réseau de type non bouclés "Feedforward".

c) Réseaux de neurones de type "Feedforward"

Les réseaux de neurones à anticipation, aussi appelés réseaux de neurones de type "Feedforward", sont la plus ancienne forme de réseaux de neurones artificiels conçue [Ros1957]. Ils consistent en un classificateur binaire entre des catégories, représentées par des neurones groupés en une couche de sortie. La plus simple version de ce type de réseau est le perceptron simple couche [Ros1957]. Il n'est composé que d'une couche de sortie, sur laquelle les entrées sont directement fournies. Cependant, ce type de réseau n'est pas capable de traiter les problèmes non linéaires. Pour corriger cela, des couches supplémentaires ont été ajoutées dans le réseau, formant le perceptron multi-couches [Ron1961]. Les entrées sont fournies à des neurones formant une couche d'entrée. Une ou plusieurs couches appelées couches cachées sont insérées entre les couches d'entrée et de sortie, permettant un traitement

plus fin des informations transitant dans le réseau. La figure 3.14 montre un schéma de ce type de réseau avec une couche cachée. Dans un réseau à anticipation, une couche n'est connectée qu'à la couche suivante, par des liens unidirectionnels. Ainsi, les informations ne transitent que dans un seul sens. Chaque connexion est pondérée par un poids synaptique. Ainsi, chaque neurone appartenant à une couche reçoit les informations pondérées de tous les neurones de la couche précédente. La décision sur l'activation ou l'inhibition d'un neurone est effectuée par une fonction d'activation sur la somme des données pondérées reçues. Cette fonction peut aller de la fonction d'Heaviside, ou fonction échelon unitaire, à la fonction sigmoïde. La complexité du neurone artificiel dépend donc de la complexité de la fonction d'activation et des poids synaptiques de ses connexions.

L'apprentissage dans un tel réseau est effectué à l'aide d'un algorithme appelé rétro-propagation. Ce dernier ajuste les poids synaptiques dans le but de minimiser la fonction d'erreur quadratique entre la sortie du réseau, c'est-à-dire les neurones de la couche de sortie, et le résultat espéré. Cet algorithme permet de faire un apprentissage supervisé dans le réseau.

D'autres réseaux de neurones dont le fonctionnement s'appuie sur les perceptrons ont aussi vu le jour. Ainsi, les réseaux de neurones convolutionnels sont des variations de perceptrons multi-couches dont les neurones sont disposés de façon à reproduire le fonctionnement du cortex visuel [Lec1998]. Ils sont utilisés principalement dans des applications de reconnaissance d'images. Ces réseaux ont l'avantage de garder une structure très simple tant que les problèmes auxquels ils sont confrontés sont linéaires. Dans le cas contraire, les fonctions d'activation se complexifient, pour aller par exemple jusqu'à la fonction sigmoïde. De plus, le stockage des poids synaptiques pour chaque connexion s'avère complexe à implanter. Pour une implantation numérique, chaque poids nécessite plusieurs bits de quantification, tandis qu'en électronique analogique, des composants passifs, coûteux en termes de surface, sont nécessaires, [Mat2014, Bof2004]. Des multiplications, coûteuses matériellement, doivent aussi être implantées pour chaque connexion. Le point faible de ce type de réseau est donc la complexité matérielle pour traiter des problèmes non linéaires.

- **Rétro propagation du gradient de l'erreur**

L'entraînement d'un réseau de neurones nécessite l'ajustement des poids de chaque neurone de telle façon que l'erreur entre la sortie désirée et la sortie réelle soit réduite. Cette étape ne peut être effectuée que si le réseau de neurone calcule la dérivée de l'erreur par rapport à un poids. L'algorithme de propagation consiste à déterminer cette erreur.

Soit l'exemple d'un réseau de type Perceptron multicouche présenté par la figure 3.14.

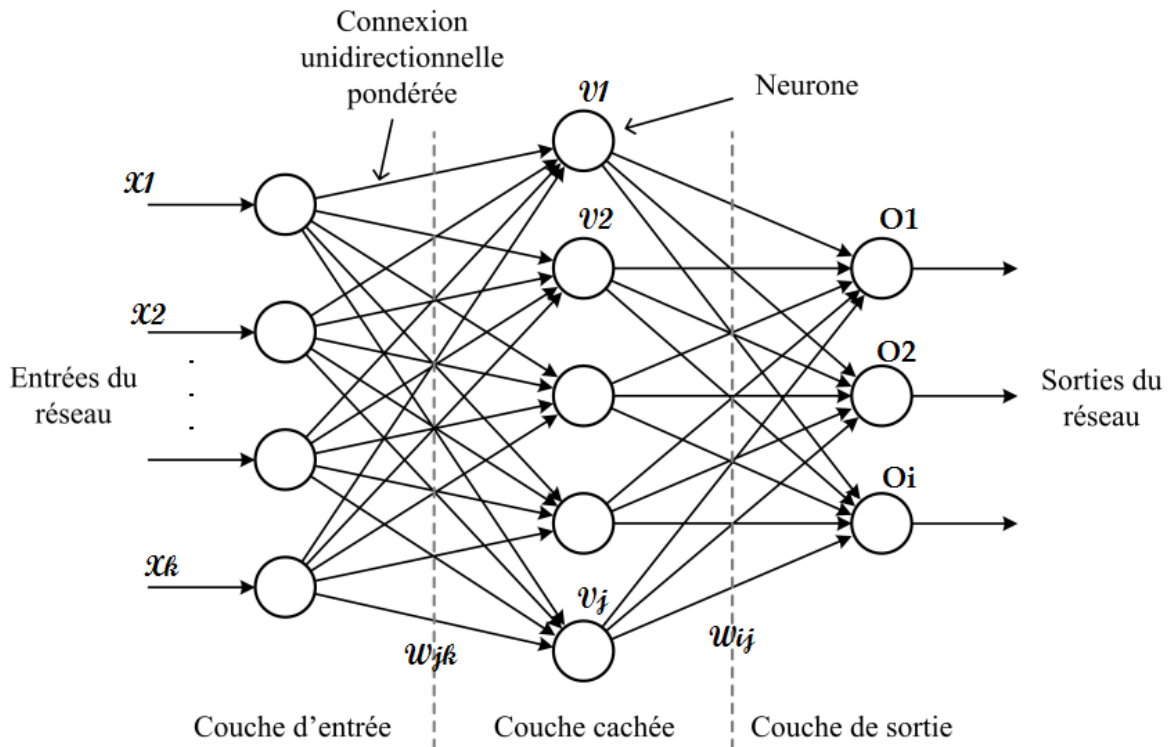


Figure 3.14: Un Perceptron multicouche.

o_i , v_j et x_k représentent respectivement les neurones de sortie, les neurones cachées, et les neurones d'entrée. w_{jk} représentent les connexions des neurones d'entrée aux neurones cachées, par contre w_{ij} représentent les connexions des neurones cachées aux neurones de sortie.

Pour la donnée d'entrée p , la valeur de sortie des neurones cachés j est donnée par :

$$v_j^p = f(a_j^p) = f\left(\sum w_{jk} x_k^p\right) \quad (3.27)$$

Les neurones de sortie ont comme valeur :

$$o_i^p = f(a_i^p) = f\left(\sum w_{ij} v_j^p\right) \quad (3.28)$$

Ainsi, les fonctions d'erreurs partielles et globales sont définies par :

$$E^p = \frac{1}{2} \sum (o_i^p - x_i^p)^2 \quad (3.29)$$

Et

$$E = \sum_p E^p \quad (3.30)$$

La fonction d'erreur globale va être minimisée par une descente de gradient. Par la suite, la valeur de chaque connexion est modifiée par la règle suivante:

$$\Delta w = -\eta \frac{\partial E}{\partial w} = -\eta \sum_p \frac{\partial E^p}{\partial w} \quad (3.31)$$

η : Représente la pas d'apprentissage. Ce facteur influe sur la vitesse de convergence du réseau.

Cette règle d'apprentissage est appelée la règle de delta généralisée. Cette règle est décomposée dans deux cas de connexions.

- **Cas des connexions entre la couche cachée et celle de sortie (w_{ij})**

Pour les neurones de sortie, l'expression (3.29) devient fonction du paramètre w_{ij} qui influe uniquement sur la sortie du neurone d'indice i . Nous pouvons donc décomposer la dérivée de l'expression (3.25) par :

$$\frac{\partial E^p}{\partial w_{ij}} = \frac{\partial E^p}{\partial o_i^p} \cdot \frac{\partial o_i^p}{\partial a_i^p} \frac{\partial a_i^p}{\partial w_{ij}} = (o_i^p - x_i^p) f_i(a_i^p) v_j^p \quad (3.32)$$

La règle de delta devient alors :

$$\Delta w_{ij} = \eta \sum_p f_i(a_i^p) (x_i^p - o_i^p) v_j^p \quad (3.33)$$

- **Cas des connexions entre la couche d'entrée et la couche cachée (w_{jk})**

Concernant des neurones cachés, l'expression (3.31) est fonction du paramètre w_{jk} influant non seulement sur la sortie du neurone j de la deuxième couche, mais aussi sur tous les neurones i de la couche de sortie qui lui sont connectés. On obtient alors l'équation suivante:

$$\frac{\partial E^p}{\partial w_{ik}} = \frac{\partial E^p}{\partial v_j^p} \cdot \frac{\partial v_j^p}{\partial a_j^p} \frac{\partial a_j^p}{\partial w_{jk}} = \frac{\partial E^p}{\partial v_j^p} f_i(a_j^p) x_k^p \quad (3.34)$$

Le premier terme de cette expression devient alors :

$$\frac{\partial E^p}{\partial v_j^p} = \sum_i \frac{\partial E^p}{\partial o_i^p} \cdot \frac{\partial o_i^p}{\partial v_j^p} = \sum_i \frac{\partial E^p}{\partial o_i^p} \frac{\partial o_i^p}{\partial a_i^p} \frac{\partial a_i^p}{\partial v_j^p} = \sum_i (o_i^p - x_i^p) f_i(a_i^p) w_{ij} \quad (3.35)$$

On obtient alors la modification des poids

$$\Delta w_{jk} = \sum_p \left(f(a_j^p) x_k^p \left(\sum_i (x_i^p - o_i^p) f_i(a_i^p) w_{ij} \right) \right) \quad (3.36)$$

La variation des poids des connexions pour tous les neurones de sortie, et la variation des poids des connexions de la couche cachée sont calculées pour mettre à jour les poids des connexions de la couche de sortie jusqu'à la couche d'entrée: on rétropropage ainsi le signal d'erreur. C'est de là que vient le nom de cet algorithme: rétropropagation du gradient de l'erreur.

d) ELM

L'ELM (Extreme Learning Machines) est un algorithme de réseau de neurone Feedforward qui possède une seule couche cachée nommée (SLFN : Single Hidden Layer Feedforward Neural Network). Il a été développé par Huang et al. [Hun2004], pour surmonter les difficultés d'un réseau neuronal par une vitesse d'apprentissage rapide et haute performance [Kwa2008, Coe2008]. L'ELM compense les défauts d'algorithme d'apprentissage à base de gradient en calculant analytiquement les poids optimaux du SLFN. Tout d'abord, les poids entre la couche d'entrée et la couche cachée sont choisis aléatoirement pour exprimer le SLFN dans une équation linéaire, et ensuite nous pouvons obtenir la valeur optimale pour les poids entre la couche de sortie et la couche cachée en calculant l'équation matricielle linéaire [Wer2015].

Supposé que nous avons N points de données d'entrée et \tilde{N} neurones cachés, le réseau neuronal SLFN est défini par l'équation suivante :

$$\sum_{i=1}^{\tilde{N}} B_i g_i(x_j) = \sum_{i=1}^{\tilde{N}} B_i g(w_i x_j + b_i) = t_j \quad (3.37)$$

$$j = 1, \dots, N \quad (3.38)$$

Où w_i est le vecteur de poids entre le $i^{\text{ième}}$ neurone dans la couche cachée et la couche d'entrée, b_i signifie le biais du $i^{\text{ième}}$ neurone dans la couche cachée, x_i est le vecteur des entrées $j^{\text{ième}}$, $g(\cdot)$ est la fonction d'activation du neurone caché, B_i est le vecteur de poids entre le $i^{\text{ième}}$ neurone caché et la couche de sortie et T_j signifie le vecteur label de la $j^{\text{ième}}$ entrées.

Si w_i et b_i sont des constantes alors $g(w_i x_j + b_i)$, qui est la sortie du $i^{\text{ième}}$ neurone caché, peut être une matrice constante. Ainsi, l'équation (3.41) peut être reformulée à l'aide de cette matrice de sortie de la couche cachée H .

$$H.B = T \quad (3.39)$$

$$H(w_1, \dots, w_{\hat{N}}, b_1, \dots, b_{\hat{N}}, x_1, \dots, x_N) = \begin{bmatrix} g(w_1 x_1 + b_1) \dots g(w_{\hat{N}} x_1 + b_{\hat{N}}) \\ \dots \\ g(w_1 x_N + b_1) \dots g(w_{\hat{N}} x_N + b_{\hat{N}}) \end{bmatrix} \quad (3.40)$$

Avec

$$B = \begin{bmatrix} B_1 \\ \dots \\ B_{\hat{N}} \end{bmatrix} \quad (3.41)$$

Et

$$T = \begin{bmatrix} T_1 \\ \dots \\ T_{\hat{N}} \end{bmatrix} \quad (3.42)$$

Dans l'équation (3.39), le vecteur label T et la matrice H de sortie de la couche cachée comportent un système linéaire. Ainsi, la procédure d'apprentissage du réseau de neurones devient la découverte de la matrice optimale de poids B entre la couche de sortie et la couche

cachée. Ce processus peut être accompli en utilisant le pseudo-inverse de Moore-Penrose généralisé de H , comme montré dans l'équation (3.43).

$$\hat{B} = H^+T \quad (3.43)$$

Où H^+ est la matrice généralisée du pseudo-inverse de Moore-Penrose généralisé [Han2010]. L'algorithme ELM peut être résumé en deux étapes comme suit:

Etape 1 : les valeurs des poids d'entrée w_i et des biais b_i de la couche cachée sont produites aléatoirement et la matrice de sortie de la couche cachée H est calculée.

Etape 2 : les valeurs des poids de sortie \hat{B} sont calculées suivant l'équation $\hat{B} = H^+T$. Où T est la composante de décision.

3.4. Résultats d'évaluation de la méthode proposée

Les performances de la méthode proposée ont été évaluées à l'aide de la base de données CHB-MIT. Seuls les signaux des ensembles de données chb 03, chb 08 et chb 13 ont été utilisés pour la validation du système de détection proposé dans ce chapitre.

3.4.1. Base de données

La base de données EEG CHB-MIT disponible gratuitement pour le téléchargement a été utilisée dans la présente étude [Kwa2008]. 23 volontaires pédiatriques de l'Hôpital pour enfants de Boston ont participé à l'expérience. Les données de l'EEG ont été enregistrées chez 5 males et 17 femelles souffrant de crises. Leurs âges étaient compris entre 3 et 22 ans. Le taux d'échantillonnage du système d'acquisition était égal à 256 échantillons par seconde avec une résolution de 16 bits. Dans la plupart des cas, les données ont été obtenues à partir du cuir chevelu à l'aide de 21 électrodes de surface placées selon le système international 10-20 suivant les canaux: FP1-F7, F7-T7, T7-P7, P7-O1, FP1-F3, F3-C3, C3 -P3, P3-O1, FZ-CZ, CZ-PZ, FP2-F4, F4-C4, C4-P4, P4-O2, FP2-F8, F8-T8, T8-P8, P8-O2, P7-T7, T7-FT9, FT9-FT10, FT10-T8 et T8-P8. Un canal EEG est créé en calculant la différence de potentiels mesurés entre un couple d'électrodes.

La figure 3.15 représente les électrodes et les canaux impliqués dans l'acquisition des signaux EEG.

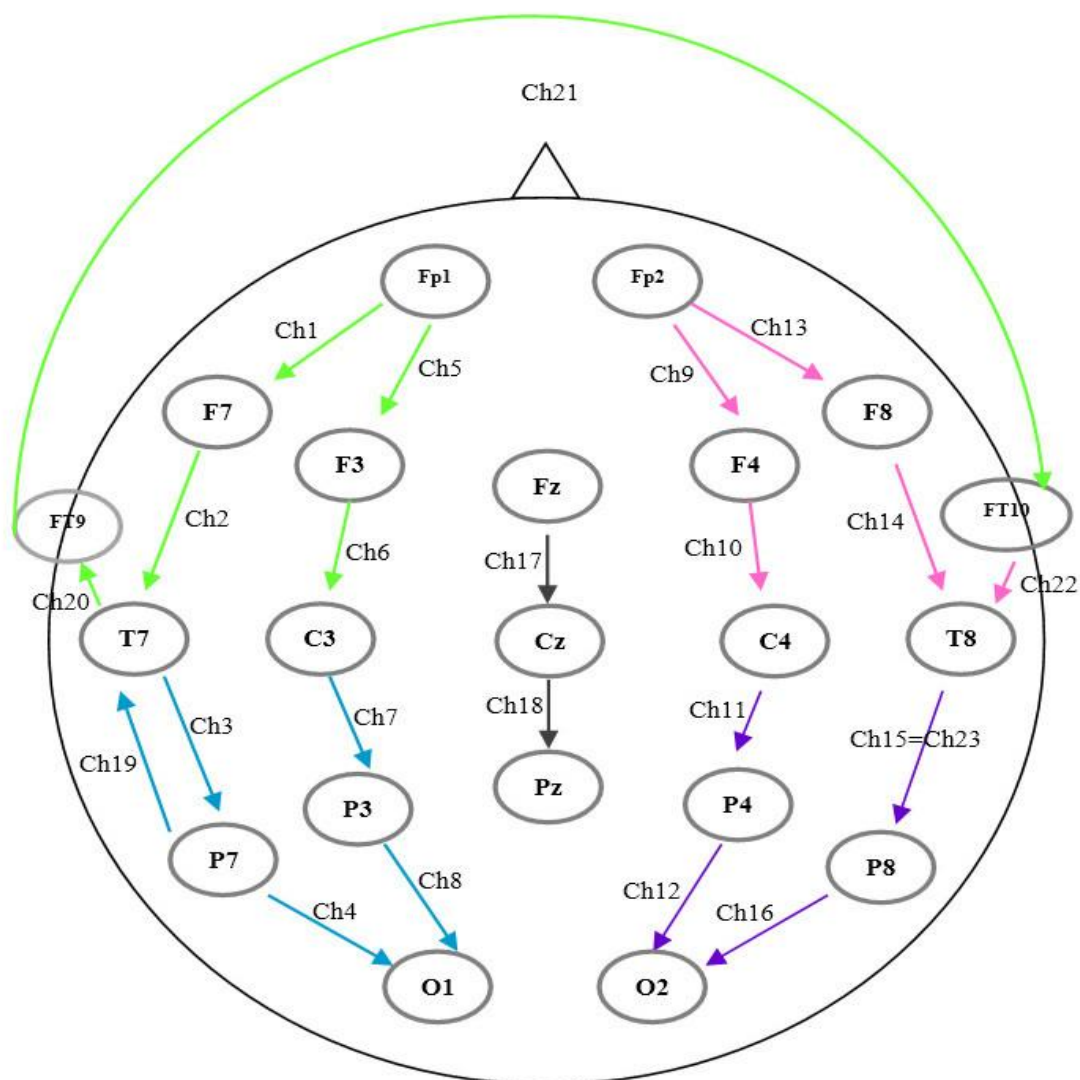


Figure 3.15: Positions des canaux et des électrodes utilisés [Amm2016].

Quelques détails supplémentaires sur les patients sont donnés dans le tableau 3.3.

Tableau 3.3 : Détails des patients.

Patient	Age	Sexe	Longueur des crises (s)
Chb 01	11	F	442
Chb 02	11	M	-
Chb 03	14	F	402
Chb 04	22	M	-
Chb 05	7	F	558
Chb 06	1,5	F	-
Chb 07	14,5	F	-
Chb 08	3,5	M	919
Chb 09	10	F	276
Chb 10	3	M	447
Chb 11	12	F	806
Chb 12	2	F	-
Chb 13	3	F	535
Chb 14	9	F	169
Chb 15	16	M	1992
Chb 16	7	F	-
Chb 17	12	F	293
Chb 18	18	F	317
Chb 19	19	F	236
Chb 20	06	F	294
Chb 21	13	F	199
Chb 22	09	F	204
Chb 23	6	F	242

Durant ces dernières années, plusieurs groupes de recherche se sont intéressés à la base de données CHB-MIT [Got1982, Gho2008, Wen1996, Pra1996, Kiy2004, Sri2007, Mar2015, Jin2009, Ors2016, Qu1997]. Le nombre relativement élevé de patients et la durée des données stockées rendent cette base adéquate pour évaluer les méthodes de détection des crises proposées.

3.4.2. Résultats

Les deux classes recherchées sont l'état normal (sans crise) et l'état de crise. La séparation entre les classes a été effectuée par le classifieur SVM et aussi par le classifieur ELM en fixant le nombre de neurones d'entrée à 28, ce qui correspond au nombre de caractéristiques extraites, et en fixant le nombre de sortie à 2, ce qui correspond au nombre de classes. Après plusieurs tests de configuration, le nombre de neurones cachés était fixé à 150, ce qui correspond à la valeur la plus appropriée. En plus, la fonction sigmoïde est sélectionnée comme la meilleure fonction d'activation. Afin d'obtenir le meilleur ajustement des poids du réseau, 2/3 de l'ensemble de données ont été sélectionnés au hasard comme base de données de l'apprentissage et les 1/3 restants comme base de données de test. Le taux de précision qui correspond au nombre de segments correctement classés divisé par le nombre total de segments est utilisé comme critère principal représentant la performance du système. L'efficacité de l'algorithme proposé peut être vérifiée par les résultats expérimentaux donnés dans le tableau 3.4.

Tableau 3.4: Évaluation de la méthode basée sur la transformé en ondelettes [Amm2016].

Identificateur du patient	Taux de précision avec ELM (%)	Taux de précision avec SVM (%)
Chb 03	96.88	95.25
Chb 08	94.97	92.97
Chb 13	95.05	92.41
Valeur moyenne	95.63	93.54

La précision globale du système a atteint 95,63% avec le classifieur ELM ce qui est considérée comme satisfaisante. Ce résultat prouve l'efficacité des caractéristiques dans la représentation des différentes informations du signal EEG nécessaires pour la distinction entre les classes [Amm2016].

Les résultats trouvés montrent aussi que la méthode ELM est plus performante que la méthode SVM dans la reconnaissance des crises épileptiques. En effet, les réseaux de neurones jouent un rôle important dans l'analyse des données et l'apprentissage automatique. Généralement,

cette approche de classification est considérée comme très précise dans la séparation entre les différents groupes ou classes [Yua2013].

Ainsi, dans cette méthode proposée, l'analyse multi-échelles par la transformée en ondelettes nous a offert une meilleure vue d'ensemble du signal et une localisation plus facile en temps et en fréquence ce qui permet d'analyser les signaux non-stationnaires. De même, elle nous a permis de travailler en sous bandes avec la possibilité de séparer les composantes du bruit du reste du signal. Par la suite l'adaptation de cette solution dans notre méthode nous a permis de surmonter les problèmes causés par les méthodes classiques de traitement de signal comme la transformée de Fourier. D'autre part, l'utilisation de 2 caractéristiques spectrales et de 5 caractéristiques temporelles pour chaque niveau d'ondelettes permet une excellente représentation des propriétés morphologiques et fréquentielles du signal ce qui facilite la création de la limite de décision par le classifieur. L'utilisation du classifieur ELM apporte au système l'avantage d'avoir une étape d'apprentissage extrêmement rapide avec une performance de généralisation élevée. La vitesse élevée d'apprentissage est basée sur la prise aléatoire des poids et des biais d'entrée et le calcul analytique des poids de sortie. Ceci représente une supériorité par rapport aux méthodes basées sur la rétropropagation où la méthode d'apprentissage est basée sur la descente de gradient, et le processus d'apprentissage est effectué en ajustant tous les paramètres et donc de nombreuses étapes d'apprentissage itératif peuvent être nécessaires pour obtenir les performances d'apprentissage optimales. Ainsi, l'ELM permet d'éviter la détérioration du processus d'apprentissage et également l'augmentation de la possibilité de convergence vers les minima locaux.

Tout ce cumulatif des avantages des techniques utilisées permet de concevoir un système efficace de détection des crises épileptiques. Ceci est prouvé par les hautes performances trouvées pour les trois patients de la base de données CHB-MIT. D'autre part l'utilisation d'un seul canal dans la méthode proposée est très utile surtout pour les cas où un enregistrement à domicile est demandé.

La méthode proposée peut être très satisfaisante pour certains patients mais ceci ne peut pas être généralisé pour tous les patients. En effet, la méthode présente certaines limites. Par exemple, l'utilisation de la transformée en ondelettes nécessite un bon choix d'ondelette mère analysante pour le traitement numérique du signal EEG dans le cadre de l'épilepsie. En effet, le choix de l'ondelette utilisée pour la décomposition temps-échelle est le point le plus important. Celui-ci a une influence sur la résolution en temps et en fréquence du résultat. Nous ne

pouvons modifier de cette manière les caractéristiques de la transformée en ondelettes (les basses fréquences ont une bonne résolution fréquentielle mais une mauvaise résolution temporelle ; les hautes fréquences ont une bonne résolution temporelle et une mauvaise résolution fréquentielle), mais nous pouvons toutefois augmenter la résolution fréquentielle totale ou la résolution temporelle totale. Ceci est directement proportionnel à la largeur de l'ondelette utilisée. En plus, la transformée en ondelettes n'est pas conçue pour traiter les signaux générés par des systèmes non-linéaires et complexes comme le cerveau. D'autre part, la sélection aléatoire des poids et des biais d'entrée du classifieur ELM engendre des résultats instables. Aussi, l'utilisation de paramètres fixes (canal, caractéristiques, Bondes d'ondelettes...) limite l'adaptativité la généralité et la souplesse du système face à la variabilité inter-sujet des signaux EEG.

Toutes ces limites étaient prises en considération dans le nouveau système spécifique au patient proposé.

3.5. Conclusion

Dans ce chapitre, nous avons donné un état de l'art sur les méthodes de traitement des signaux les plus utilisées pour la conception d'un système de détection automatique des crises épileptiques. De même, Nous avons détaillé dans un premier exemple le système centré autour de la transformée en ondelettes avec les classifieurs ELM et SVM. Ceci permet de mieux comprendre les différents blocs qui constituent le système de reconnaissance des crises ainsi que leurs rôles dans l'amélioration de la précision de classification. Enfin, nous avons détaillé les résultats de l'implémentation de cette méthode avec des signaux EEG réels. Ces résultats prouvent l'efficacité du modèle d'apprentissage automatique (machine-learning) classique dans la résolution d'une telle problématique.

Nous présenterons dans le chapitre suivant notre nouvelle méthode proposée pour l'amélioration des performances du système.

Chapitre 4

*Méthode auto-adaptative proposée pour la
détection des crises épileptiques*

Chapitre 4: Méthode auto-adaptative proposée pour la détection des crises épileptiques

4.1. Introduction

4.2. Etat de l'art en méthodes spécifiques au patient de détection automatique des crises épileptiques

4.3. Nouvelle approche proposée

4.4. Modélisation UML

4.5. Résultats d'évaluation de la méthode proposée

4.6. Conclusion

4.1. Introduction

Les méthodes automatiques de détection des crises épileptiques proposées dans la littérature peuvent être divisées principalement en deux groupes: le groupe de méthodes qui traitent les signaux d'un seul patient à la fois dites "spécifique au patient" et le groupe de méthodes qui traitent les signaux de tous les sujets de la même manière dites "non spécifique au patient". Les deux groupes comprennent deux fonctions principales en commun. En fait, ils intègrent un bloc d'acquisition pour mesurer les signaux EEG et un bloc de traitement pour décoder les activités cérébrales et générer un rapport qui indique les périodes des crises parmi les données analysées. Étant donné que les signaux EEG des crises d'un patient peuvent ressembler largement aux signaux EEG normaux d'un autre patient, une méthode spécifique au patient permet d'atteindre de meilleures performances que celles d'une méthode non spécifique au patient.

Dans ce chapitre, nous proposons un nouveau système automatisé de détection des crises épileptiques spécifique au patient. Plusieurs caractéristiques des domaines temporel et fréquentiel sont extraites du signal comme étant une nouvelle représentation plus significative des signaux d'origine avec une dimensionnalité inférieure. Pour augmenter les performances du système, l'EMD a été ajouté à la chaîne de la méthode proposée. L'algorithme génétique (GA: Genetic algorithm) a été introduit dans le système comme moyen pour adapter les paramètres selon chaque patient.

Nous allons commencer par expliquer en détail la nouvelle approche proposée. Ensuite, nous allons présenter les résultats de l'implémentation avec une étude des différents paramètres qui

peuvent agir sur les performances de la méthode proposée. Finalement, nous allons évaluer notre méthode par une comparaison avec les différentes méthodes qui existent dans la littérature.

4.2. Etat de l'art en méthodes spécifiques au patient de détection automatique des crises épileptiques

La majorité des méthodes proposées dans la littérature ont été évaluées en fonction de la sensibilité, qui reflète la capacité du système à détecter les segments épileptiques, et selon la spécificité, qui reflète sa capacité à détecter les périodes sans crises. L'objectif est d'atteindre la sensibilité la plus élevée avec une spécificité acceptable puisque le médecin inspectera les périodes épileptiques et non pas les périodes sans crises. Un exemple d'une méthode non spécifique au patient qui permet d'obtenir des hautes performances est le travail de L. Orosco et al. [Ors2016]. Afin d'assurer une représentation de haute qualité des activités cérébrales, cette méthode utilise plusieurs niveaux de sélection de caractéristiques. Tout d'abord, 264 caractéristiques (12 pour chaque canal) sont extraites du segment de données de 2 s de longueur. Ensuite, les caractéristiques sont divisées en cinq groupes en fonction des emplacements des canaux bipolaires correspondants. Puis, le calcul de la valeur moyenne des caractéristiques du même groupe est effectué. Cela réduit le nombre de fonctions à 72. Enfin, le nombre de caractéristiques est réduit à 26 par une méthode basée sur le paramètre statistique Lambda de Wilks. La base de données CHB-MIT a été utilisée pour évaluer la méthode. Pour assurer le processus d'apprentissage, le classificateur LDA a été alimenté chaque fois par les données de tous les sujets, à l'exception des données d'un sujet spécifique qui ont été utilisées pour le processus de test. La spécificité moyenne était de 99,9% et la sensibilité moyenne était de 87,5%. S. Kiranyaz et al. [Kia2014] ont montré que la capacité d'un type de caractéristiques à définir de manière significative la crise épileptique varie considérablement d'un sujet à un autre. Leur étude prouve que la fixation préalable de la liste des caractéristiques entraîne une détérioration des performances du système. Ils ont proposé un système spécifique au patient basé sur un réseau collectif multiple de classificateurs binaires avec un filtrage morphologique pour la classification et la sélection des paramètres. Le vecteur de caractéristiques est créé à partir de plusieurs fonctions qui appartiennent aux domaines : temporel, fréquentiel, temporel-fréquentiel et non linéaires pour des données d'entrée de durée égale à 1s. Les caractéristiques sont ensuite normalisées et lissées. Le

système établit un taux de sensibilité moyenne supérieur à 89% et un taux de spécificité moyenne supérieur à 93% avec la base de données CHB-MIT.

D'autre part, L. Orosco et al. [Ors2016] ont utilisé un ensemble de caractéristiques liés à l'énergie extraites de la transformée d'ondelettes stationnaire. Deux classifieurs ont été testés: les réseaux de neurones (NN : Neural Networks) et l'analyse discriminante linéaire (LDA : Linear Discriminant Analysis). Les résultats montrent que la LDA permet d'atteindre de meilleures performances. La robustesse et la fiabilité de l'algorithme LDA ont été également prouvées dans d'autres études telles que le travail de Y. U. Khan et al. [Khn2012] où le vecteur des caractéristiques est créé à partir des coefficients d'ondelettes, des valeurs d'énergies dans les échelles d'ondelettes et de certaines caractéristiques liées au coefficient de variation. Ce système été capable d'atteindre une sensibilité de 83%, une spécificité de 100% et un taux d'exactitude de 92% avec la base de données CHB-MIT. De même, L. Orosco et al. [Oro2010] ont choisi d'utiliser la LDA pour la séparation entre les différentes classes. La décomposition en mode empirique (EMD : Empirical Mode Decomposition) a été utilisée pour décomposer le signal en plusieurs fonctions de mode intrinsèque (IMF : Intrinsic Mode Functions), puis plusieurs fonctions des domaines temporel et fréquentiel ont été extraites de chaque IMF. Les résultats montrent que seul le premier, le deuxième et le troisième IMF sont pertinents et mènent à améliorer les performances du système. La sensibilité et la spécificité de cette méthode étaient respectivement de 69,4% et de 69,2%. Dans un autre travail, R. Sharma et al. [Sar2015] et K. Rai et al. [Rai2015] ont bénéficié des avantages de l'EMD pour améliorer les performances de leurs systèmes afin atteindre respectivement 98,67% et 98,33% du taux d'exactitude.

4.3. Nouvelle approche proposée

L'objectif de la nouvelle méthode proposée est de garantir le taux de sensibilité le plus élevé possible. Pour cette fin, les paramètres adéquats qui ont un impact sur ce critère devraient être sélectionnés selon le sujet [Amr2017].

Le schéma fonctionnel de la méthode proposée est illustré dans la figure 4.1.

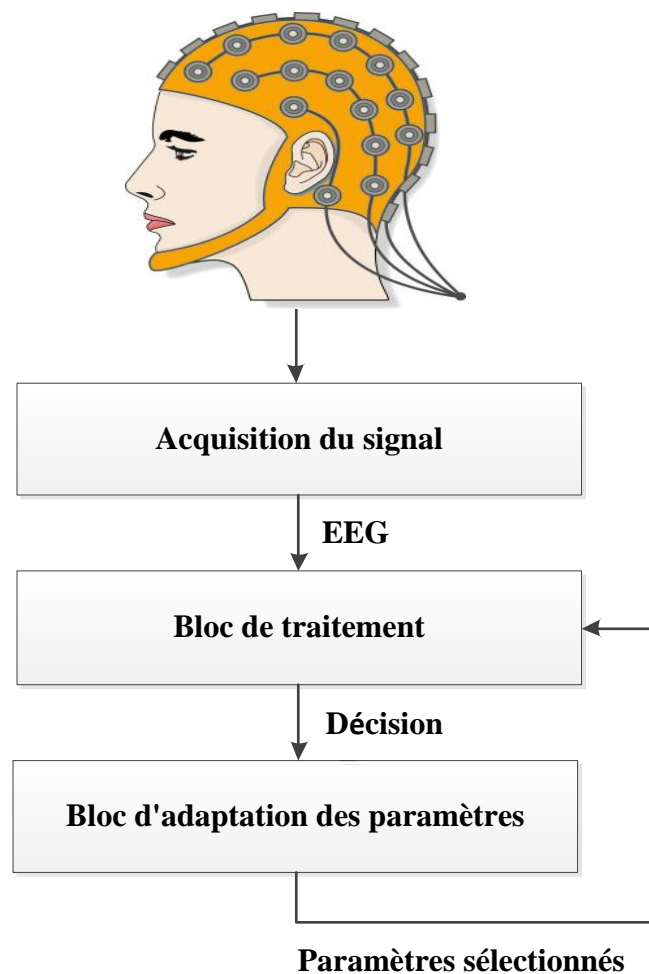


Figure 4.1: Schéma de principe de la méthode proposée [Amr2017].

Le système proposé assure deux fonctions principales. La première est le traitement des données qui transforme les signaux EEG en décisions indiquant la présence ou non des crises, tandis que la seconde est l'adaptation des paramètres qui sélectionne la meilleure combinaison de paramètres du système pour chaque patient [Amr2017].

4.3.1. Bloc de traitement

Le système automatique de détection des crises est habituellement composé de quatre étapes successives, comme l'illustre la figure 4.2.

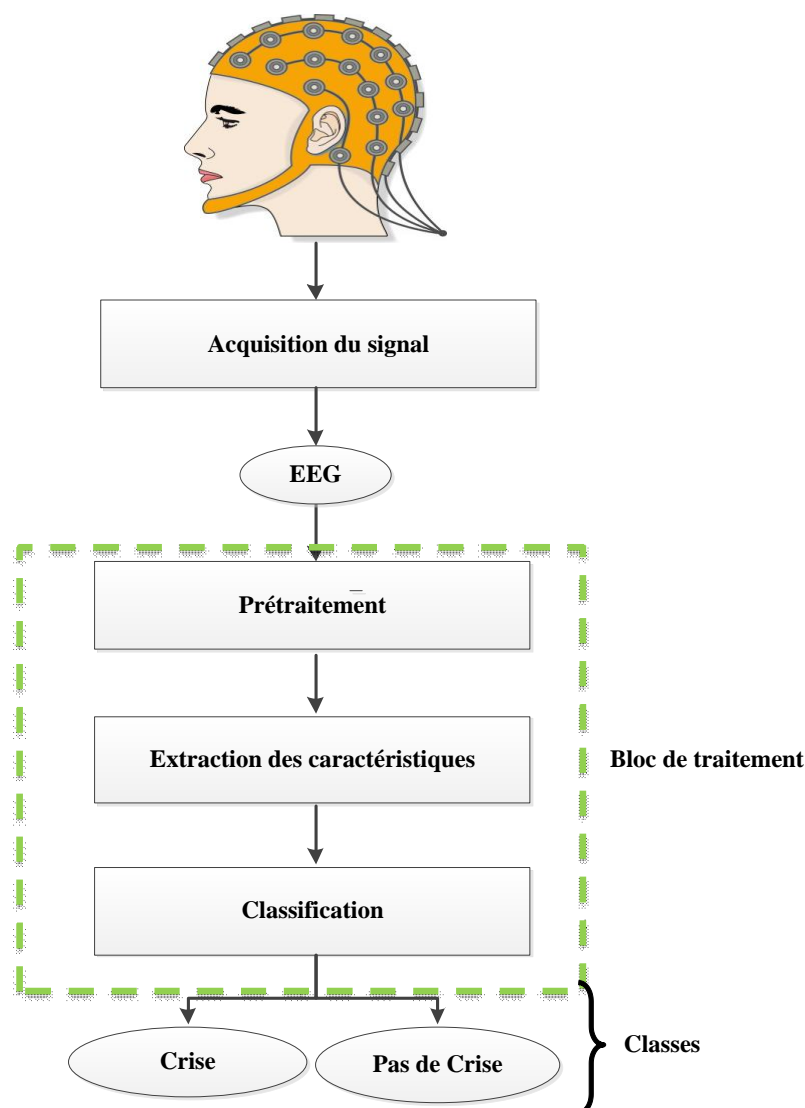


Figure 4.2: Schéma de principe du bloc de traitement.

Tout d'abord, un dispositif d'acquisition numérique permet de transformer le phénomène neurophysiologique en signaux EEG. Les électrodes placées sur le cuir chevelu détectent les activités électrochimiques de milliers de neurones ensuite ces signaux seront filtrés, amplifiés et convertis en données numériques et enfin envoyés à l'ordinateur.

Le but de ce travail est de concevoir un système capable de détecter automatiquement avec précision la présence des crises épileptiques tout au long de ces signaux. Pour cette fin, un bloc de traitement composé de trois étapes est proposé. Les séries temporelles représentant les données EEG sont d'abord envoyées à une étape de prétraitement pour améliorer leur qualité. Ensuite, les indications utiles du signal sont extraites sous la forme de caractéristiques. Les caractéristiques sont une deuxième représentation du signal incluant toutes ses informations originales avec une dimension réduite. Elles permettent au classificateur de différencier les

différentes classes avec une efficacité élevée. 14 caractéristiques sont utilisées pour la représentation du signal. Finalement, l'algorithme LDA est utilisé pour détecter si une crise épileptique existe pour une période définie.

4.3.1.1. *Prétraitement*

Étant donné que les signaux EEG sont générés par le cerveau qui peut être considéré comme le système le plus complexe, ces séries temporelles sont évidemment de nature non linéaire et non stationnaire. L'EMD est utilisé dans la présente étude pour analyser et traiter les signaux EEG tout en tenant compte de ces deux propriétés (non linéarité et non stationnarité). Seuls les trois premiers IMF résultant de la décomposition sont utilisés pour la reconnaissance des crises et les IMF restants qui ont une fréquence centrale très faible sont rejetés car ils sont situés dans la bande de fréquence de bruit non utile [Hug2005].

a) Décomposition en mode empirique

L'EMD a été proposé par Huang et al. [Lot2007] comme une nouvelle approche pour l'analyse des signaux non-stationnaires et non-linéaires. Elle permet d'évaluer les fréquences et les amplitudes des séries temporelles complexes tout en gardant le domaine temporel du signal. Cette méthode décompose le signal original en un nombre fini de fonctions modèles intrinsèques, qui sont des composantes oscillatoires à différentes échelles, et un résidu, qui est une fonction monotone ou une fonction non oscillante (ne contient pas un cycle complet), qui traduit la tendance générale du signal. L'EMD est basé sur les hypothèses suivantes [Jih2014]:

- 1) Tout signal se compose de différents modes intrinsèques d'oscillations;
- 2) Chaque mode linéaire ou non linéaire possède le même nombre des extrémums et de passages par zéro;
- 3) Il n'y a qu'une seule extrémité entre deux passages par zéro successifs;
- 4) Chaque mode doit être indépendant des autres.

La décomposition est assurée à l'aide d'un algorithme fort et adaptatif appelé processus de tamisage. Les différentes étapes de ce processus sont les suivants :

- **Étape 1: Définition**
 - X est le vecteur des données initiales;
 - R est le vecteur des résidus;

- M est le vecteur des valeurs moyennes entre les enveloppes;
- H est le vecteur des différences entre le signal d'origine et les moyennes M ;
- IMF est le vecteur des IMF;
- i est le compteur des IMF et des résidus;
- k est le compteur des moyennes M et des différences H .
- **Étape 2:** initialisation
 - Initialiser le compteur i à la valeur 1;
 - Initialiser le compteur k à la valeur de 1;
 - Le résidu $R[i]$ reçoit la valeur de la donnée initiale X ;
 - La différence $H[k]$ reçoit la valeur du résidu $R[i]$;
- **Étape 3:** Localises les maximums et minimums locaux dans $H[k]$
- **Étape 4:** Estimer les enveloppes supérieures et inférieures.
- **Étape 5:** calculer $M[k]$ comme étant la moyenne entre l'enveloppe supérieure et l'enveloppe inférieure.
- **Étape 6:** calculer la nouvelle différence $H[k+1]$ en soustrayant la moyenne $M[k]$ de la différence $H[k]$.
- **Étape 7:** si les critères d'arrêt sont validés alors le $IMF[i]$ est la dernière différence calculée $H[k+1]$; Sinon, incrémenter k et revenir à l'étape 3.
- **Étape 8:** calculer le nouveau résidu $R[i+1]$ en soustrayant l' $IMF[i]$ du résidu $R[i]$.
- **Étape 9:** si $R[i+1]$ n'est pas monotone alors :
 - Incrémenter la valeur de i ;
 - Réinitialiser k à la valeur 1 ;
 - La différence $H[k]$ reçoit la valeur du résidu $R[i]$ et passer à l'étape 3.
- **Étape 10:** fin du processus de tamisage et $R[i+1]$ est le résidu final.

Plus tard, le signal d'origine peut être construit comme suit:

$$X(t) = \sum_{i=1}^n IMF_i(t) + r(t) \quad (4.1)$$

Avec n qui est le nombre des IMF extraites. En effet, l'extraction des IMF est non-linéaire mais la reconstruction du signal original se fait de façon linéaire.

Normalement, le critère d'arrêt de l'étape 7 est composé de deux conditions.

Tout d'abord, le nombre d'extrémums et le nombre de passages par zéro doivent différer au plus de 1. Deuxièmement, la valeur moyenne de l'enveloppe définie par les maximums locaux et l'enveloppe définie par les minimums locaux est nulle à n'importe quel point. Cependant, puisqu'il est très difficile de remplir la deuxième condition, un nouveau critère d'arrêt a été proposé pour la remplacer. Ce critère est approuvé si l'écart-type (SD) est inférieur à une valeur prédéterminée (0.1) avec:

$$SD = \sum_{t=0}^T \frac{|H_{k-1}(t) - H_k(t)|^2}{H_{k-1}^2(t)} < 0.1 \quad (4.2)$$

Plusieurs études de la littérature se sont intéressées au choix de la méthode d'interpolation la plus adéquate pour la méthode EMD. Par exemple, Linderhed [Lin2004] a présenté une étude comparative des méthodes d'interpolation qui peuvent être utilisées dans le processus de tamisage. De même Huang et al. [Hua1998] ont étudié l'effet des différentes méthodes d'interpolation sur les performances de la méthode EMD. Les résultats montrent que l'interpolation cubique splines est le meilleur choix pour la création des deux enveloppes.

La figure 4.3 illustre un exemple des étapes du processus de tamisage pour l'extraction de la première IMF à partir d'un signal quelconque.

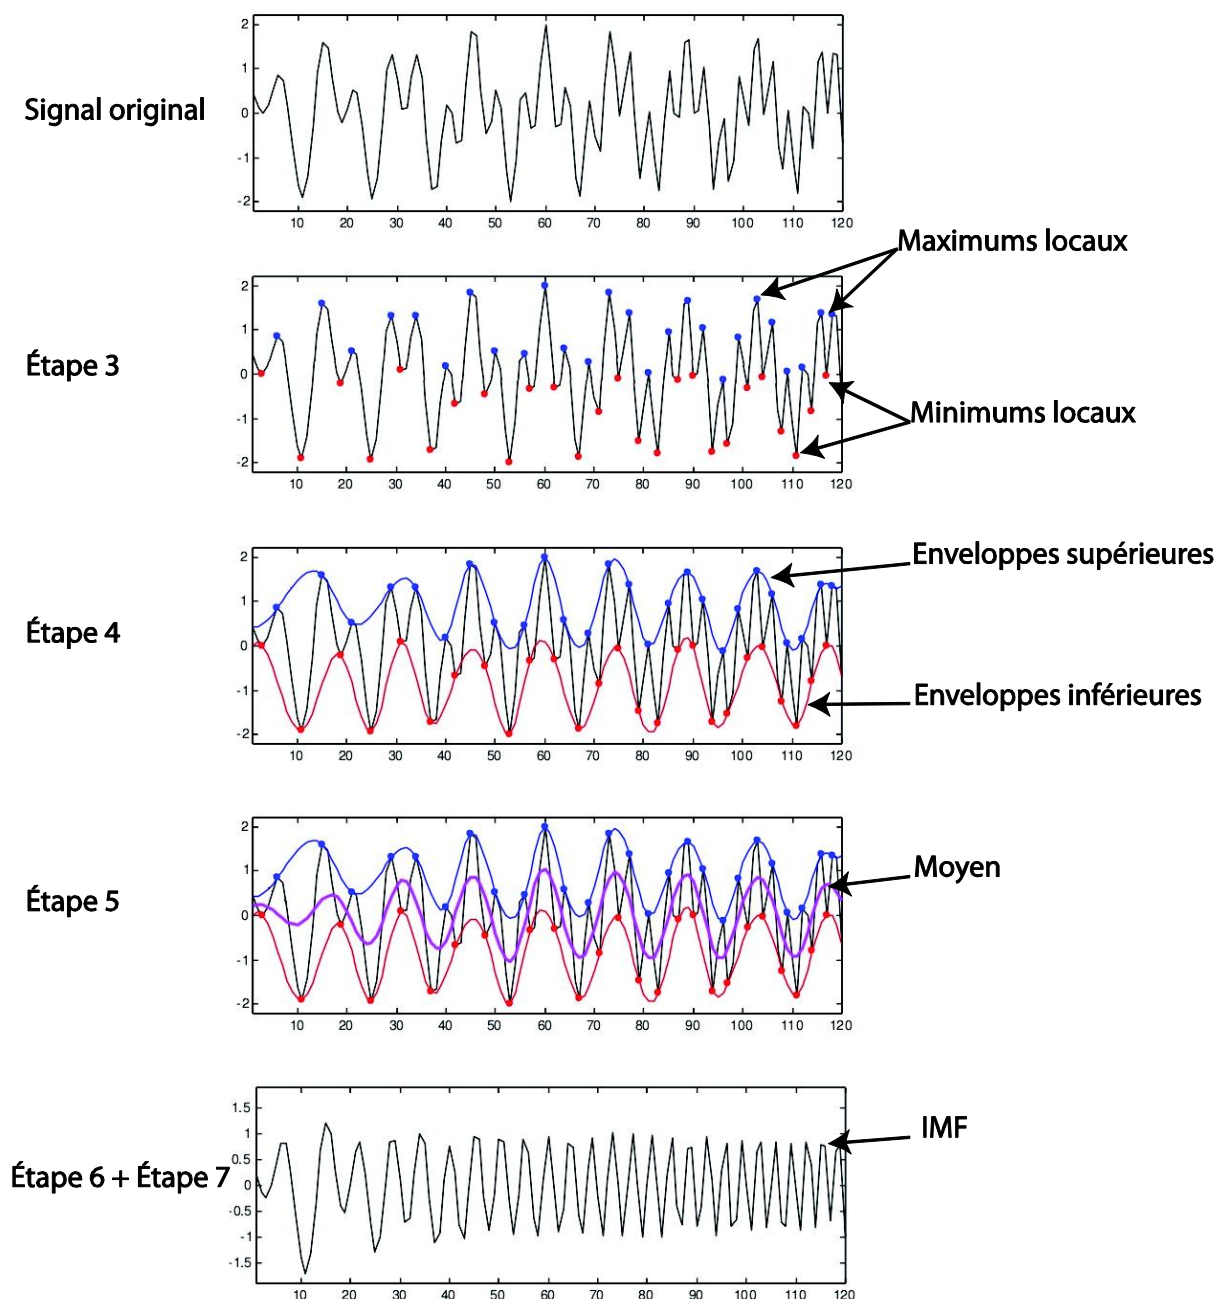


Figure 4.3: Exemple d'extraction d'IMF.

Une IMF représente un mode oscillatoire simple. Concrètement, l'IMF passe par zéro entre chaque maximum et minimum consécutifs.

L'EMD est essentiellement une approche algorithmique qui manque d'une preuve théorique bien établie. Pour cette raison elle est basée sur un grand nombre de simulations numériques et dans des conditions contrôlées [Fla2003]. En plus, plusieurs travaux de la littérature ont montré que l'EMD est une technique flexible et très puissante pour l'analyse adaptative et multi-échelle des signaux non-stationnaires et non-linéaires [Fln2004, Hua1998].

L'organigramme du processus de tamisage est illustré dans la figure 4.4.

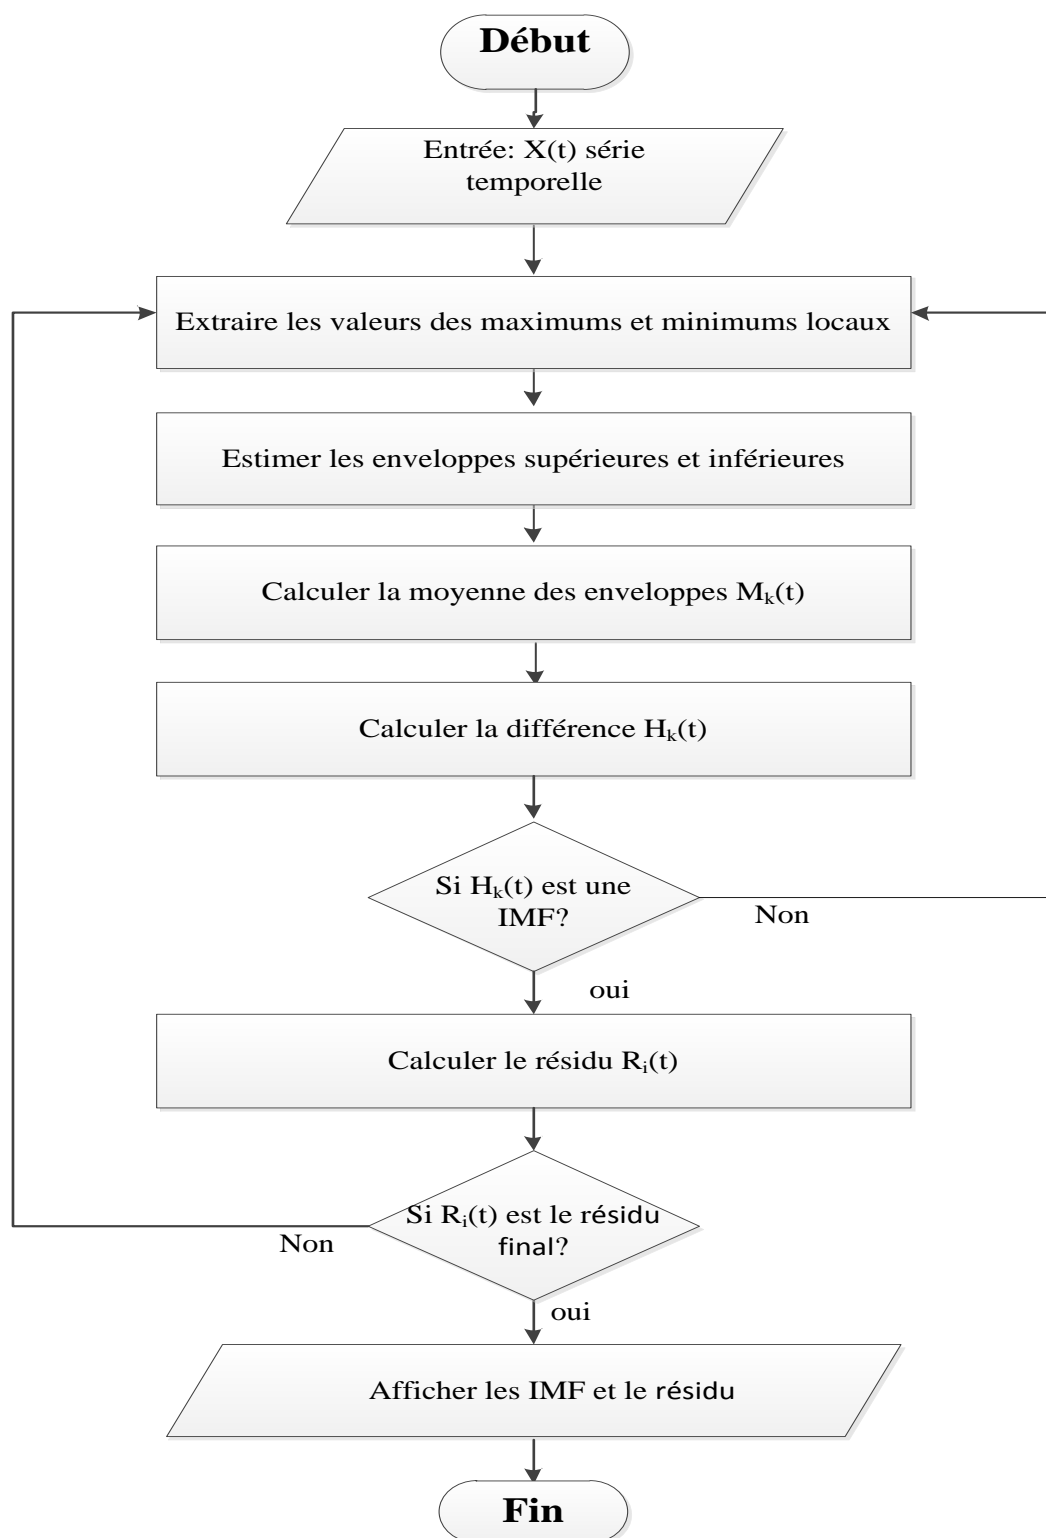


Figure 4.4: Organigramme de l'EMD.

La figure 4.5 illustre le résultat du processus de tamisage d'un signal EEG de largeur égale à 2s avec une fréquence d'échantillonnage égale à 128 Hz.




Figure 4.5: Décomposition du signal original en un nombre finie d'IMF et un résidu.

Les IMF sont des composantes d'une forme d'onde oscillante de moyenne nulle, modelée en amplitude et en fréquence [Hau1998]. Chaque IMF est localisée dans une bande de fréquences supérieure à celle de l'IMF suivante. La décomposition obtenue ressemble à l'application d'un banc de filtre adaptatif.

Une IMF doit être une fonction purement oscillante avec un niveau de référence nul. Les IMF sont conçues pour respecter ces deux conditions. Une IMF est une fonction mono-composante incluant une seule fréquence fondamentale ou un mode oscillatoire simple. Son estimation est basée sur les extrémums locaux du signal d'origine. Par conséquent, le processus de tamisage garantit automatiquement le niveau référence nul.

Le problème de mélange de mode (Mode Mixing Problem) est un inconvénient majeur qui entraîne la perte de la signification physique. Ce problème est rencontré en cas de présence d'échelles (ou composantes fréquentielles) très disparates dans une seule IMF ou la présence d'une échelle similaire dans différentes IMF. Pour résoudre ce problème, Huang et al. [Hua1998] ont proposé une solution appelée test d'intermittence. Cependant, cette méthode

reste non satisfaisante puisqu'elle souffre de deux lacunes majeures. Tout d'abord, une sélection subjective des échelles est nécessaire ce qui perturbe la propriété adaptative de l'EMD. Deuxièmement, il n'est pas toujours clair de séparer subjectivement les échelles.

Wo et Huang ont proposé une meilleure solution appelée Décomposition en Mode Empirique de l'Ensemble (EEMD: Ensemble Empirical Mode Decomposition) [Wu2009]. L'EEMD se compose de quatre étapes:

- **Étape 1:** créer une nouvelle série de bruit blanc et l'ajouter au signal d'origine;
- **Étape 2:** appliquer l'EMD sur le signal créé et enregistrer les IMF trouvées;
- **Étape 3:** répéter l'étape 1 et l'étape 2 n fois; Où n est la taille de l'ensemble;
- **Étape 4:** le résultat final est la moyenne des IMF correspondantes.

Le bruit blanc est considéré comme un fond uniforme permettant de projeter les échantillons des signaux de différentes échelles sur les échelles appropriées. En plus, la moyenne d'un nombre suffisant d'IMF annule le bruit et conserve le signal pertinent.

4.3.1.2. *Extraction des caractéristiques*

14 caractéristiques sont utilisées pour représenter le signal EEG. L'utilisation d'un grand nombre de caractéristiques offre une meilleure chance d'une description significative du signal et permet d'obtenir des performances optimales. Le tableau 4.1 présente les caractéristiques utilisées dans cette étude.

Tableau 4.1: Caractéristiques utilisées pour la quantification de la crise épileptique.

Nom de la caractéristique		Description
Caractéristiques extraites à partir des trois premier IMF	Mn	La moyenne des points de données.
	Var	La variance qui représente la répartition des points de données par rapport à la valeur moyenne.
	Std	L'écart type qui décrit la répartition des points de données.
	MAD	L'écart absolu moyen qui est la distance moyenne entre les points de données et la valeur moyenne.
	Sk	Le Skewness qui est une mesure de l'asymétrie de la distribution de l'ensemble de données.
	Ku	Le Kurtosis qui décrit la valeur du pique de la distribution.
	SE	L'entropie d'échantillon (Sample Entropy) comme mesure de la complexité du signal
	Cv	Coefficient de variation qui reflète la variabilité des points de données.
	RMS	la valeur moyenne quadratique pondérée (Root Mean Square) qui est une représentation de la valeur effective du phénomène observé.
Caractéristiques extraites à partir du périodogramme des IMF	Sk-P	Le Skewness relative aux points du périodogramme.
	Ku-P	Le Kurtosis relative aux points du périodogramme.
	IR-P	La gamme interquartile (Interquartile Range) qui est la différence entre le troisième et le premier quartile, considérée comme une mesure de la dispersion statistique.
	MP-P	La valeur de puissance maximale du périodogramme donnant des informations sur la fréquence principale du signal.
	F-MP	La fréquence associée à la MP-P.

a) Écart absolu moyen

L'écart absolu moyen d'un ensemble de données est la distance moyenne entre chaque valeur de données et la moyenne.

$$MAD = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}| \quad (4.3)$$

Où n est le nombre d'éléments de x et \bar{x} est la valeur moyenne de x .

b) Entropie d'échantillon

La notion de l'entropie a été adaptée pour la première fois dans une application réelle en 1991 par Pincus au il a introduit l'entropie approximative (ApEn : Approximate Entropy). L'ApEn calcule le logarithme naturel négatif de la probabilité conditionnelle (CP : Conditional Probability) qu'une période courte de données est répétée pendant la série temporelle. Pour cela, cette méthode commence par sélectionner un modèle de points de longueur m puis elle identifie les autres modèles qui sont similaires au premier avec une tolérance r ensuite elle détermine lequel de ces modèles reste similaire pour le prochain échantillon. La tolérance r est généralement un facteur de l'écart type. Le logarithme négatif de la probabilité conditionnelle est calculé pour chaque modèle possible et les résultats sont les valeurs moyennes. L'estimation de l'ApEn est donnée par l'équation 4.4.

$$ApEn = \sum -\log\left(\frac{1 + A_i}{1 + B_i}\right) \quad (4.4)$$

Avec A_i est le nombre de modes similaires de longueur $m+1$ avec le $i^{\text{ième}}$ modèle et B_i est le nombre de modes similaires de longueur m avec le $i^{\text{ième}}$ modèle.

Si les données sont ordonnées alors les modèles qui sont similaires pour le m points sont souvent similaires pour les $m+1$ points, alors CP tend vers 1 et l'ApEn tend vers 0. L'entropie d'échantillon est une modification de l'entropie approximative définie par l'équation 4.5.

$$SampEn = -\log\left(\frac{\sum A_i}{\sum B_i}\right) = -\log(A/B) \quad (4.5)$$

Pour des données régulières et répétitives A/B tend vers 1 et SampEn tend vers 0.

La figure 4.6 illustre un exemple de l'incrémentation des variables de similarités.




Figure 4.6: Démonstration schématique de l'estimation de l'entropie.

La série temporelle commence avec le $i^{\text{ème}}$ modèle. Dans cet exemple, m est fixé à 2. La tolérance pour l'acceptation des correspondances est r fois l'écart type. Elle est affichée par les barres d'erreur. Le mode est similaire aux points numéros 11 et 12 cadrés en ligne solide. De même le $m+1$ points sont similaire aussi (représenté en trait interrompu). Dans ce cas les deux compteurs A et B seront incrémentés par 1.

c) Coefficient de variation

Le coefficient de variation permet de comparer la variabilité de deux séries qui ont des moyennes très différentes ou même qui ne sont pas exprimées dans les mêmes unités puisque le coefficient de variation exprime l'écart-type en pourcentage de la moyenne.

$$C_v = \frac{\delta}{\mu} \times 100\% \quad (4.6)$$

où μ est la valeur moyenne de x et δ est l'écart type de x .

Le coefficient de variation donne l'homogénéité de la série, si le coefficient de variation est inférieur à 15%, on considère que les données sont homogènes et inversement, si le coefficient de variation est supérieur à 15%, on dit que les données sont hétérogènes.

d) Valeur moyenne quadratique pondérée

Pour un ensemble de n nombres ou valeurs d'une distribution discrète $x_1 \dots x_n$, la valeur moyenne quadratique pondérée, est la racine carrée de la moyenne des valeurs x_i^2 .

$$RMS = \sqrt{\frac{x_1^2 + x_2^2 + \dots + x_n^2}{n}} \quad (4.7)$$

$$RMS = \sqrt{\langle x^2 \rangle} \quad (4.8)$$

Ici $\langle x^2 \rangle$ désigne la moyenne des valeurs x_i^2 .

Ainsi, la valeur moyenne quadratique pondérée est une mesure de la grandeur d'un ensemble de nombres. Cela donne un sens à la taille typique des nombres.

4.3.1.3. Classification avec l'analyse discriminante linéaire

Le LDA est utilisé pour reconnaître la classe ou le groupe de chaque série d'échantillons. Les variables prédictives calculées à partir des caractéristiques de chaque période de données permettent d'identifier si une crise se trouve ou non.

L'objectif du LDA est de prédire si un segment (observation) est un membre d'une classe ou d'un groupe prédéfini au moyen des variables prédictives extraites à partir de ses caractéristiques mesurées. Ces méthodes consistent à créer des modèles de fonctions de densité de probabilité pour les données générées par chaque classe. Ensuite, un nouveau point de données est classé en déterminant la fonction de la densité de probabilité qui a la plus grande valeur [Has2008]. Chacune des fonctions de densité de probabilité de classe est modélisée comme une densité de distribution normale multivariée [Wu1996].

Supposons les paramètres suivants: k le nombre de classes; N le nombre d'instances d'apprentissage; N_k le nombre d'observations de la classe k ; π_k la probabilité antérieure de la classe k ; X_k un échantillon avec une taille $(p \times N_k)$ et μ_k la moyenne de la distribution normale multivariée pour chaque classe.

Le LDA est le cas spécial lorsque l'on considère que les classes ont une matrice de covariance commune Σ . Un nouveau point de données x est classé par:

$$\arg \max \delta_k(x) \quad (4.9)$$

Avec

$$\delta_k(x) = x^T \Sigma^{-1} \mu_k - \frac{1}{2} \mu_k^T \Sigma^{-1} \mu_k + \log \pi_k \quad (4.10)$$

Pour calculer $\delta_k(x)$, nous devons estimer ces paramètres en utilisant les équations suivantes au moyen des données d'apprentissage:

$$\hat{\pi} = N_k / N \quad (4.11)$$

$$\hat{\mu}_k = \sum_{i \in k} \frac{x_i}{N_k} \quad (4.12)$$

$$\hat{\Sigma} = \frac{\sum_{k=1}^K \sum_{i \in k} (x_i - \hat{\mu})(x_i - \hat{\mu}_k)^T}{N - K} \quad (4.13)$$

4.3.2. Bloc d'adaptation des paramètres

Afin de détecter la crise épileptique avec précision, des signaux d'une période finie de temps sont utilisés à chaque fois. Ainsi, une fenêtre rectangulaire d'une longueur L est appliquée aux signaux originaux pour les diviser en plusieurs segments. Afin d'améliorer les performances du système, N segments successifs de même longueur sont utilisés pour prendre une décision. La moyenne des N résultats est considérée comme la décision finale pour la période qui comprend ces segments. En plus, pour améliorer l'homogénéité entre les segments, tous les deux segments successifs sont chevauchés [Coa2011]. Par la suite, les principaux paramètres qui peuvent influencer la détection de la crise sont les suivants:

- La durée de la période traitée;
- Le taux de chevauchement;
- Le nombre de segments utilisés pour prendre une décision;
- Les canaux EEG sélectionnés;
- Les caractéristiques utilisées ;
- La limite de décision du classifieur.

Puisque les propriétés des signaux EEG qui sont pris pendant la crise diffèrent d'un sujet à un autre, le système doit être capable d'adapter ses paramètres selon chaque patient. Un bloc

d'adaptation des paramètres basé sur l'algorithme génétique était proposé pour sélectionner la meilleure combinaison de paramètres appropriée à chaque patient, [Amr2017] ce qui permet certainement d'atteindre de meilleures performances. La figure 4.7 présente le schéma du sous-système responsable de la sélection des paramètres.

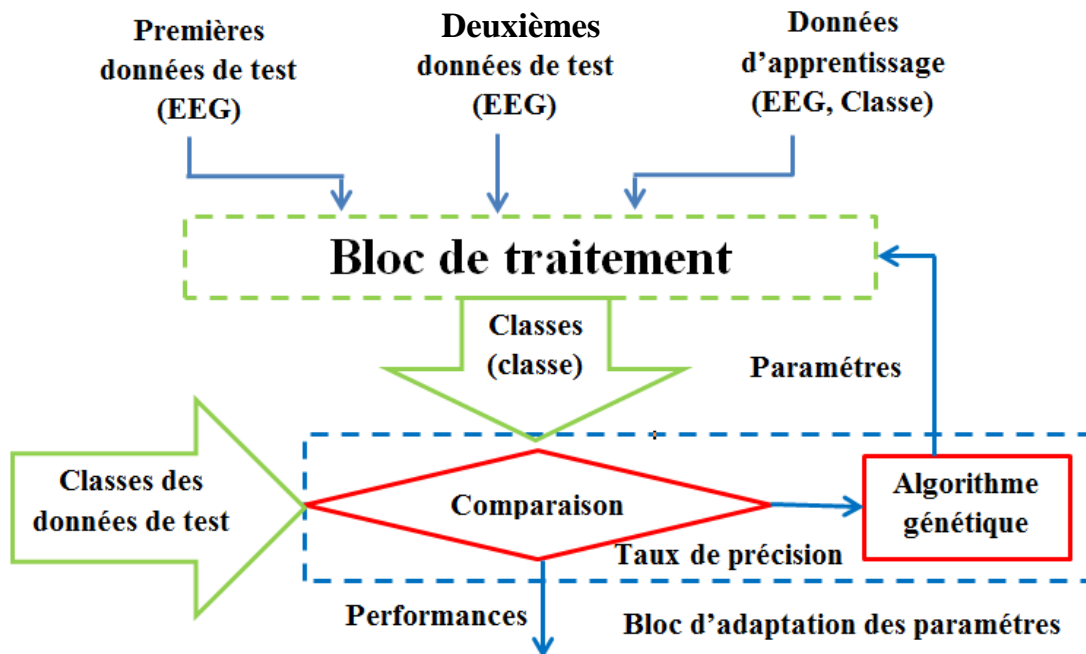


Figure 4.7: Méthode de sélection des paramètres [Amr2017].

Pour chaque chromosome, le système utilise les classes des échantillons de test pour calculer le taux d'exactitude. Ensuite, l'AG utilise tous les taux de précision trouvés pour progresser vers la prochaine génération et pour converger vers une combinaison optimale. Les données recueillies auprès de chaque patient sont divisées en trois groupes:

- Les données d'apprentissage utilisées pour l'apprentissage du classifieur;
- Les premières données de test utilisées pour l'exécution de l'algorithme génétique;
- Les deuxièmes données de test utilisées pour extraire les différentes performances du système afin d'évaluer la méthode proposée.

Dans chaque étape, l'AG utilise les derniers taux de précision trouvés pour sélectionner un nouvel ensemble de paramètres. L'objectif de la fonction fitness est donc la maximisation de la précision du système. D'une étape à une autre, l'AG converge vers la solution optimale jusqu'à trouver la meilleure combinaison [Cho2012]. Finalement, les données restantes sont

utilisées pour estimer les performances de l'ensemble du système. En raison de sa capacité à s'adapter aux caractéristiques spécifiques des signaux de chaque patient, notre système proposé est plus efficace que les systèmes de la littérature. L'algorithme génétique a été utilisé pour sélectionner automatiquement les paramètres optimaux sans besoin de faire une recherche tout au long de toutes les possibilités. Cette technique d'optimisation heuristique adaptative s'inspire de la mécanique de la génétique et de la sélection naturelle. L'AG comprend un processus d'évolution dans le but d'optimiser la valeur fitness qui est le résultat de la fonction objective. Le processus commence par une génération aléatoire et étudie à chaque étape comment une solution résout le problème afin d'évoluer progressivement vers les gènes optimaux représentant les paramètres.

4.3.2.1. Algorithme génétique

L'algorithme génétique (AG) a été introduit pour la première fois dans les années 1970 par Holland. Cette approche tire ses avantages de la théorie de l'évolution de Darwin et de la génétique. Elle commence par une population initiale aléatoire d'individus et évolue vers la solution optimale grâce à un processus de calcul itératif basé sur la sélection, le croisement et les techniques de mutation. En utilisant la fonction d'adaptation (Fitness Function), l'AG évalue les individus ou les chromosomes et sélectionne ceux qui produisent les meilleurs scores. Les gènes de ces chromosomes appelés parents sont utilisés dans la prochaine génération. Le croisement permet de mélanger les gènes de deux parents afin de créer un nouveau chromosome proche des dernières solutions. D'autre part, la mutation consiste à modifier de façon aléatoire une partie des gènes enfants [Che2010, Iza2015, Oca2008, Yan2012].

La figure 4.8 illustre le mécanisme de l'AG. La diversité des individus et l'examen parallèle des voies de solutions multiples améliorent la probabilité de converger vers la solution optimale sans se coincer dans une solution locale.

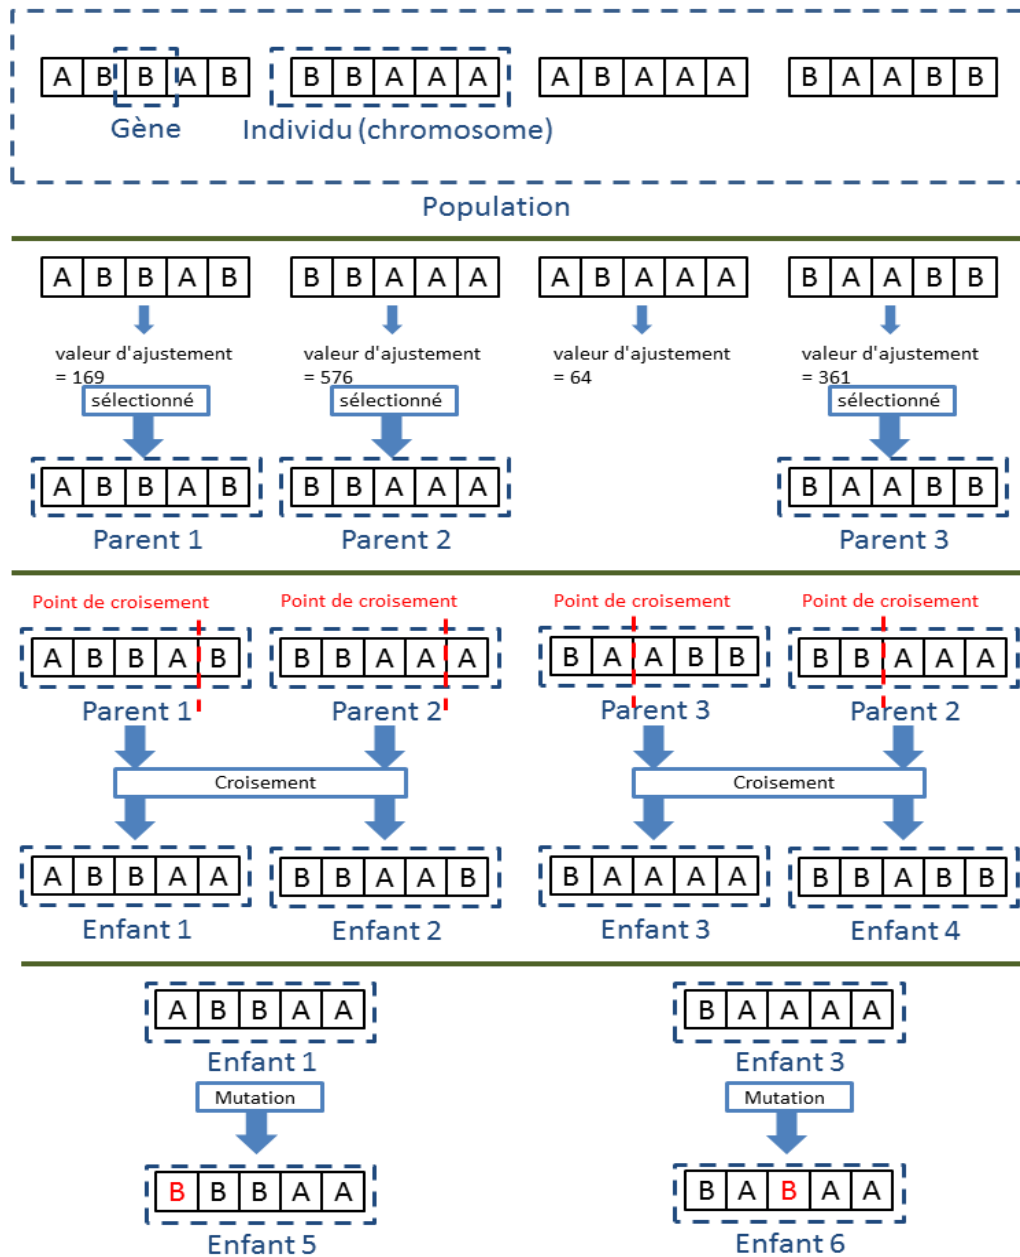


Figure 4.8: Mécanisme d'algorithme génétique [Eib1998].

4.4. Modélisation UML

L'UML est l'acronyme anglais pour « Unified Modeling Language » qui se traduit par « langage de modélisation unifié ». C'est un langage visuel constitué d'un ensemble de schémas, appelés des diagrammes, qui donnent chacun une vision différente du projet à traiter [Roe2015].

UML nous permet, grâce à ses différents diagrammes, de représenter l'architecture du système ou logiciel à développer ainsi que son fonctionnement, sa mise en route, les actions susceptibles d'être effectuées par le logiciel et beaucoup d'autres.

UML est un langage formel et normalisé qui présente plusieurs avantages parmi lesquels, nous citons :

- Gain de précision;
- Gage de stabilité;
- Un support de communication performant;
- Il cadre l'analyse;
- Il facilite la compréhension des représentations abstraites complexes;
- Son caractère polyvalent et sa souplesse en font un langage universel.

4.4.1. Les diagrammes UML

A ce jour, il existe treize diagrammes UML qui peuvent être qualifiés d'officiels. Ces diagrammes sont répartis selon le schéma de 4+1 vues d'un système (figure 4.9) en 5 groupes de diagrammes.

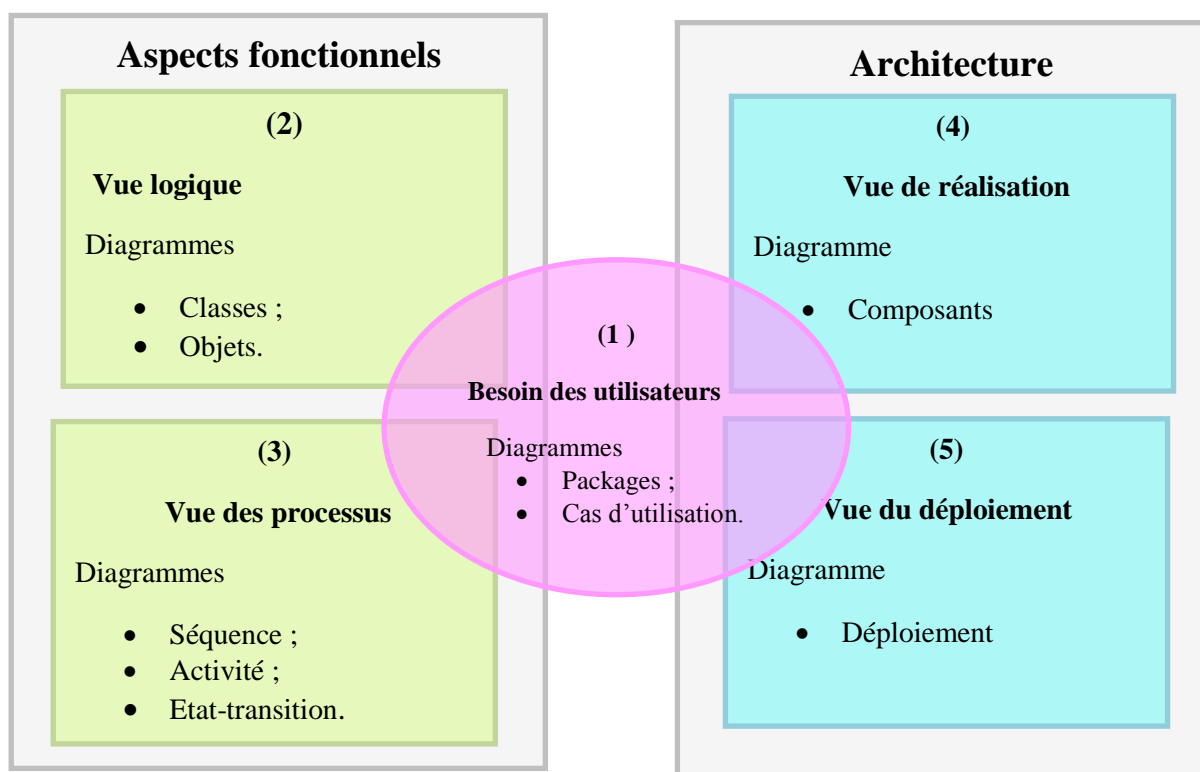


Figure 4.9: Les 4+1 vues d'un système.

Dans la partie suivante, nous présentons la conception de notre système suivant les besoins des utilisateurs et les 2 vues d'UML logique et de processus.

4.4.2. Identification des cas d'utilisation

Après avoir présenté la notion d'UML, nous modélisons dans un premier temps les cas d'utilisation que nous avons identifiés en utilisant le diagramme de cas d'utilisation d'UML. Notons que les cas d'utilisation jugés les plus importants sont suivis par une description textuelle.

4.4.2.1. Définition du diagramme de cas d'utilisation

Le diagramme de cas d'utilisation est l'un des diagrammes du langage de modélisation d'UML les plus utilisés. Il représente une représentation graphique des interactions entre les différents acteurs du système d'un côté et le système lui-même d'un autre côté. Il permet d'identifier, de clarifier et d'organiser les exigences du système à développer. En général, un diagramme de cas d'utilisation est formé en se basant sur les différents besoins fonctionnels et techniques déjà identifiés, sachant que chaque cas d'utilisation dans le diagramme peut regrouper une ou plusieurs spécifications fonctionnelles et/ou techniques [Bat2011].

4.4.2.2. Les packages de cas d'utilisation

Les packages, paquetages en français, sont utilisés avec la plupart des diagrammes UML (diagramme de classes, diagrammes de cas d'utilisation, ...) afin de regrouper et d'organiser les éléments de ces diagrammes dans des ensembles cohérents permettant ainsi de réaliser des diagrammes plus structurés et donc plus faciles à lire et à comprendre.

Dans notre système, nous avons pu répartir les cas d'utilisation identifiés en un package principale présenté dans la figure 4.10.

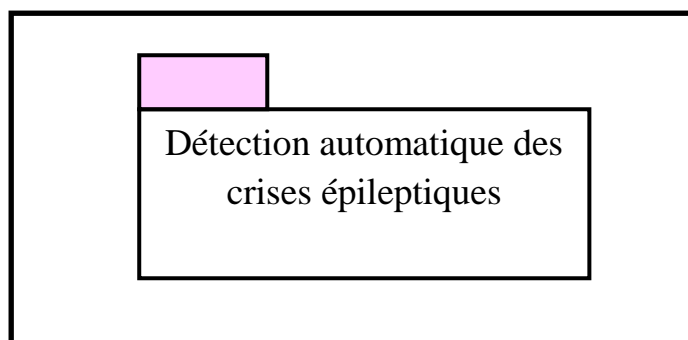


Figure 4.10: Package cas d'utilisation.

a) **Le package de détection automatique des crises épileptiques**

Ce package compte un seul utilisateur qui peut être le traiteur des signaux, le neurologue ou le médecin.

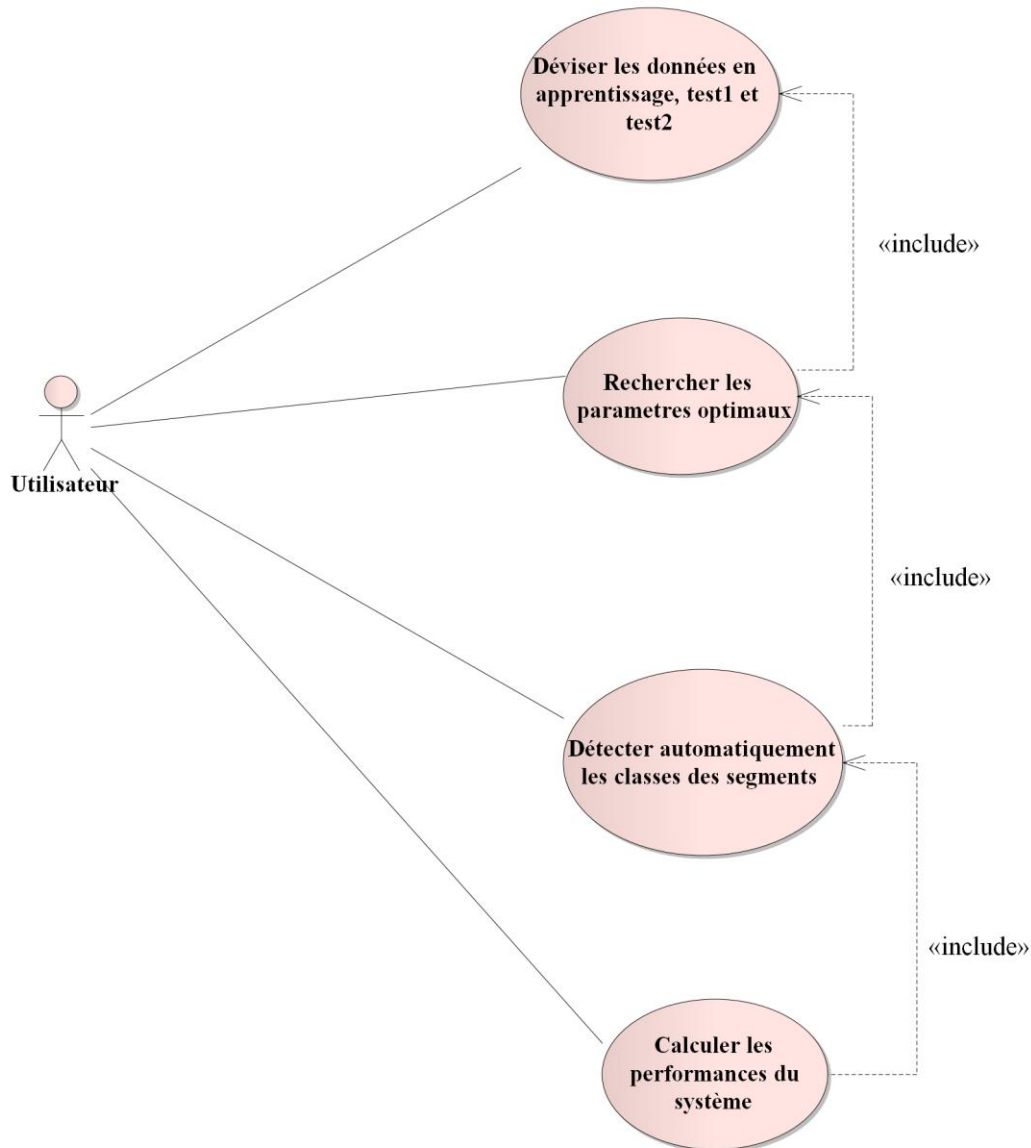


Figure 4.11 : Les cas d'utilisation du package de détection automatique des crises épileptiques.

- **Documentation du cas d'utilisation « Diviser les données en apprentissage, test1 et test2 »:**

Tableau 4.2: Documentation du cas d'utilisation diviser les données en apprentissage, test1 et test2.

CU : Diviser les données en apprentissage, test1 et test2.
Description brève : les données EEG doivent être divisées en trois groupes. Le premier groupe (apprentissage) assurera l'apprentissage du classifieur. le deuxième groupe (test1) sera utilisé pour l'optimisation des paramètres. Le troisième groupe, le reste des signaux, (test 2) sera traité afin de détecter automatiquement les classes et de calculer les performances du système. L'identification des classes des segments se fait par l'expert.
Acteurs concernés : le traiteur des signaux, le neurologue ou le médecin.
Préconditions : aucun
Scénario principal : <ol style="list-style-type: none">1. Ce CU démarre lorsqu'un acteur clique sur le bouton « Groupe de données »;2. Un onglet pour définir les paramètres d'affichage des signaux (choix du patient, choix des canaux et taille des données...) est affiché;3. L'utilisateur introduit les informations d'affichage;4. L'utilisateur clique sur le bouton «valider»;5. Les signaux sont affichés sur l'écran;6. L'utilisateur peut utiliser la barre de défilement pour parcourir tous les signaux ;7. L'utilisateur sélectionne une partie des signaux;8. L'utilisateur clique sur un bouton radio pour choisir le groupe des signaux sélectionnés;9. L'utilisateur clique sur le bouton « localiser une crise » pour identifier manuellement les signaux d'une crise;10. Deux zones de texte sont affichées pour entrer le début et la fin de la crise;11. L'utilisateur introduit les informations sur la crise;12. L'utilisateur clique sur le bouton «valider».
Postconditions : les groupes de signaux et les classes de segments sont enregistrés dans la base de données.

• **Documentation du cas d'utilisation « Rechercher les paramètres optimaux » :**

Tableau 4.3 : Documentation du cas d'utilisation rechercher les paramètres optimaux.

CU : Rechercher les paramètres optimaux.
Description brève : ce CU permet au système de trouver les paramètres optimaux pour chaque patient.
Acteurs concernés : le traiteur des signaux, le neurologue ou le médecin.
Préconditions : aucun
Scénario principal <ol style="list-style-type: none"> 1. Ce CU démarre quand l'utilisateur clique sur le bouton « trouver les paramètres optimaux »; 2. Un cercle de pourcentage graphique est affiché pour indiquer l'avancement de l'exécution; 3. A la fin de l'exécution un rapport sous forme d'un fichier Excel est créé.
Postconditions : les paramètres optimaux du patient sont enregistrés sous forme d'un fichier «.mat».

• **Documentation du cas d'utilisation « Détecter automatiquement les classes de segments » :**

Tableau 4.4: Documentation du cas d'utilisation détecter automatiquement les classes de segments.

CU : Détecter automatiquement les classes des segments.
Description brève : ce CU permet au système de trouver les classes de segments.
Acteurs concernés : le traiteur des signaux, le neurologue ou le médecin.
Préconditions : aucun
Scénario principal : <ol style="list-style-type: none"> 1. Ce CU démarre lorsque l'utilisateur clique sur le bouton « détection automatique »; 2. Un cercle de pourcentage graphique est affiché pour indiquer l'avancement de l'exécution; 3. A la fin de l'exécution un rapport sous forme d'un fichier Excel est créé; 4. les signaux épileptiques sont affichés avec la couleur rouge.
Postconditions : les signaux épileptiques sont fournis ce qui permet à l'expert de vérifier les résultats.

- **Documentation du cas d'utilisation « Calculer les performances du système » :**

Tableau 4.5 : Documentation du cas d'utilisation calculer les performances du système.

CU : Calculer les performances du système.
Description brève : ce CU permet de comparer les résultats de l'expert avec les résultats du système afin de calculer ses performances.
Acteurs concernés : le traiteur de signaux, le neurologue ou le médecin.
Préconditions : aucun
Scénario principal : 1. Ce CU démarre lorsque l'utilisateur clique sur le bouton « performance »; 2. Le système affiche les valeurs du taux de précision, de la sensibilité et de la spécificité.
Postconditions : les valeurs de performances sont fournies à l'utilisateur.

4.4.3. Le diagramme de classes

Le diagramme de classes représente les classes et les interactions entre les différentes classes. La figure 4.12 présente le diagramme de classes de notre solution.

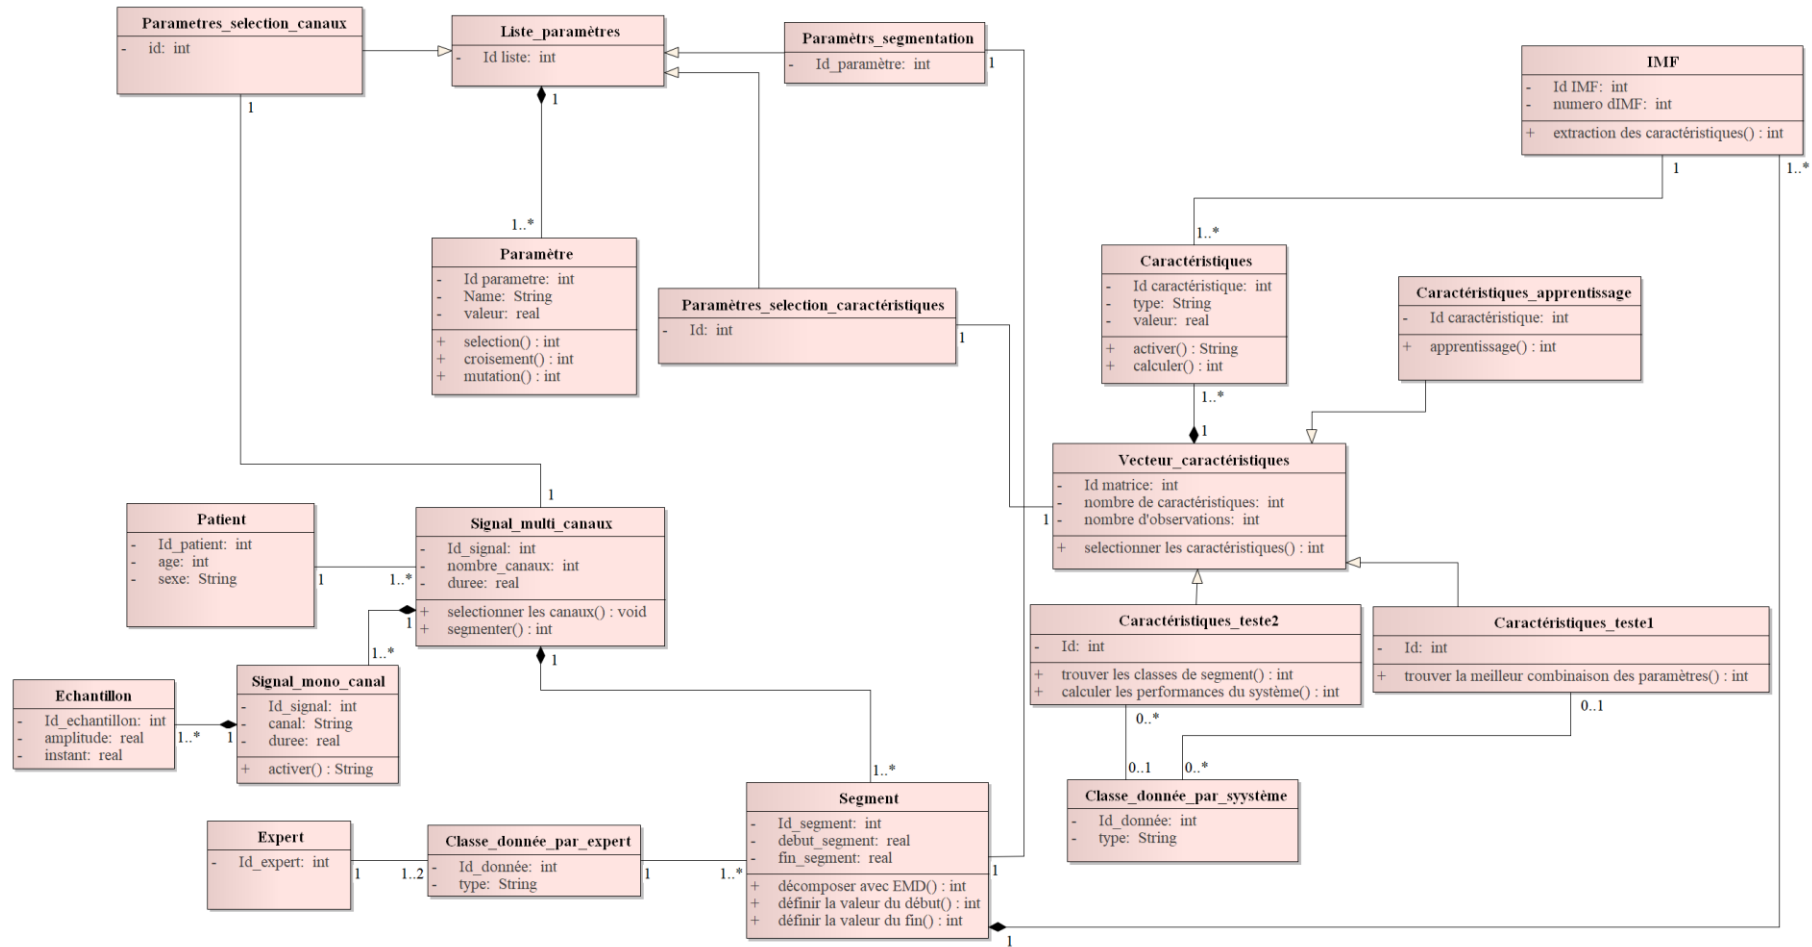


Figure 4.12: Diagramme de classes.

Dans le diagramme de classes nous avons représenté les classes de notre système ainsi que les associations et les dépendances entre ces classes ; Une dépendance entre deux classes est expliquée par le fait qu'une classe manipule un objet de l'autre classe dans une opération ou une classe fait appel à une méthode de l'autre classe. Le tableau 4. 6 présente chaque classe et son rôle dans le système.

Tableau 4.6: Les classes et leurs rôles.

Classe	Rôle
Paramètres_Sélection_Canaux	Cette classe représentera les paramètres liés à l'étape de sélection des canaux.
Liste_Paramètres	Cette classe contiendra un ensemble de paramètres.
Paramètres_Segmentation	Cette classe représentera les paramètres liés à l'étape de segmentation.
Paramètre	Cette classe représentera un paramètre qui peut agir sur le fonctionnement du système.
Signal_Multi_Canaux	Cette classe contiendra un ensemble de signaux mono-canal. Elle représente le signal EEG du patient.
Patient	Cette classe servira à instancier un patient et à enregistrer quelque information à son propos.
Signal_Mono_Canal	Cette classe contiendra un ensemble d'échantillons en provenance d'un seul canal.
Echantillon	Elle représentera l'élément unitaire du signal.
Classe_Donnée_par_Expert	Elle représentera la classe (crise ou non crise) donnée par l'expert pour un segment.
Expert	Cette classe servira à instancier un expert.
Segment	Elle représentera une partie du signal EEG entre deux instants spécifiques.
IMF	Cette classe représentera une IMF produite par le processus de tamisage.
Caractéristique	Cette classe représentera une valeur qui décrit le signal.
Vecteur_Caractéristiques	Cette classe contiendra un ensemble de caractéristiques.
Paramètres_Sélection_Caractéristiques	Cette classe représentera les paramètres liés à l'étape de sélection des caractéristiques.
Caractéristiques_Apprentissage	Cette classe représentera les vecteurs des caractéristiques des signaux d'apprentissage.
Caractéristiques_Test 2	Cette classe représentera les vecteurs des caractéristiques des signaux du test2.
Classe_Donnée_par_Système	Elle représentera la classe (crise ou non crise) donnée par le système pour un segment.
Caractéristiques_Test1	Cette classe représentera les vecteurs des caractéristiques des signaux du test1.

4.4.4. Le diagramme de Séquence

Le diagramme de séquence décrit une opération ordonnée dans le temps en se basant sur trois concepts principaux : Les lignes de vie, les messages et les fragments.

- **Une ligne de vie** représente un seul participant dans une interaction. Elle peut représenter un objet, une instance d'une classe ou un acteur ;
- **Un message** représente une communication entre deux lignes de vie durant une interaction. Il s'agit de l'appel d'une opération, de la création ou de la destruction d'instance, ou de l'envoi d'un signal ;
- **Un fragment** peut contenir un ou plusieurs messages et peut être caractérisé par une ou plusieurs conditions.

Dans ce qui suit, nous allons présenter les diagrammes de séquence de quatre activités principales effectuées par notre système :

Afin de garantir le bon fonctionnement du système, l'utilisateur doit commencer par diviser les données du patient en trois groupes (apprentissage, test1 et test2). Une fois un groupe créé, l'utilisateur doit introduire les classes de segments.

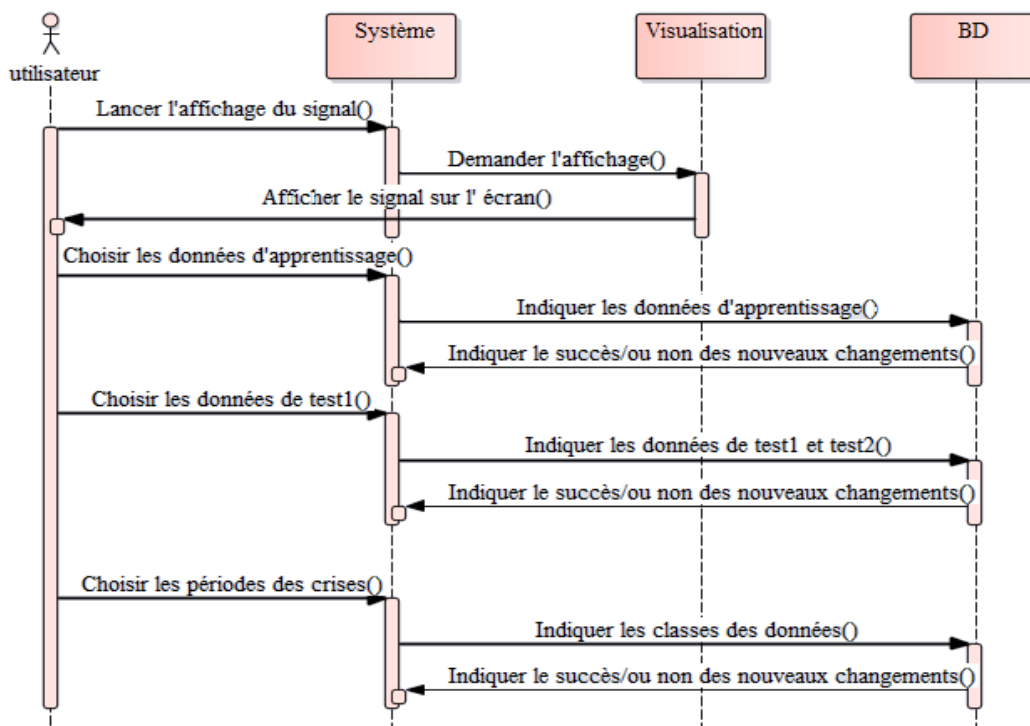


Figure 4.13: Diagramme de séquence « choix des données d'apprentissage et de test1 ».

Quand un utilisateur souhaite chercher les paramètres optimaux spécifiques à un patient, il doit cliquer sur le bouton « trouver les paramètres optimaux ». Ainsi, une méthode basée sur l'optimisation avec l'algorithme génétique sera exécutée.

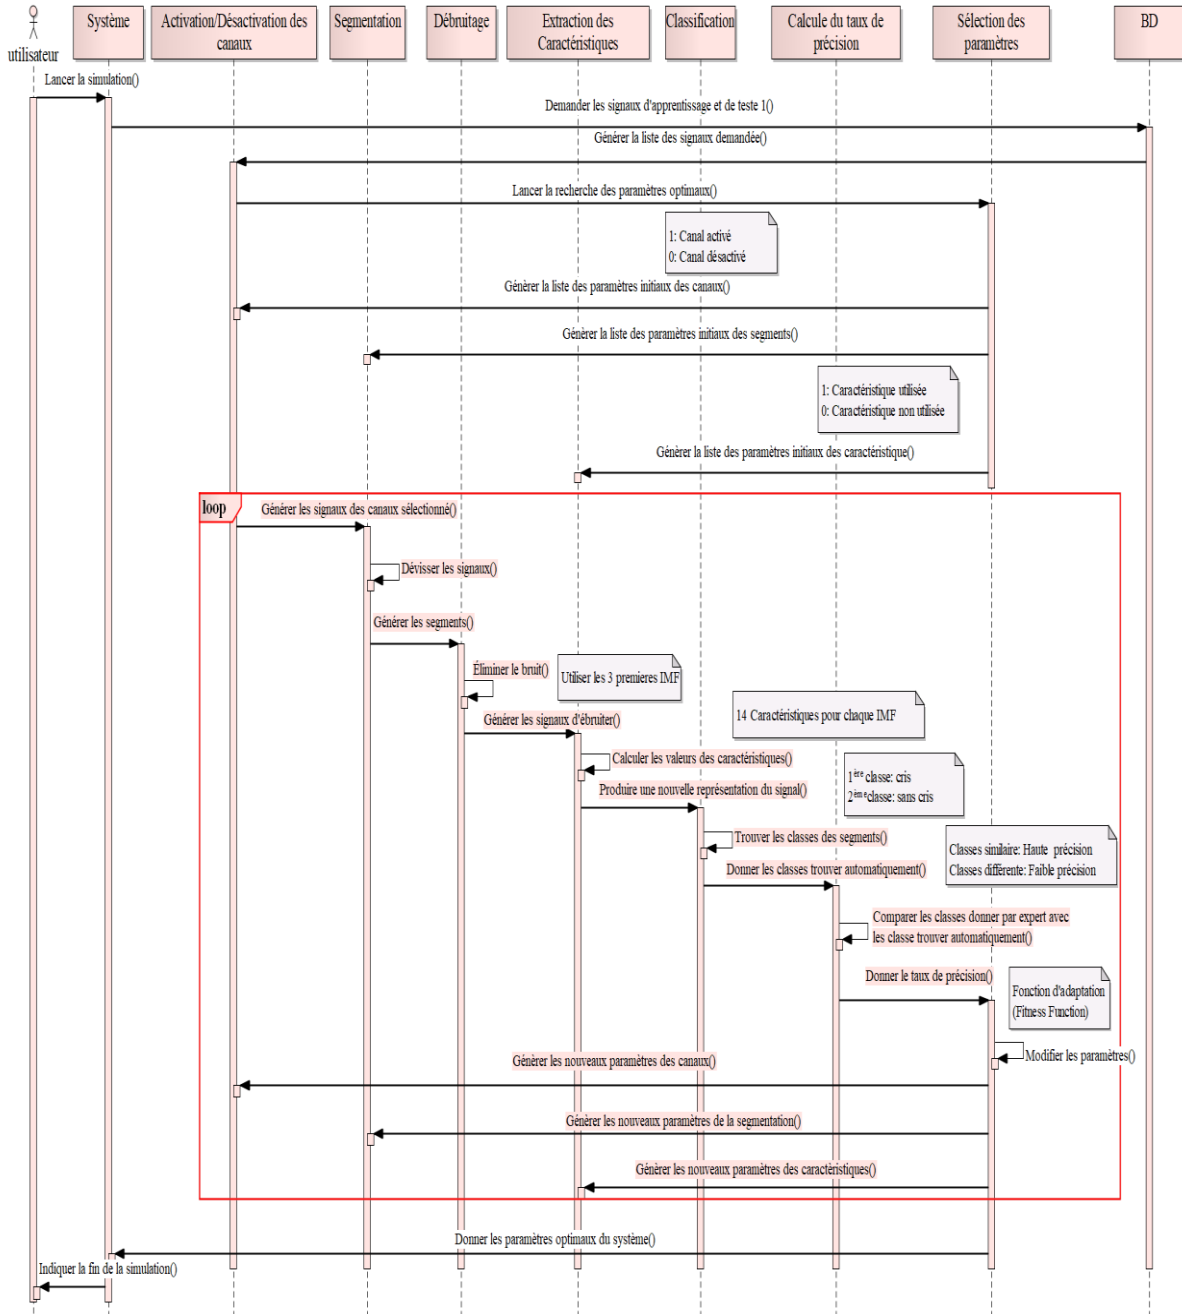


Figure 4.14: Diagramme de séquence « recherche des paramètres optimaux ».

Afin de classer automatiquement les segments, le système utilise les paramètres optimaux et la limite de décision du classifieur trouvés dans l'étape précédente.

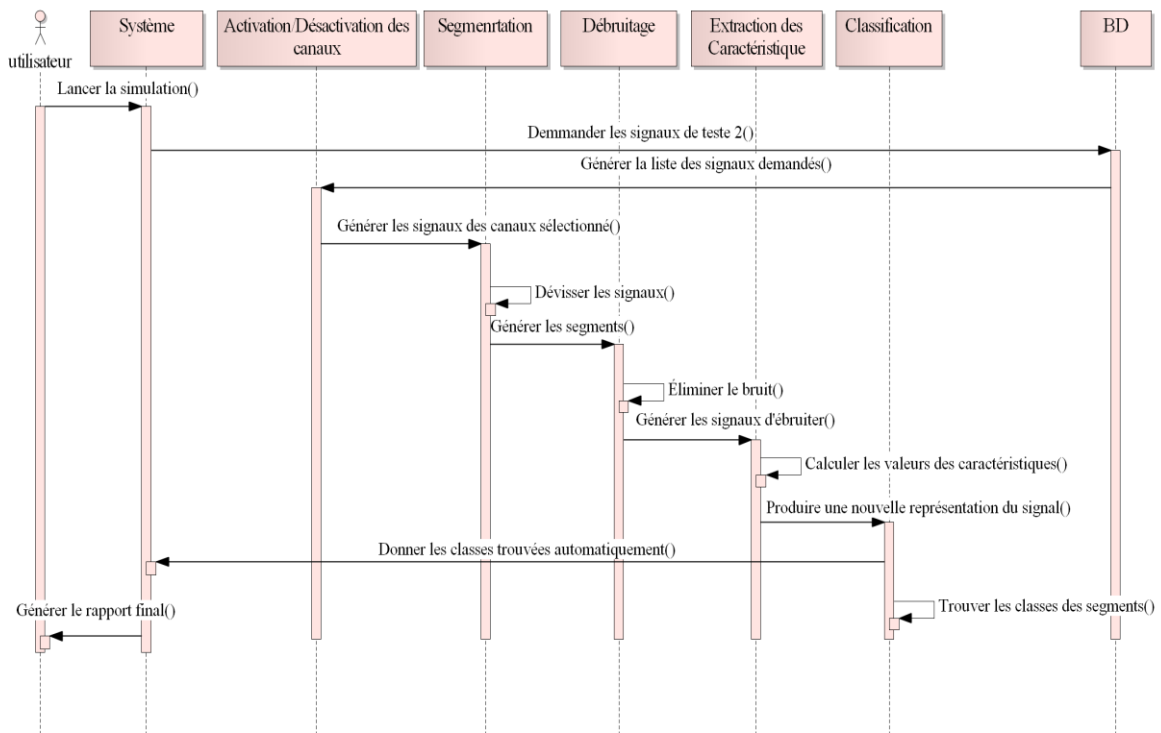


Figure 4.15: Diagramme de séquence « détection automatique des crises épileptiques».

Afin d'évaluer le système proposé, cette étape calcule le vrai positif et le faux négatif pour trouver la sensibilité ainsi que le vrai négatif et le faux positif pour trouver la spécificité.

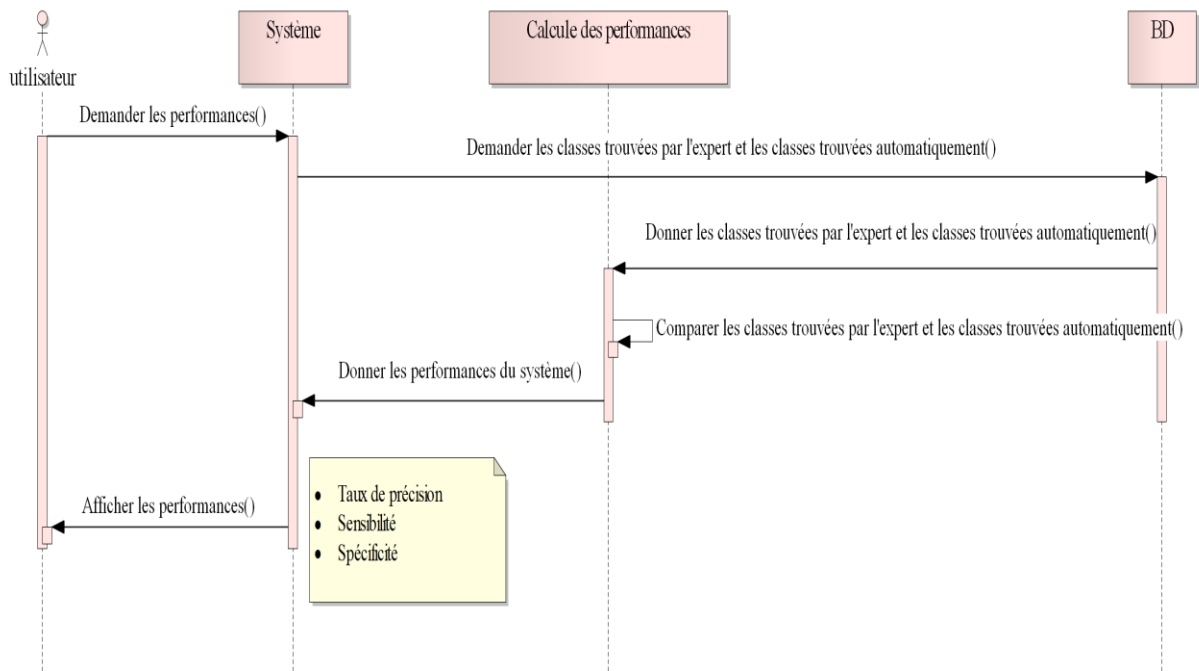


Figure 4.16: Diagramme de séquence « calculer des performances du système».

4.4.5. Le diagramme d'activité

Le diagramme d'activité est un diagramme comportemental d'UML qui permet de représenter des processus en tant qu'une activité composée de plusieurs nœuds connectés. Une activité peut être attachée à n'importe quel élément du modèle (cas d'utilisation, classe, ...) et elle modélise essentiellement un comportement. Les activités sont des réseaux composés de nœuds et de connecteurs. Les connecteurs représentent le flux entre les nœuds.

4.4.5.1. Diagramme d'activité « recherche des paramètres optimaux » :

Ce diagramme illustre le déroulement de la recherche des paramètres optimaux depuis le choix des groupes des signaux jusqu'à l'obtention de la solution.



Figure 4.17: Diagramme d'activité de la recherche des paramètres optimaux.

4.4.5.2. Diagramme d'activité « détection automatique des classes et calcul des performances du système » :

Ce diagramme illustre le déroulement de la détection automatique des classes et du calcul des performances du système depuis la lecture des paramètres optimaux jusqu'à la présentation des résultats.

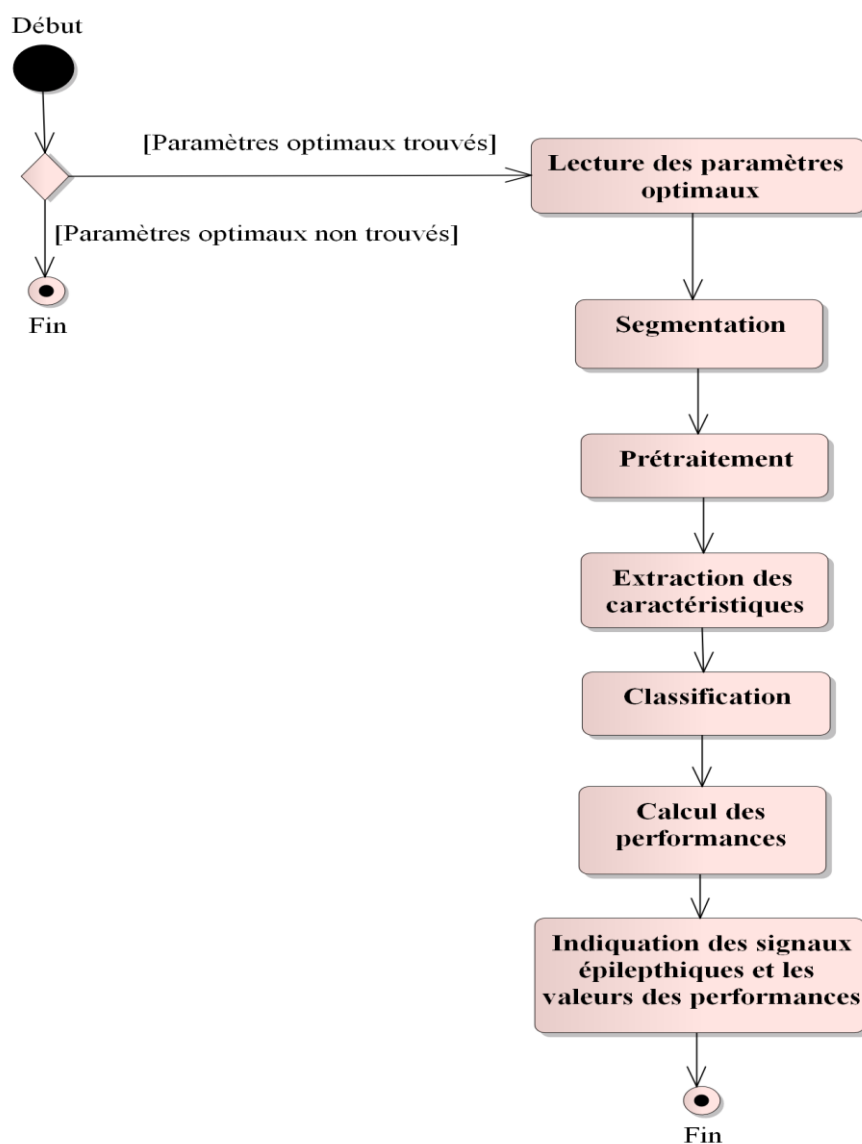


Figure 4.18: Diagramme d'activité de la détection automatique des classes et calcul des performances du système.

4.5. Résultats d'évaluation de la méthode proposée

Afin d'évaluer les performances de notre algorithme, nous l'avons testé en utilisant la base de données CHB-MIT. Pour chaque patient, deux types de fichiers sont nécessaires: les fichiers Edf qui incluent les données EEG stockées et les fichiers Txt qui incluent les annotations indiquant le début et la fin de chaque crise. Les fichiers de données des patients 2, 4, 6, 7, 9 et 10 comprennent certains défauts tels que l'absence de fichier requis, le manque d'informations concernant l'annotation ou la présence de quelques annotations hors limites (hors période d'acquisition). Pour cette raison, ces patients ne sont pas considérés dans la présente étude. Les données d'apprentissage sont composées de 1/3 des segments de crises épileptiques avec son triple des segments d'état normal (sans crise) [Amr2017].

4.5.1. Résultat du processus de tamisage

Après avoir appliqué la fenêtre rectangulaire, l'EMD a été appliqué pour tous les segments trouvés de chaque canal. Le premier, le deuxième et le troisième IMF ont été utilisés pour estimer les caractéristiques. Les IMF restants sont considérés comme non pertinents ne comprenant pas d'informations significatives. Les figures 4.19 et 4.20 présentent 2048 échantillons d'un signal EEG original acquis à partir d'un seul canal, de ses IMF et de son résidu. Il est clair que chaque IMF est situé dans une bande de fréquences supérieure à celle de la suivante. En plus, le résidu est un signal monotone proche du signal constant avec la fréquence la plus basse.




Figure 4.19: Résultats du processus de tamisage de l'IMF1 à l'IMF5 (2048 échantillons).




Figure 4.20: Résultats du processus de tamisage de l'IMF6 au résidu (2048 échantillons).

4.5.2. Comparaison entre l'EMD et l'EEMD

L'EMD et l'EEMD sont appliqués au signal EEG original. La figure 4.21 illustre le résultat du processus de tamisage pour une période de 1 s. Afin d'estimer l'EEMD le nombre d'itération

de l'ajout de bruit est fixée à 100. Aussi, le rapport de l'écart-type du bruit additionné et celui du signal d'origine a été fixé à 0,2.




Figure 4.21 (a)




Figure 4.21 (b)

Figure 4.21: Décomposition du signal d'origine en un ensemble d'IMF et un résidu (a) avec la méthode EMD et (b) avec la méthode EEMD.

Le nombre et les formes des IMF dépendent de la complexité du signal d'origine. Chaque IMF a une fréquence plus élevée que la suivante.

D'après les courbes des IMF, il est clair que les résultats des deux méthodes ont une forte similitude ce qui prouve le succès de la technique du calcul de la moyenne pour éliminer le bruit blanc additif.

La figure 4.22 illustre le spectre de Hilbert-Huang obtenu par l'EMD et l'EEMD.




Figure 4.22 (a)




Figure 4.22 (b)

Figure 4.22: Spectre temps-fréquence: (a) en utilisant l'EMD (b) en utilisant l'EEMD.

Les résultats montrent que l'EEMD rend le spectre du signal plus uniforme et élimine les composants non coordonnés et dispersés.

4.5.3. Optimisation des paramètres du système

Les algorithmes génétiques, initiés dans les années 1970 par John Holland, sont des algorithmes d'optimisation s'appuyant sur des techniques dérivées de la génétique et des mécanismes d'évolution de la nature : sélection, croisement et mutation.

L'Algorithme génétique a été mis en place pour sélectionner la meilleure combinaison de paramètres du système. Les gènes responsables à la sélection des électrodes et des caractéristiques concernées sont autorisés à avoir des valeurs de 0 ou 1 pour indiquer si elles sont utilisées dans le traitement ou non.

Le choix des paramètres de l'algorithme génétique nécessite des connaissances sur la problématique étudiée afin d'assurer une estimation raisonnable en terme de la précision de la solution et du temps de calcul. L'opérateur de mutation consiste à changer la valeur allélique d'un gène avec une probabilité qui doit être très faible, généralement comprise entre 0.01 et 0.001. D'autre part, Le croisement utilisé par les algorithmes génétiques est la transposition informatique du mécanisme qui permet, dans la nature, la production de chromosomes qui héritent partiellement des caractéristiques des parents. Il est généralement admis que les valeurs de la probabilité de croisement comprises entre 0.8 et 0.95 donnent les résultats les plus satisfaisants dans la plus plupart des cas. Après plusieurs tests et évaluations des résultats trouvées avec différentes paramètres d'algorithme génétique, la taille de la population a été fixée à 20 alors que la probabilité de croisement était de 0,8 et la probabilité de mutation était de 0,01. Pour les critères d'arrêt, le nombre maximum de générations a été fixé à 20. D'autre part, les gènes utilisés pour déterminer la valeur de la longueur de la période traitée, le taux de chevauchement (qui représente l'intersection entre deux fenêtres temporelles utilisées pour extraire deux segments successifs) et le nombre de segments pour chaque décision sont autorisés à avoir une valeur entière dans un domaine déterminé. La période des données traitées peut durer entre 4 et 10 secondes, le taux de chevauchement peut prendre une valeur en % de {10, 20 ..., 90} et 1 à 10 segments chevauchés peuvent être utilisés pour une prise de décision. La figure 4. 23 montre le vecteur de paramètres utilisés dans l'AG.

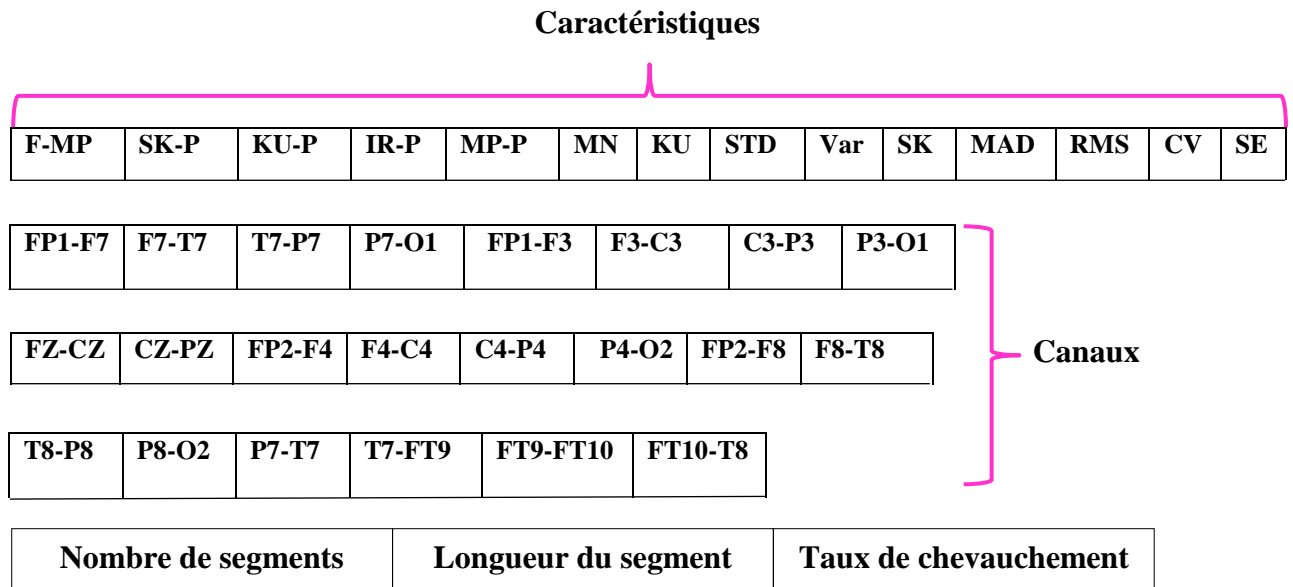


Figure 4.23: *Composition du chromosome.*

Le tableau 4.7 illustre les différentes valeurs de taux de précision du système (en utilisant l'EMD) trouvé pour l'apprentissage en utilisant les meilleures combinaisons de paramètres. Le taux d'exactitude de la classification est calculé en divisant le nombre d'échantillons corrects, où le système a pu détecter correctement s'il y a une crise ou non dans un segment, par le nombre total d'échantillons. Le tableau 4.7 et le tableau 4.8 montrent les valeurs de la longueur de la période, le nombre de segments dans une période, le taux de chevauchement, la combinaison des meilleures caractéristiques et canaux qui ont donné le meilleur taux de précision pour chaque sujet pendant la phase d'apprentissage.

La longueur du segment EEG traité pour extraire les caractéristiques peut influencer leurs valeurs. Ainsi, ce paramètre peut être capital dans l'amélioration de la classification. De même, en cas de segments de crise et de non-crise de degré de similitude élevée un nombre élevé de segments utilisé pour la prise de décision peut améliorer la précision du système. Pour ces raisons, la longueur de la période, le nombre de segments et le taux de chevauchement varient d'un patient à un autre.

Tableau 4.7: Sélection des meilleurs paramètres : Longueur de la période, nombre de segments, le taux de chevauchement, Caractéristiques extraites et canaux (Chb 01-Chb 14) [Amr2017].

Patient	Longueur de la période	Nombre de segments	Taux de chevauchement (%)	Meilleure combinaison de caractéristiques	Meilleure combinaison de canaux	Taux de précision apprentissage (%)
Chb 01	9 s	3	10	F-MP, Ku, Var, MAD, RMS, SE	1, 2, 3, 6, 10, 12, 13, 16, 19, 21, 22, 23	84.72
Chb 03	6 s	3	10	Ku-P, Ku, STD, Sk, MAD, RMS, CV, SE	2, 3, 5, 7, 8, 9, 11, 12, 15, 16, 18, 19, 20, 21, 22, 23	90.19
Chb 05	7 s	1	-	SK-P, MP-P, MN, STD, Var, SK, MAD, CV, SE	1, 2, 4, 5, 12, 14, 15, 16, 17, 19, 23	90.16
Chb 08	8 s	2	20	MN, Var, SK, MAD, CV	3, 4, 6, 7, 8, 9, 10, 11, 14, 15, 16, 17, 18, 19, 20, 22	89.38
Chb 11	7 s	2	20	F-MP, SK-P, IR-P, MN, STD, Var, CV, SE	2, 3, 4, 5, 7, 10, 11, 12, 13, 15, 16, 17, 18, 19, 21, 23	90.22
Chb 12	8 s	3	20	SK-P, MN, KU, Var, MAD	1, 5, 7, 8, 11, 12, 13, 15, 18, 21, 22, 23	82.72
Chb 13	6 s	1	-	F-MP, SK-P, Ku-P, MP-P, STD, Var, SK, MAD, RMS	2, 3, 4, 6, 8, 9, 10, 11, 15, 17, 20, 21, 22, 23	89.72
Chb 14	9 s	2	20	F-MP, SK-P, Ku-P, IR-P, MP-P, STD, SK, MAD, CV, SE	1, 2, 3, 5, 7, 8, 9, 11, 15, 18, 21, 22, 23	81.94

Tableau 4.8: Sélection des meilleurs paramètres : Longueur de la période, nombre de segments, le taux de chevauchement, Caractéristiques extraites et canaux (Chb 15- Chb 23) [Amr2017].

Patient	Longueur de la période	Nombre de segments	Taux de chevauchement (%)	Meilleure combinaison de caractéristiques	Meilleure combinaison de canaux	Taux de précision apprentissage (%)
Chb 15	7 s	1	-	IR-P, MP-P, Ku, STD, Var, RMS, CV	2, 3, 5, 6, 10, 11, 12, 13, 15, 17,18, 21, 22	89.62
Chb 16	8 s	1	-	F-MP, Ku-P, MN, CV, SE	2, 4, 5, 6, 7, 8, 9, 12, 13, 14, 15, 17, 21, 23	86.88
Chb 17	8 s	3	10	SK-P, Ku-P, IR-P, MP-P, MN, RMS, CV, SE	4, 5, 6, 7, 8, 10, 11, 13, 14, 17, 18, 19, 20, 22, 23	82.72
Chb 18	7 s	3	20	Ku-P, MP-P, STD, Var, SK, RMS	1, 2, 5, 6, 7, 8, 10, 11, 18, 19, 20, 22, 23	88.52
Chb 19	7 s	2	20	Sk-P, MP-P, Ku, STD, Var, SE	1, 6, 8, 9, 11, 13, 18, 19, 20, 1, 6, 8, 9, 11, 13, 18, 19, 20,21, 23	89.07
Chb 20	6 s	3	10	F-MP, Ku, Var, MAD, RMS, SE	3, 5, 7, 8, 9, 10, 11, 12, 15, 20, 22	89.25
Chb 21	9 s	3	20	Ku-P, Ku, STD, SK, MAD, RMS, CV, SE	2, 5, 8, 9, 10, 12, 14, 17, 19, 21, 22, 23	83.33
Chb 22	7 s	1	-	SK-P, MP-P, MN, STD, Var, SK, MAD, CV, SE	1, 8, 11, 16, 19, 20	88.52
Chb 23	8 s	2	10	MN, Var, SK, MAD, CV	7, 8, 9, 10, 11, 14, 15, 16, 17, 18, 19, 22, 23	92.50

Les résultats trouvés montrent l'importance de l'étape de sélection des paramètres pour obtenir les meilleures performances. Il existe une grande différence entre la meilleure combinaison de paramètres de chaque sujet ce qui clarifie l'importance de considérer la distinction de chaque patient. En effet, les canaux EEG choisis comme impliqués dans la génération des crises épileptiques diffèrent d'un patient à un autre. Ceci est attendu puisque les zones corticales liées à ces crises varient en fonction du type de l'épilepsie. De même, les caractéristiques qui décrivent l'allure et les propriétés des segments EEG épileptiques varient d'un patient à un autre suivant le type de l'épilepsie. Si le bloc d'adaptation de paramètres proposé est non utilisé, plusieurs zones corticales et caractéristiques non pertinentes seront utilisées. Ceci affaiblira les performances du système par l'ajout des données redondantes ou liées à d'autres phénomènes neurophysiologiques qui vont dégrader la capacité du classifieur à séparer entre les deux classes.

Afin de comparer la contribution de l'EMD et de l'EEMD dans le système nous avons répété l'expérience précédente en utilisant l'EEMD. La valeur moyenne du taux de précision trouvée pour tous les patients est de 83,23% avec l'EEMD face à 87,6% avec l'EMD. Les résultats montrent que, comme prévu, le taux de précision est amélioré en introduisant l'AG dans le système. Cependant, l'utilisation de l'EEMD réduit les performances du système. En effet, le processus de décomposition est répété plusieurs fois avec différents segments de bruit avant le calcul de la moyenne. Par conséquent, cette méthode est plus lente que l'EMD ce qui peut créer un problème dans la conception d'une application en temps réel. En plus, l'EEMD résout en partie uniquement le problème de mélange de mode mais le signal d'origine ne peut pas être reconstruit exactement. Ainsi, les fonctions créées peuvent être une représentation d'un signal modifié. De même, le choix de l'amplitude du bruit ajouté peut fausser la décomposition si cette valeur n'est pas appropriée pour le signal recherché. Enfin, le bruit inclus dans le signal d'origine peut interagir avec le bruit ajouté et complique le problème de mélange de mode. Tous ces inconvénients expliquent l'incapacité de l'EEMD à améliorer les performances du système.

4.5.4. Etude de la complexité de la méthode proposée

Avec le développement continu des nouvelles technologies de calcul avancées comme les architectures multiprocesseurs, les multithreads et les GPU (Graphical Processing Unit) des nouvelles opportunités de développer des méthodes et des algorithmes plus complexes se présentent. Ainsi, tous les domaines ont connu une expansion et surtout ceux qui sont liés aux

industries de santé qui est l'un des secteurs les plus innovants qui ont un chiffre d'affaires particulièrement élevé. Par conséquent les chercheurs en ingénierie biomédicale ne se limitent plus par les ressources de mémoire et de calcul disponibles mais se concentre sur l'amélioration des performances de ses systèmes.

Le tableau 4.9 représente une étude sur la complexité du système et le besoin en ressources de calcul en fonction du temps de calcul nécessaire pour l'adaptation des paramètres de tous les patients.

Tableau 4.9: Temps de calcul nécessaire pour l'adaptation des paramètres de tous les patients.

Patient	Temps de calcul en minutes	Patient	Temps de calcul en minutes
Chb 01	348	Chb16	362
Chb 03	298	Chb17	214
Chb 05	312	Chb18	368
Chb 08	235	Chb19	395
Chb 11	398	Chb20	344
Chb12	211	Chb21	259
Chb13	325	Chb22	278
Chb14	298	Chb23	325
Chb15	302		

Le système était conçu à l'aide du logiciel MATLAB version 2016 et testé sur une station de travail qui possède 2 processeurs Xeon E5-2630 v4 de 10 Cœurs chacun. L'utilisation du multithreads permet d'utiliser toutes les ressources de calcul disponibles dans la machine.

Les résultats trouvés semblent être satisfaisants par rapport au temps précieux du médecin qui peut être sauvé. En plus, des machines plus sophistiquées peuvent améliorer les résultats.

4.5.5. Evaluation de la méthode proposée

La sensibilité et la spécificité sont les paramètres les plus utilisés dans l'évaluation des systèmes automatisés de détection des crises [Bos2016]. Ces deux quantités reflètent le degré de précision du diagnostic d'épilepsie.

La sensibilité est donnée par l'équation (4.14).

$$SEN = TP/P = TP/(TP + FN) \quad (4.14)$$

Où:

- TP est le vrai positif ou le nombre de segments pendant l'épilepsie qui sont détectés comme des périodes de crise;
- FN est le faux négatif ou le nombre de segments pendant l'épilepsie qui sont détectés comme des périodes normales (sans crise).

La sensibilité qui est également appelée le vrai taux positif nous indique à quel point un test positif détecte la crise.

La spécificité est donnée par l'équation (4.15).

$$SPC = TN/N = TN/(TN + FP) \quad (4.15)$$

Où:

- TN est le vrai négatif ou le nombre de segments dans une situation normale qui sont détectées comme sans crise;
- FP est le faux positif ou le nombre de segments dans une situation normale détectée comme crise.

La spécificité qui est aussi appelée le vrai taux négatif nous indique à quel point un test négatif détecte la situation normale (sans crise).

Le tableau 4.10 illustre les performances du système proposé trouvées pour les participants étudiés.

Tableau 4.10: Performances du système proposé [Amr2017].

Patient	SEN	SPC	Patient	SEN	SPC
Chb 01	75.5	100	Chb 16	34.8	100
Chb 03	100	100	Chb 17	100	100
Chb 05	100	100	Chb 18	100	100
Chb 08	100	100	Chb 19	100	99.5
Chb 11	100	100	Chb 20	100	100
Chb 12	100	100	Chb 21	90	100
Chb 13	100	100	Chb 22	99	100
Chb 14	89.8	100	Chb 23	100	100
Chb 15	100	100	Mean	93.4	99.9

La haute sensibilité garantit que le système manquera la détection que d'un très petit nombre de segments de crises ce qui n'affectera pas les résultats du diagnostic du médecin. D'autre part, dans certains cas, la valeur de spécificité est légèrement inférieure à la valeur parfaite (100%), ce qui signifie que certains segments normaux seront reconnus comme représentant la crise. Lorsque le médecin examine les segments sélectionnés, il les reclassera dans le bon groupe. L'examen du médecin conduira à exclure toutes les défaillances et à conclure les mêmes résultats que ceux constatés avec une inspection visuelle de l'ensemble des données.

Le tableau 4.11 présente une comparaison entre les résultats de la méthode proposée et les résultats de certaines méthodes proposées dans la littérature par d'autres groupes de recherche utilisant la même base de données.

Tableau 4. 11: Évaluation des méthodes [Amr2017].

Auteurs	SEN	SPC
[Ors2016]	87,5	99,9
[Kia2014]	89	93
[Kos2015]	90	-
[Fer2015]	93	94
Approche proposée	93,4	99,9

Il est clair que la sensibilité et la spécificité trouvées atteignent des valeurs supérieures à la majorité des travaux. Ces résultats prouvent l'efficacité de la méthode proposée.

Afin d'obtenir les meilleures performances possibles de l'ensemble du système, les caractéristiques les plus représentatifs des différentes classes devraient être extraites du signal EEG. Cette étape permet d'éliminer la redondance et d'obtenir les informations les plus utiles pour une meilleure classification. D'autre part, chaque classifieur suit une stratégie spécifique pour créer des limites entre les classes appelées également surface de décision. Ainsi, chaque classifieur doit être alimenté avec les caractéristiques appropriées. Il existe encore d'autres obstacles qui empêchent les systèmes d'atteindre des hautes performances. En fait, la forme des signaux EEG recherchés et leurs propriétés ainsi que les canaux impliqués changent d'un sujet à l'autre. Ainsi, la précision du système sera affectée de manière significative si la

variabilité des signaux EEG entre les patients pour les états normaux et les états de crise ne sera pas prise en compte. Pour surpasser ces restrictions, plusieurs méthodes de traitement du signal ont été proposées. Par exemple, E. Kabiret al. [Kab2016] et M. Mera-Gaona et al. [Mer2016] ont utilisé une technique de sélection des caractéristiques pour éliminer les caractéristiques responsables de la détérioration du système, ce qui a considérablement amélioré la précision. P. Fergus et al. [Fer2015] ont divisé les électrodes en cinq régions du cuir chevelu et ont sélectionné la meilleure combinaison de caractéristiques pour chaque région séparément. Dans la présente étude, la meilleure combinaison de caractéristiques, de canaux et tous les paramètres du système ont été estimés pour chaque sujet, ce qui rend le système plus spécifique au patient. L'adaptation automatique des paramètres permet de déterminer quels canaux peuvent produire la meilleure combinaison de caractéristiques selon le classificateur et les paramètres choisis. La haute dépendance au patient rend le nouveau système proposé hautement efficace et adaptatif et lui permet de surpasser plusieurs méthodes de la littérature.

Ainsi, la méthode spécifique au patient proposée tire ses avantages de toutes les techniques et les méthodes qu'elle inclut afin de s'ajuster le maximum aux propriétés des signaux de chaque patient. En effet, nous avons choisi d'utiliser l'EMD à la place de la transformée en ondelettes pour travailler en sous bandes avec la possibilité de séparer les composantes du bruit du reste du signal. L'EMD rend notre méthode plus adaptative, plus générique et aussi plus adaptée aux signaux non-stationnaires générés par les systèmes non-linéaires. Ceci est dû au fait que l'EMD ne nécessite aucune information préalable sur le signal traité et peut s'adapter automatiquement au signal sans avoir besoin de spécifier des paramètres antérieurs comme le type de l'ondelette mère. De même, l'utilisation de 14 caractéristiques différentes dans les domaines temporel et fréquentiel pour chaque IMF offre plus de possibilité de décrire toutes les particularités du phénomène neurophysiologique traité (épilepsie). Ce qui offre plus d'opportunité de distinguer entre les deux classes. Aussi, afin de consolider notre méthode proposée, nous avons utilisé l'algorithme génétique pour trouver les meilleurs paramètres du système pour chaque patient. L'inspection de tous les paramètres possibles liés à l'étape de segmentation et à l'étape d'extraction des caractéristiques rend le système proposé entièrement auto-adaptatif à ses paramètres et garantit de meilleures performances que les méthodes de la littérature. L'algorithme génétique garantit aussi que le système trouvera la meilleure combinaison des paramètres sans rester coincer dans une solution locale.

4.6. Conclusion

Les systèmes de détection des crises épileptique spécifiques aux patients sont le meilleur choix pour détecter la crise avec des performances optimales. Dans ce chapitre, une nouvelle méthode de reconnaissance des segments de crise spécifique au patient avec sélection automatique des paramètres optimaux est présentée. La variété de caractéristiques utilisées offre un large choix pour sélectionner les plus pertinentes selon chaque patient. L'analyse discriminante linéaire qui montre de bonnes performances dans la littérature, a été utilisée pour l'étape de classification. En plus, l'algorithme génétique a été utilisé pour sélectionner de manière adaptative les canaux et les caractéristiques appropriés et pour optimiser les paramètres de l'étape de segmentation. Les résultats expérimentaux montrent que les caractéristiques extraites avec la méthode proposée forment une bonne représentation des signaux d'EEG des deux classes (état normal et crise) et permettent d'atteindre de hauts taux de sensibilité et de spécificité. Le système a été capable de détecter les crises épileptiques dans les enregistrements EEG de la base de données CHB-MIT avec une sensibilité moyenne de 93,4%. Cette valeur est meilleure que celle obtenue par les travaux de la littérature qui se situent généralement entre 87% et 93%.

Conclusion et perspective

Conclusion et perspectives

Le premier souci dans le domaine de détection automatique des crises épileptiques est de concevoir des systèmes capables de prédire l'existence des crises épileptiques et de concourir les résultats trouvés par une inspection visuelle du neurologue. De ce fait, le premier objectif des chercheurs dans ce domaine devient l'amélioration du taux de sensibilité du système.

Dans ce sujet de thèse, nous nous sommes intéressés à développer une méthode de traitement du signal EEG capable d'améliorer les performances des systèmes présentes dans la littérature.

Dans ce travail, nous avons présenté dans un premier temps les différentes connaissances nécessaires pour comprendre le fonctionnement de ce type de systèmes. Ainsi, nous avons exposé des informations pertinentes liées à la neurophysiologie, aux techniques de détection et de mesure des activités cérébrales et à la structure générale d'un tel système.

Dans une deuxième étape, nous avons présenté la maladie de l'épilepsie en expliquant les différents aspects nécessaires pour comprendre cette thématique.

Nous avons ensuite donné un état de l'art sur les méthodes de traitement du signal les plus efficaces et les plus utilisées. La méthode de détection des crises basée sur la transformée en ondelettes est considérée comme l'une des méthodes les plus puissante par sa capacité de créer des caractéristiques faciles à discriminer qui respectent les propriétés temporelles et fréquentielles du signal EEG. L'implémentation de cette méthode et le test avec des données EEG réelles permet de mieux comprendre les différents blocs du système et d'examiner leurs effets sur les performances globales du système.

S'inspirant des méthodes spécifiques au patient, et tenant compte des caractéristiques de non-linéarité et de non-stationnarité du signal EEG, nous avons proposé une nouvelle méthode pour la reconnaissance des crises épileptiques. L'étape de prétraitement consiste à décomposer le signal original en plusieurs IMF à l'aide de l'EMD puis à utiliser seulement les IMF qui incluent des informations pertinentes. Le reste des IMF seront éliminées. Cette technique de filtrage permet de réduire le niveau de bruit et d'artefacts en concevant le maximum d'information nécessaire à la phase suivante. 14 caractéristiques différentes sont ensuite extraites du nouveau signal créé à partir des IMF restantes. Ce nombre important de

caractéristiques garantit la meilleure quantification de toutes les propriétés du signal. Pour la phase de classification nous avons utilisé l'analyse discriminante linéaire qui a donné des résultats prometteurs dans la littérature. Le dernier bloc consiste à sélectionner les meilleurs paramètres du système suivant chaque patient à l'aide de l'algorithme génétique. Finalement, nous avons testé ce système avec des données EEG réelles de la base CHB-MIT. Cette approche a prouvé son efficacité par rapport aux méthodes de la littérature.

En perspectives nous envisageons de mener des recherches pour :

- L'amélioration de la méthode proposée par l'utilisation d'une méthode plus efficace pour le choix des paramètres du système les plus adéquates.
- L'amélioration de la résolution spatiale par l'utilisation du problème inverse pour une meilleure localisation de la zone corticale responsable de la génération du phénomène neurophysiologique recherché.
- La résolution du problème de mélange de mode de l'EMD pour une meilleure séparation entre les composantes du signal pertinentes et le reste du signal.

Références

Références

- [Ada2000] A. Adam, A. Arzimanoglou, M. Baulac, B. Bendriem, A. Biraben, C. Chiron, S. Dupont, E. Hirsch, C. Marescaux, F. Semah et L. Martin, "Epilepsies : de la clinique aux examens complémentaires", *Tome 2, Expressions Santé Éditions*, Paris, France, pp. 105-106, (2000).
- [Ade2003] H. Adeli, Z. Zhou, N. Dadmehr, "Analysis of EEG records in an epileptic patient using wavelet transform", *Journal of Neuroscience Methods*, Vol. 123, No. 1, pp. 69-87, (2003).
- [Aga2001] R. Agarwal et J. Gotman, "Long-term EEG compression for intensive-care settings", *IEEE Engineering in Medicine and Biology Magazine* , Vol. 20, No. 5, pp. 23-29, (2001).
- [Alb2016] D. Alban, "Interface cerveau-machine hybride pour pallier le handicap causé par la myopathie de Duchenne", *Thèse de Doctorat de l'Université de Lille 1 - Sciences et Technologies*, Lille, France, (2016).
- [Alo2012] L. N. Alonso et J.G. Gil, "Brain Computer Interfaces, a Review", *Sensors- Open Access Journal*, Vol. 12, pp. 1211-1279, (2012)
- [Amm2016] S. Ammar et M. Senouci, "Seizure detection with single-channel EEG using Extreme Learning Machine", *17th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA)*, Sousse, Tunis pp. 4 , (19-21 Decembre 2016).
- [Amr2017] S. Ammar, O. Trigui et M. Senouci, "Automated Patient-Specific seizure detection system with Self-Parameters adaptation", *Control and Intelligent Systems*, Vol. 45, No. 11, pp. 29-39, (2017).
- [Art2012] X. Artusi, "Interface Cerveau Machine avec adaptation automatique à l'utilisateur", *Thèse de Doctorat de l'École Centrale de Nantes*, Nantes, France (2012).
- [Aze2009] F. A. Azevedo, L. R. Carvalho, L. T. Grinberg, J. M. Farfel, R. E. Ferretti, R. E. Leite, W. Jacob Filho, R. Lent et S. Herculano-Houzel, "Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up

- primate brain", *journal of comparative neurology*, Vol. 513, No. 5, pp. 532-541, (2009).
- [Bai1999] S. Baillet, L. Garnero, G. Marin et J.P. Hugonin, "Combined MEG and EEG source imaging by minimization of Mutual Information", *IEEE Transactions on Biomedical Engineering*, Vol. 46, pp. 522-534, (1999).
- [Ban1973] J. Bancaud, J. Talairach, S. Geier et J. Scarabin, "EEG et SEEG dans les tumeurs cérébrales et l'épilepsie", *Paris : Edifor*, (1973).
- [Bar2012] A. Barachant, "Commande robuste d'un vecteur par une interface cerveau-machine EEG asynchrone", *Thèse de Doctorat de l'Université Grenoble Alpes*, Grenoble, France, (2012).
- [Bat2011] S. Batata, M.A. Mostefai, "Cours igl : Cours 5 analyse", (2011).
- [Ben2014] A. Ben Sghier, "Les Epilepsies Pharmacoresistantes (A propos de 25 cas)", *Thèse de Doctorat en Médecine, Université de Sidi Mohamed Ben Abdellah*, Fes, Maroc (2014).
- [Ber1929] H. Berger, "Über das Electroencephalogram des Menschen", *Archives of Psychiatry*, pp. 527-570, (1929).
- [Beg2010] A.T. Berg, S. F. Berkovic, M. J. Brodie, J. Buchhalter, J. H. Croix, W. van Emde Boas, J. Engel, T. A. Glauser, G. W. Mathern, S. L. Moshé, D. Nordli et P. Plouin, "Nouvelle terminologie et des concepts pour l'organisation des saisies et des épilepsies: rapport de la Commission sur la LICE classification et la terminologie, 2005-2009", *Epilepsia*, Vol. 51, No. 4, pp. 676-85, (2010).
- [Bes2007] M. Besserve, "Analyse de la dynamique neuronale pour les Interfaces Cerveau-Machines : un retour aux sources", *Thèse de Doctorat de l'Ecole Doctorale Sciences et Technologies de l'Information, des Télécommunications et des Systèmes*, Faculté des sciences d'Orsay, Université PARIS- SUD 11, Paris, France, (2007).
- [Bi2013] L. Bi, X. A. Fan et Y. Liu, "EEG-Based Brain-Controlled Mobile Robots: A Survey", *IEEE Transactions On Human-Machine Systems*, Vol. 43, No. 2, pp. 161-176, (2013).

- [Bio2005] B. Bioulac, P. Burbaud, J. R. Cazalets et C. Gross, "Fonctions motrices", *EMC-Kinésithérapie*, Vol. 1, No. 4, pp. 183–233, (2005).
- [Bof2004] A. Bofill-i Petit et A.F. Murray, "Synchrony detection and amplification by silicon neurons with STDP synapses", *Transactions Neural Networks*, Vol. 15, No. 5, pp. 1296-1304, (2004).
- [Bos2016] R. Bose, A. Khasnobish, S. Bhaduri et D. N. Tibarewala, "Performance Analysis of Left and Right Lower Limb Movement Classification from EEG", 3rd *International Conference on Signal Processing and Integrated Networks (SPIN)*, Noida, India, pp. 174–179, (2016).
- [Bra1968] M. Brazier, "Studies of the EEG activity of limbic structures in man", *Electroencephalography and Clinical Neurophysiology*, Vol. 25, No. 4, pp. 309–318, (1968).
- [Cha2007] A. Chakir, "Intervalle thérapeutique et pharmacorésistance dans l'épilepsie temporale: étude clinique, expérimentale dans un modèle animal", *Thèse de Doctorat de l'Université mohammed V– Agdal*, faculté des sciences Rabat, Rabat, Maroc, (2007).
- [Che2010] K. H. Cheng et S. YNien, "Detection of seizures in EEG using subband nonlinear parameters and genetic algorithm", *Computers in Biology and Medicine*, Vol. 40, No. 10, pp. 823-830, (2010).
- [Cho2012] A. Choucha, A. Hellal, L. Mokrani et S. Arif, "New Approach to the Optimization of Power System Stabilizers: Genetic Algorithm with Dynamic Constraints", *Control and Intelligent Systems*, Vol. 40, No. 3, pp. 129-143, (2012).
- [Cor2007] A. G. Correa, E. Laciari, H. D. Patiño et M. E. Valentinuzzi, "Artifact removal from EEG signals using adaptive filters in cascade", *16th Argentine Bioengineering Congress and the 5th Conference of Clinical Engineering*, pp. 1-10, (Decembre 2007).
- [Coe2008] A. G. Correa, E. Laciari, H. D. Patiño et M. E. Valentinuzzi, "An Automatic Sleep-Stage Classifier Using Electroencephalographic Signals", *International journal of Medical Science and technology*, Vol. 1, No. 1, pp. 13-21, (2008).

Références

- [Cos2009] N. Corson, "Dynamique d'un modèle neuronal, synchronisation et complexité. Mathématiques", *Thèse de Doctorat de l'Université du Havre*, Havre, France, (2009).
- [Coa2011] R. Corralejo, R. Hornero et D. Álvarez, "Feature Selection using a Genetic Algorithm in a Motor Imagery based Brain Computer Interface", *International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS Boston, Massachusetts, USA*, pp. 7703-7706, (30 Aout- 3 Septembre 2011).
- [Cul1943] W. McCulloch et W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *Bulletin of Mathematical Biophysics*, Vol. 5, pp. 115-133, (1943).
- [Dav2017] S. David, "Adapting Brain Signals With Reinforcement Learning Strategies for Brain Computer Interfaces", *Master-Thesis aus Offenbach am Main, Technische Universitat Darmstadt*, Darmstadt, Allemagne, (2017).
- [Deu2002] G. Deuschl et A. Eisen, "Guide pratique de neurophysiologie clinique : Recommandations de la Fédération Internationale de Neurophysiologie Clinique", *Elsevier- Masson*, (2002).
- [Die1998] J. Dien, "Issues in the application of the average reference: review, critiques and recommendations ", *Behavior Research Methods, Instruments, & Computers*, Vol. 30, No. 1, pp. 34–43, (1998).
- [Dur2003] P.J. Durka, H. Klekowicz, K.J. Blinowska, W. Szelenberger et SZ. Niemcewicz, "A simple system for detection of EEG artifacts in polysomnographic recordings", *IEEE Transactions on Biomedical engineering*, Vol. 50, No. 4, pp. 526-528, (2003).
- [Eib1998] A.E. Eiben, J.E. Smith, " Introduction to Evolutionary Computing", *Natural Computing Series*, pp.40-52, (1998).
- [Eng1998] J. Engel, "Research on the human brain in an epilepsy surgery setting", *Epilepsy Research*, Vol. 32, No. 1-2, pp. 1-11, (1998).
- [Erk1998] S. J. Erkelens et P. M. T. Broersen, "LPC Interpolation by Approximation of the Sample Autocorrelation Function", *IEEE Transactions on Speech and Audio*

Processing, Vol. 6, No. 6, pp. 569-573, (1998).

- [Eul2015] I. Euloge, "Epilepsie de l'enfant au Gabon : Aspects socioculturels et thérapeutiques", *Thèse de Doctorat de l'Université de Limoges*, Limoges, France, (2015).
- [Fel2007] E.A. Felton, J.A. Wilson, J.C. Williams et P.C. Garell, "Electrocorticographically controlled brain-computer interfaces using motor and sensory imagery in patients with temporary subdural electrode implants", *Journal of Neurosurgery*, Vol. 106, No. 3, pp. 495-500, (2007).
- [Fer2015] P. Fergus, D. Hignett, A. Hussain, D. Al-Jumeily et K. Abdel-Aziz, "Automatic Epileptic Seizure Detection Using Scalp EEG and Advanced Artificial Intelligence Techniques", *BioMed Research International*, Vol. 2015, pp.17, (2015).
- [Ffr2009] Ffre, "Fondation française pour la recherche sur l'épilepsie", (2009).
- [Fis1999] B. Fisch, "Fisch and Spehlmann's EEG Primer: Basic principles of digital and analog EEG", *Elsevier publication*, (1999).
- [Fih2005] R.S. Fisher , W. van Emde Boas, W. Blume, C. Elger, P. Genton, P. Lee et al. "Epileptic seizures and epilepsy: definitions proposed by the International League Against Epilepsy (ILAE) and the International Bureau for Epilepsy (IBE) ", *Epilepsia*, Vol. 46, No. 4, pp. 470-472, (2005).
- [Fie2014] R. S. Fisher, C. Acevedo, A. Arzimanoglou, A. Bogacz, J.H. Cross, C.E. Elger et al, "ILAE official report: a practical clinical definition of epilepsy", *Epilepsia* Vol. 55, No. 4, pp. 475-482, (2014).
- [Fla2003] P. Flandrin et P. Gonçalves, "Sur la décomposition modale empirique", *Proceedings of the 19th Colloquium GRETSI*, Groupe d'Etudes du Traitement du Signal et des Images (GRETSI), Paris, France, pp. 1-4, (2003).
- [Fln2004] P. Flandrin, G. Rilling et P. Gonçalves, "Empirical Mode Decomposition as a Filter Bank", *IEEE Signal Processing Letters*, Vol. 11, No. 2, pp. 112-114, (2004).

- [Gal2008] F. Galán, M. Nuttin, E. Lew, P.W. Ferrez, G. Vanacker, J. Philips J. del et R. Millán, "A brain-actuated wheelchair: Asynchronous and non-invasive Brain-computer interfaces for continuous control of robots", *Clinical Neurophysiology*, Elsevier, Ireland, Vol. 119, No. 9, pp. 2159-2169, (2008).
- [Gho2008] S. Ghosh-Dastidar, H. Adeli et N. Dadmehr, "Principal component analysis enhanced cosine radial basis function neural network for robust epilepsy and seizure detection", *IEEE Transactions on Biomedical Engineering*, Vol. 55, No. 2, pp. 512-518, (2008).
- [Gol1950] D. Goldman, "The clinical use of the "average" reference electrode in monopolar recording", *Electroencephalography and Clinical Neurophysiology*, Vol. 2, No. 1-4, pp. 209-212, (1950).
- [Got1982] J. Gotman, "Automatic recognition of epileptic seizures in the EEG", *Electroencephalography and Clinical Neurophysiology*, Vol. 54, No. 5, pp. 530-540, (1982).
- [Gom1990] J. Gotman, "Automatic seizure detection: improvements and evaluation", *Electroencephalography and clinical Neurophysiology*, Vol. 76, No. 4, pp. 317-324, (1990).
- [Goa1993] J. Gotman et H. Qu, "Improvement in seizure detection performance by automatic adaptation to the EEG of each patient", *Electroencephalography and clinical Neurophysiology*, Vol. 86, No. 2, pp. 79- 87, (1993).
- [Gon1999] J. Gotman, "Automatic Detection of Seizures and Spikes", *Journal of Clinical Neurophysiology*, Vol. 16, No. 2, pp.130-140, (1999).
- [Gra2002] F. J. Gray, "Anatomy for the medical clinician", *first edition*, Shannon Books Pty Ltd, Victoria, Australia, (2002).
- [Grn2012] R. Grandchamp, "Electroencéphalographie et Interfaces Cerveau-Machine : nouvelles méthodes pour étudier les états mentaux", *Thèse de Doctorat de l'Université Paul Sabatier - Toulouse III*, Toulouse, France, (2012).
- [Has2008] T. Hastie, R. Tibshirani et J. Friedman, "The Elements of Statistical Learning:

- Data Mining, Inference, and Prediction", *Second Edition, Springer Series in Statistics*, (2008).
- [Hen2015] S. Hennion, "Neuropsychologie et neuroimagerie des troubles de cognition sociale dans l'épilepsie du lobe temporal", *Thèse de Doctorat de l'Université du Droit et de la Santé Lille II*, Lille, France, (2015).
- [Hjo1975] B. Hjorth, "An on-line transformation of EEG scalp potentials into orthogonal source derivations", *Electroencephalography and Clinical Neurophysiology*, Vol. 39, No. 5, pp. 526-530, (1975).
- [Hof2013] J. Hofmanis, "Contribution to the cerebral forward model by depth electric stimulation and SEEG measurements : application in epilepsy", *Thèse de Doctorat de l'Ecole doctorale IAEM Lorraine, l'Université de Lorraine*, Lorraine, France, (2013).
- [Hop1982] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities", *Proceeding of the National Academy of the United States of America*, Vol. 79, No. 8, pp. 2554–2558, (1982).
- [Hou2013] D. Houinato, L.P. Yemadje, G. Glitho, C. Adjien, F. Guédou, P.M. Preux, D.G. Avode, M. Druet-cabanac, "Epidemiology of epilepsy in rural Benin: Prevalence, incidence, mortality, and follow-up", *Epilepsia*, Vol. 54, No. 4, pp. 757-763, (2013).
- [Hon2014] H. C. Hounsossou, "Insertion professionnelle et maintien dans l'emploi des patients souffrant d'épilepsie au Bénin", *Thèse de Doctorat de l'Université de Limoges et d'abomey-calavi*, France et Bènin, (2014).
- [Hu2007] S. Hu, M. Stead et G. Worrel, "Automatic identification and removal of scalp reference signal for intracranial EEGs based on Independent Component Analysis", *IEEE Transactions on Biomedical Engineering*, Vol. 54, No. 9, pp. 1560– 1572, (2007).
- [Hua1998] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung et H. H. Liu, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis", *Proceedings of the*

Royal Society A, Vol. 454, No. 1971, pp. 903-993, (1998).

- [Hun2004] G. B. Huang, Q. Yu Zhu et S. Chee-Kheong, "Extreme learning machine: a new learning scheme of feedforward neural networks", *International Joint Conference on Neural Networks*, Budapest, Hungary, Vol. 2, No. 25-29, pp. 985-990, (2004).
- [Hug2005] N. E. Huang et S. S. P. Shen, "Hilbert-Huang Transform and Its Applications", *Interdisciplinary Mathematical Sciences*, Volume 5, pp.2-14, (2005).
- [Han2010] G.B. Huang, X. Ding, et H. Zhou, "Optimization method based extreme learning machine for classification", *Neurocomputing*, Vol. 74, No. 1-3, pp. 155-163, (2010).
- [Hui1999] J.Huggins, S.P. Levine, S.L. BeMent, R.K. Kushwaha, L.A. Schuh, E.A. Passaro, M.M. Rohde, D.A. Ross, K.V. Elisevich et B.J. Smith, "Detection of EventRelated Potentials for Development of a Direct Brain Interface", *Journal of Clinical Neurophysiology*, Vol. 16, No. 5, pp. 448-455, (1999).
- [Ita2016] M. Itamar, C. Abigail, C. Dan, D. Tarun, N. Arindam, et L. Ramanan, "Health and economic benefits of public financing of epilepsy treatment in India : An agent-based simulation model", *Epilepsia*, Vol. 57, No. 3, pp. 464-474, (2016).
- [Iza2015] R. Izabela, "Genetic Algorithms for Feature Selection for Brain–Computer Interface", *International Journal of Pattern Recognition and Artificial Intelligence*, Vol. 29, No. 5, pp. 1-27 , (2015).
- [Jet2015] N. Jette, E. Beghi, D. Hesdorffer, S.L. Moshé, S. M. Zuberi, M.T. Medina et D. Bergen, "ICD coding for epilepsy: Past, present, and future—A report by the International League Against Epilepsy Task Force on ICD codes in epilepsy", *Epilepsia*, Vol. 56, No. 3, pp. 348-355, (2015).
- [Jih2014] J. Yan et L. Lu, "Improved Hilbert–Huang transform based weak signal detection methodology and its application on incipient fault diagnosis and ECG signal analysis", *Signal Processing*, Vol. 98, pp.74-87, (2014).
- [Jin2009] K. Jinkwon, S. Hang, S. Kwangsoo et L. Myoungho, "Robust algorithm for arrhythmia classification in ECG using extreme learning machine", *BioMedical*

- Engineering Online*, Vol. 8, No. 31, pp. 8–31, (2009).
- [Kab2016] E. Kabir, Siuly et Y. Zhang, "Epileptic seizure detection from EEG signals using logistic model trees", *Brain Informatics*, Vol. 3, No. 2, pp. 93-100, (2016).
- [Kha2012] Y. U. Khan, N. Rafiuddin et O. Farooq, " Automated seizure detection in scalp EEG using multiple wavelet scales", *IEEE International Conference on Signal Processing, Computing and Control*, Wahnaghat Solan, India, pp.5, (15-17 Mars 2012).
- [Khn2012] Y. U. Khan, O. Farooq et P. Sharma, "Automatic Detection of Seizure Onset in Pediatric EEG", *International Journal of Embedded Systems and Applications (IJESA)*, Vol. 2, No. 3, pp. 81-89, (September 2012).
- [Kiy2004] M. K. Kiyimik, A. Subasi et H. R. Ozcalik, "Neural networks with periodogram and autoregressive spectral analysis methods in detection of epileptic seizure", *Journal of Medical Systems*, Vol. 28, No. 6, pp. 511-522, (2004).
- [Kir2009] T. Kirschstein et R. Kohling, "What is the Source of the EEG?", *Clinical EEG and Neuroscience*, Vol. 40, No. 3, pp. 146-149, (2009).
- [Kia2014] S. Kiranyaz, T. Ince, M. Zabihi et D. Ince, "Automated patient-specific classification of long-term Electroencephalography", *Journal of Biomedical Informatics*, Vol. 49, pp. 16-31, (2014).
- [Kol2015] M. Kolodziej, A. Majkowski et R. J. Rak, "A new method of spatial filters design for brain-computer interface based on steady state visually evoked potentials", *International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications*, Warsaw, Poland, pp. 697-700, (24-26 Septembre 2015).
- [Kos2015] M. T. Kostas, S. Konitsiotis, S. Markoula, D. D. Koutsouris, I. A. Sakellarios et D. I. Fotiadis, "An Unsupervised Methodology for the Detection of Epileptic Seizures in long-term EEG signals", *15th International Conference on Bioinformatics and Bioengineering (BIBE)*, Belgrade, Serbia, pp. 1-4, (2-4 November 2015)
- [Kot2002] I. A. W. Kotsopoulos, T. V. Merode, F.G.H. Kessels, M. C. T. F. M de Krom et J.A. Knottnerus, "Systematic review and meta-analysis of incidence studies of

- epilepsy and unprovoked seizures", *Epilepsia*, Vol. 43, No. 11, pp. 1402-1409, (2002).
- [Kwa2008] C. Kwak et W. O. Kwon, "Cardiac disorder classification Based on Extreme learning Machine", *World Academy of Science, Engineering and Technology International Journal of Computer and Information Engineering*, Vol. 2, No. 12, pp. 4110-4113, (2008).
- [Lec1998] Y. Lecun, L. Bottou, Y. Bengio et P. Haffner, "Gradient-based learning applied to document recognition", *Proceedings of the IEEE*, Vol. 86, No.11, pp. 2278–2324, (1998).
- [Leu2004] E.C. Leuthardt, G. Schalk, J.R. Wolpaw, J.G. Ojemann et D.W. Moran, "A brain computer interface using electrocorticographic signals in humans", *Journal of Neural Engineering*, Vol. 1, No. 2, pp. 63-71, (2004).
- [Lin2004] A. Linderhed, "Adaptive Image Compression with Wavelet Packets and Empirical Mode Decomposition", *Thèse de Doctorat de Linköping University*, Linköping, Suède, (2004).
- [Lot2007] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche et B. Arnaldi, "A review of classification algorithms for EEG-based brain–computer interfaces", *Journal of Neural Engineering, IOP Publishing*, Vol. 4, No. 2, pp.1-24, (2007).
- [Lou1997] A. K. Louis, D. Maass et A. Rieder, "Wavelets: Theory and Applications", *John Wiley & Sons*, (1997).
- [Mal1995] J. Malmivuo et R. Plonsey, "Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields", *Oxford University Press*, USA, (1995).
- [Maa2000] S. Mallat, "Une exploration des signaux en ondelette", *Les Editions de l'Ecole Polytechnique*, Paris, (2000).
- [Mat2014] D. Maliuk et Y. Makris. "An experimentation platform for on-chip integration of analog neural networks : A pathway to trusted and robust analog/RF ICs", *Neural Networks and Learning Systems*, Vol.1, No.1, pp. 89-99, (2014).
- [Mar2015] A. Maragakis et A. Rosengarten, "Seizure Detection with Single-Channel On-Scalp EEG using SVM-Ensembles", *International Mathematics Research Notices*,

Vol. 2015, pp. 1-8, (2015).

- [Mah2006] C. Matthieu, "Analyse automatique des crises d'épilepsie du lobe temporal à partir des EEG de surface", *Thèse de Doctorat de l'Institut National Polytechnique de Lorraine - INPL*, Nancy, France, (2006).
- [Mer2016] M. Mera-Gaona, R. Vargas-Canas et D. M. Lopez, "Towards a Selection Mechanism of Relevant Features for Automatic Epileptic Seizures Detection", *Studies in Health Technology and Informatics*, Vol. 228, pp. 722-726, (2016).
- [Mil2007a] K. Miller, E. Leuthardt, G. Schalk, R. Rao, N. Anderson, D. Moran, J. Miller et J. Ojemann, "Spectral Changes in Cortical Surface Potentials during Motor Movement", *Journal of Neuroscience*, Vol. 27, No. 9, pp. 2424-2432, (2007).
- [Mil2015b] M. Milosevic, "Automated detection of epileptic seizures in pediatric patients based on accelerometry and surface electromyography", *Thèse de Doctorat de KU Leuven University*, Leuven, Belgique, (2015).
- [Nie2004] E. Niedermeyer et F. da Silva, "Electroencephalography: Basic Principles, Clinical Applications, and Related Fields", *5th edition, Lippincott Williams & Wilkins*, (2004).
- [Nid2005] E. Niedermeyer et F. da Silva, "Electroencephalography: basic principles, clinical applications, and related fields, Lippincott Williams & Wilkins", *5th edition, Lippincott Williams & Wilkins*, (2005).
- [Nun2006] P. Nunez, et S. Srinivasan, "Electric fields of the brain : the neurophysics of EEG", *Oxford University Press*, USA, (2006).
- [Oca2008] H. Ocak, "Optimal classification of epileptic seizures in EEG using wavelet analysis and genetic algorithm", *Signal Processing*, Vol. 88, No. 7, pp. 1858-1867, (2008).
- [Off1950] F. Offner, "The EEG as potential mapping : the value of the average monopolar reference", *Electroencephalography and Clinical Neurophysiology*, Vol. 2, No. 2, pp. 213-214, (1950).
- [Oro2010] L. Orosco, A. G. Correa et E. Laciari, "Multiparametric Detection of Epileptic Seizures using Empirical Mode Decomposition of EEG Records", *Annual*

- International Conference of the IEEE Engineering in Medicine and Biology*, Buenos Aires, Argentina, pp. 951-954, (31 Août - 4 Septembre 2010).
- [Ors2016] L. Orosco, A. Garcés Correa, P. Diez et E. Laciari, "Patient non-specific algorithm for seizures detection in scalp EEG", *Computers in Biology and Medicine*, Vol. 71, No. 1, pp. 128–134, (2016).
- [Oso2017] I. Osorio, P. Hitten, Zaveri, M. G. Frei, S. Arthurs, "Epilepsy: The Intersection of Neurosciences, Biology, Mathematics, Engineering, and Physics", *CRC Press, Taylor & Francis Group*, pp. 258-259, (2017).
- [Pan2008] M. Panigrahi, et S. Jayalakshmi, "Presurgical evaluation of epilepsy", *Journal of Pediatric Neurosciences*, Vol. 3, No. 1, pp. 74–81, (2008).
- [Pat2009] R. S. Pathak et G. Pandey, "The Wavelet Transform on Spaces of Type W ", *Atlantis Studies in Mathematics for Engineering and Science*, Vol. 39, No. 2, pp. 619-63., (2009).
- [Pol2007] K. Polat et S. Güneş, "Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform", *Journal of Applied Mathematics and Computing*, Vol. 187, No. 2, pp. 1017-1026, (2007).
- [Poy2010] G. E. Polychronaki, P. Y. Ktonas, S. Gatzonis, A. Siatouni, P. A. Asvestas, H. Tsekou, D. Sakas et K. S. Nikita, "Comparison of fractal dimension estimation algorithms for epileptic seizure onset detection", *Journal of Neural Engineering*, Vol. 7, No. 4, pp. 1-8, (2010).
- [Pra1996] N. Pradhan, P. K. Sadasivan et G. R. Arunodaya, "Detection of seizure activity in EEG by an artificial neural network: A preliminary study", *Computers and Biomedical Research*, Vol. 29, No.4, pp. 303-313, (1996).
- [Qu1997] H. Qu et J. Gotman, "A patient-specific algorithm for the detection of seizure onset in long-term EEG monitoring: Possible use as a warning device", *IEEE Transaction on Biomedical Engineering*, Vol. 44, No. 2, pp. 115-122, (1997).
- [Rai2015] K. Rai, V. Bajaj et A. Kumar, "Features extraction for classification of focal and non-focal EEG signals", *Information Science and Applications*, vol. 339, pp. 599-605, (2015).

Références

- [Roe2015] C.Roels, "Débutez l'analyse logicielle avec uml", (2015).
- [Rom2010] R. Romo-Vazquez, "Contribution à la détection et à l'analyse des signaux EEG épileptiques: débruitage et séparation de sources", *Thèse de Doctorat de l'Institut National Polytechnique de Lorraine - INPL*, Nancy, France, (2010).
- [Ros1957] F. Rosenblatt, "The Perceptron: A Perceiving and recognizing automaton", *Technical report, Cornell Aeronautical Laboratory, INC*, (1957).
- [Ron1961] F. Rosenblatt, "Principles of neurodynamics. perceptrons and the theory of brain mechanisms", *Technical report, DTIC Document*, (1961).
- [Rum1986] D. Rumelhart, G. Hinton et R. Williams, "Learning internal representations by error propagation," *Parallel Distributed Processing*, Cambridge: MIT Press, Vol. 1, pp. 318-362, (1986).
- [Saa2004] M.E. Saab et J. Gotman, "A system to detect the onset of epileptic seizures in scalp EEG", *Clinical Neurophysiology*, Vol. 116, No. 2, pp. 427-442, (2004).
- [Sad2016] M. Sadibelouiz, "Journée mondiale de l'épilepsie : 400.000 cas en Algérie", (2016).
- [Sal2012] R. A. Salido-Ruiz "Problèmes inverses contraints en EEG : applications aux potentiels absolus et à l'influence du signal de référence dans l'analyse de l'EEG", *Thèse de Doctorat de l'Ecole doctorale IAEM Lorraine, Université de Lorraine*, Nancy, France, (2012).
- [Sch2002] M. Scheuer, "Continuous EEG monitoring in the intensive care unit", *Epilepsia*, Vol. 43, No. 3, pp. 114-127, (2002).
- [Sce2004] M. Scheuer and S. Wilson, "Data analysis for continuous EEG monitoring in the ICU: seeing the forest and the trees", *Journal of Clinical Neurophysiology*, Vol. 21, No. 5, pp. 353-378, (2004).
- [Sci2008] G. Schalk, K.J. Miller, N.R.Anderson, J.A. Wilson, M.D. Smyth, J.G. Ojemann, D.W. Moran, J.R. Wolpaw et E.C. Leuthardt, "Two dimensional movement control using electrocorticographic signals in humans", *Journal of Neural*

Engineering, Vol. 5, No. 1, pp. 75-84, (2008).

- [Sco2004] B. Scott, Wilson, L. Mark, Scheuer, G. Ronald, Emerson et A. J. Gabor, "Seizure detection: evaluation of the Reveal algorithm", *Clinical Neurophysiology*, Vol. 115, No. 10, pp. 2280-2291, (2004).
- [Sem2007] F. Semah, "La TEP et la TEMP pour l'étude des épilepsies", *Médecine Nucléaire*, Vol. 31, No. 6, pp. 329–336, (2007).
- [Sha2006] A. Shah, R. Agarwal, J. Carhuapoma, et J. Loeb, "Compressed EEG pattern analysis for critically ill neurological-neurosurgical patients", *Neurocritical Care*, Vol. 5, No. 2, pp. 124-133, (2006).
- [Sar2015] R. Sharma et R. B. Pachori, "Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions", *Expert Systems with Applications*, Vol. 42, No. 3, pp. 1106-1117, (2015).
- [Sho2004] A. Shoeb, H. Edwards, J. Connolly, B. Bourgeois, S. Ted Treves et J. Guttag, "Patient-specific seizure onset detection", *Epilepsy and Behavior*, Vol. 5, No. 4, pp. 483-498,(2004).
- [Sri2007] V. Srinivasan, C. Eswaranand et N. Sriraam, "Approximate entropy-based epileptic EEG detection using artificial neural networks", *IEEE Transactions on Information Technology in Biomedicine*, Vol. 11, No. 3, pp. 228-295, (2007).
- [Tal1974] J. Talairach, J. Bancaud, et G. Szikla, "Exploration Fonctionnelle Stéréotaxique. Approche nouvelle de la neurochirurgie de la épilepsie", *Neurochirurgie*, Vol. 20, No.1, pp. 240-245, (1974).
- [Tho2003] P. Thomas et A. Arzimanoglou. "Epilepsies", *Elsevier/ Masson*, Paris, (2003).
- [Tra2008] D. S. Tran, P. Odermatt, L. Delneuveille, S. Singphuoangphet, M. Druet-Cabanac, H. Barennes, P. Nubukpo, M. Strobel et P. Pierre-Marie, "Anxiété et dépression chez des patients atteints d'épilepsie en république démocratique du Laos", *Epilepsies*, Vol. 20, No. 1, pp. 33-37, (2008).
- [Tri2017] O. Trigui, " Etude de la Commande d'une Machine à Partir des Signaux EEG : Application Biomedicale de l'interface Homme-Machine", *Thèse de Doctorat de*

l'École Nationale d'Ingénieurs de Sfax (ENIS), Sfax, Tunisie (2017).

- [Tza2007] AT. Tzallas, MG. Tsipouras et DI. Fotiadis, "Automatic seizure detection based on time-frequency analysis and artificial neural networks", *Computational Intelligence and Neuroscience*, Vol. 2007, No. 18, pp. 805-810, (2007).
- [Vel2010] H. A. Velez-Prez, "Localisation et caractérisation du déroulement de la crise d'épilepsie temporale", *Thèse de Doctorat de l'Institut National Polytechnique de Lorraine*, Nancy, France, (2010).
- [Wan2005] L. Wang, "Support Vector Machines: Theory and Applications", *Springer Science & Business Media*, Berlin, (2005).
- [Wen1996] W. Weng et K. Khorasani, "An adaptive structure neural network with application to EEG automatic seizure detection", *Neural Networks*, Vol. 9, No. 7, pp. 1223-1240, (1996).
- [Wer2015] H. Werteni, S. Yacoub et N. Ellouze, "Classification of Sleep Stages Based on EEG Signals", *International Review on Computers and Software (IRECOS)*, Vol. 10, No. 2, pp. 1-6, (2015).
- [Wil2006] O. T. William, A. M. Husain, S. R. Benbadis et P. W. Kaplan, "Normal Adult EEG and Patterns of Uncertain Significance", *Journal of Clinical Neurophysiology*, Vol. 23, No. 3, pp. 194-207, (2006).
- [Wol2006] J. R. Wolpaw, G. E. Loeb, B. Z. Allison, E. Donchin, O. F. Nascimento, W. Heetderks, F. Nijboer, W. G. Shain et J. N. Turner, "BCI Meeting 2005—workshop on signals and recording methods", *IEEE transactions on neural systems and rehabilitation engineering: a publication of the IEEE Engineering in Medicine and Biology Society*, Vol. 14, No. 2, pp. 138-141, (2006).
- [Wu1996] A. W. Wu, Y. Mallet, B. Walczak, W. Penninckx, D. L. Massart, S. Heuerding, et F. Erni, "Comparison of regularized discriminant analysis linear discriminant analysis and quadratic discriminant analysis applied to NIR data", *Analytica Chimica Acta*, Vol. 329, No. 3, pp. 257-265, (1996).
- [Wu2009] Z. Wu et N. E. Huang, "Ensemble empirical mode decomposition: A noise-assisted data analysis method", *Advances in Adaptive Data Analysis*, *World Scientific Publishing Company*, Vol. 1, No. 1, pp. 1-41, (2009).

- [Yan2012] J. Yang, H. Singh, E. L. Hines, F. Schlaghecken, D. D. Iliescu, M. S. Leeson et N. G. Stocks, "Channel selection and classification of electroencephalogram signals: An artificial neural network and genetic algorithm-based approach", *Artificial Intelligence in Medicine*, Vol. 55, No. 2, pp. 117-126, (2012).
- [Yao2001] D. Yao, "A method to standardize a reference of scalp EEG recordings to a point at infinity", *Physiological Measurement*, Vol. 22, No. 4, pp. 693-711, (2001).
- [Yua2013] P. Lu, D. Yuan, Y. Lou, C. Liu et S. Huang, "Single-Trial Identification of Motor Imagery EEG based on HHT and SVM", *Chinese Intelligent Automation Conference, Lecture Notes in Electrical Engineering 256*, Springer-Verlag Berlin Heidelberg, Yangzhou, China, pp. 681-689, (2013).
- [Zab2015] M. Zabihi, S. Kiranyaz, A. Bahrami Rad, K. Aggelos, Katsaggelos, M. Gabbouj et T. Ince, "Analysis of high-dimensional phase space via Poincaré section for patient-specific seizure detection", *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 24, No. 3, pp. 386-398, (2015).
- [Zak2005] Zaknich et Anthony, "Principles of Adaptive Filters and Self-learning Systems", pp. 217-218, (2005).
- [Zou2008] L. Zoubek, "Automatic classification of human sleep recordings combining artifact identification and relevant features selection", *Thèse de Doctorat de l'Université Joseph Fourier GRENOBLE*, Grenoble, France, (2008).