

République Algérienne Démocratique et Populaire
Ministère de L'enseignement Supérieur et de la Recherche Scientifique

Université 20 Août 1955 Skikda
Faculté de Technologie

N° d'ordre: **D012125023D**



Thèse

En vue de l'obtention du diplôme de

DOCTORAT EN SCIENCES

Filière : **Electronique**

Spécialité : **Traitement de signal**

Thème

Analyse et traitement des signaux physiologiques et Application

Présentée par : BENZAID Amel

Soutenue le : 29/05/2025

Devant le Jury composé par :

Nom et prénom	Grade	Qualité	Affiliation
GOUTAS Ahcene	Professeur	Président	Université 20 août 1955 Skikda
DJEMILI Rafik	Professeur	Rapporteur	Université 20 août 1955 Skikda
FERDI Youcef	Professeur	Examineur	École Nationale Supérieure Biotechnologie (ENSB) Constantine
BOUROUBA Hocine	Professeur	Examineur	Université 8 mai 1945 Guelma
DOGHMANE Hakim	MCA	Examineur	Université 8 mai 1945 Guelma
BELMEGUENAI Aissa	Professeur	Examineur	Université 20 août 1955 Skikda

Année Universitaire : 2024/2025

ملخص

تركز هذه الأطروحة على تحليل الإشارات الفسيولوجية، مع اهتمام خاص بإشارات تخطيط الدماغ الكهربائي (EEG) وتخطيط القلب الكهربائي (ECG)، وذلك بعد عرض شامل لحالة الفن فيما يخص هذين النوعين من الإشارات. بالنسبة لإشارات EEG، تم تقسيم الإشارة إلى عينات مدة كل منها ثانية واحدة، ثم تمت تصفيتها وفقًا لنطاقات التردد المعروفة للنشاط الدماغية. بعد ذلك، تم استخراج خصائص غير خطية من الإشارة بهدف تصنيف المقاطع إلى فئتين: نشاط طبيعي أو نشاط ناتج عن نوبة (صرعية).

أما بالنسبة لإشارات ECG، فقد بدأ المعالجة باستخراج مركبات QRS، ومن هذه المقاطع تم حساب خصائص غير خطية بغرض التمييز بين المراحل الانقباضية الطبيعية والانقباضات الخارجة (Extrasystoles). وقد تم استخدام عدة مصنفات لكلا النوعين من الإشارات، من بينها تقنيات التعلم الآلي والتعلم العميق مثل: LSTM، DNN، KNN، وغيرها من أساليب التعلم الآلي، وذلك بهدف تحسين عملية الكشف وتصنيف الشذوذات.

الكلمات المفتاحية: EEG، ECG، إشارات فسيولوجية، تصنيف، مرشحات، خصائص غير خطية، تعلم آلي، DNN، LSTM، KNN.

Abstract

This thesis focuses on the analysis of physiological signals, with particular emphasis on electroencephalography (EEG) and electrocardiography (ECG) signals, following a comprehensive review of the state of the art related to both types. For EEG signals, the data is segmented into one-second samples and filtered according to the characteristic frequency bands of brain activity. Nonlinear features are then extracted to enable classification of the segments into two categories: normal activity or seizure (epileptic) activity.

Regarding ECG signals, the processing begins with the extraction of QRS complexes. From these segments, nonlinear features are calculated to distinguish between normal systolic phases and extrasystoles. For both types of signals, several classifiers have been used, including machine learning and deep learning methods such as KNN, DNN, LSTM, and other approaches, to enhance the detection and classification of abnormalities.

Keywords: EEG, ECG, physiological signals, classification, filters, nonlinear features, machine learning, DNN, LSTM, KNN.

RESUME

Cette thèse porte sur l'analyse des signaux physiologiques, avec un focus particulier sur les signaux d'électroencéphalographie (EEG) et d'électrocardiographie (ECG), après avoir présenté un état de l'art détaillé concernant ces deux types de signaux. Pour l'EEG, le signal est segmenté en échantillons d'une seconde chacun, puis filtré selon les bandes de fréquence caractéristiques de l'activité cérébrale. Des caractéristiques non linéaires sont ensuite extraites afin de permettre une classification des segments en deux catégories : activité normale ou activité de crise (épileptique).

En ce qui concerne les signaux ECG, le traitement commence par l'extraction des complexes QRS. À partir de ces segments, des caractéristiques non linéaires sont calculées dans le but de différencier les phases systoliques normales des extrasystoles. Pour les deux types de signaux, plusieurs classificateurs ont été utilisés, notamment des méthodes d'apprentissage automatique et profond : KNN, DNN, LSTM, et d'autres approches de machine learning, afin d'optimiser la détection et la classification des anomalies.

Mots-clés : EEG, ECG, signaux physiologiques, classification, filtres, caractéristiques non linéaires, ML, DNN, LSTM, KNN.

Liste des publications

Benzaid, A., Djemili, R., & Arbateni, K. (2024). Seizure detection using nonlinear measures over EEG frequency bands and deep learning classifiers. *Computer Methods in Biomechanics and Biomedical Engineering*, 1-17.

Liste des communications

Amel Benzaid, Rafik Djemili, Time-domain exponential energy for classifying epileptic EEG signals using multilayer perceptron neural network classifier, Skikda, SIGIMA'2022, 23-24 October 2022.

Amel Benzaid, Rafik Djemili, Signal Analysis for Brain-Computer Interface (BCI) Applications: A Review, Skikda, ICEE'2022, November 22-23, 2022.

Amel Benzaid, Rafik Djemili, Larbi Boubchir, Brain-Computer Interfaces: Main Concepts and Front-End EEG Signal Analysis, Skikda, ICTAEE'23, May 23-24 2023.

Amel Benzaid, Rafik Djemili, Larbi Boubchir , EEG Feature Extraction Method Using Hjorth Parameter and MLP LSTM classifiers, Skikda, ICPET23, November 21-23 2023.

Amel Benzaid, Rafik Djemili, EEG Spectrogram Technique for epileptic Seizures detection and classification, a Review, Skikda, ICAEPI'23, November 28-29-30 2023.

Amel Benzaid, Rafik Djemili, Maaoui Chebeila, Extraction of Heart Rate from vowel Speech Signal, Skikda, CNCSSI 2024, 25-26 November 2024.

Remerciements

Le travail présenté dans cette thèse a été réalisé au **Laboratoire de Recherche en Electronique de Skikda (LRES)**, sous la direction de Monsieur DJEMILI Rafik professeur de l'enseignement supérieur à l'Université 20 août 1955-Skikda, à qui j'exprime ma sincère reconnaissance pour tous les conseils et encouragements qu'il m'a prodigués pendant toute la durée de ce travail.

Je tiens à exprimer ma reconnaissance à Monsieur GOUTAS Ahcene professeur à l'Université de Skikda, pour avoir accepté de présider le jury de soutenance.

Je remercie très vivement Monsieur FERDI Youcef, professeur à L'école nationale biotechnologie Constantine, pour l'honneur qu'il me fait en acceptant de juger mon travail.

Toute ma reconnaissance va à Monsieur BOUROUBA Hocine professeur à l'Université Guelma, à qui j'exprime mes plus vifs remerciements pour sa participation dans le jury.

Je tiens à remercier très vivement Monsieur DOGHMANE Hakim maître de conférences à l'Université de Guelma, d'avoir accepté de participer dans le jury de ma thèse.

Toute ma reconnaissance va à Monsieur BELMEGUENAI Aissa professeur à l'Université de Skikda, à qui j'exprime mes sincères remerciements pour sa participation dans le jury.

Je n'oublierai jamais le soutien de mes parents, mon mari mes chers frères et sœurs, je prends ces quelques mots pour leurs dire merci.

Que toute personne ayant contribué, de près ou de loin, à l'aboutissement de ce travail trouve ici le témoignage de ma profonde reconnaissance. Enfin je ne pourrais terminer ces remerciements sans une pensée à l'ensemble de mes enseignants, qu'ils trouvent ici, dans ces lignes, l'expression de ma profonde gratitude.

Dédicace

À mes chers parents,

Mezghache messaouda, Benzaid Ramdane

qui m'ont donné la vie, l'amour, le courage et l'éducation,
merci pour vos prières silencieuses et votre soutien sans faille.

À mon époux **Benredouane Mahiedine,**

ton amour, ta patience et ton soutien inconditionnel ont été ma force dans les moments les plus
difficiles. Merci d'avoir toujours cru en moi.

À mes enfants, mes trésors:

Mohamed Redouane, Charafedine Wassime,

mes princes au regard rempli de fierté,

et mes princesses **Ritadj, Basmala et Miral,**

votre présence dans ma vie est mon plus beau cadeau. Ce travail est aussi pour vous.

À mes sœurs et mes frères,

merci pour votre tendresse, vos encouragements et vos mots de réconfort.

Et à la mémoire de mon amie chère, **Boudakhana Fatima,**

qui m'a toujours encouragée avec ces mots:

« Il faut que tu aies ton doctorat, pour que je dise avec fierté : mon amie est docteur. »

Ton souvenir m'a portée jusqu'au bout.

Et enfin, à **toutes mes amies et tous mes collègues,**

merci pour vos sourires, votre soutien, vos conseils, vos partages et votre bienveillance.

Vous avez enrichi ce voyage et adouci les étapes les plus exigeantes.

Table des matières

I Signaux physiologiques

Introduction	5
I.1 L'ELECTROENCEPHALOGRAMME.....	5
I.1.1 Historique.....	6
I.1.2 Activités neuronales.....	7
I.1.3 Potentiels d'action.....	8
I.1.4 Génération des signaux EEG.....	10
I.1.5 Décomposition fréquentielle du signal EEG.....	13
I.1.6 Enregistrement et Mesure de le EEG.....	16
I.1.6.1 Positionnement conventionnel des électrodes.....	17
I.1.6.2 Conditionnement des signaux.....	20
I.1.7. Modèles EEG anormaux.....	20
I.2 L'ELECTOCARDIOGRAMME.....	21
I.2.1.Historique.....	21
I.2.2 Anatomie du cœur.....	22
I.2.2 Cycle cardiaque.....	23
I.2.3 Activité électrique cardiaque.....	25
I.2.4 Fréquence cardiaque.....	26
I.2.5 Le signal électrique cardiaque.....	27
I.2.5.1 Les dérivations électrocardiographiques.....	28
I.2.5.2 Notion vectorielle.....	29
I.2.6 Les Arythmies Cardiaques.....	31
I.2.6.1.Extrasystoles supraventriculaires.....	31
I.2.6.2.Extrasystole ventriculaire.....	32
I.3 L'ELECTROMYGRAPHIE.....	32
I.3.1.Historique.....	32
I.3.2 Structure et Organisation du Muscle Squelettique	33

I.3.3	Caractéristiques des signaux EMG.....	35
I.3.3.1	Définition de l'électromyogramme.....	35
I.3.3.2	Prétraitement du signal EMG.....	35
I.4	ELECTROOCULOGRAMME.....	36
I.4.1	L'anatomie de l'œil.....	36
I.4.1.1	Description des principaux composants du globe oculaire humain.....	37
I.4.2	Définition de l'électromyogramme.....	38
I.4.3	Relation entre EOG EEG et EMG.....	39
I.4.4	Hypovigilance et EOG.....	40
I.5	LA VARIABILITE DU RYTHME CARDIAQUE (HVR).....	42
I.5.1	Filtre passe-bande.....	43
I.5.2	Filtre passe-haut.....	44
I.5.3	Dérivation.....	43
I.5.4	Fonction de mise au carré.....	44
I.5.4	Fenêtre d'intégration mobile et ajustement du seuil.....	44
I.5.5	Étude de la variabilité du rythme cardiaque (HRV).....	45
Conclusion	46
 II État de la recherche sur le signal EEG et le signal ECG		
Introduction.....		47
II.1	ETAT DE LA RECHERCHE SUR LES SIGNAUX EEG.....	48
II.1.1	Prétraitement et filtrage des signaux EEG.....	48
II.1.1.1	Artefacts dans les signaux EEG.....	48
II.1.1.2	Filtrage linéaire.....	53
II.1.1.3	Analyse en Composantes Indépendantes (ICA).....	54
II.1.1.4	Décomposition en ondelettes.....	55
II.1.2	Méthodes d'analyse des signaux EEG et extraction de caractéristiques.....	57
II.1.2.1	Méthodes d'analyse dans le domaine temporel.....	57
II.1.2.1.1	Prédiction Linéaire (LP).....	57
II.1.2.1.2	Analyse des composantes.....	58
II.1.2.1.2.1	Analyse en Composantes Principales (PCA).....	59

II.1.2.1.2.2. Analyse en Composantes Indépendantes (ICA).....	59
II.1.2.1.2.3 Analyse Discriminante Linéaire (LDA).....	59
II.1.2.2 Méthodes d'analyse en domaine fréquentiel.....	60
II.1.2.2.1. Méthode non paramétrique.....	60
II.1.2.2.2 Méthode paramétrique.....	61
II.1.2.3.Méthodes en temps-fréquence.....	62
II.1.2.3.1Transformée en ondelettes.....	63
II.1.2.3.2Transformée de Hilbert–Huang (HHT).....	64
II.1.2.4. Méthode d'analyse non linéaire.....	64
II.1.3. Classification des signaux EEG.....	65
II.1.3.1 Machine à Vecteurs de Support (SVM).....	65
II.1.3.2 Modèle de Mélange Gaussien (GMM).....	65
II.1.3.3 Classificateur Flou de Sugeno (FSC).....	65
II.1.3.4 K-Plus Proches Voisins (KNN).....	66
II.1.3.5 Classificateur Naïf de Bayes (NBC).....	66
II.1.3.6 Arbre de Décision (DT).....	66
II.1.3.7 Long Short-Term Memory (LSTM).....	66
II.1.3.8 Le Deep Neural Network (DNN).....	67
II.2 ETAT DE LA RECHERCHE SUR LES SIGNAUX ECG.....	67
II.2.1 Artefacts dans les signaux ECG.....	67
II.2.1.1 Bruit à basse fréquence.....	67
II.2.1.2 Bruit musculaire.....	68
II.2.1.3 Bruit électromagnétique.....	69
II.2.2 Prétraitement et filtrage des signaux ECG.....	70
II.2.3 Techniques d'extraction des caractéristiques d'un signal ECG.....	71
II.2.3.1 Caractéristiques du complexe P-QRS-T.....	71
II.2.3.2 Caractéristiques statistiques.....	72
II.2.3.3 Caractéristiques morphologiques.....	72
II.2.3.4 Caractéristiques ondelettes.....	73
II.2.3.5 Autres caractéristiques.....	74

II.2.4 Classification des signaux ECG	74
II.2.4.1 Réseaux de neurones artificiels (ANN)	75
II.2.4.2 Arbre de décision (DT)	75
II.2.4.3 Analyse discriminante linéaire (LDA)	75
II.2.4.4 Machine à vecteurs de support (SVM)	76
II.2.4.5 K plus proches voisins (kNN)	76
II.2.4.6 Classificateurs bayésiens	76
II.2.4.7 Autres approches de classification	77
Conclusion	77
 III Détection des crises épileptiques	
Introduction	79
III.1 ETAT DE LA RECHERCHE SUR LA DETECTION DES CRISES EPILEPTIQUES	82
III.3 BASE DE DONNEE DE BONN ET HAUZ KHAS	84
III.4 METHODES DE DETECTION	85
III.4.1 Filtrage Dans les bandes de fréquence	86
III.4.2 Extraction des caractéristiques non linéaires	86
III.4.3.1 Exposant de Hurst	87
III.4.3.2 Paramètres de Hjorth	88
III.4.3.3 Entropie Multiscalaire Modifiée (MMSE)	89
III.4.3.4 Detrended Fluctuation Analysis (DFA)	90
III.4.2.5 Dimension Fractale (FD)	91
III.4.2.6 Dimension fractale de Katz	90
III.4.2.7 Dimension Fractale de Higuchi	92
III.4.3 Classification	92
III.4.3.1 Réseau de Neurones Profonds (DNN)	92
III.4.3.2 Mémoire à Long et Court Terme (LSTM)	94
III.4.4 Performances d'Évaluation des Classificateurs	95
III.5. Résultats de la simulation	95
III.5.1 Filtrage sous bande	96
III.5.2 Choix des caractéristiques	97

III.5. 3 Choix du vecteur d'entrée.....	97
CONCLUSION.....	106
IV Détection des extrasystoles dans un signal ECG	
Introduction.....	108
IV.1 CLASSIFICATION DES EXTRASYSTOLES.....	109
IV.1.1 Etat de l'art la détection et la classification des extrasystoles.....	109
IV.1.2 Description du système automatique de classification du signal ECG.....	110
IV.2 LES DONNÉES ECG ÉTUDIÉES.....	111
IV.2.1 Description de la base de données MIT-BIH.....	111
IV.2.2. Fichiers de la base MIT-BIH.....	112
IV.2.1.1 Le fichier de données (*.dat).....	112
IV.2.1.2. Le fichier d'en-tête (*.hea).....	112
IV.2.1.3. Le fichier d'annotations (*.atr).....	112
IV.2.3 Base de données des tests de bruit de stress MIT-BIH.....	114
IV.3 TRAITEMENT DU SIGNAL ET EXTRACTION DES CARACTERISTIQUE.....	114
IV.3.1 Normalisation Temporelle.....	115
IV.3.2 Méthode de Détection par Amplitude.....	116
IV.3.3 Dérivée du premier ordre.....	117
IV.3.4 Détection des complexes QRS.....	118
IV.3.5 Extraction des Caractéristiques.....	119
IV.4 RÉSULTATS DES SIMULATIONS.....	120
IV.4.1 Classification des extrasystoles.....	120
IV.4.1.1 Choix du vecteur de classification.....	121
IV.1.2 Paramètres d'évaluation des performances.....	121
IV.1.3 Choix du vecteur d'entre.....	122
IV.1.4 Choix des classificateurs.....	123
IV.5 RÉSULTATS ET DISCUSSION.....	125
Conclusion.....	129

Liste des figures

Figure I. 1 Les variations du potentiel de membrane neuronale et le flux de courant lors de l'activation synaptique sont enregistrés au moyen de microélectrodes intracellulaires [1].....	8
Figure I.2 Un exemple de potentiel d'action [1].....	9
Figure I.3 Modification du potentiel membranaire d'un calmar géant en fermant les canaux Na et en ouvrant les canaux K [1].....	9
Figure I.4 Structure d'un neurone. A gauche : Schéma d'un neurone moteur. A droite : Photographie au microscope électronique à balayage (grossi 6000 fois) montrant le corps cellulaire du neurone et les dendrites.....	11
Figure.I.5. Vue des méninges en trois dimensions. Coupe frontale montrant la situation de la dure-mère, de l'arachnoïde et de la pie-mère. Le feuillet interne de la dure-mère forme la faux du cerveau [15].....	12
Figure.I.6 Représentation schématique des principales parties du cerveau [1].....	13
Figure I.7 Positions conventionnelles des électrodes EEG 10–20 pour le placement de 20 électrodes	20
Figure I.8 Représentation schématique de 10 à 20 réglages d'électrodes pour 75 électrodes, y compris les électrodes de référence : (a) et (b) représentent les mesures tridimensionnelles, et (c) indique une vue bidimensionnelle de la configuration de l'installation des électrodes.....	20
Figure I.9 Anatomie du cœur [3].....	24
Figure I.10 Cycle cardiaque [5].....	24
Figure I.11 Représentation du système de cellules cardionectrices du cœur [3].....	26
Figure I.12 Illustration et interprétation des différentes ondes d'un électrocardiogramme. Un battement cardiaque est représenté	27
Figure I.13 Les dérivations électrocardiographiques, a : Les dérivations bipolaires, b : les dérivations unipolaires des membres, c : Les dérivations unipolaires précordiales.....	30
Figure I.14 Propagation du signal électrique.....	31
Figure I.15 Le signal enregistré par l'électrode.....	31
Figure I.16 Le muscle squelettique est attaché aux os par deux extrémités appelées origine (O) et insertion (I) [2].....	34
Figure I.17 Organisation des muscles squelettiques [4].....	35

Figure I.18 Un exemple de signal EMG de surface enregistré à partir du muscle extenseur radial du carpe long lorsqu'un sujet effectue une ouverture de la main pendant deux secondes.....	36
Figure I.19 Le globe de l'œil humain et les composants principaux.....	38
Figure I.20 En haut : les emplacements recommandés par l'AASM pour les électrodes destinées à l'acquisition des signaux EOG et EEG. Les électrodes E1 et E2 servent respectivement à enregistrer les signaux EOG gauche et droit. Les électrodes F3, F4, C3, C4, O1 et O2 sont les plus fréquemment utilisées pour l'EEG dans le cadre du suivi du sommeil. En bas : comparaison entre le signal EEG C3 et le signal EOG droit (E2) [6].....	41
Figure I. 21 Changements du potentiel EOG liés aux mouvements des yeux [7].....	42
Figure I.22 – Placement des électrodes pour l'enregistrement EOG.....	43
Figure I.23 La génération du signal HRV à travers la détection des pics R (Algorithme de Pan–Tompkins) [10].....	44
Figure II.1 Étapes du traitement du signal EEG.....	49
Figure II.2 Exemples d'artefacts oculaires et électromyographiques. Les artefacts oculaires tels que les mouvements oculaires (a) et le clignement des yeux (b) sont représentés par un potentiel électrique important, généralement caractérisé par une localisation antérieure, bilatérale et une apparence synchronisée. Les artefacts électromyographiques (c).....	51
Figure II.3 Quatre types de filtres : filtres passe-bas, passe-haut, passe-bande et coupe-bande. Un filtre passe-basHaut du formulaire.....	55
Figure.II.4 Organigramme de base du débruitage du signal basé sur les ondelettes [18].....	58
Figure II.5 Signal EEG corrompu par clignement des yeux en rouge, signal EEG corrigé basé sur DWT en noir [18].....	58
Figure II.6 Signaux EEG typiques : (a) normal, (b) intercritique et (c) critique.....	60
Figure II.7 Illustration de l'utilisation de l'ICA dans la détection de l'épilepsie.....	61
Figure II.8 Estimation de la densité spectrale de puissance (PSD) à l'aide de la méthode de Burg pour les signaux normaux, interictaux et ictaux présentés dans la figure 1.....	64
Figure II.9 Décomposition en paquets d'ondelettes.....	65
Figure II.10 Low frequency noise present in ECG signal [46].....	70
Figure II.11 Exemple de bruit musculaire dans les signaux ECG [46].....	71
Figure II.12 Interférence du réseau électrique dans le signal ECG [46].....	71
Figure.III.1 Échantillons de signaux EEG provenant de la base de données EEG de l'Université de Bonn.....	87

Figure III.2. Schéma bloc des approches proposées basées sur des mesures non linéaires des rythmes EEG.....	88
Figure III.3 Un exemple de structure de Réseau de Neurones Profonds.....	96
Figure III.4 Structure typique d'un bloc de Mémoire à Long et Court Terme (LSTM).....	97
Figure III. 5. Les huit principales caractéristiques les mieux classées extraites des deux classes de signaux EEG, avec leurs valeurs moyennes et écarts-types (SD - standard deviation) correspondants pour les quatre sous-bandes (EEG normal en bleu, EEG ictal en rouge).....	100
Figure III.6. Matrice de dispersion des trois fonctionnalités choisies, classées pour deux classes différentes après le filtrage en sous-bandes pour tous les rythmes EEG sélectionnés.....	101
Figure III.7. Taux de classification de trois méthodes (MLP, DNN, LSTM) pour plusieurs cas : a : A-E, b : B-E, c : C-E, d : D-E, e : AB-E, f : CD-E.....	105
Figure III.8 Sensibilité moyenne de classification (%) spécificité (%) précision (%) de tous les cas expérimentaux avec DNN.....	106
Figure.IV.1 : Tracé ECG d'un individu en bonne santé.....	110
Figure IV.2 Exemple de signal présentant une déformation du complexe QRS due à une ESV (Extrasystole).....	111
Figure IV.3 Segments du signal ECG utilisés.....	113
Figure IV.5 Segment du signal utilisé en haut, Première dérivation en bas.....	121
Figure IV.6 Détection des pics R.....	121
Figure IV.7 Détection des complexes QRS + Seuil utilisé.....	124
Figure IV.8 Les six principales caractéristiques les mieux classées extraites des deux classes de signaux ECG, avec leurs valeurs moyennes et écarts-types SD - standard déviation (ECG cycle normal en bleu, ECG extrasystole en rouge).....	125
Figure IV.9 Matrice de dispersion des trois fonctionnalités choisies, classées pour deux classes pour tous les rythmes ECG sélectionnés.....	125
Figure IV.10 Taux de classification de trois méthodes (MLP, DNN, LSTM) pour le cas : A-E1.....	130
Figure IV.11 Taux de classification de trois méthodes (MLP, DNN, LSTM) pour le cas : A-E2.....	130

Liste des tableaux

Table I.1 Analyse fréquentielle du signal EEG.....	14
Table II.1 Artefacts physiologiques et non physiologiques.....	53
Table II.2 Caractéristiques typiques de l'ECG de la dérivation II et leurs valeurs normales dans le rythme sinusal à une fréquence cardiaque de 60 bpm pour un homme adulte en bonne santé [18].	75
Table III.1 Taux de classification pour le vecteur 1.....	104
Table III.2 Taux de classification pour le vecteur 2.....	104
Table III.3 Taux de classification pour le vecteur 3.....	104
Table III.4 Taux de classification pour le vecteur 4.....	105
Table III.5 Meilleure précision de classification avec la sensibilité et la spécificité correspondantes pour différents cas expérimentaux.....	106
Table III.6 Quelques résultats de classification utilisant la base données de Bonn ces dernières années.....	107
Table IV.1 la base de données de tests de bruit de stress MIT-BIH.....	116
Tableau IV.2 Importance des différentes ondes dans le signal ECG.....	117
Table IV.3 Taux de classification pour le vecteur 1.....	129
Table IV.3 Taux de classification pour le vecteur 2.....	129
Table IV.3 Taux de classification pour le vecteur 3.....	129
Table IV.3 Taux de classification pour le vecteur 4.....	129
TableIV.7 Meilleure précision de classification correspondante pour différents cas expérimentaux.....	131

Liste des abréviations

EEG : Electroencéphalogramme.

ECG : Electrocardiogramme.

EMG: Electromyogramme.

EOG: Electrooculogramme.

HRV: Heart Rate Variability.

SNR : Système Nerveux Central.

PA : Potentiel Action.

VT : Valve Tricuspide.

VD : Ventricule Droit.

OD : Oreillette Droite.

VCS : Veine Cave Supérieure.

VCI : Veine Cave Inférieure.

OG : Oreillette Gauche.

VPG : Veines Pulmonaires Gauches.

VPD : Veines Pulmonaires Droites.

VG : Ventricule Gauche.

FFT : transformation de Fourier rapide

STFT : Transformation de Fourier à court terme.

BCI : Interfaces Cerveau-Ordinateur.

ICA : Analyse en Composantes Indépendantes.

ACP : Analyse en Composantes Principales.

PL: Prédiction Linéaire.

LDA : Analyse Discriminante Linéaire.

SVM : Machine à Vecteurs de Support.

GMM : Modèle de Mélange Gaussien.

FSC : Classificateur Flou de Sugeno.

KNN : K-Plus Proches Voisins.

NBC : Classificateur Naïf de Bayes.

DT : Arbre de Décision.

LSTM : Long Short-Term Memory.

DNN: Deep Neural Network .

MLP : Perceptron Multicouche.

INTRODUCTION GENERALE

L'évolution rapide des technologies numériques a renforcé le rôle central du traitement du signal dans des domaines variés tels que les télécommunications, le multimédia, la médecine, la télédétection ou encore le traitement automatique de la parole. Cette discipline vise à analyser, interpréter et transformer les signaux à l'aide d'outils tels que le filtrage, la compression, la prédiction ou encore la classification. Elle occupe une place cruciale dans le domaine biomédical, notamment pour le traitement des signaux physiologiques comme l'EEG et l'ECG, contribuant à la détection précoce des pathologies et à l'amélioration des systèmes de diagnostic et de surveillance.

Les techniques de traitement du signal permettent d'analyser les signaux physiologiques afin d'en extraire les caractéristiques essentielles et d'évaluer leur utilité pour localiser les zones pathologiques. Le traitement et l'analyse des signaux biomédicaux, tels que l'électrocardiogramme (ECG), l'électroencéphalogramme (EEG), l'électromyogramme (EMG), Electrooculogramme (EOG) et Heart Rate Variability (HRV) sont indispensables dans de nombreuses disciplines médicales.

La détection automatique d'événements significatifs dans les signaux EEG et ECG représente un axe de recherche prioritaire en ingénierie biomédicale. Ce travail de thèse s'inscrit dans cette dynamique, avec pour ambition de proposer des méthodes d'analyse avancées permettant de développer des systèmes intelligents d'aide au diagnostic.

L'électroencéphalogramme (EEG), qui mesure l'activité électrique cérébrale, est un outil fondamental dans le diagnostic des troubles neurologiques tels que l'épilepsie, la démence ou encore les troubles du sommeil. Toutefois, l'analyse de ce signal complexe et non stationnaire nécessite des méthodes avancées, notamment l'analyse temps-fréquence, la transformée de Fourier à court terme ou encore les modèles autorégressifs. Malgré cela, certaines limitations subsistent, comme la précision temporelle et la sensibilité au bruit.

L'électrocardiogramme (ECG), de son côté, enregistre l'activité électrique du cœur sous forme graphique. Il permet d'identifier diverses pathologies cardiaques, notamment les arythmies. Ce signal est également essentiel à la conception de dispositifs médicaux tels que les pacemakers, qui nécessitent une modélisation précise du cycle cardiaque. L'analyse de l'EEG, comme celle de

l'ECG, repose sur l'extraction de caractéristiques pertinentes, souvent à l'aide de techniques telles que les transformées en ondelettes, les séries de Fourier ou encore les fonctions d'Hermite.

Cependant, nous avons identifié trois limitations importantes à ces techniques : premièrement, l'extraction des caractéristiques est réalisée à partir de segments de taille fixe, Deuxièmement, l'extraction des paramètres se fait de manière globale à partir de segments, à la fin de l'étape précédente, nous obtenons un vecteur de caractéristiques qui sera utilisé comme entrée pour le classificateur. Plusieurs types de classificateurs ont été testés. Ces derniers jouent un rôle central dans de nombreuses applications réelles et sont des outils incontournables, ayant démontré leur efficacité dans la pratique grâce à leur capacité de généralisation et leur robustesse face au bruit. Dans notre travail, nous nous sommes principalement concentrés sur une architecture neuronale couramment utilisée pour la classification des signaux comme le Perceptron Multi-Couche (MLP).

Le manuscrit de thèse est structuré en quatre chapitres Chaque chapitre commence par une introduction et se termine par un résumé . Le contenu de ces chapitres est organisé de la manière suivante :

Dans le chapitre I, nous explorons en détail les signaux physiologiques tels qu'EEG, ECG, EMG, EOG et HRV, avec un accent particulier sur EEG et ECG. Ces signaux, essentiels pour comprendre et diagnostiquer les dysfonctionnements des systèmes cérébral et cardiaque, sont introduits en décrivant leur nature, leurs applications et leurs défis. L'EEG, qui mesure l'activité électrique cérébrale, est présenté comme un outil clé pour analyser les troubles neurologiques, tels que l'épilepsie, la démence et certains troubles psychiatriques. L'historique des découvertes liées à l'EEG, depuis l'Antiquité jusqu'à aujourd'hui, est détaillé, tout comme les différentes étapes de traitement des données EEG : acquisition, prétraitement, extraction des caractéristiques et classification. Les rythmes cérébraux (delta, thêta, alpha, bêta, gamma), associés à divers états physiologiques (sommeil, relaxation, activité cognitive), sont également abordés. En outre, les anomalies EEG causées par des troubles cérébraux, des crises ou l'effet des médicaments sont décrites. L'ECG, qui enregistre l'activité électrique du cœur, est exploré à travers son évolution historique, ses bases anatomiques et son importance dans le diagnostic des pathologies cardiaques. Le cycle cardiaque est expliqué en trois phases principales : remplissage ventriculaire, contraction isovolumique et relaxation. Le rôle du système cardionecteur, notamment le nœud sinusal, dans la

génération des potentiels d'action est souligné. L'ECG permet de détecter des anomalies comme les arythmies et les troubles coronariens.

Ce chapitre met en évidence l'importance des signaux EEG et ECG dans le diagnostic médical, tout en soulignant les défis liés aux artefacts et au prétraitement des données pour une analyse fiable. Ces avancées ouvrent de nouvelles perspectives dans les applications cliniques et technologiques.

Dans le chapitre II, nous examinons l'état de l'art des signaux électrophysiologiques, notamment l'EEG et l'ECG, en mettant en avant leurs méthodes d'analyse, applications cliniques et défis. Pour l'EEG, largement utilisé dans des domaines comme les interfaces cerveau-ordinateur, l'analyse du sommeil et la détection des crises épileptiques, diverses approches ont été développées pour examiner les variations subtiles des signaux EEG et ECG. Ces approches peuvent être regroupées en quatre grandes catégories : (1) domaine temporel, (2) domaine fréquentiel, (3) domaine temps-fréquence et (4) méthodes non linéaires. Le traitement comprend des étapes telles que la suppression des artefacts (ICA, filtres adaptatifs), l'extraction des caractéristiques (FFT, DWT) et la classification (SVM, LDA). Ces méthodes permettent de diagnostiquer des troubles neurologiques comme l'autisme, la paralysie cérébrale et l'épilepsie. Concernant l'ECG, utilisé pour détecter des anomalies cardiaques, l'analyse inclut des stratégies de débruitage (EMD, DWT) et des indices de qualité du signal (SQI) pour différencier les signaux acceptables des artefacts.

Le chapitre III se concentre sur le développement d'un système automatique pour la détection des crises épileptiques en utilisant des caractéristiques non linéaires extraites des signaux EEG et des techniques avancées d'apprentissage automatique (ML) et d'apprentissage profond (DL). L'épilepsie, affectant plus de 40 millions de personnes, est analysée à travers les signaux EEG, dont les bandes de fréquences (delta, thêta, alpha, bêta) permettent d'identifier les états cérébraux normaux et pathologiques. La méthode proposée repose sur un filtrage des bandes de fréquences et l'extraction de six caractéristiques non linéaires clés, comme les dimensions fractales de Katz et Higuchi, l'entropie multiscalaire modifiée (MMSE) et l'exposant de Hurst. Ces caractéristiques sont ensuite combinées dans des vecteurs pour alimenter divers classificateurs, notamment le Perceptron Multicouche (MLP), le Réseau de Neurones Profond (DNN) et la Mémoire à Long et Court Terme (LSTM). Les résultats expérimentaux montrent une précision de

classification élevée, atteignant jusqu'à 100 % pour certaines combinaisons de vecteurs et classificateurs. La méthode démontre son efficacité dans la différenciation des signaux EEG normaux, interictaux et ictaux, tout en soulignant le rôle des mesures non linéaires.

Le chapitre IV explore la détection des extrasystoles dans les signaux ECG. Après une introduction sur l'importance de l'ECG et des extrasystoles dans les maladies cardiovasculaires, le chapitre détaille les méthodes de traitement des signaux ECG, notamment la segmentation, la normalisation temporelle et d'amplitude, ainsi que l'élimination des bruits (artéfacts musculaires, dérives de la ligne de base, etc.). Les extrasystoles, classées en supraventriculaires et ventriculaires, sont analysées à l'aide d'algorithmes de détection des complexes QRS et d'extraction de caractéristiques non linéaires, comme l'entropie multiscalaire, les dimensions fractales (Higuchi, Katz) et l'analyse des fluctuations détrendées. Ces caractéristiques sont ensuite utilisées dans des modèles de classification avancés, tels que les réseaux de neurones profonds (DNN), les modèles, pour distinguer les cycles cardiaques normaux des cycles pathologiques.

Les résultats expérimentaux, réalisés sur des bases de données de référence (MIT/BIH), montrent une précision de classification élevée, atteignant jusqu'à 100 % dans certaines configurations, soulignant la pertinence des techniques non linéaires pour analyser la nature complexe des signaux ECG. L'approche proposée permet d'automatiser la détection des extrasystoles, de réduire la charge de travail des cardiologues et d'améliorer la prise en charge des patients.

CHAPITRE 1

Signaux physiologiques

Introduction

Les signaux électrophysiologies sont, par définition, des potentiels électriques qui reflètent les changements d'état d'un ou plusieurs organes constituant un sous-système du corps humain. Ces potentiels sont initialement le résultat d'une stimulation chimique. L'étude des signaux électrophysiologies a débuté dans le domaine médical, dans le but de poser un diagnostic de pathologies en analysant les caractéristiques de ces signaux. L'évolution technologique, facilitant l'acquisition et le traitement de ces signaux, a ouvert de nouveaux horizons d'application. Ainsi, les chercheurs ont commencé à s'intéresser à la compensation des déficiences fonctionnelles du corps humain par le contrôle de dispositifs externes. Cette exploration s'est élargie à d'autres domaines. Il existe diverses applications telles que la classification, la traduction ou la détection d'anomalies. On constate depuis quelques années un intérêt croissant pour l'application de l'apprentissage profond aux signaux physiologiques.

Dans ce chapitre, nous proposons un aperçu des signaux physiologiques liés à l'électrophysiologie des organes, Les signaux cardiaques sont souvent étudiés en combinaison avec d'autres mesures physiologiques, notamment l'activité cérébrale enregistrée par EEG et MEG. Ces enregistrements multicanaux fournissent des informations précieuses sur le cerveau, mais sont souvent perturbés par des artefacts tels que l'activité oculaire, musculaire, cardiaque et les interférences environnementales. Ces bruits, parfois d'amplitude supérieure aux signaux utiles, compliquent l'analyse des données et peuvent entraîner des erreurs d'interprétation.

I.1.1. L'ELECTROENCEPHALOGRAMME

Le cerveau est l'organe le plus étonnant et complexe du corps humain, chargé de contrôler tous les autres organes. L'activité neuronale du cerveau humain commence entre la 17^e et la 23^e semaine du développement prénatal. On considère que dès cette étape précoce et tout au long de la vie, les signaux électriques générés par le cerveau reflètent non seulement son fonctionnement, mais également l'état global du corps. Cette hypothèse souligne l'importance d'étudier et de comprendre les différentes activités cérébrales, telles que les rythmes cérébraux normaux, les réponses aux stimuli, la génération des fonctions motrices et la connectivité cérébrale. Des changements dans une ou plusieurs de ces activités sont souvent révélateurs de troubles, de

maladies ou d'anomalies du cerveau. En appliquant des techniques avancées de traitement numérique du signal et d'apprentissage automatique aux signaux électroencéphalographiques (EEG) mesurés à partir du cerveau, il devient possible d'évaluer l'état de santé cérébrale et, dans certains cas, d'inférer la condition globale du corps. Les signaux EEG sont essentiels pour analyser l'activité électrique du cerveau et détecter les troubles neurologiques. Le processus d'analyse des signaux EEG suit généralement plusieurs étapes : (1) l'acquisition des données, (2) le prétraitement, (3) l'extraction des caractéristiques, (4) la sélection des caractéristiques pertinentes, (5) l'entraînement et la classification des modèles, et (6) l'évaluation des performances. Cependant, la compréhension des fonctions neuronales et des propriétés neurophysiologiques du cerveau, ainsi que des mécanismes sous-jacents à la génération des signaux et à leur enregistrement, est essentielle pour ceux qui travaillent avec ces signaux dans le cadre de la détection, du diagnostic et du traitement des troubles cérébraux et des maladies associées. L'examen de l'activité cérébrale ou des anomalies ne se limite toutefois pas à l'utilisation de l'EEG. Nous commençons par fournir une brève histoire des mesures EEG, en examinant le parcours depuis le moment où les fonctions cérébrales ont été initialement reconnues jusqu'à aujourd'hui, où les nouvelles techniques de traitement des données, d'apprentissage automatique et d'intelligence artificielle sont devenues des axes de recherche populaires.

1.1.2. Historique

L'histoire de la compréhension du cerveau remonte à l'Antiquité, avec les premières observations consignées dans le papyrus d'Edwin Smith. Hippocrate identifie l'épilepsie comme une perturbation cérébrale, tandis qu'Avicenne en affine la classification. Au XIXe siècle, Matteucci et Du Bois-Reymond enregistrent pour la première fois des signaux électriques nerveux, posant les bases de la neurophysiologie. En 1912, Pravidch-Neminsky réalise le premier EEG sur un chien, suivi par Hans Berger qui identifie le rythme alpha et initie les recherches EEG humaines dès 1920.

Dans les années 1930, les avancées en EEG s'accroissent avec le développement d'amplificateurs biologiques et l'exploration des anomalies cérébrales par Gibbs, Lennox et Gray Walter. La fondation de la Société Américaine d'EEG en 1947 marque un tournant, tandis que des chercheurs comme Bremer et Motokawa approfondissent les études EEG à travers le monde. Les

années 1950 voient l'essor des interventions chirurgicales pour l'épilepsie et l'apparition des microélectrodes intracérébrales, révolutionnant l'étude des potentiels cérébraux.

L'analyse de Fourier appliquée à l'EEG dès les années 1930 se développe dans les années 1950, facilitant l'interprétation des signaux. Les recherches sur le sommeil débutent avec Kleitman, et les années 1960 et 1970 voient l'émergence des études EEG sur les nouveau-nés et des potentiels évoqués pour le diagnostic des troubles mentaux. Aujourd'hui, les EEG modernes, invasifs ou non invasifs, bénéficient d'outils informatisés avancés, permettant des analyses précises et des enregistrements prolongés dans les domaines clinique et expérimental.

I.1.2 Activités neuronales

Le système nerveux central (SNC) comprend des neurones et des cellules gliales. Chaque neurone est composé d'un corps cellulaire, d'axones et de dendrites. Le corps cellulaire produit des protéines essentielles au fonctionnement du neurone, transportées via un système de « moteurs moléculaires » le long des axones. Ces derniers transmettent les impulsions électriques sur de longues distances, pouvant atteindre plusieurs mètres. Les dendrites, connectées à d'autres cellules nerveuses, reçoivent et relaient les signaux. Dans le cerveau humain, chaque neurone est connecté à environ 10 000 autres via des connexions dendritiques. Dans le SNC, les activités synaptiques sont essentiellement dues aux courants se déplaçant entre les synapses des axones et des dendrites, ou entre dendrites. Un potentiel membranaire d'environ 60 à 70 mV avec une polarité négative peut être mesuré, variant en fonction des activités synaptiques. Lorsqu'un potentiel d'action atteint une synapse excitatrice, il génère un potentiel postsynaptique excitateur (EPSP) dans le neurone suivant. Si plusieurs EPSP se produisent sur une courte distance le long d'une même fibre, ils peuvent s'additionner et déclencher un potentiel d'action, si le seuil de potentiel de membrane est atteint. À l'inverse, une synapse inhibitrice provoque une hyperpolarisation, correspondant à un potentiel postsynaptique inhibiteur (IPSP) [1]. La figure I.1 illustre schématiquement ces activités.

Après la génération d'un potentiel postsynaptique inhibiteur (PPSI), un flux ionique modifie le potentiel de la membrane neuronale. Ce flux génère des courants transmembranaires primaires et secondaires, responsables de la formation des potentiels de champ dans l'espace extracellulaire. Ces potentiels généralement à une fréquence inférieure à 100 Hz, peuvent être enregistrés sous forme d'EEG lorsque le signal moyen reste stable, ou de courants continus (DC) en cas de dérives

lentes dans la moyenne des signaux, ce qui peut masquer les signaux EEG réels. Une combinaison des potentiels EEG et DC est fréquemment observée lors de certaines anomalies cérébrales, telles que les crises (induites par le pentylène-tétrazole), l'hypercapnie et l'asphyxie. L'étude se concentrera ensuite sur la nature des potentiels actifs.

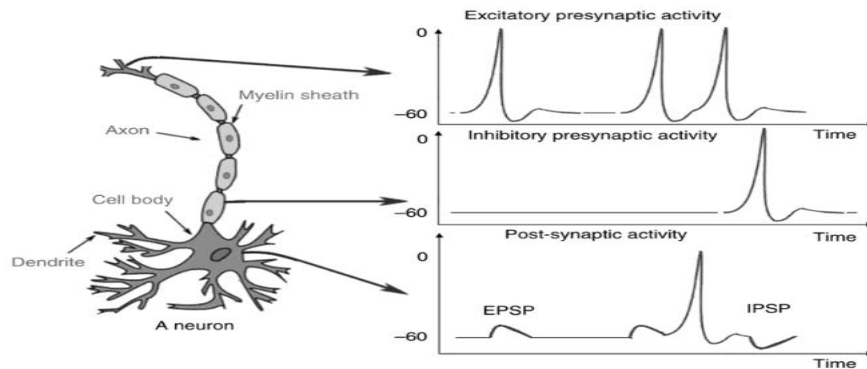


Figure I. 1 Les variations du potentiel de membrane neuronale et le flux de courant lors de l'activation synaptique sont enregistrés au moyen de microélectrodes intracellulaires [1].

I.1.3 Potentiels d'action

Le potentiel d'action (PA) est un changement temporaire du potentiel membranaire, causé par un échange d'ions, qui se propage le long de l'axone. Ce processus, débutant dans le corps cellulaire, inclut une dépolarisation suivie d'une repolarisation de la membrane. Les PA durent entre 5 et 10 millisecondes et se déplacent dans une seule direction. Un exemple est présenté dans la figure 1.2. La vitesse de conduction des potentiels d'action varie entre 1 et 100 m/s. Les PA sont déclenchés par divers types de stimuli ; les nerfs sensoriels réagissent à des stimuli variés tels que les stimuli chimiques, lumineux, électriques, la pression, le toucher et l'étirement. En revanche, les nerfs du système nerveux central (cerveau et moelle épinière) sont principalement stimulés par l'activité chimique aux synapses. Un stimulus doit dépasser un certain seuil pour déclencher un PA.

Les stimuli trop faibles provoquent une petite perturbation électrique locale, mais ne génèrent pas de PA transmis. Dès que l'intensité du stimulus dépasse ce seuil, un potentiel d'action se forme et se propage le long du nerf. Le pic du potentiel d'action est causé par l'ouverture des

canaux sodiques, permettant au sodium de pénétrer dans la cellule et de provoquer la dépolarisation. Ce processus est illustré par la Figure I.3 pour un calmar géant, avec une amplitude de PA chez l'homme allant de -60 mV à 10 mV [1].




Figure I.2 Un exemple de potentiel d'action [1]

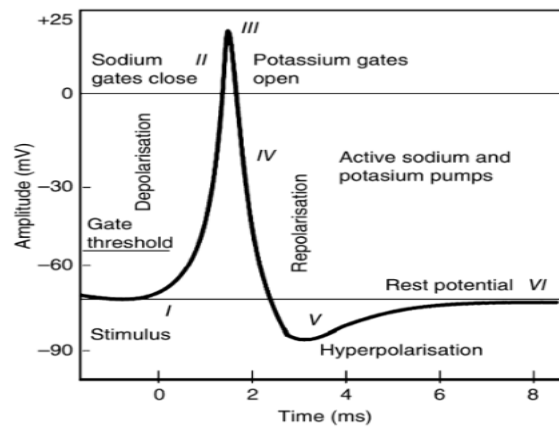


Figure I.3 Modification du potentiel membranaire d'un calmar géant en fermant les canaux Na et en ouvrant les canaux K [1].

1. Lorsque les dendrites d'une cellule nerveuse reçoivent un stimulus, les canaux Na^+ s'ouvrent. Si l'ouverture est suffisante pour faire passer le potentiel intérieur de -70 mV à -55 mV, le processus continue.
2. Dès que le seuil d'action est atteint, des canaux Na^+ supplémentaires (souvent appelés canaux voltage-dépendants) s'ouvrent. L'afflux de Na^+ fait monter le potentiel de la membrane cellulaire à environ $+30$ mV. Ce processus jusqu'à ce point est appelé dépolarisation.

3. Ensuite, les canaux Na^+ se ferment et les canaux K^+ s'ouvrent. Comme les canaux K^+ mettent plus de temps à s'ouvrir, la dépolarisation a le temps de se compléter. Si les canaux Na^+ et K^+ étaient ouverts simultanément, cela ramènerait le système vers la neutralité et empêcherait la création du potentiel d'action.
4. Une fois les canaux K^+ ouverts, la membrane commence à se repolariser, revenant vers son potentiel de repos.
5. La repolarisation dépasse généralement le potentiel de repos, atteignant environ -90 mV . Cela s'appelle l'hyperpolarisation et semble contre-productive, mais elle est en réalité importante pour la transmission de l'information. L'hyperpolarisation empêche le neurone de recevoir un autre stimulus durant ce temps, ou du moins élève le seuil pour tout nouveau stimulus. Son rôle est aussi de prévenir que tout stimulus déjà transmis par un axone ne déclenche un autre potentiel d'action dans la direction opposée. En d'autres termes, l'hyperpolarisation garantit que le signal se propage dans une seule direction.
6. Après l'hyperpolarisation, les pompes Na^+/K^+ ramènent finalement la membrane à son état de repos de -70 mV .

Le nerf nécessite environ deux millisecondes avant qu'un autre stimulus puisse être présenté. Pendant ce temps, aucun potentiel d'action ne peut être généré. Cette période est appelée période réfractaire. La génération des signaux EEG est ensuite décrite.

I.1.4. Génération des signaux EEG

Synaptiques des dendrites de nombreux neurones pyramidaux dans le cortex cérébral. Lorsque les cellules cérébrales (neurones) sont activées, des courants synaptiques se produisent au niveau des dendrites. Ce courant génère un champ magnétique mesurable par des appareils d'électromyogramme (EMG) et un champ électrique secondaire au niveau du cuir chevelu, mesurable par des systèmes EEG. Les différences de potentiels électriques sont causées par les potentiels gradués postsynaptiques sommés des cellules pyramidales, créant des dipôles électriques entre le soma (corps cellulaire du neurone) et les dendrites apicales qui se ramifient à partir des neurones (Figure 1.4). Le courant dans le cerveau est principalement généré par le pompage des ions positifs tels que le sodium (Na^+), le potassium (K^+), le calcium (Ca^{++}) et l'ion

négatif du chlore (Cl^-) à travers les membranes neuronales, selon la direction déterminée par le potentiel de membrane.




Figure I.4 Structure d'un neurone. A gauche : Schéma d'un neurone moteur. A droite : Photographie au microscope électronique à balayage (grossi 6000 fois) montrant le corps cellulaire du neurone et les dendrites.

La tête humaine est composée de différentes couches, notamment le cuir chevelu, le crâne et le cerveau (Figure 1.5), ainsi que plusieurs fines couches intermédiaires. Le crâne atténue les signaux environ cent fois plus que les tissus mous. Par ailleurs, la majorité des interférences proviennent soit du bruit interne généré dans le cerveau, soit du bruit externe ou systémique à la surface du cuir chevelu. Ainsi, seules de grandes populations de neurones actifs peuvent produire des potentiels suffisamment forts pour être détectés par des électrodes placées sur le cuir chevelu. Ces signaux sont ensuite fortement amplifiés pour être visualisés.

À la naissance, environ 10^{11} neurones sont développés, moment où le système nerveux central (SNC) devient complet et fonctionnel. Cela correspond à une moyenne d'environ 10^4 neurones par millimètre cube. Les neurones sont interconnectés par des synapses, formant des réseaux neuronaux. Chez l'adulte, on estime qu'il y a environ 5×10^{14} synapses. Avec l'âge, le nombre de synapses par neurone augmente tandis que le nombre total de neurones diminue. Sur le plan anatomique, le cerveau se divise en trois parties principales : le cerveau, le cervelet et le tronc cérébral (Figure 1.6). Le cerveau comprend les hémisphères gauche et droit, dont la surface très plissée forme le cortex cérébral. Le cerveau comprend les régions responsables de l'initiation des mouvements, de la conscience des sensations, de l'analyse complexe, ainsi que de l'expression des émotions et des comportements.




Figure.I.5. Vue des méninges en trois dimensions. Coupe frontale montrant la situation de la dure-mère, de l'arachnoïde et de la pie-mère. Le feuillet interne de la dure-mère forme la faux du cerveau [15].

À la naissance, environ 10^{11} neurones sont développés, moment où le système nerveux central (SNC) devient complet et fonctionnel [15]. Cela correspond à une moyenne d'environ 10^4 neurones par millimètre cube. Les neurones sont interconnectés par des synapses, formant des réseaux neuronaux. Chez l'adulte, on estime qu'il y a environ 5×10^{14} synapses. Avec l'âge, le nombre de synapses par neurone augmente tandis que le nombre total de neurones diminue. Sur le plan anatomique, le cerveau se divise en trois parties principales : le cerveau, le cervelet et le tronc cérébral (Figure 1.6). Le cerveau comprend les hémisphères gauche et droit, dont la surface très plissée forme le cortex cérébral. Le cerveau comprend les régions responsables de l'initiation des mouvements, de la conscience des sensations, de l'analyse complexe, ainsi que de l'expression des émotions et des comportements. Le cervelet, quant à lui, coordonne les mouvements volontaires des muscles et assure le maintien de l'équilibre. Le tronc cérébral régule les fonctions involontaires telles que la respiration, le contrôle cardiaque, les rythmes biologiques, ainsi que la sécrétion de neurohormones et d'hormones.

Cette liste met en évidence le vaste potentiel de l'analyse EEG et souligne l'importance de techniques avancées de traitement du signal pour assister les cliniciens dans leur interprétation. Les rythmes cérébraux, qui sont généralement observés dans les signaux EEG, seront présentés dans la section suivante.




Figure.I.6 Représentation schématique des principales parties du cerveau [1].

I.1.5 Décomposition fréquentielle du signal EEG

De nombreux troubles cérébraux sont diagnostiqués par inspection visuelle des signaux EEG. Les experts cliniques dans ce domaine sont familiers avec la manifestation des rythmes cérébraux dans les signaux EEG. Chez les adultes en bonne santé, les amplitudes et fréquences de ces signaux varient en fonction des différents états d'une personne, comme l'éveil et le sommeil. Les caractéristiques des ondes changent également avec l'âge. Les signaux EEG occupent une bande fréquentielle limitée, atteignant au maximum 100 Hz. Cependant, les fréquences contenant des informations pertinentes se situent principalement en dessous de 40 Hz. Cette plage de fréquences (0-40 Hz) est couramment subdivisée en cinq bandes, également appelées ondes, comme le montre le Tableau I.1. Cette classification découle de recherches cliniques. Les cinq types d'ondes cérébrales se distinguent par leurs différentes gammes de fréquences. Ces bandes, allant des fréquences les plus basses aux plus élevées, sont appelées alpha (α), theta (θ), beta (β), delta (δ) et gamma (γ). Les ondes alpha et beta ont été décrites pour la première fois par Berger en 1929. Jasper et Andrews (1938) ont utilisé le terme « gamma » pour désigner les ondes supérieures à 30 Hz. Le rythme delta a été introduit par Walter (1936) pour désigner toutes les fréquences

inférieures à la gamme alpha. Il a également introduit les ondes theta comme celles ayant des fréquences comprises entre 4 et 7,5 Hz. La notion d'onde theta a été introduite par Wolter et Dovey en 1944.

Table I.1 Analyse fréquentielle du signal EEG.

Bande	Fréquence (Hz)	Etude physiologique
Delta δ	0.1-4	sommeil lent profond
Thêta θ	4 - 8	sommeil lent léger
Alpha α	8 - 12	veille calme, repos les yeux fermées
Mu μ	8 - 13	veille calme, repos moteur
Beta β	13-30	veille active, tâche cognitives
Gamma γ lent	30 -70	traitement cognitif spécifique
Gamma γ rapide	>70	traitement cognitif spécifique

Les ondes delta se situent dans la gamme de 0,5 à 4 Hz. Elles sont principalement associées au sommeil profond, bien qu'elles puissent également être présentes pendant l'état de veille. Il est facile de confondre les signaux d'artefacts causés par les gros muscles du cou et de la mâchoire avec la véritable réponse delta. En effet, ces muscles, étant proches de la surface de la peau, produisent des signaux importants, tandis que le signal d'intérêt provient des profondeurs du cerveau et est fortement atténué lorsqu'il traverse le crâne. Cependant, en appliquant des méthodes simples d'analyse du signal à l'EEG, il est facile de déterminer lorsque la réponse est due à un mouvement excessif. Les ondes thêta se situent dans la plage de 4 à 7,5 Hz. Le terme "thêta" a été choisi pour faire référence à leur origine présumée dans le thalamus. Ces ondes apparaissent lorsque la conscience s'oriente vers un état de somnolence. Elles ont été associées à l'accès à des contenus inconscients, à l'inspiration créative et à une méditation profonde. Une onde thêta est souvent accompagnée d'autres fréquences et semble être liée au niveau de l'excitation. Il est connu que les guérisseurs et les médiateurs expérimentés présentent une onde alpha qui diminue progressivement en fréquence au cours de longues périodes. L'onde thêta joue un rôle crucial dans l'enfance et la petite enfance. Des niveaux plus élevés d'activité des ondes thêta chez l'adulte éveillé sont anormaux et peuvent être causés par divers problèmes pathologiques. Les changements dans le rythme des ondes thêta sont étudiés dans le cadre de recherches sur la maturation et les émotions.

Les ondes alpha, de fréquence 8-13 Hz, se manifestent principalement dans la région occipitale du cerveau et sont liées à un état de relaxation sans concentration. Elles peuvent prendre une forme sinusoïdale ou, plus rarement, aiguë, similaire au rythme mu rolandique. Les ondes

alpha sont associées à des états de détente et de veille, et leur présence est souvent observée lorsque les yeux sont fermés. Elles sont supprimées par des stimuli comme l'ouverture des yeux, les sons inconnus, l'anxiété ou la concentration. Bien que leur origine et signification physiologique soient encore inconnues, des recherches sont en cours pour mieux comprendre ce phénomène .

Une onde beta correspond à l'activité électrique du cerveau variant entre 14 et 26 Hz (bien que certaines sources ne fixent pas de limite supérieure). Elle représente généralement le rythme cérébral de l'état de veille, associé à une pensée active, à l'attention, à la concentration sur le monde extérieur ou à la résolution de problèmes concrets, et est couramment observée chez les adultes en bonne santé. Une onde beta de niveau élevé peut apparaître lorsqu'une personne est en état de panique. Cette activité rythmique est principalement observée dans les régions frontale et centrale. Il est important de noter qu'un rythme beta central est lié au rythme mu rolandique et peut être inhibé par une activité motrice ou une stimulation tactile. L'amplitude de ce rythme beta est généralement inférieure à 30 μ V. De manière similaire au rythme mu, l'onde beta peut aussi être renforcée par un défaut osseux ou autour des régions tumorales.

Les fréquences supérieures à 30 Hz (principalement jusqu'à 45 Hz) correspondent à la gamme gamma (parfois appelée onde beta rapide). Bien que les amplitudes de ces rythmes soient très faibles et leur apparition rare, leur détection peut être utilisée pour confirmer certaines maladies cérébrales. Les régions de fréquences EEG élevées et les niveaux les plus élevés de flux sanguin cérébral (ainsi que l'absorption d'oxygène et de glucose) se trouvent dans la zone frontocentrale. La bande des ondes gamma a également été prouvée comme un bon indicateur de la synchronisation liée à un événement du cerveau et peut être utilisée pour localiser le mouvement des index droit et gauche, des orteils droits et de la zone assez large et bilatérale du mouvement de la langue.

Des ondes dans des fréquences bien plus élevées que celles de l'activité normale de l'EEG, principalement dans la gamme de 200 à 300 Hz, ont été trouvées dans les structures cérébelleuses des animaux, mais elles n'ont pas joué de rôle en neurophysiologie clinique. La figure 1.7 présente les rythmes cérébraux normaux typiques avec leurs niveaux d'amplitude habituels. En général, les signaux EEG sont la projection des activités neuronales, atténuées par les leptoméninges, le liquide céphalo-rachidien, la dure-mère, les os, la galea et le cuir chevelu. Les décharges cartographiques

montrent des amplitudes de 0,5 à 1,5 mV, et peuvent atteindre plusieurs millivolts pour les pointes. Cependant, sur le cuir chevelu, les amplitudes se situent généralement entre 10 et 100 μ V.

Les rythmes mentionnés ci-dessus peuvent durer si l'état du sujet ne change pas et sont donc généralement cycliques par nature. En revanche, d'autres formes d'ondes cérébrales peuvent : Les rythmes cérébraux, détectés par EEG, peuvent varier selon leur fréquence, leur amplitude et leur origine. Parmi les différents types de rythmes, on trouve Les rythmes EEG peuvent être affectés par des artefacts et des troubles cérébraux, comme les lésions tumorales. Les signaux peuvent aussi être transitoires. Le rythme mu, associé au cortex moteur, est cyclique et peut être bloqué par des mouvements physiques. En résumé, les rythmes EEG reflètent divers états cérébraux, et leur analyse aide à comprendre les fonctions cérébrales et à identifier les anomalies.

I.1.6 Enregistrement et Mesure de l'EEG

Les systèmes EEG modernes comportent des électrodes sensibles, des amplificateurs différentiels, des filtres, et des dispositifs d'enregistrement de type styler. L'évolution a conduit à des systèmes informatisés capables de numériser et stocker les signaux EEG. La conversion analogique-numérique des signaux EEG est effectuée par des convertisseurs multicanaux, avec une bande passante limitée à environ 100 Hz. Une fréquence d'échantillonnage de 200 échantillons/s est souvent suffisante, mais des fréquences plus élevées peuvent être utilisées pour des résolutions supérieures. Le bon fonctionnement des électrodes d'enregistrement EEG est crucial pour obtenir des données de qualité, et différents types d'électrodes sont utilisés pour ces enregistrements.

- Électrodes jetables (types sans gel ou pré-gélées) ;
- Électrodes à disque réutilisables (en or, argent, acier inoxydable ou étain) ;
- Bandeaux et bonnets électrodes ;
- Électrodes à base de solution saline ;
- Électrodes à aiguille.

Pour les enregistrements multicanaux nécessitant un grand nombre d'électrodes, des casques d'électrodes sont souvent utilisés. Les électrodes de cuir chevelu les plus courantes sont des disques en Ag–AgCl, de moins de 3 mm de diamètre, équipés de fils flexibles et longs pouvant

être connectés à un amplificateur. Les électrodes en aiguille, quant à elles, doivent être implantées sous le crâne par des interventions minimales. Une forte impédance entre le cortex et les électrodes, ou des électrodes à haute impédance, peut entraîner des distorsions pouvant même masquer les signaux EEG réels. Les systèmes commerciaux d'enregistrement EEG incluent souvent des moniteurs d'impédance. Pour garantir un enregistrement satisfaisant, les impédances des électrodes doivent être inférieures à $5\text{ k}\Omega$ et équilibrées à moins de $1\text{ k}\Omega$ entre elles. Pour des mesures plus précises, ces impédances sont vérifiées après chaque essai. Cependant, en raison de la structure en couches et en spirale du cerveau, la distribution des potentiels sur le cuir chevelu (ou le cortex) n'est pas uniforme [1]. Cette inégalité peut influencer certains résultats liés à la localisation des sources à partir des signaux EEG.

1.1.6.1. Positionnement conventionnel des électrodes

La fédération internationale des sociétés d'électroencéphalographie et de Neurophysiologie clinique recommande l'utilisation du système conventionnel de positionnement des électrodes, appelé système 10–20, pour un total de 21 électrodes (hors électrodes de lobes d'oreille), comme illustré dans la figure I.8. Les électrodes des lobes d'oreille, désignées A1 et A2, sont souvent utilisées comme électrodes de référence, étant connectées respectivement aux lobes gauche et droit. Le système 10–20 évite les positions trop proches des globes oculaires et se base sur des distances constantes mesurées à partir de repères anatomiques spécifiques. Ces distances sont ensuite divisées en intervalles correspondant à 10 ou 20 % de la distance totale. Les électrodes impaires sont placées sur le côté gauche et les électrodes paires sur le côté droit. Pour un nombre d'électrodes plus important, des électrodes supplémentaires sont positionnées de manière équidistante entre celles déjà définies par le système 10–20. Par exemple, l'électrode C1 est placée entre C3 et Cz. La Figure 1.9 illustre une configuration élargie avec 75 électrodes, y compris les électrodes de référence, conformément aux recommandations de l'American EEG Society. Des électrodes supplémentaires peuvent parfois être utilisées pour enregistrer les activités EOG, ECG ou EMG des paupières et des muscles entourant les yeux. Dans certaines applications spécifiques, comme l'analyse des potentiels évoqués (ERP) ou l'interface cerveau-ordinateur, un seul canal peut suffire. Cependant, dans ces cas, la position de l'électrode concernée doit être précisément définie.




Figure I.7 Positions conventionnelles des électrodes EEG 10–20 pour le placement de 21 électrodes.

Par exemple, les électrodes C3 et C4 peuvent être utilisées pour enregistrer les signaux associés aux mouvements des doigts droit et gauche dans les applications d'interface cerveau-machine (BCI). Deux modes d'enregistrement sont couramment utilisés : le mode différentiel et le mode référentiel. En mode différentiel, les deux entrées de chaque amplificateur différentiel proviennent de deux électrodes distinctes. En mode référentiel, une ou deux électrodes de référence sont utilisées. Différentes positions de référence sont mentionnées dans la littérature, telles que le sommet du crâne (Cz), les oreilles reliées, les mastoïdes reliées, l'oreille ipsilatérale, l'oreille controlatérale, C7, des références bipolaires ou encore le bout du nez. Il existe également des techniques d'enregistrement sans référence, qui utilisent une moyenne commune comme référence. Cependant, le choix de la référence peut entraîner des distorsions topographiques si elle n'est pas relativement neutre. Dans un autre système similaire, appelé le système de positionnement des électrodes Maudsley, le système conventionnel 10–20 a été modifié pour mieux capter les signaux des foyers épileptiques lors des enregistrements de crises. La principale différence réside dans l'abaissement des électrodes externes afin de mieux enregistrer les signaux nécessaires. Ce système offre une couverture plus étendue de la partie inférieure de la convexité cérébrale, augmentant ainsi la sensibilité pour les enregistrements des structures sous-temporales basales. D'autres adaptations du système international 10–20 utilisées par des chercheurs sont décrites dans la référence [1].

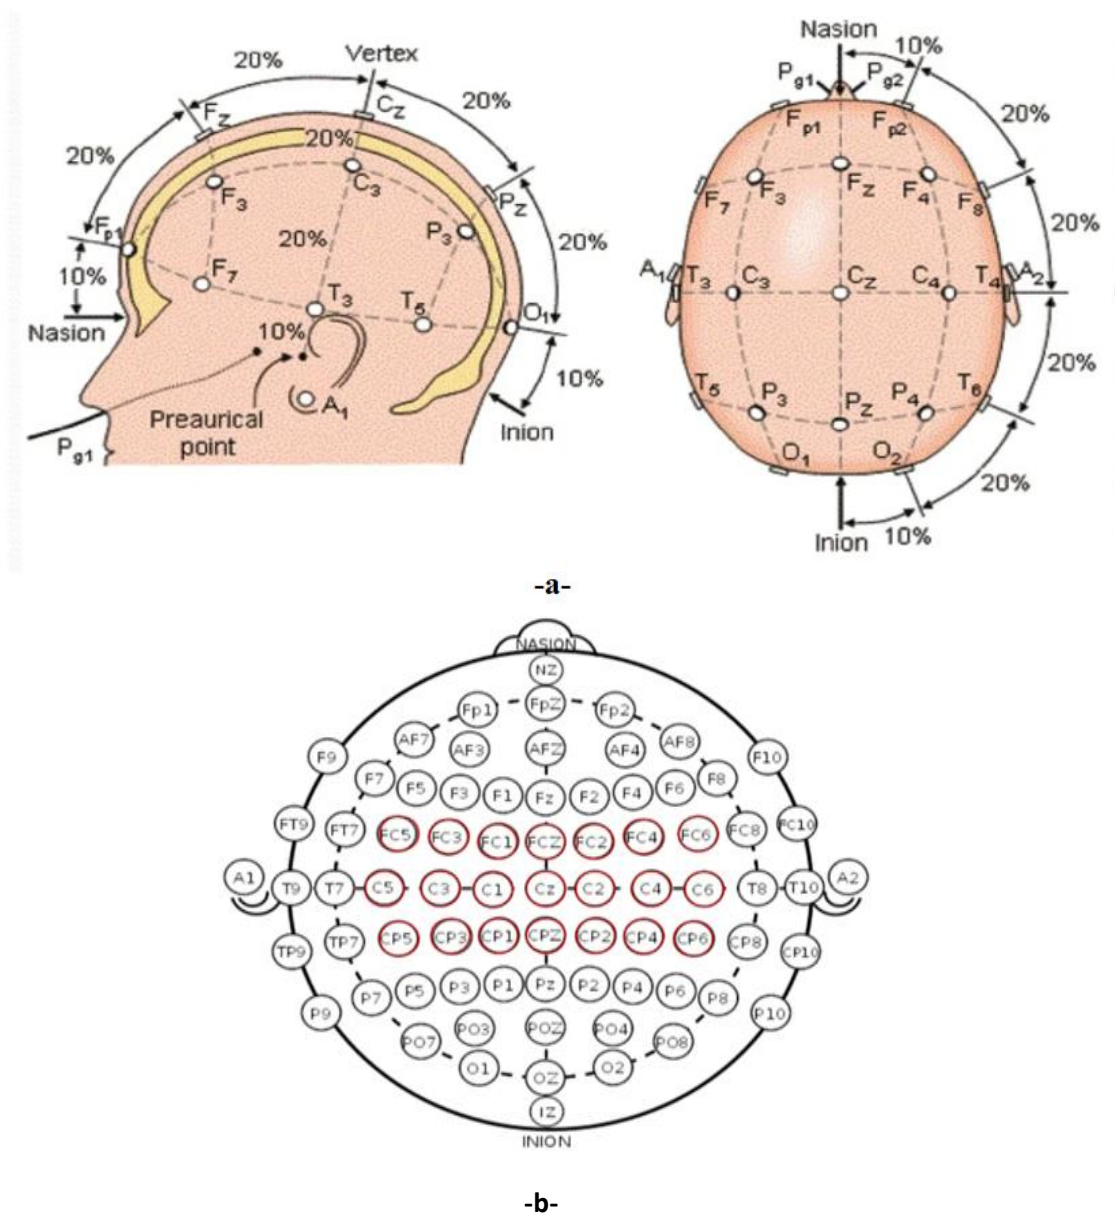


Figure I.8 Représentation schématique de 10 à 20 réglages d'électrodes pour 75 électrodes, y comprises électrodes de référence : (a) représente les mesures tridimensionnelles, et (b) indique une vue bidimensionnelle de la configuration de l'installation des électrodes

1.1.6.2 Conditionnement des signaux

Les signaux EEG bruts ont des amplitudes de l'ordre du microvolt et comprennent des composants fréquentiels allant jusqu'à 300 Hz. Afin de conserver les informations pertinentes, ces

signaux doivent être amplifiés avant leur conversion analogique-numérique (ADC) et filtrés, soit avant, soit après l'ADC, pour réduire le bruit et rendre les signaux adaptés au traitement et à la visualisation. Les filtres sont conçus pour éviter toute modification ou distorsion des signaux.

Des filtres passe-haut, avec une fréquence de coupure généralement inférieure à 0,5 Hz, sont utilisés pour éliminer les très basses fréquences perturbatrices, comme celles liées à la respiration. À l'inverse, les bruits à haute fréquence sont atténués à l'aide de filtres passe-bas ayant une fréquence de coupure d'environ 50 à 70 Hz. Enfin, des filtres en échancrure, réglés sur une fréquence nulle de 50 Hz, sont souvent nécessaires pour rejeter efficacement les interférences dues à l'alimentation électrique à 50 Hz. Dans ce contexte, la fréquence d'échantillonnage peut être aussi basse que deux fois la largeur de bande utilisée par la plupart des systèmes EEG. Les fréquences d'échantillonnage couramment employées pour les enregistrements EEG sont de 100, 250, 500, 1000 et 2000 échantillons par seconde. Les principaux artefacts sont classés en deux catégories :

- Artefacts liés au patient (physiologiques) : mouvements corporels, EMG (électromyogramme), ECG (électrocardiogramme) et pulsations, EOG (électro-oculogramme), ballistocardiogramme et transpiration.
- Artefacts liés au système : interférences de l'alimentation électrique à 50/60 Hz, fluctuations d'impédance, défauts de câbles, bruit électrique provenant des composants électroniques, et déséquilibres d'impédance des électrodes.

Ces artefacts sont généralement réduits de manière significative lors de l'étape de prétraitement, ce qui permet de restaurer les informations pertinentes pour l'analyse.

I.1.7. Modèles EEG anormaux

Les variations des modèles EEG peuvent signaler des anomalies liées à des dysfonctionnements cérébraux. Sharbrough classe ces anomalies en trois catégories : (a) les ondes lentes intermittentes associées à des troubles cérébraux, (b) les EEG bilatéraux persistants liés à des altérations de la conscience et (c) les EEG focaux persistants indiquant des perturbations cérébrales localisées.

Les anomalies EEG se divisent également en trois types : les signaux de type "burst", influencés par des facteurs externes et liés à des pathologies comme les tumeurs ; les EEG bilatéraux persistants, associés à une conscience altérée ; et les EEG focaux persistants, marqués par des distorsions des rythmes normaux et des pertes de réactivité, souvent causés par des lésions ou inflammations. L'analyse et la classification des anomalies EEG nécessitent une approche dynamique intégrant des informations neurologiques et cliniques pour mieux diagnostiquer des pathologies comme l'épilepsie, la SSPE ou la maladie de Creutzfeldt–Jakob.

I.2. L'ELECTROCARDIOGRAMME

En raison de son caractère non invasif, de son innocuité et de la richesse des informations contenues dans le signal électrocardiographique, l'électrocardiographie constitue une méthode privilégiée pour l'exploration du myocarde. Celui-ci, élément central du système cardiovasculaire, a pour fonction principale d'assurer un flux sanguin continu, sous pression adéquate, vers les organes et les tissus afin de répondre à leurs besoins énergétiques et de permettre leur renouvellement cellulaire.

I.2.1.Historique

L'électrocardiographie a évolué grâce à des avancées technologiques et scientifiques majeures. Au XVIII^e siècle, Galvani observe des phénomènes électriques précédant la contraction musculaire. En 1856, Koëlliker et Mueller détectent une activité électrique cardiaque, tandis que Lippmann invente l'électromètre capillaire en 1872, permettant à Marey d'enregistrer les premiers potentiels cardiaques animaux.

En 1887, Waller démontre que les courants cardiaques sont mesurables à la surface du corps et introduit le terme « électrocardiogramme ». Einthoven perfectionne ensuite le galvanomètre à corde (1894-1903), standardise les ondes ECG et réalise les premiers enregistrements à distance en 1906. Entre 1910 et 1930, Lewis cartographie les potentiels épicaudiques, et des travaux sur les troubles du rythme et les pathologies coronaires émergent.

Les années 1926-1942 voient l'apparition du premier ECG portable (1926) et la standardisation des électrodes modernes (1934). Goldberger introduit les dérivations unipolaires

en 1942, formant le système à 12 dérivations encore utilisé aujourd'hui. Des avancées suivent avec l'identification des maxima et minima de potentiel thoracique (1939) et les premières courbes isopotentielles humaines (1951).

Dans les années 1960-1980, des études approfondissent la complexité des potentiels thoraciques et soulignent les défis du traitement des données. Entre 1995 et 2003, les progrès informatiques redynamisent l'électrocardiographie thoracique, favorisant son application diagnostique pour certaines pathologies. Toutefois, des limitations subsistent : le système à 12 dérivations ne couvre pas toutes les anomalies, et l'électrocardiographie thoracique reste peu répandue en clinique en raison de coûts élevés et d'un manque de standardisation.

I.2.2 Anatomie du cœur

Le cœur est un muscle qui se contracte continuellement, dès les premiers mois de la vie embryonnaire jusqu'à la mort. Au cours d'une vie, il battra environ 3 milliards de fois. Sa principale fonction est de pomper et de propulser le sang vers l'ensemble des organes du corps. Chaque minute, il pompe environ 5 litres de sang. Le cœur est constitué de deux ventricules et de deux oreillettes (Figure I.9). Chaque oreillette, droite et gauche, est en communication avec le ventricule correspondant. Dans l'oreillette droite (OD), arrivent la veine cave supérieure (VCS) et la veine cave inférieure (VCI), tandis que l'oreillette gauche (OG) reçoit le sang des quatre veines pulmonaires : les veines pulmonaires gauches (VPG) et droites (VPD). Le sang est ensuite expulsé du ventricule gauche (VG) par l'aorte (Ao) et du ventricule droit (VD) par l'artère pulmonaire (AP). Ces vaisseaux — artères, veines et capillaires — constituent le réseau de transport sanguin. Les artères acheminent le sang riche en oxygène (O₂) vers les organes, tandis que les veines ramènent le sang chargé de dioxyde de carbone (CO₂) vers le cœur. Les capillaires, quant à eux, sont de fins vaisseaux permettant les échanges entre le sang des artères et celui des veines. Chaque oreillette communique avec le ventricule correspondant par des orifices auriculo-ventriculaires équipés de valves. À gauche, la valve mitrale (VM) régule ce passage, tandis qu'à droite, c'est la valve tricuspide (VT). L'artère pulmonaire est dotée de trois valvules sigmoïdes pulmonaires (VSP), un système empêchant le reflux sanguin, et l'aorte possède également un système similaire avec ses valvules sigmoïdes aortiques (VSAo). Ces valves permettent uniquement le flux du sang des oreillettes vers les ventricules. Le sang appauvri en oxygène arrive à l'oreillette droite depuis l'ensemble des organes, à l'exception des poumons, par les veines caves (VCS et VCI). Il est

ensuite dirigé vers le ventricule droit, qui le pompe dans l'artère pulmonaire en direction des poumons. Là, le sang s'oxygène grâce à l'air inspiré, puis retourne dans l'oreillette gauche par les veines pulmonaires. De là, il passe dans le ventricule gauche, qui l'expulse dans l'aorte pour alimenter le reste du corps [3].

I.2.2 Cycle cardiaque :

Le cycle cardiaque comprend deux phases principales : une phase de contraction complète du cœur, appelée la systole, suivie d'une phase de relâchement complète, appelée la diastole. Il existe une synchronisation entre l'activité du cœur droit (oreillette droite et ventricule droit) et celle du cœur gauche (oreillette gauche et ventricule gauche). Le cycle cardiaque se décompose en trois étapes successives, illustrées ici à travers l'exemple du ventricule gauche (Figure I.10).

- Remplissage ventriculaire : Lorsque la valve aortique est fermée, le sang en provenance des veines pulmonaires s'écoule dans l'oreillette gauche. Pendant que le ventricule gauche se relâche, la contraction de l'oreillette gauche pousse le sang à travers la valve mitrale dans le ventricule. Cette phase correspond au remplissage du ventricule gauche.
- Contraction isovolumique et éjection systolique : Une fois le sang accumulé dans le ventricule gauche, la pression intraventriculaire augmente en raison de la contraction ventriculaire. La valve aortique reste fermée à ce stade, ce qui maintient un volume constant dans le ventricule (phase isovolumique). Lorsque la pression ventriculaire dépasse celle de l'aorte, la valve aortique s'ouvre, permettant au sang d'être expulsé dans la circulation systémique. Durant cette phase, le volume ventriculaire diminue d'environ 70 à 80 mL (volume d'éjection systolique). Pendant ce temps, les oreillettes se relâchent (diastole) et se remplissent à nouveau de sang.
- Relaxation ventriculaire : Une fois l'éjection terminée, le ventricule gauche se relâche complètement (diastole). La pression intraventriculaire, devenue inférieure à celle de l'aorte, provoque la fermeture de la valve aortique, marquant le début d'un nouveau cycle cardiaque.




Figure I.9 Anatomie du cœur [3].




Figure I.10 Cycle cardiaque [4].

I.2.3 Activité électrique cardiaque

Le fonctionnement normal du muscle cardiaque (myocarde) repose sur la génération et la propagation d'un potentiel d'action, suivies d'une période réfractaire avant la génération de l'impulsion suivante. Ce mécanisme dépend de l'activation séquentielle de cellules spécialisées, appelées cellules cardionectrices ou pacemakers cardiaques (Figure I.11).




Figure I.11 Représentation du système de cellules cardionectrices du cœur [3]

Ces cellules, regroupées au sein du nœud sinusal situé près de la veine cave supérieure, produisent spontanément des potentiels d'action à un rythme régulier, généralement de 100 à 110 impulsions par minute. Ces potentiels d'action se propagent progressivement à travers les cellules cardiaques, depuis les oreillettes jusqu'au nœud atrioventriculaire, puis le long du faisceau de His et du réseau de Purkinje (Figure I.11).

La génération des potentiels d'action dans le myocarde résulte de l'activation et de l'inactivation successives de canaux ioniques membranaires, permettant les courants de dépolarisation (entrée des ions sodium, Na^+ , et calcium, Ca^{2+}) et de repolarisation (sortie des ions potassium, K^+) dans les cellules cardiaques. Ce fonctionnement électrique coordonné du cœur est observable par un électrocardiogramme (ECG) de surface (Figure 1.12).




Figure I.12 Illustration et interprétation des différentes ondes d'un électrocardiogramme. Un battement cardiaque est représenté

I.2.4 Fréquence cardiaque

La fréquence cardiaque correspond au nombre de battements du cœur par minute. Elle peut être influencée par divers facteurs : par exemple, après une émotion intense comme la peur, notre cœur accélère. Le cœur, constitué de cellules musculaires, nécessite une stimulation par des influx nerveux pour se contracter. Cependant, il est à l'abri du phénomène de téτανisation (contraction permanente) observé dans les muscles squelettiques, ce qui lui permet de remplir sa fonction de pompe. En effet, le cœur possède un système interne capable de générer des influx nerveux autonomes, assurant la contraction des fibres cardiaques : on parle d'autoexcitabilité.

Plusieurs faits illustrent cette propriété : les battements cardiaques apparaissent dès la 4^e semaine de développement embryonnaire, et quelques jours plus tard, le sang commence à circuler

dans les vaisseaux de l'embryon, alors que le cœur n'est pas encore innervé ; en laboratoire, des fibres musculaires cardiaques cultivées montrent des contractions spontanées et rythmiques ; de même, un cœur transplanté continue de battre malgré la coupure de toutes ses connexions nerveuses. Ce système, appelé système de conduction cardiaque ou système cardionecteur, est constitué de cellules nodales. Ces cellules produisent et transmettent des influx nerveux permettant aux fibres cardiaques de se contracter de manière coordonnée, des oreillettes aux ventricules, comme si le cœur fonctionnait tel un tout unique.

Le nœud sinusal, situé sous l'entrée de la veine cave supérieure, agit comme un centre rythmogène ou pacemaker naturel du cœur. Ses cellules se dépolarisent spontanément de 70 à 80 fois par minute, générant des influx qui se propagent dans le système de conduction pour assurer les contractions rythmiques du cœur. Bien que ce système soit autonome et indépendant du système nerveux, il peut être influencé par le système nerveux autonome. En cas de dysfonctionnement du nœud sinusal, des pacemakers artificiels, ou stimulateurs cardiaques, peuvent être implantés temporairement ou de façon permanente dans le thorax pour maintenir un rythme cardiaque normal.

I.2.5 Le signal électrique cardiaque

L'électrocardiographie permet d'étudier l'activité électrique des cellules cardiaques, essentielle à leur contraction. Le tracé graphique obtenu, appelé électrocardiogramme (ECG), peut se modifier en cas d'anomalies dans la génération ou la propagation des influx électriques, dans la masse cellulaire globale ou régionale, ou en présence de souffrance cellulaire. Ce signal fournit des informations cruciales, largement exploitées en médecine.

Un cycle cardiaque complet équivaut à une période cardiaque, correspondant à un peu plus d'un battement par seconde chez un adulte. Les bruits cardiaques entendus lors d'une auscultation proviennent des fermetures successives des valves. L'ECG reflète la propagation de l'onde de dépolarisation dans le cœur. Les électrodes placées sur le corps mesurent cette propagation en fonction de la distance de l'onde : lorsque l'onde se rapproche d'une électrode, le signal est positif ; lorsqu'elle s'éloigne, le signal devient négatif.

1.2.5.1 Les dérivations électrocardiographiques

a) **Les dérivations bipolaires**

Les dérivations bipolaires enregistrent les variations de potentiel entre deux électrodes placées à la surface du corps. La ligne de dérivation désigne l'axe théorique reliant ces deux électrodes d'enregistrement.

- **I ou D I** : entre le bras droit et le bras gauche.
- **II ou D II** : entre le bras droit et la jambe gauche.
- **III ou D III** : entre le bras gauche et la jambe gauche.

Ces trois dérivations forment les côtés du triangle d'Einthoven (Figure 1.4 a), un triangle théoriquement équilatéral dont le cœur occupe le centre.

b) **Les dérivations unipolaires des membres**

Une électrode exploratrice, connectée au pôle positif de l'électrocardiographe, est placée sur le corps. Le pôle négatif est relié à une électrode neutre, appelée borne centrale de Wilson (Figure 1.4 b) :

- **aVR** : électrode sur le bras droit, reliée à la borne centrale.
- **aVL** : électrode sur le bras gauche, reliée à la borne centrale.
- **aVF** : électrode sur la jambe gauche, reliée à la borne centrale.

Chaque ligne de ces dérivations passe par un sommet du triangle d'Einthoven et son centre géométrique. Les dérivations bipolaires et unipolaires des membres analysent l'activité électrique du cœur dans le plan frontal.

c) **Les dérivations unipolaires précordiales : V1, V2, V3, V4, V5, V6**

Dans ces dérivations, l'électrode exploratrice est reliée au pôle positif de l'électrocardiographe, tandis que le pôle négatif est connecté à la borne centrale (Figure I.13 c). Ces électrodes explorent l'activité électrique cardiaque dans un plan approximativement horizontal.




Figure I.13 Les dérivation électrocardiographiques, a : Les dérivation bipolaires, b : les dérivation unipolaires des membres, c : Les dérivation unipolaires précordiales

I.2.5.3 Notion vectorielle

Pour comprendre le principe des dérivation, il est essentiel de revenir à une notion fondamentale, les différences de potentiel et les vecteurs. L'ECG correspond à l'enregistrement des potentiels électriques traversant le cœur. La propagation des potentiels d'action dans le myocarde reflète en réalité le déplacement d'une zone de dépolarisation (positive) au sein d'un tissu cardiaque repolarisé (négatif). L'ECG enregistre donc l'intensité, la vitesse et la direction moyenne de ce front de propagation. Cela revient à mesurer le vecteur représentant la différence de potentiel entre les zones positive et négative. Par conséquent, un cœur au repos, entièrement repolarisé (négatif) ou entièrement dépolarisé (positif), produit un enregistrement "nul" visible sous la forme d'une ligne de base, appelée ligne isoélectrique. Lorsqu'une électrode détecte qu'un front positif se rapproche, elle enregistre un signal positif. À l'inverse, si ce front s'éloigne, le signal enregistré sera négatif.

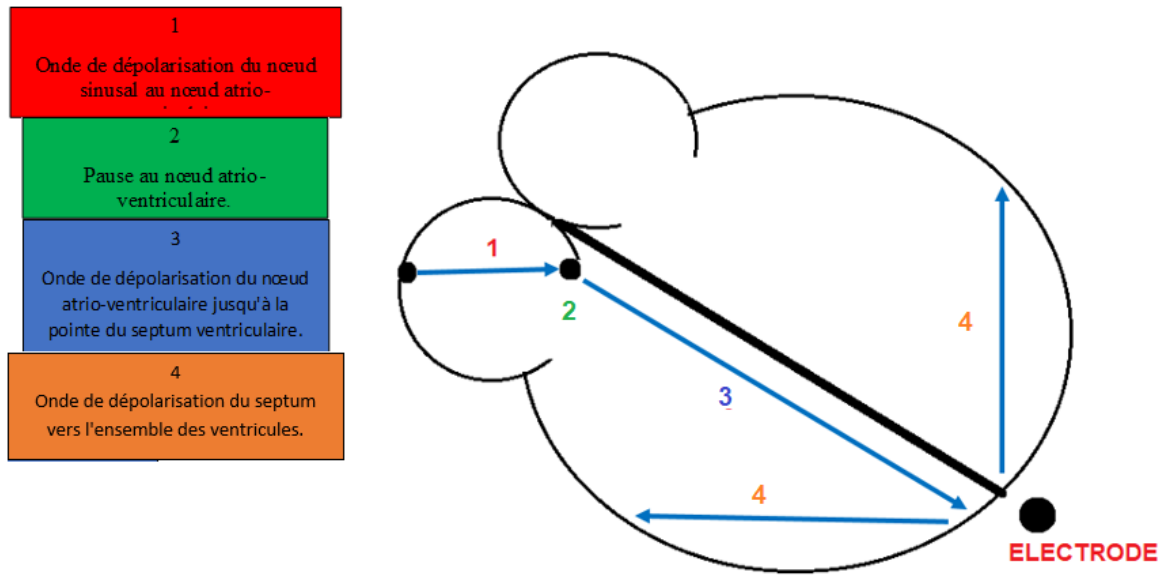


Figure L14 Propagation du signal électrique

En bas, en noir, l'électrode qui enregistre le signal ci-dessous. Activation cardiaque et ECG
Signal enregistré par l'électrode

1. Onde positive : le signal se dirige vers l'électrode.
2. Tracé isoélectrique : absence de déplacement de la dépolarisation.
3. Onde positive : le signal se dirige vers l'électrode.
4. Onde négative : le signal s'éloigne de l'électrode.
5. Tracé isoélectrique : myocarde au repos (totalement repolarisé).figure




Figure L15 Le signal enregistré par l'électrode

I.2.6. Les Arythmies Cardiaques

Les arythmies cardiaques sont une cause majeure de mortalité et un enjeu central des maladies cardiovasculaires. Leur compréhension reste limitée, et les traitements, qu'ils soient médicamenteux ou basés sur l'électrostimulation, reposent souvent sur des approches empiriques aux résultats imprévisibles. Une attention particulière est portée aux arythmies liées à l'infarctus du myocarde, aux blocs de conduction auriculo-ventriculaires et à la fibrillation ventriculaire, à travers l'analyse de signaux recueillis chez des patients.

Le rythme cardiaque est régulé par le nœud sinusal, qui ajuste la fréquence des impulsions électriques selon les besoins de l'organisme. Il peut ralentir jusqu'à 45 battements par minute chez un athlète au repos et atteindre 180 battements par minute lors d'un effort intense. Une arythmie survient lorsque l'excitation électrique ne provient pas du nœud sinusal ou suit une trajectoire anormale, entraînant une contraction irrégulière du cœur. Une contraction prématurée, ou extrasystole, perturbe la séquence normale et peut provoquer une pause compensatrice ressentie comme une interruption du rythme.

Les arythmies sont classées en fonction de leur origine et de leur effet sur le rythme cardiaque. Les arythmies supraventriculaires concernent les oreillettes ou le nœud atrio-ventriculaire, tandis que les arythmies ventriculaires affectent les ventricules. Une augmentation anormale du rythme cardiaque est appelée tachycardie, tandis qu'un ralentissement est désigné sous le terme de bradycardie. Certaines arythmies peuvent être bénignes, mais d'autres compromettent la fonction cardiaque, créant un cercle vicieux où un cœur affaibli favorise l'arythmie, et inversement.

I.2.6.1. Extrasystoles supraventriculaires

Une extrasystole supraventriculaire se manifeste par une stimulation cardiaque prématurée par rapport au rythme normal. En fonction de son origine, elle peut être auriculaire (dans les oreillettes) ou jonctionnelle (au niveau du nœud atrio-ventriculaire). L'hypertension artérielle, en imposant une surcharge au cœur, peut entraîner une distension des oreillettes, favorisant ainsi leur contraction prématurée. Une faiblesse du muscle cardiaque peut également être à l'origine de ce type d'extrasystole.

1.2.6.2.Extrasystole ventriculaire

L'extrasystole ventriculaire résulte de la présence d'une zone irritée dans le ventricule, qui échappe au rythme harmonieux de l'activation cardiaque. Elle peut être déclenchée par des émotions, un déséquilibre en sels minéraux, une fièvre ou une infection. Dans de tels cas, elle est généralement considérée comme bénigne. En revanche, lorsque des extrasystoles apparaissent en association avec une maladie cardiaque, elles peuvent révéler un problème nécessitant une prise en charge médicale. Si les extrasystoles deviennent fréquentes et que la stimulation électrique s'amplifie, la fréquence cardiaque peut augmenter, ce qui conduit à une tachycardie.

1.3.L'ELECTROMYGRAPHIE

Un signal électromyographie (EMG) représente l'activité électrique générée par les muscles lorsqu'ils se contractent. Il est mesuré à l'aide d'électrodes placées sur la peau (EMG de surface) ou insérées dans le muscle (EMG intramusculaire). Les signaux EMG reflètent la somme des potentiels d'action des unités motrices actives dans un muscle. Ces signaux sont largement utilisés pour évaluer la fonction musculaire, diagnostiquer des troubles neuromusculaires, ou pour des applications en biomécanique, en ergonomie et en robotique.

1.3.1.Historique

L'électromyographie (EMG) évalue l'activité musculaire en analysant les phénomènes électrochimiques liés aux contractions musculaires. L'association entre l'activité musculaire et l'électricité remonte au XVIIe siècle avec Francesco Redi, qui relia les décharges électriques d'un animal marin à un phénomène musculaire. Plus tard, Luigi Galvani popularisa le concept de "bioélectricité" en observant la contraction du tissu musculaire de grenouille sous stimulation électrique. Au XIXe siècle, Jules-Étienne Marey fut le premier à mesurer l'activité électrique d'une contraction musculaire humaine à l'aide d'un appareil qu'il nomma "électromyographe". Aujourd'hui, l'EMG désigne l'enregistrement des variations de potentiels électriques associées à l'activité neuromusculaire.

I.3.2. Structure et Organisation du Muscle Squelettique

Le corps humain compte plus de 650 muscles attachés au squelette, représentant environ 40 % de la masse corporelle totale. Les tissus musculaires se répartissent en trois catégories principales : les muscles squelettiques, les muscles lisses et les muscles cardiaques. Les muscles squelettiques jouent un rôle central dans le système locomoteur en remplissant diverses fonctions essentielles. Chaque muscle squelettique est fixé aux os par deux extrémités : l'origine (O) et l'insertion (I), comme illustré à la figure I.16. Ces muscles sont reliés aux os par des tendons. Ensemble, muscles et tendons agissent pour stabiliser les articulations et permettre le mouvement des segments corporels.




Figure I.16 Le muscle squelettique est attaché aux os par deux extrémités appelées origine (O) et insertion (I)

[2]

Le muscle squelettique est l'un des trois types de muscles du corps humain. Il est rattaché aux os par les tendons et intervient dans les mouvements volontaires, Ce type de muscle est constitué de plusieurs faisceaux (Figure I.17), Les faisceaux sont des groupes de fibres musculaires (cellules musculaires) regroupées en unités fonctionnelles. Chaque faisceau est entouré par une couche de tissu conjonctif appelée périnysium, Les fibres musculaires sont des cellules longues, cylindriques et multinucléées qui constituent l'unité contractile du muscle, Chaque fibre est entourée par une membrane fine appelée sarcolemme, qui assure la protection et la conduction des signaux électriques, Le muscle est enveloppé et soutenu par plusieurs couches de tissu conjonctif:

- **Épimysium** : Couvre l'ensemble du muscle. Il protège le muscle et permet l'attachement aux tendons.
- **Périmysium** : Enveloppe chaque faisceau musculaire. Il contient les vaisseaux sanguins et les nerfs qui alimentent les fibres musculaires.
- **Endomysium** : Entoure chaque fibre musculaire individuellement. Il apporte un soutien structurel et contient des capillaires sanguins microscopiques.

Vaisseaux sanguins pénètrent dans le muscle via le périmysium pour alimenter les fibres musculaires. Le sang fournit l'oxygène et les nutriments nécessaires au métabolisme musculaire et élimine les déchets métaboliques, comme le dioxyde de carbone. Chaque fibre musculaire reçoit un signal d'un neurone moteur, qui transmet des impulsions électriques via son axone. Ces signaux déclenchent la contraction musculaire en stimulant les unités motrices. Les muscles squelettiques, avec leurs fibres et tendons, génèrent une contraction contrôlée qui entraîne le déplacement des os. Les couches de tissu conjonctif contribuent à transmettre la force générée par les fibres contractiles vers les points d'attache du muscle.




Figure I.17 Organisation des muscles squelettiques [2]

I.3.3. Caractéristiques des signaux EMG

I.3.3.1 Définition de l'électromyogramme

L'électromyographie (EMG) est une technique électrodiagnostique qui enregistre les signaux électriques générés par les muscles squelettiques lors de leur contraction. Elle permet d'évaluer l'activité neuromusculaire et d'analyser l'état des muscles et des motoneurons.

Les signaux EMG ont une amplitude de 50 μ V à 20 mV et une fréquence de 20 à 2000 Hz. Leur analyse fournit des informations sur la condition physique, la fatigue et la biomécanique musculaire, aidant ainsi à détecter d'éventuelles déficiences fonctionnelles.

I.3.3.2 Prétraitement du signal EMG

Le prétraitement des données consiste à éliminer les informations perturbatrices ou les sources de corruption des données de manière stratégique. Dans les applications EMG, une fois que les signaux EMG bruts ont été préparés (figure I.18), plusieurs étapes de prétraitement des données sont mises en place afin de minimiser l'impact du bruit, qui pourrait compromettre leur interprétation. Dans les applications EMG, les sources de bruit fréquentes incluent, sans s'y limiter, les vibrations, les perturbations des lignes électriques et le bruit électronique propre à l'équipement. On utilise les étapes de prétraitement afin de diminuer l'incidence de ces sources de corruption et de préparer les données d'entrée pour une analyse ultérieure.




Figure I.18 Un exemple de signal EMG de surface enregistré à partir du muscle extenseur radial du carpe long lorsqu'un sujet effectue une ouverture de la main pendant deux secondes

Les algorithmes de contrôle myoélectrique étant capables de détecter l'intention de mouvement, ils sont principalement utilisés pour faire fonctionner les prothèses des amputés . Par conséquent, le défi de la reconnaissance des formes pour les systèmes de contrôle myoélectrique repose principalement sur la précision de la classification . Un certain nombre de caractéristiques sont extraites du signal myoélectrique pour être classées afin de réaliser une reconnaissance de formes pour les applications myoélectriques. En plus du domaine temporel, d'autres domaines comme le domaine fréquentiel (parfois appelé domaine spectral), l'échelle de temps et le temps–fréquence peuvent également être utilisés pour la catégorisation des caractéristiques.

I.4.ELECTROOCULOGRAMME

La perception visuelle constitue l'une des principales interactions sensorielles dans le cerveau, les mouvements oculaires fournissent des informations cruciales sur la santé physique et psychologique, la perception, l'intention et les préférences. Avec les progrès des technologies des dispositifs portables, la performance des systèmes de suivi oculaire s'est considérablement améliorée, ouvrant la voie à de nombreuses applications destinées à assister et à augmenter les activités humaines. Parmi ces technologies, l'électrooculogramme (EOG), mesuré à l'aide d'électrodes placées sur la peau, est largement utilisé pour suivre avec précision les mouvements oculaires. Par ailleurs, les dispositifs de suivi optique, qui détectent les signaux réfléchis, offrent une alternative sans recourir à des capteurs portables. L'EOG, en tant qu'indicateur clé des troubles neurologiques, permet d'enregistrer les mouvements oculaires. Ce signal électrique, généré par les déplacements du globe oculaire, est souvent perturbé par des interférences liées à l'activité cérébrale et aux bruits des lignes électriques lors de son enregistrement. En raison de sa nature non stationnaire.

I.4.1 L'anatomie de l'œil

L'œil, principal récepteur des informations visuelles, fonctionne avant tout comme un instrument optique permettant de former une image sur la rétine. Sa mobilité est assurée par six muscles extraoculaires, et il se compose d'une vingtaine de structures essentielles pour une vision correcte, telles que la rétine, l'iris, la cornée et le cristallin. L'œil transforme les vibrations électromagnétiques de la lumière en influx nerveux transmis au cerveau. L'œil humain est un globe

d'un diamètre variant entre 2,2 et 2,5 centimètres, avec une différence de 10 % en moyenne chez les adultes . Vu de face, il apparaît comme un disque sombre (la pupille) entouré d'un anneau coloré (l'iris). Il est partiellement recouvert par les paupières, laissant visible la sclérotique blanche, souvent de forme triangulaire, sur un ou deux côtés (Figure I.19).




Figure I.19 Le globe de l'œil humain et les composants principaux.

I.4.1.1 Description des principaux composants du globe oculaire humain

La figure I.19 illustre un schéma horizontal de l'œil humain, mettant en évidence ses principales structures :

- **La cornée** : Membrane transparente et rigide, d'environ 11 mm de diamètre, qui laisse entrer la lumière dans l'œil. Elle est nourrie par l'humeur aqueuse, un liquide qui maintient ses 78 % d'eau. Ce niveau d'hydrophilie est préservé par un film lacrymal alimenté par les glandes lacrymales et réparti par les clignements des paupières. La cornée assure environ 80 % de la réfraction de la lumière.
- **La sclérotique** : Enveloppe protectrice qui recouvre environ cinq sixièmes de la surface de l'œil. Elle confère à l'œil sa rigidité et sa couleur blanche caractéristique.
- **L'iris** : Diaphragme de l'œil, percé en son centre par la pupille. C'est un muscle qui

contrôle l'ouverture de la pupille (entre 2,5 et 7 mm) pour réguler la quantité de lumière entrant dans l'œil, évitant ainsi l'éblouissement en plein soleil et favorisant la vision dans des conditions de faible luminosité.

- **La pupille** : Ouverture centrale de l'iris, permettant aux rayons lumineux de passer vers la rétine.
- **Le cristallin** : Lentille souple composée de couches fines et superposées, située derrière l'iris. Sous l'action des muscles ciliaires, il se déforme pour ajuster la puissance optique de l'œil selon la distance de vision, un processus appelé accommodation.
- **La rétine** : Structure complexe, elle reçoit et traite la lumière selon un schéma précis La rétine comporte deux types de photorécepteurs.

I.4.1 Définition de l'électromyogramme

les signaux cardiorespiratoires et de mouvements sont plus faciles à enregistrer (Chen et al., 2019). Cependant, ces méthodes restent au stade exploratoire et leur performance n'est pas encore satisfaisante pour les cliniciens. Par conséquent, il est nécessaire de développer une méthode conviviale et offrant une grande précision pour la classification des stades de sommeil. la perception visuelle constitue l'une des principales interactions sensorielles dans le cerveau, les mouvements oculaires fournissent des informations cruciales sur la santé physique et psychologique, la perception, l'intention et les préférences. Avec les progrès des technologies des dispositifs portables, la performance des systèmes de suivi oculaire s'est considérablement améliorée, ouvrant la voie à de nombreuses applications destinées à assister et à augmenter les activités humaines. Parmi ces technologies, l'EOG, mesuré à l'aide d'électrodes placées sur la peau, est largement utilisé pour suivre avec précision les mouvements oculaires. Par ailleurs, les dispositifs de suivi optique, qui détectent les signaux réfléchis, offrent une alternative sans recourir à des capteurs portables. L'EOG, en tant qu'indicateur clé des troubles neurologiques, permet d'enregistrer les mouvements oculaires. Ce signal électrique, généré par les déplacements du globe

oculaire, est souvent perturbé par des interférences liées à l'activité cérébrale et aux bruits des lignes électriques lors de son enregistrement. En raison de sa nature non stationnaire.

L'EOG Consiste à mesurer l'activité électrique générée par l'œil. Elle permet ainsi de détecter les mouvements oculaires et les clignements. L'œil est considéré comme un dipôle électrique, avec la cornée comme pôle positif et la rétine comme pôle négatif. L'EOG mesure la différence de potentiel électrique entre ces deux pôles. Lorsque les yeux sont au repos, l'EOG enregistre une tension constante, appelée ligne de base. En cas de mouvement des yeux, les pôles s'éloignent ou se rapprochent des électrodes, provoquant un changement de potentiel, comme l'illustre la figure1. La direction du mouvement détermine le signe de ce changement, tandis que l'amplitude de la mesure est proportionnelle à celle du mouvement oculaire .donc L'EOG est l'une des technologies utilisées pour suivre les mouvements oculaires en mesurant le potentiel entre la cornée chargée positivement et la rétine chargée négativement. En général, l'amplitude des signaux EOG mesurés varie entre 50 μV et 3500 μV , en fonction de la quantité de lumière incidente sur la rétine [6,7]. Il est courant d'utiliser des capteurs électriques classiques pour la détection de l'EOG. Cependant, ces dispositifs EOG conventionnels étant rigides, les plateformes de dispositifs portables basées sur l'électronique souple et les communications de données sans fil pourraient offrir une expérience utilisateur améliorée. Lorsque l'œil bouge, le dipôle cornée-rétine génère un champ électrique autour des yeux, qui peut être mesuré en plaçant une paire d'électrodes sur la peau autour des yeux.

I.4.2 Relation entre EOG EEG et EMG

La classification des stades de sommeil joue un rôle crucial dans l'évaluation de la qualité du sommeil et le diagnostic des troubles du sommeil. Selon l'American Academy of Sleep Medicine (AASM), les stades du sommeil sont classés en cinq catégories : éveil, N1, N2, N3 et sommeil paradoxal. Les techniciens du sommeil utilisent généralement la polysomnographie (PSG), qui inclut un ensemble de signaux physiologiques tels que l'électroencéphalogramme (EEG), l'électrooculogramme (EOG) et l'électromyogramme (EMG), pour déterminer les stades du sommeil. Cependant, cette méthode reste fastidieuse et chronophage.

À l'inverse, les signaux cardiorespiratoires et de mouvements sont plus faciles à enregistrer. Cependant, ces méthodes restent au stade exploratoire et leur performance n'est pas encore

satisfaisante pour les cliniciens. Par conséquent, il est nécessaire de développer une méthode conviviale et offrant une grande précision pour la classification des stades de sommeil. En tenant compte du compromis entre faisabilité et précision, l'EOG s'avère être une modalité prometteuse pour la classification des stades de sommeil. Tout d'abord, les enregistrements EOG reflètent l'activité oculaire, un indicateur clé pour différencier les stades de sommeil. Ensuite, les signaux EOG sont souvent contaminés par des signaux EEG. Comme le montre la figure I.20, une forte similarité entre le canal EEG C3 et le canal EOG E2 a été observée. Enfin, l'acquisition des signaux EOG est généralement simple grâce à la facilité de placement des électrodes.

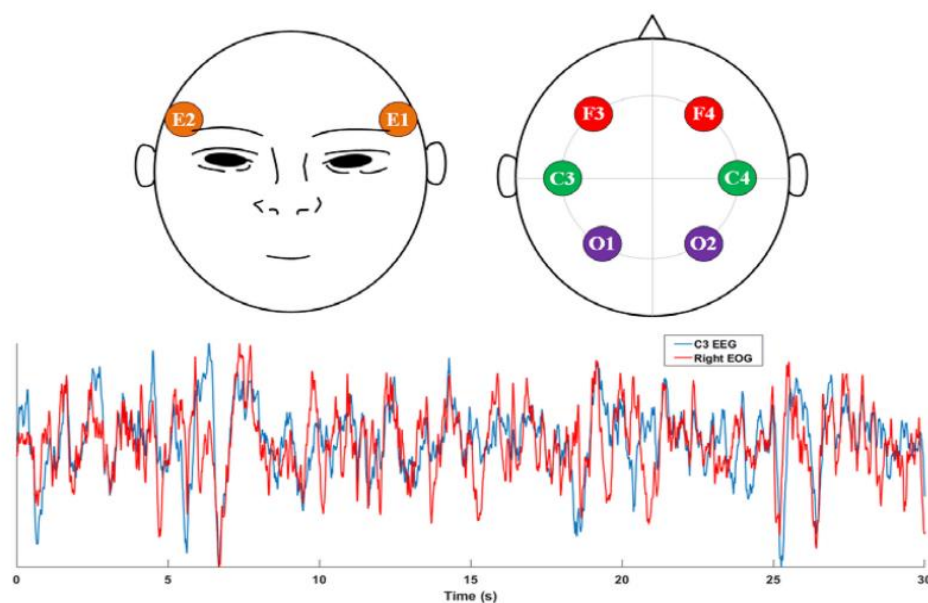


Figure I.20 En haut : les emplacements recommandés par l'AASM pour les électrodes destinées à l'acquisition des signaux EOG et EEG. Les électrodes E1 et E2 servent respectivement à enregistrer les signaux EOG gauche et droit. Les électrodes F3, F4, C3, C4, O1 et O2 sont les plus fréquemment utilisées pour l'EEG dans le cadre du suivi du sommeil. En bas : comparaison entre le signal EEG C3 et le signal EOG droit (E2) [6].

I.4.3-Hypovigilance et EOG

Bien que l'EOG puisse ne pas sembler être la méthode la plus évidente pour analyser les signaux visuels (la vidéo étant souvent considérée en premier), elle est largement utilisée par les spécialistes de l'hypovigilance. En effet, cette technique offre une précision remarquable dans la détection et la caractérisation des clignements. Lorsque les yeux sont immobiles, l'EOG enregistre

une tension constante, appelée ligne de base. En revanche, lors des mouvements oculaires, les pôles se rapprochent ou s'éloignent des électrodes, entraînant une variation du potentiel mesuré, comme illustré dans la figure I.21. Le sens de cette variation dépend de la direction du mouvement, tandis que l'amplitude du signal est directement proportionnelle à celle du déplacement oculaire [7]. L'EOG est enregistré en positionnant des électrodes autour des yeux. Il est essentiel de distinguer les mouvements horizontaux et verticaux de l'œil, car les clignements correspondent uniquement à des mouvements verticaux des paupières. Pour mesurer l'EOG vertical (EOG-V), les électrodes sont placées de part et d'autre de l'œil, dans un alignement vertical. Pour l'EOG horizontal (EOG-H), elles sont positionnées sur les côtés extérieurs des yeux. Une électrode de référence est également placée au centre du front. Le schéma illustrant la disposition des électrodes est présenté dans la figure I.22

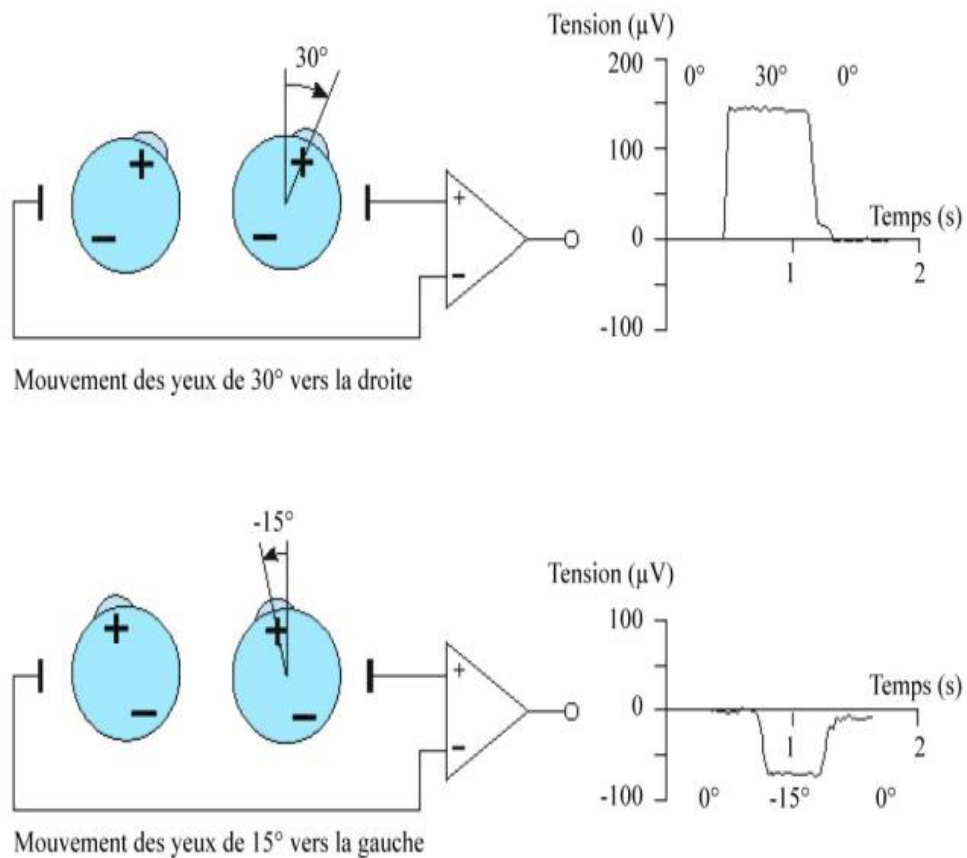


Figure I. 21 Changements du potentiel EOG liés aux mouvements des yeux [7]

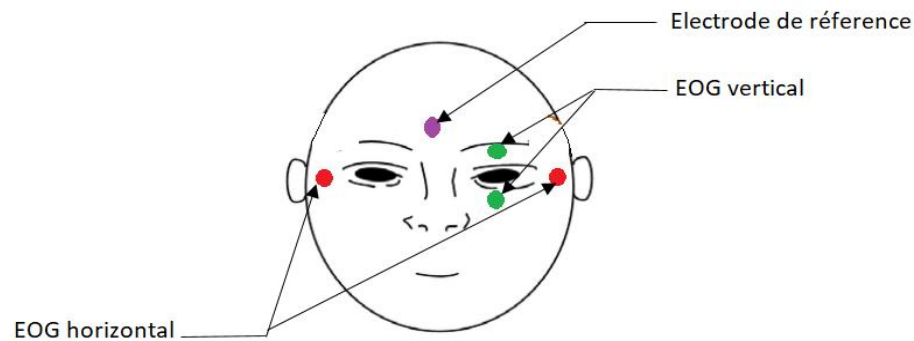


Figure I.22 Placement des électrodes pour l'enregistrement EOG

Dans la suite, nous nous concentrerons uniquement sur l'EOG vertical. Pour garantir une résolution optimale, les enregistrements sont effectués avec une fréquence d'échantillonnage élevée (dans ce cas, $F_e=250\text{Hz}$). L'enregistrement de la composante continue (DC) de l'EOG permet de prendre en compte les clignements prolongés. Cependant, cette méthode présente un inconvénient majeur : une dérive lente de la ligne de base, pouvant entraîner la saturation de l'amplificateur. À l'inverse, l'enregistrement en mode courant alternatif résout le problème de dérive, mais au prix d'un filtrage de la composante continue, ce qui complique la détection des clignements prolongés. Le choix entre ces modes d'enregistrement dépend donc des exigences spécifiques de l'application.

I.5 LA VARIABILITE DU RYTHME CARDIAQUE (HVR)

La variabilité du rythme cardiaque (HRV) est une méthode non invasive permettant de surveiller l'état de santé et d'évaluer l'équilibre et l'interaction entre les systèmes sympathique et parasympathique du système nerveux autonome. Le signal HRV est extrait des enregistrements ECG en détectant les pics R grâce à l'algorithme Pan-Tompkins [8], puis en mesurant les intervalles entre les pics R successifs. Ces intervalles reflètent les variations temporelles entre les battements cardiaques. Ce processus convertit les intervalles entre deux pics R du signal ECG en une amplitude correspondant au signal HRV (Figure 1.23).




Figure L23 La génération du signal HRV à travers la détection des pics R (Algorithme de Pan–Tompkins) [10]

Comme illustré dans la Figure 1.19, la méthode de Pan-Tompkins se déroule en plusieurs étapes : application d’un filtre passe-bande, suivi d’un filtre de dérivation, d’une fonction de mise au carré, d’une fenêtre d’intégration mobile et enfin d’un ajustement du seuil.




Figure L24 Algorithme de Pan–Tompkins [10]

I.5.1 Filtre passe-bande

Un filtre passe-bande est utilisé pour améliorer le rapport signal/bruit des données ECG. Il permet de réduire les interférences à 50 Hz, de supprimer les variations de la ligne de base et d’atténuer les perturbations causées par l’onde T. Ce filtre numérique, avec une plage de fréquences comprise entre 5 Hz et 15 Hz, renforce l’intensité des complexes QRS tout en réduisant le bruit d’origine musculaire.

Le filtre numérique passe-bande est constitué d'une combinaison en cascade de filtres passe-bas et passe-haut. La fonction de transfert du filtre passe-bas du second ordre est donnée par (I.1) :

$$H(Z) = \frac{(1-z^{-6})^2}{(1-z^{-1})^2} \quad (\text{I.1})$$

La fréquence de coupure et le gain du filtre passe-bas sont respectivement fixés à 11 Hz et 36, avec un délai de traitement de 6 échantillons.

I.5.2 Filtre passe-haut

Le filtre passe-haut est conçu et simulé en soustrayant la sortie d'un filtre passe-bas de premier ordre de celle d'un filtre passe-tout. La fonction de transfert du filtre passe-haut est donnée par l'équation (1.2).

$$H(Z) = \frac{-1+32Z^{-16}+Z^{-32}}{1-Z^{-1}} \quad (\text{I.2})$$

Ce filtre présente une fréquence de coupure de 5 Hz, un gain de 32 et un délai de traitement de 16 échantillons.

I.5.3 Dérivation

Le signal ECG filtré est soumis à une dérivation afin de mettre en évidence la pente de l'onde R. Cette opération est réalisée à l'aide d'un filtre différentiel numérique, dont la fonction de transfert est exprimée par l'équation (1.3).

$$H(Z) = \frac{1}{8T}(-Z^{-2} - 2Z^{-1} + 2Z + Z^2) \quad (\text{I.3})$$

I.5.4 Fonction de mise au carré

Ce filtre permet d'amplifier le signal de sortie du filtre de dérivation et rendre le signal positif. L'équation de la fonction de mise au carré est donnée par (1.4).

$$y(nT) = [x(nT)]^2 \quad (\text{I.4})$$

I.5.5 Fenêtre d'intégration mobile et ajustement du seuil

Fenêtre d'intégration mobile et réglage du seuil, Le signal traverse une fenêtre d'intégration mobile, permettant de déterminer plus facilement son amplitude maximale et sa largeur. Ce processus est décrit par l'équation (1.5).

$$y(nT) = [x(nT - (N - 1)T) + x(nT - (N - 2)T) + \dots + x(nT)] \quad (I.5)$$

Où N représente le nombre d'échantillons contenus dans la largeur de la fenêtre d'intégration, et T correspond à la période d'échantillonnage.




Figure I.25 – Les bandes fréquentielle du signal HRV [10]

1.5.5 Étude de la variabilité du rythme cardiaque (HRV)

La variabilité du rythme cardiaque (HRV) reflète l'influence sympathique et parasympathique de l'activité du système nerveux autonome (SNA), analysable dans le domaine fréquentiel. Ce signal présente deux bandes de fréquences principales, associées respectivement aux composantes sympathique et parasympathique du SNA. La bande des basses fréquences est liée à l'activité sympathique, tandis que la bande des hautes fréquences représente un indicateur de l'activité parasympathique influençant le cœur. Plusieurs bandes de fréquences sont d'intérêt pour l'analyse des signaux HRV (voir Figure 1.25) :

- **Très basses fréquences (VLF)** : 0,003 à 0,04 Hz.
- **Basses fréquences (LF)** : 0,04 à 0,2 Hz.

- **Hautes fréquences (HF)** : 0,2 à Fmax Hz.

La bande LF est considérée comme un marqueur de l'activité sympathique, tandis que la bande HF est principalement associée à la modulation parasympathique, principalement influencée par l'arythmie sinusale respiratoire (RSA) [9]. Le signal HRV, extrait du signal ECG, peut être analysé à l'aide de méthodes d'estimation de densité spectrale de puissance (PSD), qu'elles soient paramétriques ou non paramétriques. Cependant, ces approches ne permettent pas de prendre en compte la non-stationnarité du signal et ne fournissent pas une localisation temporelle des informations. Pour surmonter ces limitations, le signal HRV peut être analysé dans le domaine temps-fréquence. La distribution temps-fréquence joue un rôle crucial en permettant de localiser les informations spectrales dans le temps, ce qui aide à mieux décrire la nature et le contenu des composantes non stationnaires tout en réduisant les interférences dues aux termes croisés.

Conclusion

L'étude des signaux physiologiques tels que l'EEG (électroencéphalogramme), l'ECG (électrocardiogramme), le HRV (variabilité de la fréquence cardiaque), l'EMG (électromyogramme) et l'EOG (électro-oculogramme) revêt une importance majeure dans le domaine de la santé et des sciences biomédicales. Ces signaux fournissent des informations précieuses sur l'état et le fonctionnement des systèmes physiologiques du corps humain. L'EEG permet d'analyser l'activité électrique cérébrale et est essentiel pour le diagnostic des troubles neurologiques comme l'épilepsie ou les troubles du sommeil. L'ECG et le HRV, quant à eux, sont des outils clés pour évaluer la santé cardiovasculaire, détecter les arythmies et mesurer l'impact du stress sur le système autonome. L'EMG est indispensable pour étudier l'activité musculaire et diagnostiquer des troubles neuromusculaires, tandis que l'EOG sert à analyser les mouvements oculaires, essentiel pour les études sur le sommeil, les interfaces homme-machine ou les troubles visuels. Ensemble, ces signaux permettent une compréhension intégrée des interactions complexes entre différents systèmes du corps humain, ouvrant ainsi la voie à des diagnostics précoces, des traitements personnalisés et des avancées en neurotechnologie et en télémédecine.

CHAPITRE 2

État de la recherche sur le signal EEG et le signal ECG

Introduction

L'EEG et L'ECG sont des méthodes médicales fondamentales utilisées pour détecter, visualiser et enregistrer l'activité électrique du cerveau ou du cœur. Cette section en revue les techniques d'analyse de ces signaux. Parmi les techniques abordées figurent la transformation de Fourier rapide (FFT), la transformation de Fourier à court terme (STFT) et les potentiels évoqués liés à un événement (ERP). En résumé, l'EEG ainsi que l'ECG s'impose comme un outil essentiel pour la détection précoce des pathologies, la réhabilitation, la classification des états pathologiques ou l'assistance aux patients, adapté aux besoins spécifiques de chaque pathologie. En général, l'analyse d'un signal EEG ou ECG suit plusieurs étapes communes. Le signal brut, une fois extrait, subit un prétraitement comprenant l'acquisition du signal, l'élimination des artefacts, l'addition moyenne des signaux, l'établissement d'une valeur seuil pour le signal de sortie, l'amélioration du signal obtenu et la détection des contours. Ensuite, une étape d'extraction de caractéristiques permet de sélectionner les informations ou attributs les plus importants pour la classification. En général, l'analyse d'un signal EEG/EEG suit plusieurs étapes communes. Le signal brut, une fois extrait, subit un prétraitement comprenant l'acquisition du signal, l'élimination des artefacts, l'addition moyenne des signaux, l'établissement d'une valeur seuil pour le signal de sortie, l'amélioration du signal obtenu. Ensuite, une étape d'extraction de caractéristiques permet de sélectionner les informations ou attributs les plus importants pour la classification. Le signal est ensuite classé à l'aide de méthodes d'analyse linéaire, d'analyse non linéaire, d'algorithmes adaptatifs, de techniques de regroupement et floues. La figure II.1 illustre le diagramme de flux représentant l'ensemble du processus de traitement du signal EEG et ECG. Les méthodes employées pour le traitement du signal seront succinctement présentées dans la section suivante. La première étape de l'analyse des signaux EEG et ECG consiste à éliminer les artefacts tout en amplifiant les signaux biologiques issus du cerveau ou du cœur. Diverses techniques sont utilisées pour les séparer efficacement. Les chercheurs ont développé diverses techniques de suppression des artefacts, notamment les méthodes basées sur la régression, les méthodes basées sur les composants et les méthodes de filtrage adaptatif. L'analyse par régression repose sur une mesure propre du signal d'artéfact à soustraire, ce qui la rend inadaptée au traitement en temps réel. Après l'élimination des artefacts, les caractéristiques significatives des signaux EEG et ECG sont extraites à l'aide de techniques de sélection de caractéristiques. Ces techniques jouent un rôle

essentiel pour identifier des propriétés spécifiques pouvant être utilisées efficacement dans la classification de ces signaux.




Figure II.1 Étapes du traitement du signal EEG

II.1 ETAT DE LA RECHERCHE SUR LES SIGNAUX EEG

L'électroencéphalographie (EEG) est un outil largement reconnu pour l'enregistrement de l'activité cérébrale. Ces dernières années, il a été massivement utilisé dans l'étude et le diagnostic de divers troubles neurologiques, notamment l'épilepsie, la prédiction des crises, la maladie d'Alzheimer, les troubles cognitifs légers, la maladie de Parkinson, la maladie de Creutzfeldt-Jakob, les études sur le sommeil, la schizophrénie, l'analyse des états émotionnels et les interfaces cerveau-ordinateur (BCI).

II.1.1 Prétraitement et filtrage des signaux EEG

Le prétraitement et le filtrage des signaux EEG sont des étapes essentielles pour garantir une analyse fiable et précise des activités cérébrales. Les enregistrements EEG sont souvent affectés par divers artefacts et bruits, provenant de sources physiologiques (mouvements oculaires, activité musculaire, interférences cardiaques) et non physiologiques (interférences électromagnétiques, mauvaises connexions des électrodes). Un prétraitement efficace permet d'améliorer la qualité du signal en réduisant ces perturbations, facilitant ainsi l'extraction des caractéristiques pertinentes pour des analyses cliniques ou expérimentales.

II.1.1.1 Artefacts dans les signaux EEG

Les signaux EEG sont souvent contaminés par divers artefacts, Comme résumé dans le tableau (II.1), les artefacts présents dans les enregistrements EEG peuvent être classés en deux grandes catégories : les artefacts physiologiques et non physiologiques. Pour améliorer la qualité des données, plusieurs méthodes de prétraitement sont employées :

Les artefacts physiologiques : correspondent aux potentiels électriques générés par des activités biologiques, principalement issus des structures proches de la tête, comme les yeux, les muscles ou le cœur, ou encore causés par les mouvements du sujet. Les artefacts physiologiques proviennent généralement de sources internes au corps humain. Parmi les plus courants, on retrouve les clignements des yeux, les mouvements oculaires, les mouvements de la tête, les battements cardiaques et le bruit musculaire [12]. L'identification de ces artefacts est facilitée lorsqu'on dispose de données biométriques complémentaires. Par exemple Les clignements et mouvements des yeux peuvent être détectés à l'aide d'un EOG ou d'un système de suivi oculaire, Les artefacts liés aux battements cardiaques peuvent être identifiés grâce aux enregistrements électrocardiographiques (ECG) et les mouvements de la tête peuvent être repérés à l'aide de données issues d'un accéléromètre. L'intégration de ces signaux auxiliaires permet d'améliorer la précision de la détection et de la suppression des artefacts dans les enregistrements EEG. Les artefacts physiologiques liés aux potentiels oculaires, tels que les mouvements des yeux et les clignements (illustrés dans la Figure (II.2)), sont facilement détectables chez un sujet conscient lors d'un enregistrement EEG de routine. Lorsque les yeux se déplacent, le dipôle électrique formé entre la cornée, chargée positivement, et la rétine, chargée négativement, se déplace également. Ce phénomène génère un potentiel électrique important, généralement caractérisé par une localisation antérieure, une apparition bilatérale et une synchronisation marquée [13]. Les artefacts générés par l'activité cardiaque sont présents à des degrés variables lors des enregistrements EEG de routine [14]. L'utilisation de montages référentiels peut accentuer ces artefacts électrocardiographiques, en particulier lorsque l'on utilise une référence auriculaire ipsilatérale avec de plus grandes distances inter-électrodes. En revanche, un montage référentiel avec les oreilles reliées peut réduire ces artefacts. Certains profils de patients sont plus sujets aux artefacts électrocardiographiques, notamment les personnes en surpoids, celles ayant un cou court et épais, ainsi que les nourrissons. Chez ces sujets, le dipôle cardiaque est plus proche des électrodes d'enregistrement, facilitant ainsi la transmission du courant. Contrairement aux artefacts électromyographiques qui « contaminent » le signal EEG, les artefacts électrocardiographiques peuvent fournir des informations physiologiques précieuses durant l'enregistrement. Ainsi, l'enregistrement simultané de l'ECG lors des enregistrements EEG de routine est essentiel pour permettre l'identification des interactions entre l'activité cardiaque et cérébrale, facilitant ainsi une meilleure interprétation des signaux.

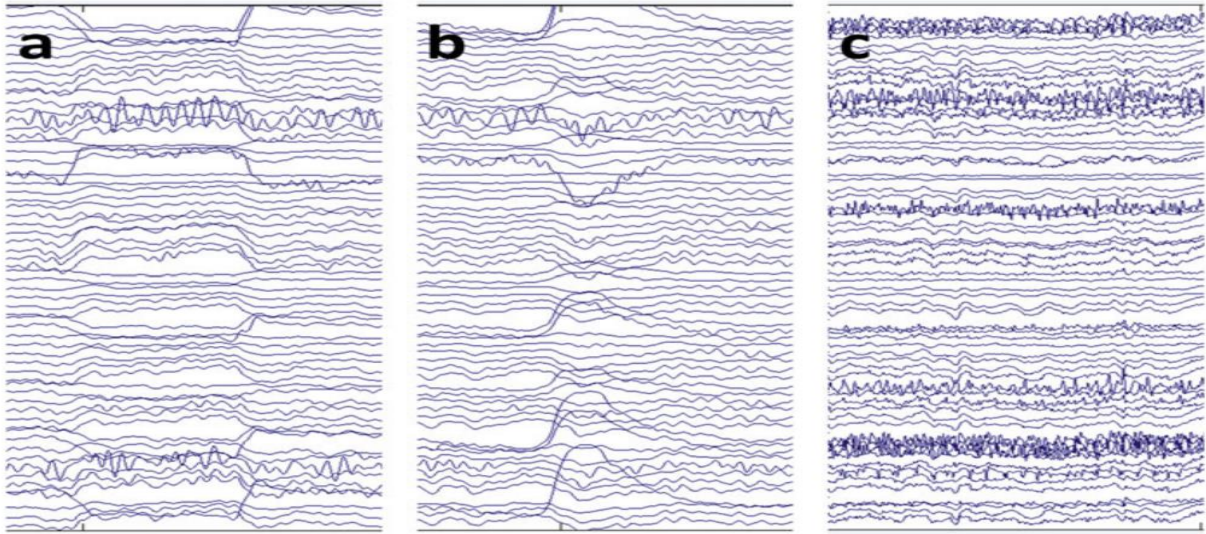


Figure II.2 Exemples d'artefacts oculaires et électromyographiques. Les artefacts oculaires tels que les mouvements oculaires (a) et le clignement des yeux (b) sont représentés par un potentiel électrique important, généralement caractérisé par une localisation antérieure, bilatérale et une apparence synchronisée. Les artefacts électromyographiques (c)

La transpiration du cuir chevelu peut générer des artefacts en créant des connexions électriques indésirables entre les électrodes. Ces artefacts apparaissent sous forme d'ondes ondulantes de faible amplitude et de très basse fréquence (environ 0,5 Hz) [15]. Les variations du potentiel électrique en courant continu (DC) dues à la transpiration peuvent entraîner une instabilité de la ligne de base, connue sous le nom de sweat sway, ainsi que des croisements de tracés entre les canaux adjacents. Par ailleurs, les mouvements du sujet, provoquant des déplacements des électrodes ou des câbles, peuvent être une source majeure d'artefacts physiologiques dans les enregistrements EEG. Ce phénomène est particulièrement observé chez les patients éveillés et ambulatoires, ainsi que chez ceux présentant une agitation ou une confusion, rendant le signal EEG plus difficile à interpréter. Les artefacts physiologiques peuvent être traités par évitement, rejet ou suppression. Pour limiter leur apparition, les expérimentateurs demandent souvent aux sujets de minimiser leurs mouvements oculaires et de réduire les clignements. Toutefois, ces artefacts restent inévitables, car les clignements et les mouvements des yeux sont souvent involontaires, en particulier chez les enfants et les personnes âgées.

Pour améliorer le rapport signal/bruit dans les enregistrements EEG, plusieurs techniques de prétraitement ont été développées afin d'atténuer ces artefacts. L'approche basée sur l'épochage (epoch-based method) consiste à rejeter complètement les segments temporels du signal EEG

contaminés. Quant à l'analyse en composantes indépendantes (Independent Component Analysis, ICA), elle permet d'extraire et de supprimer les composantes liées aux artefacts. Cependant, cette dernière méthode peut entraîner une perte importante d'informations cérébrales utiles, notamment lorsque les artefacts sont fréquents [16].

Les artefacts non physiologiques : Proviennent de l'interface électrode-cuir chevelu, des dispositifs électroniques ou de l'environnement, et peuvent être générés à proximité du système d'enregistrement EEG. Alors que les artefacts physiologiques, qui présentent des champs électriques caractéristiques, sont généralement faciles à identifier, les artefacts non physiologiques, dont les formes sont plus variées, peuvent altérer ou masquer l'activité EEG, rendant leur détection et leur correction plus complexes.

Les artefacts non physiologiques proviennent généralement d'interférences extérieures. L'une des sources les plus courantes est l'interférence électrique due à l'alimentation secteur, qui oscille à 60 Hz aux États-Unis et à 50 Hz en Europe. Ces interférences peuvent être atténuées en utilisant des câbles blindés, en réalisant les enregistrements EEG dans des salles protégées ou en éloignant le sujet de la source d'interférence dans la pièce.

De plus, le fait de connecter le sujet à la terre et de maintenir les fils des électrodes aussi courts que possible contribue à réduire les artefacts liés au courant alternatif. L'interférence du réseau électrique peut également être supprimée à l'aide d'un filtre en peigne (notch filter) réglé sur 50 ou 60 Hz, certains casques EEG intégrant déjà ce type de filtre.

Une autre cause fréquente d'artefacts non physiologiques est liée aux électrodes, notamment en raison d'une mauvaise application sur le cuir chevelu. Lorsqu'une électrode bouge et perturbe la double couche électrique, un potentiel continu (DC) est généré, similaire au phénomène de décharge d'un condensateur. Cela provoque un artefact caractéristique appelé électrode pop, qui se manifeste par une décharge soudaine, généralement positive (ou parfois négative), suivie d'une décroissance exponentielle due au filtrage basse fréquence de l'amplificateur.

La meilleure façon de minimiser ces artefacts est d'assurer une application correcte des électrodes et un entretien régulier. Il est essentiel de nettoyer les électrodes, de les inspecter fréquemment pour détecter d'éventuels signes de corrosion au niveau de la connexion entre

l'électrode et le fil conducteur, ainsi que d'identifier toute détérioration de l'isolation ou des câbles endommagés. De plus, placer une électrode supplémentaire à proximité d'une électrode suspecte peut aider à vérifier si celle-ci est la source de l'artefact.

Les dysfonctionnements des équipements d'enregistrement EEG peuvent également engendrer des artefacts. Les amplificateurs modernes sont compacts, peu énergivores et reposent sur des circuits intégrés à semi-conducteurs multicanaux. Cependant, ces appareils peuvent générer du bruit d'amplification, principalement dû à l'agitation thermique des électrons dans les circuits électroniques. Les équipements portables sont particulièrement vulnérables à l'usure mécanique, notamment en cas de vibrations ou de chocs. Un câblage desserré ou des connexions de circuits imprimés mal fixées peuvent également entraîner des artefacts, provoquant des pertes de signal ou des dysfonctionnements intermittents.

Table II.1 Artefacts physiologiques et non physiologiques

Artefacts physiologiques	Artefacts non physiologiques
Artefacts oculaires dus aux mouvements et au clignement des yeux.	Artefacts d'interférence des lignes électriques (50 Hz en Europe et 60 Hz aux États-Unis).
Artefacts d'électromyographie dus aux activités des muscles frontales et temporalisé	Artefacts d'électrode dus au mauvais placement de l'électrode sur le cuir chevelu
Artefacts électrocardiographiques dus aux battements cardiaques.	Dysfonctionnement d'une partie du système d'enregistrement EEG, par exemple des amplificateurs.
Transpiration et mouvements du cuir chevelu.	Artefacts numériques tels que des câbles desserrés ou des connexions de circuits imprimés

Enfin, les artefacts numériques peuvent résulter de divers problèmes, notamment l'aliasing (causé par un taux d'échantillonnage insuffisant), des erreurs de conversion analogique-numérique, des erreurs de synchronisation (skew errors), des artefacts de multiplexage et des blocages de signal [17].

Afin d'optimiser la qualité des données, diverses techniques de prétraitement sont mises en œuvre, chacune visant à réduire le bruit, éliminer les artefacts et améliorer la fiabilité des signaux.

II.1.1.2 Filtrage linéaire

Le filtrage constitue une étape essentielle du prétraitement des signaux EEG pour atténuer divers types de bruits, tels que les interférences du réseau électrique à 50 Hz ou 60 Hz, les bruits haute fréquence et les variations à très basse fréquence. Bien que ces bruits et artefacts superposés provenant de différentes sources puissent altérer les enregistrements EEG, ils peuvent être efficacement réduits grâce à un filtrage passe-bande adapté. Ainsi, l'application de filtres numériques aux signaux EEG bruts permet d'améliorer considérablement leur interprétation, en supprimant certaines fréquences indésirables ou en conservant uniquement les bandes fréquentielles pertinentes [16].

En fonction des fréquences conservées ou supprimées, il existe quatre types de filtres : le filtre passe-bas, qui élimine les hautes fréquences au-delà d'un seuil tout en conservant les basses fréquences ; le filtre passe-haut, qui supprime les basses fréquences en dessous d'un seuil tout en retenant les hautes fréquences ; le filtre passe-bande, qui préserve uniquement les fréquences comprises entre deux limites tout en supprimant celles en dehors de cette plage ; et le filtre coupe-bande, qui élimine une plage spécifique de fréquences tout en conservant celles situées en dehors de cette plage. Lors du choix des filtres appliqués aux signaux EEG, il est essentiel de prendre en compte les plages de fréquences des artefacts présents dans les enregistrements. Par exemple, un filtre passe-haut avec une limite de 0,1 Hz est utilisé pour éliminer les dérives de basse fréquence, tandis qu'un filtre passe-bas avec une limite de 30 Hz permet de supprimer les bruits de haute fréquence, tels que les interférences liées aux activités musculaires. Pour atténuer le bruit du réseau électrique (50 Hz en Europe et en Asie, 60 Hz aux États-Unis), un filtre coupe-bande est couramment utilisé afin de supprimer les signaux dans une bande de fréquences spécifique tout en préservant le reste du spectre. En plus de la prise en compte des fréquences des artefacts, la sélection des filtres doit également tenir compte des bandes de fréquences d'intérêt pour l'étude. Par exemple, si l'objectif est d'analyser l'influence d'une stimulation sur les ondes alpha, un filtre passe-bande ciblant la plage de 8 à 13 Hz est nécessaire afin de conserver uniquement ces signaux et d'éliminer les autres fréquences [18].

Il est recommandé d'appliquer le filtrage aux données EEG continues dès la première étape du prétraitement, en particulier avant de segmenter ces données en epochs. En effet, si le filtrage est effectué après la segmentation, il peut générer des artefacts aux frontières des epochs. Par

exemple, un filtre passe-haut à 0,1 Hz est généralement appliqué aux données EEG continues afin de minimiser les dérives lentes de basse fréquence, mais il ne doit pas être appliqué directement aux epochs segmentés. Lorsque le filtrage passe-haut à 0,1 Hz est appliqué séparément à chaque epoch, des artefacts de filtrage peuvent apparaître, car les effets de bord du filtrage peuvent persister au-delà de la durée des epochs (Cohen, 2013) [19].

Donc l'utilisation de filtres passe-bas, passe-haut et passe-bande permet d'éliminer les fréquences indésirables.




Figure II.3 Quatre types de filtres : filtres passe-bas, passe-haut, passe-bande et coupe-bande. Un filtre passe-basHaut du formulaire

II.1.1.3 Analyse en Composantes Indépendantes (ICA)

La Séparation Aveugle des Sources (Blind Source Separation - BSS) est une technique permettant d'extraire les signaux sources à partir d'un signal mélangé, sans nécessiter de connaissances préalables sur les signaux d'origine. Dans un premier temps, le signal EEG observé est décomposé en différentes sources à l'aide d'un algorithme BSS. Par la suite, les sources de bruit

sont identifiées et supprimées, tout en préservant les signaux reflétant l'activité cérébrale. Les techniques BSS sont largement utilisées pour réduire le bruit dans les enregistrements EEG [20]. Parmi ces méthodes Analyse en Composantes Indépendantes (ICA), Différents algorithmes d'ICA ont été développés dans diverses études, faisant de cette méthode l'une des principales techniques de séparation aveugle des sources en ingénierie biomédicale. L'ICA permet d'extraire des sources statistiquement indépendantes à partir d'un ensemble de signaux enregistrés [21]. De manière générale, l'élimination du bruit des signaux EEG à l'aide de l'ICA peut être formulée comme suit [22] :

$$X = AS \quad (\text{II.1})$$

L'équation considérée fait intervenir trois matrices : X, A et S. La matrice X contient les données EEG, tandis que la matrice A représente le mélange linéaire des différentes sources (notamment les signaux EEG et les artefacts). La matrice S, quant à elle, regroupe les composantes indépendantes, comprenant aussi bien les signaux cérébraux que les artefacts. Une fois ces composantes indépendantes obtenues, elles peuvent être analysées visuellement afin d'identifier d'éventuels artefacts, tels que les clignements des yeux ou l'activité musculaire. Le signal EEG peut ensuite être purifié en supprimant ces composantes indésirables.

Les algorithmes d'Analyse en Composantes Indépendantes (ICA) sont considérés comme des méthodes d'apprentissage non supervisé basées sur la théorie de l'information. Leur objectif est d'extraire des sources indépendantes à partir d'un ensemble d'observations multidimensionnelles, supposées être des combinaisons linéaires de sources inconnues via un mélangeur inconnu. Pour cela, un algorithme ICA recherche une matrice de séparation permettant de transformer ces observations en composantes de sortie indépendantes.

La plupart des travaux sur l'ICA reposent sur l'hypothèse que le mélange est instantané et linéaire. L'ICA est souvent considérée comme une extension de l'Analyse en Composantes Principales (ACP), allant au-delà de la simple décorrélation des signaux en prenant en compte des moments d'ordre supérieur et en générant une base non orthogonale [23].

II.1.1.4 Décomposition en ondelettes

En raison du chevauchement entre les activités cérébrales et les bruits artificiels dans le spectre d'un signal EEG, un filtrage effectué dans le domaine fréquentiel ou temporel peut

entraîner une perte ou une distorsion de l'activité physiologique [24]. Les méthodes basées sur la régression utilisent un ou plusieurs canaux régressifs supplémentaires, ce qui constitue une faiblesse majeure, car certaines interférences ont un spectre qui se superpose à celui du signal EEG [25]. L'analyse par transformation en ondelettes s'est révélée plus efficace dans les domaines temporel et fréquentiel pour corriger les artefacts de l'EEG tout en préservant l'intégrité du signal d'origine [26,27].

La transformation en ondelettes est couramment employée pour analyser les signaux dans le domaine temps-fréquence. Elle permet de décomposer un signal temporel en coefficients d'ondelettes à l'aide d'une fonction mère. Ces coefficients sont calculés en effectuant des translations et des dilatations de l'ondelette mère, comme illustré dans l'Équation (1).

$$\psi_{a,b} \left(\frac{t-b}{a} \right) \quad (\text{II.2})$$

Où a représente le paramètre de mise à l'échelle et b le paramètre de translation [28,29]. Lorsqu'un signal bruité est disponible, l'objectif est de récupérer l'information d'origine. Dans le débruitage par ondelettes classique, les coefficients d'ondelettes sont ajustés à l'aide des coefficients de détail et d'approximation. Les coefficients corrigés sont ensuite utilisés pour reconstruire le signal, aboutissant à un EEG sans artefacts, illustré en noir dans le panneau central de la Figure II. Cette méthode tire parti des propriétés locales des ondelettes avant d'inverser la transformation afin de restituer une version propre du signal. Une représentation schématique du processus de débruitage par ondelettes est présentée dans la Figure II.4.




Figure II.4 Organigramme de base du débruitage du signal basé sur les ondelettes [29].




Figure II.5 Signal EEG corrompu par clignement des yeux en rouge, signal EEG corrigé basé sur DWT en noir [29].

II.1.2 Méthodes d'analyse des signaux EEG et extraction de caractéristiques

L'extraction de caractéristiques pertinentes est cruciale pour l'analyse des signaux EEG, L'analyse des signaux EEG reposait principalement sur l'interprétation des formes d'onde à l'aide des méthodes descriptives et heuristiques [32]. Avec le temps, diverses approches ont été développées pour détecter des variations subtiles dans les signaux EEG. Ces méthodes d'analyse se classent généralement en quatre grandes catégories : (1) l'analyse dans le domaine temporel, (2) l'analyse dans le domaine fréquentiel, (3) l'analyse dans le domaine temps-fréquence et (4) les méthodes non linéaires.

II.1.2.1 Méthodes d'analyse dans le domaine temporel

Les principales approches utilisées pour l'analyse temporelle des signaux EEG incluent la prédiction linéaire et l'analyse des composantes. La figure II.5 illustre des formes d'onde EEG typiques dans le domaine temporel, comparant celles d'une personne en bonne santé à celles d'un patient épileptique en phases ictale et interictale.

II.1.2.1.1 Prédiction Linéaire (LP)

Cette méthode consiste à estimer la sortie d'un système linéaire en se basant sur l'entrée $x(n)$ ainsi que sur les sorties précédentes $y(n-1), y(n-2), \dots, y(n-p)$, conformément à l'équation suivante:

$$\hat{y}(n) = \sum_{k=1}^p a(k)y(n-k) + \sum_{k=0}^N b(k)x(n-k) \quad (\text{II.3})$$

Les coefficients 'a' et 'b' sont appelés coefficients de prédiction, et $\hat{y}(n)$ représente l'estimation de $y(n)$. Comme l'indique l'équation (II.3), cette estimation repose sur une combinaison linéaire des valeurs passées de la sortie ainsi que des valeurs passées et présentes de l'entrée. D'après Pradhan et Dutt [32], la prédiction linéaire (LP) peut être utilisée pour générer, stocker et transmettre des signaux EEG. D'autres chercheurs ont quant à eux appliqué la méthode de l'énergie de l'erreur de prédiction linéaire afin d'identifier les crises épileptiques dans les enregistrements EEG.

II.1.2.1.2 Analyse des composantes

L'analyse des composantes est une approche non supervisée qui consiste à transformer un ensemble de données en un ensemble de caractéristiques. Parmi les techniques couramment utilisées pour le diagnostic de l'épilepsie, on retrouve l'analyse en composantes principales (PCA), l'analyse en composantes linéaires et l'analyse en composantes indépendantes (ICA) [35].




Figure II.6 Signaux EEG typiques : (a) normal, (b) intercritique et (c) critique.

II.1.2.2.1. Analyse en Composantes Principales (PCA)

La PCA est une technique qui réduit la dimension des données en les projetant sur un sous-espace orthogonal (vecteurs propres), tout en minimisant l'erreur quadratique totale. Chaque axe de ce nouvel espace correspond à une « composante principale ». La première composante principale capture la plus grande variance des données, tandis que la deuxième, perpendiculaire à la première, saisit la seconde plus grande variance, et ainsi de suite. La dimension de l'espace de caractéristiques est déterminée par la distribution des données. Dans cette approche, la transformation reste linéaire. Plusieurs études, telles que celles menées par Ghosh-Dastidar et al. [34], Subasi et Gursoy [35] et Acharya et al. [36], ont appliqué la PCA pour classifier les signaux EEG dans le cadre du diagnostic de l'épilepsie.

II.1.1.2.2. Analyse en Composantes Indépendantes (ICA)

L'Analyse en Composantes Indépendantes (ICA) repose sur le principe que chaque signal enregistré est une combinaison linéaire de plusieurs sources indépendantes. Cette technique permet de décomposer un ensemble de données multidimensionnelles en éléments statistiquement indépendants. Elle est particulièrement utile pour éliminer les artefacts et segmenter les signaux EEG en différentes sources d'origine [35].

Dans le domaine de la détection de l'épilepsie, l'ICA est employée pour extraire des sous-composantes spécifiques aux crises épileptiques à partir des signaux EEG bruts. Ces sous-composantes servent ensuite à entraîner des modèles de classification capables de distinguer les segments normaux des segments pathologiques. Une fois le modèle entraîné, un signal EEG de test peut être analysé pour détecter la présence éventuelle de segments associés à une crise. Ce processus est illustré dans la Figure (II.6).

II.1.1.2.3. Analyse Discriminante Linéaire (LDA)

L'analyse discriminante linéaire (LDA) est une méthode fréquemment employée pour réduire la dimensionnalité des données, à l'instar de l'Analyse en Composantes Principales (ACP). Elle repose sur la recherche d'une combinaison linéaire de caractéristiques permettant de distinguer deux ou plusieurs classes, pouvant ainsi être utilisée comme un classificateur linéaire. La LDA vise à maximiser le rapport entre la variance inter-classes et la variance intra-classe afin

d'améliorer la séparation entre les différentes catégories de données, tout en conservant leur position d'origine.

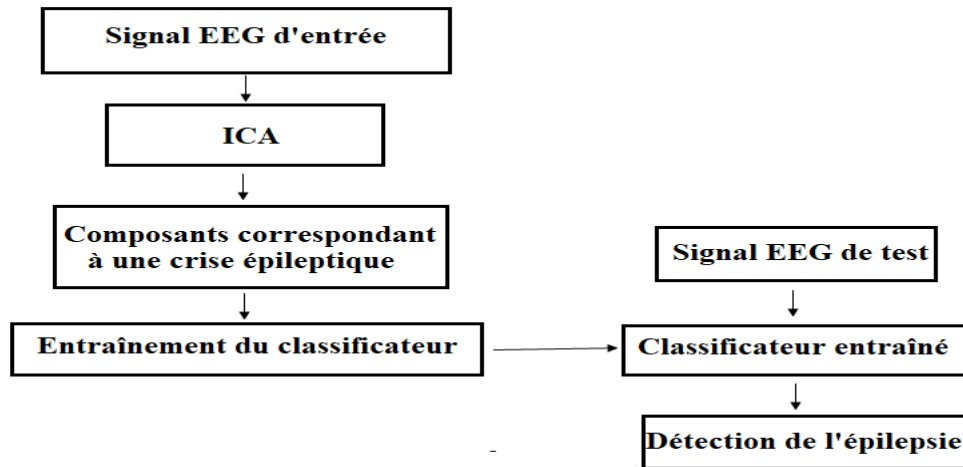


Figure II.7 Illustration de l'utilisation de l'ICA dans la détection de l'épilepsie

Kaplan [38] a analysé les caractéristiques spectrales temporelles des signaux EEG épileptiques et a extrait des paramètres statistiques dans le domaine temporel. De leur côté, Subasi et Gursoy [35] ont appliqué des techniques de réduction de dimensionnalité telles que l'ACP, l'ICA et la LDA pour simplifier les paramètres du domaine fréquentiel et ainsi optimiser la détection des signaux EEG liés à l'épilepsie.

II.1.2.2 Méthodes d'analyse en domaine fréquentiel

L'analyse spectrale permet d'examiner en détail les informations présentes dans le domaine fréquentiel en utilisant des méthodes statistiques et la transformée de Fourier (FT). Les techniques d'estimation spectrale se répartissent en deux grandes catégories : (1) les méthodes classiques ou non paramétriques et (2) les approches non classiques ou paramétriques.

II.1.2.2.1 Méthode non paramétrique

Cette méthode consiste d'abord à estimer l'autocorrélation à partir d'une série de données temporelles. Ensuite, le spectre de puissance est déterminé en appliquant la transformée de Fourier (FT) à la séquence d'autocorrélation. Parmi les techniques couramment utilisées, la méthode de Welch permet d'estimer le spectre de puissance d'un signal temporel [39]. Elle repose sur

l'application d'une fenêtre de données à chaque segment du signal, suivi d'un moyennage temporel des segments pour obtenir une estimation de la densité spectrale de puissance (PSD). Ainsi, la séquence temporelle est divisée en blocs successifs, et un périodogramme est calculé pour chaque segment.

$$x_p \cong w(n)x(n + pR) \quad n = 0, 1, \dots, M - 1, \quad p = 0, 1, \dots, k \quad (\text{II.4})$$

Où R représente le pas de saut de la fenêtre et K le nombre de trames disponibles. Le périodogramme du p-ème bloc est donné par :

$$p_{x_p, M}(W_K) = \frac{1}{M} |FFT_{N, K}(X_P)|^2 \cong \frac{1}{M} \left| \sum_{n=0}^{N-1} x_p(n) e^{-i2\pi nk/N} \right|^2 \quad (\text{II.5})$$

L'estimation de la densité spectrale de puissance (PSD) selon la méthode de Welch, obtenue par la moyenne des périodogrammes sur le temps, est donnée par :

$$PS\hat{D}(W_K) \cong \frac{1}{M} \left| \sum_{n=0}^{N-1} x_p(n) e^{-i2\pi nk/N} \right|^2 \quad (\text{II.6})$$

Polat et Gunes [30] ont appliqué la méthode de Welch pour concevoir un système de détection de l'épilepsie basé sur une classification binaire.

II.1.2.2. Méthode paramétrique

La méthode non paramétrique présente l'inconvénient d'entraîner une fuite spectrale en raison de l'utilisation de fenêtres. Cet effet indésirable peut être atténué grâce aux méthodes paramétriques ou basées sur un modèle pour l'estimation du spectre de puissance. De plus, la méthode paramétrique offre une résolution en fréquence supérieure à celle de la méthode non paramétrique.

Dans cette approche, le signal est considéré comme un processus aléatoire stationnaire. Il est modélisé comme la sortie d'un filtre recevant en entrée un bruit blanc. Les paramètres de ce filtre sont ensuite déterminés. Plusieurs techniques permettent d'estimer ces paramètres en fonction du modèle de filtre adopté.

Le choix du modèle et de la méthode d'estimation dépend de la présence ou de l'absence de pôles dans le domaine Z. Trois principaux modèles existent : le modèle à moyenne mobile (MA), le modèle autorégressif (AR) et le modèle autorégressif à moyenne mobile (ARMA).

Pour une série temporelle x_t , ces modèles peuvent être utilisés afin de prédire ses valeurs futures. Le modèle AR, en particulier, peut être interprété comme la sortie d'un filtre à réponse impulsionnelle infinie tout pôle alimenté par un bruit blanc, et il peut être défini comme :

$$x_t = c + \sum_{i=1}^a \rho_i x_{t-i} + \varepsilon_t \quad (\text{II.7})$$

Où c 'est une constante, ε_t correspond à un bruit blanc, ρ_1, \dots, ρ_a et représentent les paramètres du modèle. Le modèle ARMA, en revanche, se caractérise par la présence de a termes autorégressifs et b termes de moyenne mobile.

$$x_t = c + \sum_{i=1}^a \rho_i x_{t-i} + \varepsilon_t + \sum_{i=1}^b \mu_i x_{t-i} \quad (\text{II.8})$$

Où c 'est une constante, ε_t représente un bruit blanc, ρ_1, \dots, ρ_a désignent les paramètres du modèle AR, et ceux du modèle MA. La méthode de Burg constitue un algorithme performant pour obtenir un modèle AR stable [41]. Elle détermine les paramètres du modèle AR en minimisant simultanément les erreurs de prédiction vers l'avant et vers l'arrière, tout en estimant le coefficient de réflexion. La figure (II.5) présente l'estimation de la densité spectrale de puissance (PSD) obtenue par la méthode de Burg pour des segments normaux, interictaux et ictaux, tels qu'illustrés dans la figure (II.7).




Figure II.8 Estimation de la densité spectrale de puissance (PSD) à l'aide de la méthode de Burg pour les signaux normaux, interictaux et ictaux présentés dans la figure II.6.

II.1.2.3. Méthodes en temps-fréquence

II.1.2.3.1. Transformée en ondelettes

Une ondelette est une oscillation brève et localisée, de durée et d'énergie limitées, qui est corrélée avec le signal EEG pour extraire les coefficients d'ondelette [42]. Initialement, une ondelette de référence, appelée ondelette mère, est déplacée progressivement le long de l'axe temporel afin de générer un ensemble de coefficients à chaque instant. Ces coefficients permettent une représentation du signal dans les domaines temporel et fréquentiel. Par la suite, l'ondelette est dilatée à différentes échelles et normalisée pour conserver la même énergie que l'ondelette mère. Ce processus est répété pour chaque ondelette dilatée afin d'obtenir un nouveau jeu de coefficients.

Trois principales variantes de la transformée en ondelettes existent : la Transformée en Ondelette Discrète (DWT), la Transformée en Ondelette Continue (CWT) et la Décomposition en Paquets d'Ondelettes (WPD). Jahankhani et al. [43], Sadati et al. [44], Subasi [45] et Ocak [46] ont exploité la DWT dans leurs recherches pour l'identification automatique de l'épilepsie. De son côté, Acharya et al. [47] a utilisé la WPD pour analyser les stades épileptiques en s'appuyant sur les cumulants du Spectre d'Ordre Supérieur (HOS).

La WPD constitue une extension de la DWT. Avec la DWT, au premier niveau, le signal est divisé en coefficients d'approximation à l'aide d'un filtre passe-bas et en coefficients de détail via un filtre passe-haut. Aux niveaux suivants, la décomposition est appliquée uniquement aux coefficients d'approximation obtenus précédemment, et ce, jusqu'à atteindre le nombre de niveaux souhaité.

À l'inverse, dans la WPD, la décomposition est effectuée à chaque niveau aussi bien sur les coefficients d'approximation que sur ceux de détail. La figure (II.8) illustre ce processus : A1 représente les coefficients d'approximation obtenus après la première décomposition, tandis que D1 correspond aux coefficients de détail. De même, AA2 et DA2 sont les coefficients d'approximation et de détail issus du deuxième niveau de décomposition appliqué à A1. Ces coefficients servent d'indicateurs pour caractériser les activités épileptiques.

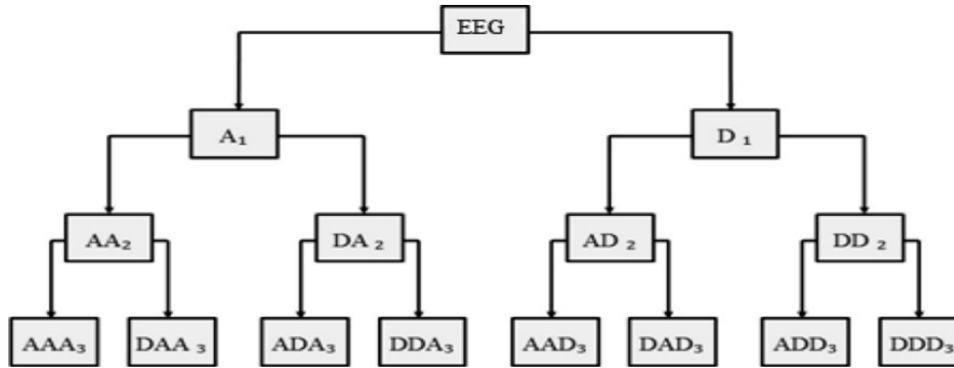


Figure II.9 Décomposition en paquets d'ondelettes.

II.1.2.3.2. Transformée de Hilbert–Huang (HHT)

La transformée de Hilbert–Huang (HHT) permet de décomposer un signal en Fonctions de Mode Intrinsèque (IMFs) afin d'extraire des informations sur la fréquence instantanée. Dans le cadre de la détection de l'épilepsie, la Décomposition Modale Empirique (EMD) est d'abord appliquée pour identifier les modes intrinsèques du signal EEG. Ensuite, la transformée de Hilbert est utilisée sur chaque mode pour analyser les variations instantanées de fréquence et d'amplitude. À partir de ces données, la fréquence pondérée de Hilbert est calculée afin de différencier les signaux normaux des activités épileptiques.

L'EMD est une approche simple, adaptative et non linéaire qui permet de mettre en évidence la variabilité d'une série temporelle [56]. Elle génère un nombre restreint de Fonctions de Mode Intrinsèque (IMFs), qui correspondent à des ondes modulées en amplitude (AM) et en fréquence (FM). Martis et al. [50] ont utilisé cette technique pour classifier les signaux EEG en trois catégories (normaux, interictaux et ictaux) et ont obtenu une précision de 95,3 %.

II.1.2.4. Méthode d'analyse non linéaire

Les méthodes basées sur le domaine fréquentiel permettent d'identifier les oscillations rythmiques d'un signal, mais elles présentent une limite : elles ne peuvent pas détecter les couplages non linéaires ni les verrouillages de phase entre les harmoniques d'un même spectre. Les systèmes biologiques, y compris l'analyse des signaux EEG, peuvent être efficacement modélisés à l'aide de techniques non linéaires. Plusieurs paramètres non linéaires ont été explorés et validés pour la détection de l'épilepsie à partir des signaux EEG [18]. Parmi eux, on retrouve le

Spectre d'Ordre Supérieur (HOS), le plus grand exposant de Lyapunov (LLE), la dimension de corrélation (CD), la dimension fractale (FD), l'exposant de Hurst (H), ainsi que différentes entropies comme l'entropie approximative (ApEn) et l'entropie échantillon (SampEn). L'Analyse de Quantification de Récurrence (RQA) est également une approche pertinente.

II.1.3. Classification des signaux EEG

Les techniques d'apprentissage automatique sont de plus en plus intégrées dans le traitement des signaux EEG pour le diagnostic médical.

II.1.3.1 Machine à Vecteurs de Support (SVM)

Le classificateur SVM est une technique de classification supervisée. Il construit un hyperplan séparateur qui maximise la marge entre les classes de données d'entrée, représentées dans un espace n-dimensionnel (où n est le nombre de caractéristiques utilisées comme entrées). Concrètement, cet hyperplan est orienté de manière à être perpendiculaire à la ligne la plus courte séparant les enveloppes convexes des données d'entraînement de chaque classe et est positionné au milieu de cette ligne. Deux hyperplans parallèles sont ensuite construits de part et d'autre de l'hyperplan séparateur afin de calculer la marge des données d'entraînement.

II.1.3.2 Modèle de Mélange Gaussien (GMM)

Le GMM est un modèle probabiliste utilisé pour l'estimation de densité à l'aide d'une distribution mixte. Il s'agit d'une technique d'apprentissage non supervisée qui repose sur les algorithmes d'espérance-maximisation pour effectuer la classification.

II.1.3.3 Classificateur Flou de Sugeno (FSC)

La logique floue permet d'utiliser des observations imprécises ou incertaines en entrée tout en générant des valeurs précises en sortie. Dans cette approche, la technique de clustering soustractif a été utilisée pour générer un Système d'Inférence Floue (FIS) [53]. Cette technique permet d'estimer le nombre de clusters ainsi que leurs centres dans l'ensemble de données étudié.

Le FIS est composé d'entrées, de sorties et d'un ensemble de règles définissant le comportement du système flou. Chaque entrée et sortie est associée à autant de fonctions

d'appartenance qu'il y a de clusters. Un paramètre de rayon est utilisé pour indiquer l'étendue de l'influence du centre de chaque cluster dans les différentes dimensions des données. Après la phase d'apprentissage, une structure FIS contenant un ensemble de règles floues couvrant l'espace des caractéristiques est générée. Ce système est ensuite utilisé pour réaliser des inférences floues sur les données de test.

II.1.3.4 K-Plus Proches Voisins (KNN)

Le KNN est une technique d'apprentissage supervisé où une nouvelle instance est classée en fonction de ses plus proches voisins dans l'espace des caractéristiques. Contrairement à d'autres algorithmes, il ne repose pas sur un modèle d'ajustement mais fonctionne uniquement par mémorisation. Lorsqu'une donnée de test est introduite, elle est affectée à la classe la plus représentée parmi ses k plus proches voisins.

II.1.3.5 Classificateur Naïf de Bayes (NBC)

Le classificateur Naïf Bayes est un modèle probabiliste basé sur le théorème de Bayes. Il repose sur l'hypothèse forte que les variables prédictives sont des variables aléatoires indépendantes [43]. Cette hypothèse simplifie le calcul des probabilités nécessaires à l'application de la formule de Bayes, même avec un ensemble de données d'entraînement de taille réduite.

II.1.3.6 Arbre de Décision (DT)

Dans un arbre de décision, les caractéristiques d'entrée sont utilisées pour construire une structure arborescente. À partir de cet arbre, un ensemble de règles est généré afin de représenter les différentes classes [44]. Ces règles permettent ensuite de prédire la classe d'un nouvel échantillon dont la catégorie est inconnue.

II.1.3.7 Long Short-Term Memory (LSTM)

Le **LSTM** est largement utilisé dans le **traitement des signaux EEG** en raison de sa capacité à capturer les dépendances **temporelles et séquentielles** dans les données [7]. L'EEG (électroencéphalogramme) est un signal **non stationnaire et bruité**, nécessitant des modèles capables de gérer des relations complexes sur de longues périodes, ce qui rend le LSTM particulièrement adapté.

II.1.3.8 Le Deep Neural Network (DNN)

Le DNN (Deep Neural Network) est une famille de réseaux de neurones profonds utilisés pour modéliser des relations complexes dans les données. Dans le cadre du traitement du signal EEG [7], les DNN sont largement utilisés pour extraire automatiquement des caractéristiques, améliorer la classification et réduire la dépendance aux méthodes de prétraitement traditionnelles.

II.2 ETAT DE LA RECHERCHE SUR LES SIGNAUX ECG

La recherche sur les signaux ECG progresse grâce aux avancées en prétraitement du signal, à l'intégration de l'intelligence artificielle avec des modèles tels que les LSTM et DNN pour la classification automatique des pathologies cardiaques, au développement de la télésurveillance via des dispositifs portables, à l'exploitation de méthodes non linéaires pour extraire de nouveaux biomarqueurs, tout en relevant les défis liés à la robustesse des algorithmes, la personnalisation des modèles et l'interopérabilité des systèmes pour une médecine plus prédictive et personnalisée.

II.2.1 Artefacts dans les signaux ECG

L'électrocardiographie (ECG) est une technique largement utilisée en cardiologie pour analyser l'état cardiaque des patients [45]. Cependant, les signaux ECG sont souvent altérés par du bruit, qu'il soit aléatoire ou déterministe, ainsi que par des artefacts. Ces interférences se superposent au signal cardiaque d'origine, compliquant l'extraction des caractéristiques essentielles et l'interprétation des résultats. Le bruit peut provenir de diverses sources, notamment les mouvements du patient, l'induction électromagnétique de dispositifs électroniques environnants ou encore des artefacts liés aux contractions musculaires. Ces bruits à basse fréquence et figurent parmi les plus complexes à filtrer.

II.2.1.1 Bruit à basse fréquence

Le bruit à basse fréquence est causé par les variations d'impédance entre l'électrode et le corps du patient. Ces fluctuations résultent des changements de distance entre la source du signal (le cœur) et l'électrode, provoqués par les mouvements du patient, notamment la respiration et les modifications du contact entre la peau et l'électrode. Une part importante de ces interférences est attribuée aux mouvements corporels du patient, comme illustré à la Figure (II.8).



Figure II.10: Low frequency noise present in ECG signal [46]

Le bruit à basse fréquence est principalement situé en dessous de 1 Hz. Cependant, dans certains types d'examens, comme les tests d'effort en ECG [46], cette plage de fréquences peut être beaucoup plus élevée, atteignant plusieurs Hz. Lors des tests d'effort, l'amplitude du bruit à basse fréquence augmente considérablement, nécessitant des méthodes de suppression du bruit plus efficaces. Une problématique similaire se pose dans les systèmes d'enregistrement et de surveillance à long terme des signaux ECG, tels que les dispositifs Holter.

II.2.1.2 Bruit musculaire

Le bruit musculaire est provoqué par la contraction des muscles squelettiques, généralement due aux mouvements du patient. Ces interférences peuvent être accentuées par des déplacements involontaires ou des conditions environnementales inadaptées lors de l'examen ECG. Comme illustré à la Figure (II.9), les signaux musculaires sont systématiquement présents aux côtés des signaux ECG. Ce type de bruit est particulièrement prononcé lors des tests d'effort,

où les contractions musculaires deviennent plus intenses, notamment lors de la course sur un tapis roulant ou de l'effort généré par un cycloergomètre.




Figure II.11 Exemple de bruit musculaire dans les signaux ECG [46]

II.2.1.3 Bruit électromagnétique

Le bruit électromagnétique résulte de l'influence des champs électromagnétiques générés par l'alimentation électrique du système de mesure (Figure(II.10)) ou par d'autres équipements médicaux [46].




Figure II.12 Interférence du réseau électrique dans le signal ECG [46]

L'interférence liée au réseau électrique se caractérise par un spectre de fréquence étroit, centré autour de la fréquence du courant alternatif. Ce type de bruit est relativement facile à éliminer grâce à l'utilisation de filtres coupe-bande à bande passante étroite, qui peuvent être analogiques mais sont majoritairement numériques. Une solution efficace pour réduire ces

interférences consiste à concevoir des dispositifs d'enregistrement avec un blindage approprié et des systèmes de suppression du bruit.

Le filtrage coupe-bande permet d'atténuer efficacement le bruit électromagnétique, car son spectre chevauche peu les fréquences du signal ECG, minimisant ainsi toute altération du signal d'origine. Parmi les différentes sources de bruit électromagnétique, on distingue notamment celles liées aux alimentations électriques, où les variations de tension et de courant se produisent aux fréquences de 50 ou 60 Hz, constituant ainsi une interférence typique des systèmes d'alimentation.

II.2.2 Prétraitement et filtrage des signaux ECG

L'électrocardiographie (ECG) est une technique largement utilisée en cardiologie pour analyser l'état cardiaque des patients [46]. Cependant, les signaux ECG sont souvent altérés par du bruit, qu'il soit aléatoire ou déterministe, ainsi que par des artefacts. Ces interférences se superposent au signal cardiaque d'origine, compliquant l'extraction des caractéristiques essentielles et l'interprétation des résultats. Le bruit peut provenir de diverses sources, notamment les mouvements du patient, l'induction électromagnétique de dispositifs électroniques environnants ou encore des artefacts liés aux contractions musculaires.

Pour atténuer ces perturbations, plusieurs méthodes ont été développées, parmi lesquelles les filtres adaptatifs [47,48], l'analyse en composantes indépendantes (ICA) [49], la décomposition modale empirique (EMD) [50], la décomposition de Fourier adaptative [51], le filtre de Savitzky-Golay [52], la méthode de seuillage pour la détection du bruit haute fréquence [53], les filtres de Kalman [54], le filtrage bayésien [55], les ondelettes [56], le regroupement des caractéristiques morphologiques [57] et les réseaux neuronaux [58]. Plus récemment, des approches basées sur l'apprentissage profond (Deep Learning, DL) ont été explorées, notamment pour la classification des arythmies cardiaques [59] et l'identification des caractéristiques QRS à l'aide de machines à vecteurs de support (SVM) [60].

Cependant, ces méthodes ne tiennent pas toujours compte des niveaux de bruit très élevés présents dans les ECG. Par exemple, une première tentative d'utilisation des réseaux de mémoire à long court terme (LSTM) pour la suppression du bruit a été proposée dans [61], tandis que [62] a exploré les autoencodeurs, sans traiter le problème du bruit dérivant, qui peut être plusieurs fois

supérieur en amplitude au signal ECG lui-même. Ce type de bruit, particulièrement fréquent dans les capteurs portables, constitue un défi majeur. Comme indiqué précédemment, les signaux ECG sont constamment perturbés par du bruit. Les bruits à basse fréquence et d'origine musculaire figurent parmi les plus complexes à filtrer.

II.2.3 Techniques d'extraction des caractéristiques d'un signal ECG

L'électrocardiographie repose sur l'analyse de l'activité électrique du cœur, et une représentation précise du signal ECG est essentielle pour un diagnostic fiable des maladies cardiaques. De nombreuses méthodes d'extraction de caractéristiques ont été développées dans la littérature afin d'extraire des informations spécifiques des signaux ECG, facilitant ainsi leur analyse et leur classification. Ces caractéristiques peuvent être exploitées individuellement ou combinées pour améliorer la précision des diagnostics. Dans cette section, nous regroupons les caractéristiques de l'ECG en cinq catégories principales : QRS, statistiques, morphologiques, ondelettes et autres caractéristiques.

II.2.3.1 Caractéristiques du complexe P-QRS-T

Les caractéristiques du complexe P-QRS-T d'un signal ECG sont définies par l'emplacement, la durée, l'amplitude et la forme de ses ondes principales : P, Q, R, S, T et U. L'onde P résulte de la dépolarisation auriculaire, tandis que le complexe QRS, élément central de l'analyse ECG, est généré par la dépolarisation ventriculaire précédant leur contraction. La repolarisation ventriculaire est représentée par l'onde T, tandis que l'onde U, plus discrète, suit immédiatement cette dernière. La repolarisation auriculaire, bien que présente, est masquée par l'amplitude du complexe QRS.

Les chercheurs utilisent plusieurs caractéristiques du complexe QRS, telles que la durée de l'onde R, les amplitudes P, QRS pic-à-pic, R, ST et T, ainsi que la surface de l'onde QRS et la pente ST. Ces paramètres permettent d'analyser la structure et les variations du signal ECG. Par exemple, la pente ST est définie par l'angle entre les points S et T, tandis que la surface du complexe QRS est déterminée en traçant un rectangle autour des points Q, R et S. Plusieurs études récentes exploitent ces caractéristiques pour l'analyse de l'ECG [73].

Certains intervalles de l'ECG fournissent des informations essentielles et sont utilisés comme caractéristiques d'analyse. L'intervalle PR correspond au temps entre le début de l'onde P

et le complexe QRS, reflétant la période entre la dépolarisation auriculaire et ventriculaire [76]. L'intervalle QT s'étend du début de la dépolarisation ventriculaire jusqu'à la fin de la repolarisation, tandis que l'intervalle ST couvre la période entre la fin de l'onde S et le début de l'onde T. L'intervalle RR, ou intervalle entre deux battements cardiaques successifs, est utilisé pour évaluer la dynamique du signal ECG. Plusieurs études exploitent ces caractéristiques du signal RR.

Les valeurs standards des caractéristiques du complexe QRS pour un ECG normal chez des sujets sains sont présentées dans le Tableau 2, avec des détails supplémentaires disponibles dans. L'extraction des caractéristiques du complexe QRS nécessite la détection de points fiduciaires, ce qui a conduit au développement de plusieurs algorithmes, dont le plus courant est celui de Pan-Tompkins [74]. D'autres approches incluent les méthodes basées sur les dérivées, les filtres numériques [74], la transformée en ondelettes, les réseaux neuronaux et la transformée de phaseur. Des techniques spécifiques, telles que l'utilisation de moments d'ordre supérieur et de la méthode d'opération différentielle, ont également été explorées.

Plusieurs études portent sur la détection des pics R, avec des approches utilisant un seuil dynamique ou la différenciation.

II.2.3.2 Caractéristiques statistiques :

Les caractéristiques statistiques, couramment utilisées ces dernières années pour l'analyse des signaux ECG, sont généralement dérivées des valeurs du domaine temporel. Parmi ces attributs, on retrouve l'énergie, la moyenne, l'écart type, les valeurs extrêmes (maximale et minimale), la kurtosis et l'asymétrie. Ces paramètres permettent d'évaluer la complexité et la distribution d'une série temporelle. Appliquées aux enregistrements ECG, elles facilitent l'identification des variations spécifiques aux patients ou aux pathologies, contribuant ainsi à améliorer la performance des classifications.

II.2.3.3 Caractéristiques morphologiques

Les caractéristiques morphologiques sont également exploitées dans l'analyse des signaux ECG. De nombreuses études les ont utilisées pour le diagnostic des signaux ECG. Certaines recherches s'en sont servies pour classifier cinq types de battements cardiaques.

Table II.2 Caractéristiques typiques de l'ECG de la dérivation II et leurs valeurs normales dans le rythme sinusal à une fréquence cardiaque de 60 bpm pour un homme adulte en bonne santé [18]

Fonction	Valeur normale	Limite normale
Largeur P	110 ms	± 20 ms
Intervalle PR	160 ms	± 40 ms
Largeur QRS	100 ms	± 20 ms
Intervalle QTc (corrigé)	400 ms	± 40 ms
Amplitude P	0,15 mV	$\pm 0,05$ mV
Hauteur QRS	1,5 mV	$\pm 0,5$ mV
Niveau ST	0 mV	$\pm 0,1$ mV
Amplitude T	0,3 mV	$\pm 0,2$ mV

II.2.3.4 Caractéristiques ondelettes

Les techniques d'analyse fréquentielle figurent parmi les méthodes les plus couramment utilisées pour l'extraction de caractéristiques des signaux ECG en vue de leur classification. En raison de la nature non stationnaire des signaux ECG, la transformation en ondelettes (WT) constitue un outil performant pour leur analyse et pour l'extraction de caractéristiques fréquentielles grâce à sa capacité de localisation temps-fréquence.

La WT est une transformation linéaire permettant de décomposer un signal en différentes composantes à diverses échelles. Elle offre une représentation temps-fréquence en identifiant la localisation temporelle des composantes spectrales. Cette méthode repose sur l'utilisation d'ondelettes, dérivées d'une ondelette mère par translation et mise à l'échelle, pour simplifier la décomposition du signal. Initialement, le signal est scindé en composantes de basse fréquence (approximations) et de haute fréquence (détails), avec une décomposition progressive des composantes d'approximation. L'analyse en paquets d'ondelettes permet une décomposition plus détaillée en subdivisant simultanément les approximations et les détails à tous les niveaux. L'un des principaux avantages de la WT est sa capacité à préserver la localité temporelle.

Plusieurs études récentes ont exploité les caractéristiques basées sur les ondelettes pour l'analyse des signaux ECG, notamment. Parmi les variantes de la WT utilisées, on retrouve la transformation en ondelettes continues, la transformation en ondelettes complexes à double arbre,

la transformation en ondelettes avec facteur Q ajustable, la transformation en ondelettes analytiques flexibles ainsi que la transformation en ondelettes dyadiques discrètes.

II.2.3.5 Autres caractéristiques

En plus des caractéristiques déjà évoquées, plusieurs techniques spécifiques d'extraction de caractéristiques pour les signaux ECG ont été développées. Parmi celles-ci figurent les exposants de Lyapunov, les attributs basés sur la densité spectrale de puissance, ainsi que les caractéristiques statistiques. L'analyse de l'autocorrélation et la complexité de Kolmogorov sont également utilisées pour extraire des informations pertinentes. Par ailleurs, certaines méthodes exploitent les variations de l'intervalle entre les battements cardiaques ou font appel aux algorithmes génétiques pour affiner l'analyse des signaux ECG.

II.2.4 Classification des signaux ECG

De nombreuses méthodes de classification ont été appliquées à l'analyse et à la classification des signaux ECG. Les études récentes recensées dans cet article regroupent ces classificateurs en plusieurs catégories, notamment les réseaux de neurones artificiels (ANNs), l'analyse discriminante linéaire (LDA), les k plus proches voisins (kNN), les machines à vecteurs de support (SVM), les arbres de décision (DT) et les classificateurs bayésiens. Ces approches, ainsi que d'autres techniques moins courantes, sont présentées en détail dans les sections suivantes.

II.2.4.1 Réseaux de neurones artificiels (ANN)

Les réseaux de neurones artificiels (ANN) sont des modèles inspirés du cerveau humain, largement utilisés pour la classification des signaux ECG. Plusieurs architectures existent [73] :

- Modèles avancés : ANN à valeurs complexes et ANN récurrentes, adaptées aux données temporelles.
- Modèles hybrides : ANN combinées avec le clustering flou pour améliorer la classification.
- Méthodes classiques : ANN à rétropropagation (BPNN) et réseaux probabilistes (PNN) offrant un apprentissage rapide.

- Méthodes basées sur les fonctions d'activation : Réseaux à fonction de base radiale (RBFNN) et réseaux avec activation adaptative (NNAAF).
- Modèles spécialisés : Réseau de régression généralisée (GRNN), quantification vectorielle d'apprentissage (LVQ) et réseau à retard temporel (TDNN).
- Approches structurales : Réseau basé sur des blocs (BbNN), organisé en unités interconnectées pour l'analyse ECG.

Chaque type de réseau est choisi en fonction des spécificités du signal ECG et de la tâche de classification à réaliser.

II.2.4.2 Arbre de décision (DT)

L'apprentissage par arbre de décision (DT) consiste à analyser des observations sur un élément afin d'en tirer une conclusion. Cette conclusion peut correspondre à une étiquette de classe cible ou à une valeur numérique. Selon cette distinction, on parle d'arbres de classification lorsque les feuilles représentent des catégories et d'arbres de régression lorsque les feuilles indiquent des valeurs continues. Les arbres de décision sont couramment utilisés dans des études de classification des signaux ECG.

En plus des approches classiques, certaines variantes spécifiques sont fréquemment employées en classification ECG. Parmi elles, l'arbre aléatoire (Random Forest Tree) est un classificateur ensembliste basé sur plusieurs arbres de décision. Dans cette méthode, chaque arbre est entraîné sur un sous-ensemble de données, et la prédiction finale repose sur un vote majoritaire des arbres individuels. Cette technique est largement utilisée dans les études de classification ECG.

II.2.4.3 Analyse discriminante linéaire (LDA)

Proposée par Fisher en 1936, l'analyse discriminante linéaire (LDA) est une méthode de classification qui, dans certains cas, offre de meilleures performances que des techniques plus modernes et sophistiquées. Elle vise à maximiser le rapport entre la variance inter-classe et la variance intra-classe afin d'optimiser la différenciation entre les classes. La LDA a été largement utilisée dans plusieurs études récentes portant sur la classification des signaux ECG.

II.2.4.4 Machine à vecteurs de support (SVM)

La machine à vecteurs de support (SVM) est une méthode de classification binaire largement adoptée en raison de ses excellentes performances de généralisation. Son objectif principal est de déterminer une frontière de décision optimale en maximisant la marge qui sépare les différentes classes de données. Cette séparation est définie à l'aide des vecteurs de support, qui sont les points les plus proches de la frontière de décision et jouent un rôle clé dans l'apprentissage du modèle.

Le SVM peut fonctionner comme un classificateur linéaire ou non linéaire, selon le type de fonction noyau utilisé. Une fonction noyau linéaire lui permet de classifier les données de manière linéaire, tandis que des noyaux plus complexes, comme le noyau gaussien à base radiale, polynomial ou sigmoïde, permettent de gérer des relations non linéaires. Cette approche est couramment appliquée dans les études portant sur la classification des signaux ECG.

II.2.4.5 K plus proches voisins (kNN)

L'algorithme des k plus proches voisins (kNN) attribue une classe à un vecteur de caractéristiques en se basant sur les étiquettes des échantillons d'apprentissage les plus proches dans l'espace des caractéristiques. Pour classer un vecteur inconnu, la distance entre celui-ci et tous les vecteurs du jeu d'entraînement est calculée à l'aide d'une mesure comme la distance euclidienne. Ensuite, l'algorithme assigne ce vecteur à la classe majoritaire parmi les k voisins les plus proches, selon un principe de vote majoritaire.

Le choix de la valeur de k, un entier positif, a un impact significatif sur la précision du modèle. Largement utilisé en reconnaissance de formes, le kNN est également employé dans plusieurs études récentes sur la classification des signaux ECG.

II.2.4.6 Classificateurs bayésiens

Les classificateurs bayésiens s'appuient sur la théorie de la décision de Bayes, une approche statistique essentielle. Leur principe repose sur la capacité à estimer les valeurs des caractéristiques lorsque la classe est connue. À défaut, la règle de Bayes permet de déterminer la classe la plus probable à partir des données disponibles. Ces modèles probabilistes sont largement utilisés pour attribuer une étiquette de classe aux nouvelles observations. Très répandus dans les

problèmes de reconnaissance de formes, ils ont été appliqués dans de nombreuses études récentes. Parmi les principales variantes utilisées pour la classification des signaux ECG, on trouve le réseau bayésien, le naïf Bayes et le classificateur bayésien du maximum de vraisemblance [73].

II.2.4.7 Autres approches de classification

En plus des méthodes de classification déjà évoquées, plusieurs autres techniques ont été appliquées à la classification des signaux ECG. Parmi celles-ci, on retrouve les classificateurs basés sur la logique floue, les classificateurs flous génétiques, l'approche d'appariement de modèles, les classificateurs basés sur les modèles de mélange gaussien et les classificateurs des plus proches voisins utilisant la dimension fractale locale. D'autres approches incluent un nouvel algorithme d'arbre de classification, la régression linéaire, la régression logistique, ainsi que des modèles hybrides tels que l'algorithme Bees couplé aux fonctions de base radiale [73].

Par ailleurs, des techniques comme les classificateurs à seuil, une version améliorée de l'algorithme de la colonie d'abeilles artificielles, les méthodes ensemblistes telles que Bagging et AdaBoost [73], l'agrégation Bootstrap combinant 100 arbres de décision, l'approche de détection basée sur les modèles de Markov cachés et le boosting avec sous-échantillonnage aléatoire ont également été explorées.

Enfin, certaines méthodes d'apprentissage non supervisé ont été employées, notamment le clustering flou, l'algorithme d'espérance-maximisation (EM) [75], l'algorithme des k-means et les cartes auto-organisatrices (self-organizing maps).

Conclusion

L'analyse des signaux EEG et ECG joue un rôle essentiel dans le diagnostic médical et l'étude des pathologies neurologiques et cardiaques. Ce chapitre a mis en évidence les différentes étapes du traitement de ces signaux, depuis l'acquisition et le prétraitement jusqu'à l'extraction des caractéristiques et la classification.

Les techniques de filtrage, telles que l'analyse en composantes indépendantes (ICA) et la transformation en ondelettes, permettent de réduire les artefacts et d'améliorer la qualité des enregistrements. L'extraction de caractéristiques repose sur des méthodes variées incluant des

analyses statistiques, morphologiques et fréquentielles, offrant une meilleure interprétation des signaux EEG et ECG.

Enfin, différentes approches de classification ont été explorées, allant des méthodes traditionnelles, comme l'analyse discriminante linéaire (LDA) et les arbres de décision (DT), aux techniques avancées basées sur l'intelligence artificielle, notamment les réseaux de neurones artificiels (ANN) et les machines à vecteurs de support (SVM). L'intégration croissante de l'apprentissage automatique et des modèles hybrides ouvre de nouvelles perspectives pour une analyse plus précise et automatisée des signaux biomédicaux, favorisant ainsi des avancées significatives dans la détection et le suivi des pathologies.

CHAPITRE 3

Détection des crises épileptiques

Introduction

L'objectif principal de ce chapitre étude est de développer un système automatique de détection de l'épilepsie reposant principalement sur les caractéristiques non linéaires se manifestant dans le domaine fréquentiel, associées à l'utilisation de nouvelles techniques d'apprentissage automatique, en particulier celles liées à l'apprentissage profond. Plus de 40 millions de personnes dans le monde souffrent d'épilepsie, et ce chiffre augmente de deux millions chaque année [77,78].

L'épilepsie est un trouble neurologique qui peut toucher des individus de tous âges. Elle se divise en cinq groupes principaux : structural (métabolique), génétique, infectieux, immunitaire et d'origine inconnue [79]. Il a été rapporté que l'épilepsie représente environ 0,6 % de la charge mondiale des maladies. Elle peut être définie comme un symptôme qui survient soudainement en perturbant l'activité électrique normale du cerveau. La principale cause des crises épileptiques réside dans une synchronisation massive de l'activité électrique des neurones, provoquée par des charges chimiques complexes qui génèrent des signaux électriques d'une amplitude comprise entre 0,5 et 1,5 mV [80].

Selon la Ligue internationale contre l'épilepsie (ILAE), une crise épileptique est une manifestation transitoire de signes et/ou symptômes résultant d'une détérioration partielle ou totale du fonctionnement du corps humain. Ces crises, souvent violentes et dangereuses, surviennent de manière soudaine et peuvent entraîner des dommages physiques liés à des blessures survenues lors d'une chute ou d'une perte de conscience. Il devient donc crucial de prédire les instants de crise chez les patients en analysant les signaux enregistrés pour chacun d'eux. Ainsi, pour diagnostiquer l'épilepsie, les experts s'appuient traditionnellement sur les signaux EEG, dont l'analyse permet de détecter les caractéristiques distinctives d'un signal enregistré chez une personne malade ou en bonne santé. Le signal EEG est une trace qui peut traduire l'activité électrique du cerveau, obtenue à partir d'électrodes placées sur le cuir chevelu du patient. L'EEG est un signal non stationnaire et non linéaire [81].

Le système international 10-20 est le système le plus couramment utilisé pour le placement des électrodes; il contient 19 électrodes et deux électrodes supplémentaires situées près des oreilles (chapitre I). Les experts neurologues peuvent identifier les crises épileptiques dans

différentes catégories telles que normal, pré-ictal, ictal et interictal [82]. Les tracés EEG englobent cinq bandes de fréquences communément appelées : la bande delta allant de 0 à 4 Hz, la bande thêta (4–8 Hz), la bande alpha (8–12 Hz), la bande bêta (13–30 Hz), et enfin la bande gamma regroupant toutes les fréquences au-delà de 30 Hz. Il n'y a aucune raison pour laquelle l'ensemble du spectre EEG devrait être plus représentatif des dynamiques cérébrales que les bandes de fréquences considérées individuellement. En réalité, ces bandes de fréquences peuvent fournir des informations plus précises sur les processus neuronaux constitutifs à l'origine de l'EEG. Par conséquent, certains changements dans les signaux EEG, qui ne sont pas visibles dans l'EEG à spectre complet, peuvent être accentués lorsque chaque bande est examinée indépendamment [83].

La nature non invasive du système EEG et la possibilité d'enregistrer de manière ambulatoire permettent aux neurologues d'examiner visuellement les signaux EEG à des fins de diagnostic. Cependant, ce processus nécessite un temps d'analyse important, d'où l'intérêt d'utiliser des algorithmes automatiques de détection des crises respectant les caractéristiques du signal EEG souhaité. Plusieurs méthodes alternatives ont été employées lors de l'étape d'extraction des caractéristiques pour extraire plusieurs caractéristiques différentes à partir des mêmes données brutes. Ainsi, la classification des signaux EEG peut être considérée comme un problème typique de classification utilisant des caractéristiques calculées [80]. En outre, les caractéristiques extraites sont de nature soit linéaire, soit non linéaire. Dans de nombreuses études, le processus sous-jacent générant les signaux EEG observés est considéré comme non linéaire ou composé de sous-systèmes dans lesquels des dynamiques non linéaires jouent un rôle clé. Ces dernières années, il y a eu un intérêt croissant pour l'application de techniques issues des domaines d'analyse non linéaire. Plusieurs approches d'analyse et de traitement des données EEG ont récemment été développées dans la littérature dans le but de détecter automatiquement les crises épileptiques. Ces méthodes se concentrent généralement sur différentes manières d'extraire des caractéristiques des données EEG, suivies d'un processus de catégorisation. Dans la plupart des cas, la technique d'extraction des caractéristiques est effectuée dans les domaines temporel, fréquentiel ou temps-fréquence (échelle). De plus, les caractéristiques extraites sont de nature soit linéaire, soit non linéaire.

Les caractéristiques temporelles et fréquentielles sont utilisées pour détecter les crises épileptiques dans les signaux EEG lorsque ceux-ci sont supposés stationnaires. En revanche, la

nature non stationnaire des signaux EEG est généralement décrite dans le domaine temps-fréquence [84]. Les paramètres non linéaires peuvent constituer un choix pertinent pour différencier les signaux EEG par rapport aux paramètres linéaires extraits. Le plus grand exposant de Lyapunov (LLE), l'entropie multiscale modifiée (MMSE) [85], et bien d'autres sont des métriques non linéaires qui ont été identifiées comme révélant des informations significatives sur l'épilepsie dans de nombreuses études. Récemment, Hancer et Subasi [86] ont remis en question l'hypothèse selon laquelle l'EEG doit être traité dans son ensemble lors de l'étude des dynamiques non linéaires sous-jacentes. Puisqu'un signal EEG représente l'effet de la superposition de divers processus dans le cerveau, les auteurs ont postulé que des paramètres pourraient être sélectionnés à partir des sous-bandes physiologiques de l'EEG et utilisés simultanément comme entrées pour les classificateurs. L'efficacité des mesures non linéaires dépend fréquemment de l'ajustement manuel de nombreux paramètres, nécessitant une implication humaine accrue [87].

La détection automatique des crises est essentielle à la fois pour le diagnostic de l'épilepsie et pour alléger la charge de travail liée à l'inspection des EEG prolongés. Yuan et al. [88] ont décrit une nouvelle approche de détection des crises épileptiques sur EEG multi-canaux à long terme. En tant que nouvelle caractéristique non linéaire des données EEG, l'interception fractale obtenue à partir de la géométrie fractale est extraite, et l'indice de fluctuation relative est déterminé comme une caractéristique linéaire. Un réseau neuronal à couche unique est utilisé pour classifier le vecteur de caractéristiques, qui comprend les deux descripteurs EEG, aboutissant à un taux de fausse détection de 0,35 par heure. Cette approche a atteint une sensibilité de 93,85 %. Déséquilibre des classes de crises. Pour relever ces défis, il est souvent nécessaire de combiner des techniques avancées de traitement du signal avec des algorithmes d'apprentissage automatique, ce qui nous a conduit à proposer une combinaison de caractéristiques non linéaires extraites dans des bandes de fréquences spécifiques de l'EEG, également appelées rythmes EEG, avec l'utilisation de divers classificateurs d'apprentissage automatique (ML) et d'apprentissage profond (DL).

Dans ce chapitre, six approches d'extraction de caractéristiques non linéaires ont été examinées, notamment la dimension fractale de Higuchi [88], la dimension fractale de Katz [89], l'entropie multiscale modifiée (MMSE) [90], les coefficients de Hjorth [91], l'exposant de Hurst et l'analyse de fluctuation sans tendance (DFA). Avant le calcul des paramètres non linéaires, les

signaux EEG ont été filtrés à l'aide d'un filtre à réponse impulsionnelle finie (RIF) d'ordre 100 dans chacune des quatre bandes de fréquences mentionnées : delta, thêta, alpha et bêta.

Les caractéristiques non linéaires sont calculées pour chaque bande de fréquence des signaux EEG. Des vecteurs de caractéristiques non linéaires sont préparés à partir des caractéristiques extraites pour l'entraînement des différents classificateurs. Comme les caractéristiques des signaux EEG sont estimées pour les bandes de fréquence alpha, bêta, thêta et delta, le bruit additif associé aux signaux EEG au-delà de 30 Hz est automatiquement éliminé. Il convient de noter que le processus d'extraction des caractéristiques pour chaque bande indépendamment, puis de classification de deux états mentaux à l'aide de ces caractéristiques par bande, offre un aperçu supplémentaire de la contribution de chaque bande de fréquence à la classification automatique. Les techniques d'extraction de caractéristiques proposées dans ce travail sont suivies par des méthodes de classification basées sur l'apprentissage automatique (ML) et l'apprentissage profond (DL). Globalement, les contributions apportées par ce chapitre sont les suivantes :

- Utilisation d'un nouveau vecteur d'extraction de caractéristiques constitué de certaines mesures non linéaires importantes calculées au sein des rythmes EEG, qui, à notre connaissance, n'a pas encore été exploré.
- Étude de l'effet de la combinaison simultanée de ces mesures non linéaires dans un seul vecteur de caractéristiques.
- Évaluation de plusieurs vecteurs de caractéristiques différents construits sur la base de ces mesures non linéaires.
- Validation de la méthode proposée à l'aide de classificateurs basés sur l'apprentissage automatique (ML) et l'apprentissage profond (DL).

III.1 ÉTAT DE LA RECHERCHE SUR LA DÉTECTION DES CRISES ÉPILEPTIQUES

De nombreuses études sur la détection et la catégorisation des crises épileptiques ont été publiées dans la littérature. Diverses approches d'extraction de caractéristiques et de classificateurs ont été développées pour caractériser les pics normaux et anormaux dans les signaux de crises épileptiques avec une grande efficacité et précision. La majorité des recherches existantes sur la détection et la classification de l'épilepsie se concentrent sur la classification des signaux normaux,

ictaux et interictaux. Des caractéristiques non linéaires avancées telles que la dimension fractale (FD), le plus grand exposant de Lyapunov (LLE), la dimension de corrélation (CD), l'exposant de Hurst (HE) et les entropies [92] sont utilisées comme caractéristiques pour la détection des crises. Une synthèse des études sur la détection automatisée des crises utilisant divers paramètres non linéaires est fournie dans des travaux de revue comme [92]. L'analyse des signaux EEG utilisant une combinaison de techniques temps-fréquence et de caractéristiques non linéaires produit des résultats remarquables [92],[93] ont pour objectif d'analyser les métriques de performance de classification ainsi que de résumer les descriptions et interprétations des caractéristiques pour définir les épisodes épileptiques à partir des signaux EEG. Ils ont mené une expérience pour évaluer la qualité de chaque caractéristique séparément afin de fournir des informations utiles pour la sélection des caractéristiques, avec des résultats satisfaisants. Pour la classification des signaux EEG normaux, préictaux et ictaux, Acharya et al.[94] ont proposé un réseau neuronal convolutionnel profond à 13 couches, atteignant un taux de classification de 88,67 % en utilisant 300 échantillons EEG de cinq individus. Guo et al. [95] ont étudié l'utilisation des coefficients d'ondelettes pour classer les signaux EEG, combinant les capacités adaptatives d'un réseau neuronal, la logique floue et l'approche quantitative de la fonction de densité de probabilité. Ils ont analysé les sous-bandes EEG (delta, thêta, alpha, bêta et gamma) en utilisant la décomposition multi-résolution et un réseau neuronal artificiel. Tzallas et al.[96] ont démontré que l'analyse temps-fréquence peut être utilisée pour classer les segments EEG et ont comparé plusieurs approches pour l'analyse temps-fréquence des EEG. Chakrabarti et al.[97] ont proposé un système automatisé de détection des crises permettant un diagnostic plus rapide et plus précis avec moins d'erreurs. Kaleem et al. [98] ont introduit une stratégie d'apprentissage de dictionnaire empirique dérivé des signaux pour l'identification automatique des crises, basée sur la décomposition en modes empiriques (EMD). Mardini et al. [99] ont utilisé 54 ondelettes mères DWT avec des algorithmes génétiques et quatre classificateurs, surpassant de nombreuses approches existantes. Ocak [100] a développé une méthode basée sur la transformation en ondelettes discrètes (DWT) et l'analyse de la complexité de l'entropie approximative (ApEn). Li et al. [101] ont proposé un réseau de convolution mixte à projection de canal (CP-MixedNet) pour capturer les caractéristiques temporelles multi-échelles des signaux EEG. Plus récemment, Lih et al. [102] ont suggéré un modèle DL basé sur des transformateurs appelé EpilepsyNet, atteignant une précision de 85 % avec 121 patients. De nombreux chercheurs ont donc tenté de classifier automatiquement les événements de crises EEG en utilisant des caractéristiques basées sur le domaine temporel,

fréquentiel ou une combinaison des deux, en employant divers algorithmes de classification. Cet article poursuit cet objectif.

III.2 BASE DE DONNEE DE BONN ET HAUZ KHAS

III.2.1 Base de donnée Bonn

La base de données EEG de l'Université de Bonn comprend des données EEG monocanal mises à disposition uniquement à des fins de recherche. Elle se compose de cinq sous-ensembles d'EEG, désignés par les ensembles A à E, chacun contenant 100 échantillons. Pour 100 segments EEG enregistrés à la surface du crâne via un canal unique, la durée totale d'enregistrement est de 23,6 secondes.

- **Ensembles A et B** : Les signaux EEG ont été enregistrés sur cinq volontaires sains, sous une surveillance attentive.
- **Ensemble C** : Les signaux proviennent de patients sans épisode épileptique dans la formation hippocampique hémisphérique.
- **Ensemble D** : L'enregistrement a été réalisé dans la zone épileptogène.
- **Ensemble E** : Les signaux EEG ont été capturés chez des patients en pleine crise épileptique.

Les données ont été numérisées à l'aide d'un convertisseur analogique-numérique (CAN) 12 bits avec une fréquence d'échantillonnage de 173,61 Hz. Chaque segment EEG contient ainsi 4096 points. La figure. 2 illustre les signaux EEG des cinq sous-ensembles.

III.2.2 Base de donnée Hauz Khas

La base de données Hauz Khas a été collectée au Neurologie et Sommeil Centre de Hauz Khas, New Delhi. Elle comprend 50 exemples de séries temporelles correspondant aux états ictal, interictal et préictal, échantillonnés à une fréquence de 200 Hz. Une description complète est disponible dans l'étude de Swami et al. (2016).




Figure III.1 Échantillons de signaux EEG provenant de la base de données EEG de l'Université de Bonn.

III.3 METHODES DE DÉTECTION

L'approche proposée pour la détection de l'épilepsie ou des crises est représentée sous forme de diagramme fonctionnel dans la Figure III.1. Avant d'aborder l'étape de filtrage par bande de fréquence, tous les signaux EEG ont été segmentés en courts segments temporels non chevauchants d'une durée de 1 seconde. Bien que le bloc de segmentation puisse être ignoré en considérant le signal EEG global comme candidat pour les blocs suivants, il est supposé que la procédure de segmentation produit des fonctions temporelles synchronisées, offrant ainsi une meilleure résolution temporelle [103]. Le cadre proposé se compose de cinq parties :

III.3.1 Filtrage sous-bandes de fréquence

Cette première étape vise à isoler les différents rythmes du signal EEG. Un filtre passe-bas RIF est utilisé pour le rythme delta (0-4 Hz) avec une fréquence de coupure de 4 Hz. Pour les rythmes thêta (4-8 Hz) et alpha (8-13 Hz), des filtres passe-bande RIF sont appliqués, et pour le rythme bêta (au-delà de 13 Hz), un filtre passe-haut RIF est utilisé. Dans tous les cas, des filtres à phase nulle sont employés afin de préserver la dynamique du signal sans distorsion de phase.

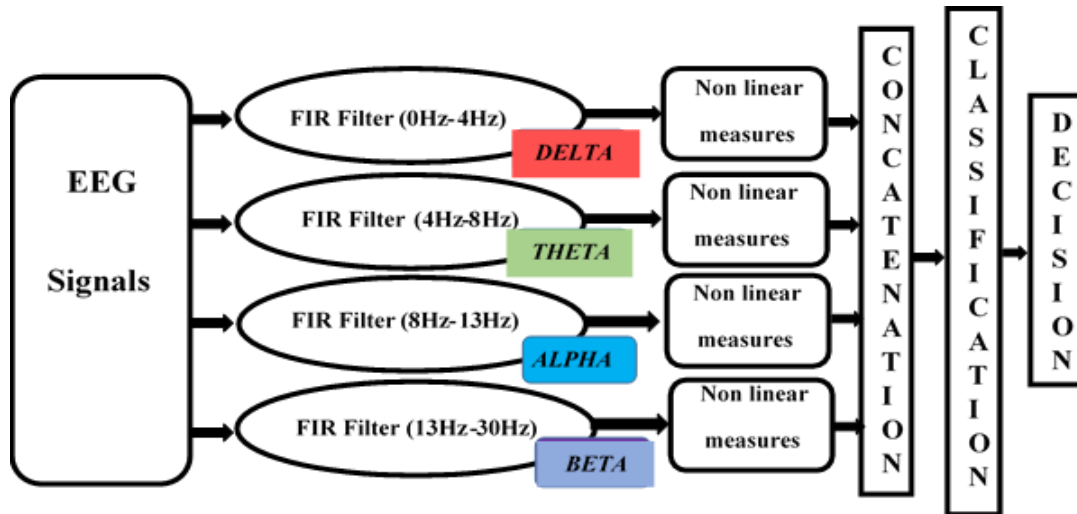


Figure III.2. Schéma bloc des approches proposées basées sur des mesures non linéaires des rythmes EEG.

III.3.1 Filtrage sous-bandes de fréquence

Cette première étape vise à isoler les différents rythmes du signal EEG. Un filtre passe-bas RIF est utilisé pour le rythme delta (0-4 Hz) avec une fréquence de coupure de 4 Hz. Pour les rythmes thêta (4-8 Hz) et alpha (8-13 Hz), des filtres passe-bande RIF sont appliqués, et pour le rythme bêta (au-delà de 13 Hz), un filtre passe-haut RIF est utilisé. Dans tous les cas, des filtres à phase nulle sont employés afin de préserver la dynamique du signal sans distorsion de phase.

III.3.2 Extraction des caractéristiques non linéaires

Les caractéristiques non linéaires sont extraites individuellement de chaque sous-bande filtrée correspondant à un rythme EEG spécifique. Chaque bande étant associée à des fonctions neurologiques différentes, elle peut être liée à des troubles neurologiques particuliers. Après de nombreux tests sur un large éventail de mesures non linéaires répertoriées dans la littérature, les caractéristiques les plus pertinentes sélectionnées sont : l'entropie multiscale modifiée (MMSE), l'exposant de Hurst, les coefficients de Hjorth, l'analyse des fluctuations sans tendance (DFA), ainsi que les dimensions fractales de Higuchi (HFD) et de Katz (KFD). **Concaténation des caractéristiques** : Les caractéristiques extraites sont concaténées pour former un vecteur global

de caractéristiques. **Classification** : Ce vecteur est ensuite introduit dans une méthode de classification appropriée. **Prise de décision** : Dans cette dernière étape, une décision est prise concernant la présence ou l'absence d'une activité de crise. Des détails supplémentaires sur les algorithmes de classification ainsi que sur les aspects théoriques des mesures non linéaires sont fournis par la suite. L'objectif fondamental de l'extraction des caractéristiques est d'obtenir davantage d'informations à partir d'un signal brut en convertissant de grandes quantités de données en un nombre réduit de vecteurs de caractéristiques.

Après le traitement des données, la méthodologie d'extraction de caractéristiques examine les signaux afin d'identifier les propriétés les plus représentatives, typiques des différentes classes de signaux. La distribution temporelle et fréquentielle des signaux EEG peut ensuite être décrite à l'aide de propriétés statistiques standard, d'entropie et d'énergie.

Dans cette étude, six caractéristiques non linéaires ont été extraites et comparées. Les caractéristiques non linéaires permettent de décrire des aspects essentiels de la morphologie des signaux EEG, souvent complexes et chaotiques. L'extraction de telles caractéristiques est couramment utilisée pour déterminer les propriétés fondamentales des signaux EEG. Vous trouverez ci-dessous les détails théoriques des caractéristiques non linéaires adoptées dans ce chapitre.

III.3.2.1 Exposant de Hurst

L'exposant de Hurst est une mesure de la douceur des séries temporelles fractales, basée sur le comportement asymptotique de l'étendue redimensionnée du processus. Motamedi, dans (Motamedi-Fakhr et al., 2014), a utilisé l'exposant de Hurst H dans l'analyse des séries temporelles EEG pour caractériser le comportement non stationnaire des épisodes de sommeil EEG. L'analyse de Hurst est une technique permettant d'évaluer le comportement stochastique d'un signal et d'estimer l'exposant de Hurst H .

Le mouvement brownien fractionnaire défini par Mandelbrot et van Ness est lié à l'exposant de Hurst (Emeksiz et Tan, 2022). Dans une série temporelle, l'exposant de Hurst H est utilisé pour évaluer la présence ou l'absence d'une dépendance à long terme, ainsi que son ampleur. La valeur de l'exposant de Hurst peut être calculée comme suit :

L'erreur moyenne de j premiers points a été définie pour une série de données x_i ($i = 1, 2, \dots, N$):

$$Z_j = \sum_{i=1}^j |x_i - \bar{x}_n| \quad j = 1, 2, \dots, n \quad (\text{III.1})$$

$$\text{Où: } \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad 1 < j < n \quad 1 < n < N$$

$R(n)$ est la plage définie par :

$$R(n) = \max(O, Z_1, Z_2, \dots, Z_n) - \min(O, Z_1, Z_2, \dots, Z_n)$$

L'écart type de l'échantillon à n points $S(n)$ a été calculé comme suit :

$$S(n) = \left\{ \frac{1}{n-1} \sum_{i=1}^n |x_i - \bar{x}|^2 \right\}^{\frac{1}{2}} \quad (\text{III.2})$$

Où $S(n)^2$ est la variance de n points. Le terme R/S a été inventé pour décrire le rapport de l'un à l'autre.

$$\frac{R}{S} = \frac{R(n)}{[S^2]^{1/2}}$$

Asymptotiquement, la valeur attendue de $R(n)/S(n)$ satisfaisait la relation de loi de puissance :

$$\frac{R(n)}{S(n)} = an^H \quad , n = 1, 2, \dots, n \quad (\text{III.3})$$

H représente l'exposant de Hurst.

III.3.2.2. Paramètres de Hjorth

Hjorth a été le premier à introduire les paramètres de Hjorth [104]. Hjorth est un calculateur de complexité des signaux qui opère dans le domaine temporel et est largement utilisé pour les signaux biologiques. La description de Hjorth implique trois paramètres : Activité, Mobilité et Complexité.

$$\text{Activity} = \text{var}(y(t)) \quad (\text{III.4})$$

$$\text{Mobility} = \sqrt{\frac{\text{var}\left(\frac{dy(t)}{dt}\right)}{\text{var}(y(t))}} \quad (\text{III.5})$$

$$Complexity = \frac{Mobility\left(\frac{dy(t)}{dt}\right)}{Mobility(y(t))} \quad (III.6)$$

Le signal est représenté par 'y(t)'. La puissance du signal, la fréquence moyenne et l'écart type du spectre de puissance sont respectivement représentés par les paramètres d'activité, de mobilité et de complexité [105].

III.3.2.3 Entropie Multiscalaire Modifiée (MMSE)

La caractéristique d'entropie peut être utilisée pour évaluer le degré d'incertitude et d'irrégularité des signaux EEG. Lorsque la diversité et la complexité des signaux EEG augmentent, l'entropie du signal augmente également. Les types d'entropie multiscalaire modifiée utilisés dans cette étude sont désignés par MMSE :

Soit $y = \{y_1, y_2, y_3, \dots, y_n\}$, une série temporelle de longueur 'N' selon Richman (Richman et Moorman, 2000)[106]. L'algorithme d'entropie d'échantillon (Sample Entropy, SampEn), modifié pour cette étude, peut s'écrire comme suit :

1. En utilisant l'équation suivante, créez le vecteur modèle i-ème avec une dimension m :

Où le paramètre δ représente le délai temporel entre les composantes consécutives du vecteur modèle.

2. En utilisant la norme infinie, calculez la distance euclidienne d_{ij}^m pour chaque paire de vecteurs modèles (y_i^m, y_j^m) :

$$d_{ij}^m(\delta) = \left\| y_i^m(\delta) - y_j^m(\delta) \right\|_{\infty}, \quad 1 \leq i, j \leq N - m\delta, j > i + \delta. \quad (III.7)$$

Lorsque $d_{ij}^m(\delta) \leq r$, on appelle (y_i^m, y_j^m) une paire de vecteurs correspondants, où r est un niveau de tolérance prédéfini.

3. Le nombre total de paires de vecteurs correspondants de dimension m est représenté par $n(m, \delta, r)$.

Lorsque $d_{ij}^m(\delta) \leq r$ augmentez $n(m, \delta, r)$ de un.

4. Pour les vecteurs modèles recréés dans la dimension m+1, répétez les étapes 1 à 3. Calculez le nombre total de paires de vecteurs correspondants m+1, $n(m + 1, \delta, r)$.
5. L'équation suivante est utilisée pour déterminer le SampEn :

$$SampEn(y, m, \delta, r) = -\ln \frac{n(m+1, \delta, r)}{n(m, \delta, r)} \quad (\text{III.8})$$

La méthode MMSE proposée combine deux procédures :

Premièrement, une procédure de moyennage mobile est utilisée pour obtenir une représentation des dynamiques d'un système à différentes échelles de temps.

Deuxièmement, les régularités de la série temporelle moyennée mobile à un facteur d'échelle τ sont quantifiées en utilisant le SampEn avec un décalage temporel de τ .

(1) Soit Z^τ représentant la série temporelle moyennée mobile à un facteur d'échelle τ .

$$Z_j^\tau = \frac{1}{\tau} \sum_{i=j}^{i+j-\tau-1} y_i, 1 \leq j \leq N - \tau + 1. \quad (\text{III.9})$$

(2) Avec un décalage temporel, le SampEn pour la série temporelle moyennée mobile Z^τ , τ est déterminé. La valeur de l'entropie multi-échelle modifiée (MMSE) de la série temporelle étudiée à un facteur d'échelle k est définie comme dans (Humeau-Hertier, 2015) [106] :

$$MMSE(y, m, \tau, r) = SampEn(Z^\tau, m, \delta = \tau, r) \quad (\text{III.10})$$

III.3.2.4 *Détrended Fluctuation Analysis (DFA)*

The fractal-like auto-correlation features of the signals are measured by DFA. It can be used to analyze biomedical signals that are typically complicated and non-stationary. DFA is a technique for scaling non-stationary signals' long-term autocorrelation. It employs the fractal property to assess the signal's complexity (Kantelhardt et al., 2002). For the Brownian noise, the method could be seen as a modified root mean square method. The signal's mean square distance from the local trend line is investigated as a function of the scale parameter. The parameter is usually exponent and there is usually power-law dependence. On a one-dimensional signal, we present the DFA algorithm.

$A(i), i = 1, \dots, N$ Pour commencer, nous utilisons une formule pour calculer le signal intégré.

$$y(k) = \sum_{i=1}^k (A(i) - A_M) \quad (\text{III.11})$$

Où A_M représente la valeur moyenne du signal. Ensuite, en utilisant un ajustement par moindres carrés dans chaque segment de manière indépendante, nous divisons les données en segments de longueur n et déterminons l'approximation linéaire $y(n)$ (représentant la tendance dans

une section donnée). La formule pour la fluctuation moyenne du signal $F(n)$ autour de la tendance est :

$$F(n) = \sqrt{\frac{1}{n} \sum_{k=1}^n (y(k) - y(k)_n)^2} \quad (\text{III.12})$$

Les calculs ont été effectués pour toutes les variables qui seront examinées. Le lien entre $F(n)$ et la taille du segment n est d'une importance particulière. En général, $F(n)$ augmente proportionnellement à la taille du segment n . Le graphique est un graphique double logarithmique en fonction de $(\log F(n) \text{ vs } \log n)$. La présence d'auto-fluctuations est indiquée par la dépendance linéaire, et la pente de la ligne $F(n)$ détermine l'exposant d'échelle :

$$F(n) \sim n^\alpha \quad (\text{III.13})$$

Les qualités d'autocorrélation du signal sont représentées par le paramètre α

III.3.2.5 Dimension Fractale (FD)

Dimension fractale est définie comme un rapport qui fournit un indice statistique de la complexité d'un motif en fonction des détails à mesure que l'échelle change. La FD peut être calculée à l'aide de divers algorithmes. Nous l'avons calculée de deux manières différentes. La complexité d'un signal représenté par une série temporelle peut être mesurée à l'aide de la dimension fractale. Dans des recherches antérieures, la dimension fractale a été utilisée comme critère pour catégoriser les données EEG. D'autres études ont découvert que les stimuli olfactifs peuvent modifier la dimension fractale de la réaction du cerveau, mesurée à partir des signaux EEG. Différents algorithmes permettent de calculer la dimension fractale d'un système, comme ceux proposés par Katz [108]. Nous avons choisi la Dimension Fractale de Higuchi (HFD) et la Dimension Fractale de Katz (KFD), car leur efficacité a été démontrée pour des ensembles de données courts et bruyants.

III.3.2.6 Dimension fractale de Katz

L'équation suivante montre que le calcul a été effectué directement à partir des données de séries temporelles en utilisant l'approche de Katz.

$$FD = \frac{\ln(N-1)}{\ln(N-1) - \ln\left(\frac{d}{L}\right)} \quad (\text{III.14})$$

Où :

L : indique la somme des distances entre les points consécutifs.

N : représente la longueur de la séquence de données.

d : correspond au diamètre de la séquence de données.

III.3.2.7 Dimension Fractale de Higuchi

Pour détecter la dimension fractale des signaux EEG, la technique de Higuchi est plus efficace que d'autres algorithmes. En utilisant une série temporelle $x(1), x(2), \dots, x(N)$ comme entrée, cette approche génère une nouvelle série temporelle comme suit :

$$x_m^k = \left\{ x(m), x(m+k), x(m+2k), \dots, x\left(m + \left\lfloor \frac{N-m}{k} \right\rfloor k\right) \right\} \quad m = 1, 2, 3 \dots k \quad (\text{III.15})$$

Dans laquelle :

m : est le premier échantillon ; $\lfloor \cdot \rfloor$ indique la partie entière de la série.

La longueur $L_m(k)$ pour x_m^k est donnée par :

$$L_m(k) = \frac{\sum_{i=1}^{N-1} |x(m+ik) - x(m+(i-1)k)| (N-1)}{\left\lfloor \frac{N-m}{k} \right\rfloor k} \quad (\text{III.16})$$

N : le nombre d'échantillons dans la série temporelle.

$\frac{N-1}{\left\lfloor \frac{N-m}{k} \right\rfloor k}$: le coefficient de normalisation.

Pour chaque k , la longueur moyenne totale $L(k)$ est calculée pour k_1 jusqu'à k_{max} .

Cette méthode de calcul de la dimension fractale (FD) est plus chronophage que d'autres méthodes.

III.3.4 Classification

Ce chapitre propose et analyse une nouvelle méthode pour l'identification et la classification des crises à partir des signaux électroencéphalographies (EEG) basée sur un ensemble de caractéristiques non linéaires. Par conséquent, différents classificateurs sont utilisés afin d'évaluer et de mettre en valeur l'approche proposée sur un ensemble de signaux. La classification constitue la dernière étape de ce travail. Suite à une recherche approfondie dans la littérature publiée sur les classificateurs les plus couramment utilisés, il a été établi que les classificateurs les plus performants et efficaces pourraient être :

- le Perceptron Multicouche (MLP),

- le K plus Proches Voisins (KNN),
- les Machines à Vecteurs de Support (SVM) comme classificateurs d'apprentissage automatique (ML),
- et le Réseau de Neurones Profonds (DNN) ainsi que la Mémoire à Long et Court Terme (LSTM) comme classificateurs d'apprentissage profond (DL).

Étant donné que les classificateurs ML ont été largement documentés dans la littérature, nous nous concentrerons désormais sur les deux autres types de classificateurs DL.

III.3.4.1 Réseau de Neurones Profonds (DNN)

Un réseau de neurones profond (DNN) est un perceptron multicouche avec plus de trois couches (couches d'entrée et de sortie incluses) (Birjandtalab et al., 2017). Un DNN est illustré dans la figure III.3 à titre d'exemple. Dans le cas d'un DNN avec M couches cachées, le vecteur v^m représente le vecteur de sortie de la m^{th} couche, les couches 0 et M+1 représentant respectivement les couches d'entrée et de sortie. Ensuite, le vecteur v^m est calculé comme suit :

$$v^m = f(z^m) = f(W^m v^{m-1} + b^m) \quad 1 < m < M \quad (\text{III.17})$$

Où :

$z^m \in \mathbb{R}^{N_m}$: est le vecteur d'activation de la couche m^{th} avec N_m neurones.

$W^m \in \mathbb{R}^{N_m \times N_{m-1}}$: est la matrice de poids.

$b^m \in \mathbb{R}^{N_m}$: est le vecteur de biais.

Notez que dans l'Équation 22 :

v^0 : est le vecteur de caractéristiques d'entrée x.

$f(.) : \mathbb{R}^{N_m \times 1} \rightarrow \mathbb{R}^{N_m \times 1}$: est la fonction d'activation.

Comme fonction d'activation, nous avons utilisé la transformation sigmoïde comme suit :

$$f(z) = \frac{1}{1+e^{-z}} \quad (\text{III.20})$$

La fonction d'activation doit être choisie en fonction du type de classification. Dans les situations avec plus de deux classes, la valeur du neurone de sortie i-ième, par exemple, représente la probabilité a posteriori de la classe $i \in \{1 \dots \dots C\}$, comme $P(c_i | x)$. Ce n'est que lorsque la classe c_i fournit la probabilité la plus élevée pour un vecteur d'entrée x que nous la choisissons. Pour

traiter les valeurs des neurones de sortie comme des probabilités, elles doivent satisfaire les conditions $0 \leq v^M \leq 1$ and $\sum_{i=1}^c v_i^M = 1$. Une fonction Softmax peut répondre à ce type de besoin de normalisation comme suit :

$$v^M = P(c_i \setminus x) = \text{softmax}_i(z^M) = \frac{e^{z_i^M}}{\sum_{i=1}^c e^{z_i^M}} \quad (\text{III.21})$$

Où:

z_i^M : est l'élément avec l'indice $i^{\text{ième}}$ dans l'activation du vecteur z^M .




Figure III.3 Un exemple de structure de Réseau de Neurones Profonds.

III.3.4.2 Mémoire à Long et Court Terme (LSTM)

La figure III.4 illustre la structure d'un bloc typique de LSTM. La porte d'état de la cellule Z conserve l'information au fil du temps, la porte d'oubli Z^f régule l'étendue de la valeur conservée dans la cellule, la porte d'entrée Z^i contrôle l'étendue du flux de valeur entrant dans la cellule, et la porte de sortie Z^o contrôle l'étendue de la valeur dans la cellule utilisée pour calculer la sortie.

Chaque porte comprend une couche entièrement connectée et une fonction d'activation. De plus, le bloc LSTM dispose de trois entrées :

- l'état de la cellule c^{t-1} ,
- l'état caché précédent h^{t-1} ,
- et l'entrée actuelle x^t .

Il produit trois sorties :

- l'état de la cellule C^t ,
- l'état caché h^{t-1} ,
- et la sortie actuelle Y^t .

La sortie actuelle est générée en fonction de l'état caché (Xu et al., 2020). La définition mathématique des unités LSTM est donnée comme suit :

$$Z^f = \sigma(W^f[x_t, h_{t-1}]) \quad (\text{III.22})$$

$$Z^i = \sigma(W^i[x_t, h_{t-1}]) \quad (\text{III.23})$$

$$Z = \tanh(W[x_t, h_{t-1}]) \quad (\text{III.24})$$

$$Z^o = \sigma(W^o[x_t, h_{t-1}]) \quad (\text{III.25})$$

$$C^t = Z^f \times C^{t-1} + Z^i \times Z \quad (\text{III.26})$$

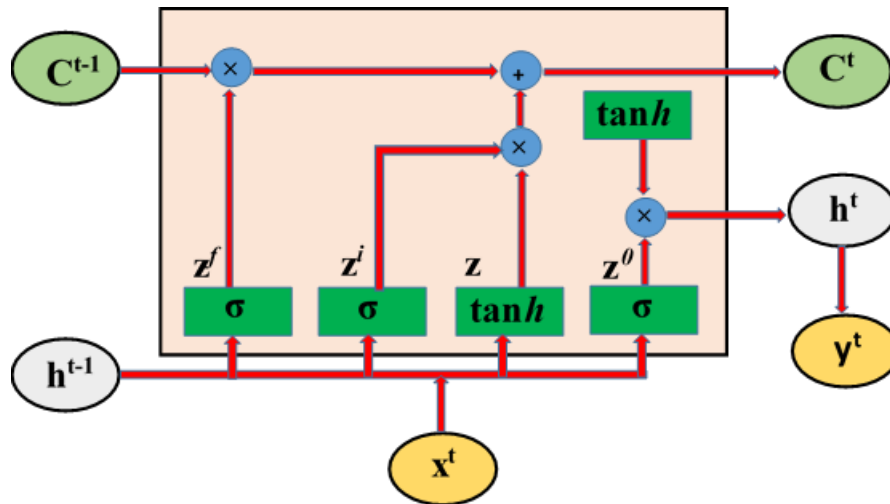


Figure III.4 Structure typique d'un bloc de Mémoire à Long et Court Terme (LSTM).

III.3.4 Performances d'évaluations des Classificateurs

Les performances des classificateurs utilisés sont évaluées à l'aide de trois mesures largement reconnues pour évaluer leur capacité à discriminer entre deux classes différentes. Ces mesures sont connues sous les noms de sensibilité (SE), spécificité (SP) et précision de classification (CA), définies comme suit :

$$SE(\%) = \frac{NCP}{TNCP} \times 100 \quad (\text{III.27})$$

Où :

NCP est le nombre de modèles positifs correctement reconnus, et **TNCP** est le nombre total de modèles positifs identifiés. Un modèle positif indique qu'une crise a été observée.

$$SP(\%) = \frac{NCN}{TNCN} \times 100 \quad (\text{III.28})$$

NCN est le nombre de modèles négatifs correctement identifiés, tandis que **TNCN** représente le nombre total de modèles négatifs. Un modèle négatif suggère qu'un motif normal ou interictal a été trouvé. **SE** ou **SP** calcule une proportion qui peut être utilisée pour classer correctement un modèle comme « malade » ou « sain ».

$$CA(\%) = \frac{NCC}{TNP} \times 100 \quad (\text{III.29})$$

III.4. Résultats de la simulation

Cette section vise à présenter les principaux résultats des expériences menées dans la présente étude, accompagnés d'une discussion.

III.4.1 Filtrage sous bande

Conformément au diagramme en blocs de l'approche proposée (Figure III.1), six différentes caractéristiques non linéaires ont été calculées pour les quatre bandes de fréquences les plus prédominantes dans les signaux EEG. Ces quatre bandes de fréquences sont définies par :

- le rythme delta (0-4 Hz),
- le rythme thêta (4-8 Hz),
- le rythme alpha (8-13 Hz),
- et le rythme bêta (13-30 Hz).

En raison de sa faible contribution au contenu fréquentiel dans les situations expérimentales étudiées, le rythme gamma (au-delà de 30 Hz) n'a pas été examiné ici.

III.4.2 Choix des caractéristiques

Après un filtrage dans le domaine temporel des signaux EEG dans les quatre bandes de fréquences, des caractéristiques non linéaires ont été extraites de chacun des signaux filtrés obtenus et utilisées pour le processus de classification. La Fig. 5 présente un boxplot des différentes caractéristiques extraites pour les quatre bandes de fréquences. Ces caractéristiques comprennent :

- l'entropie multiscalaire modifiée (MMSE),
- les dimensions fractales de Higuchi et Katz (HFD et KFD),
- l'analyse des fluctuations dé-trendées (DFA),
- l'exposant de Hurst (Hurst),
- et les coefficients de Hjorth qui donnent les paramètres d'activité, de mobilité et de complexité.

On peut facilement distinguer une différence entre les valeurs moyennes des signaux normaux et celles des signaux ictaux (sains vs épileptiques). Cela est généralement dû au fait que les signaux EEG normaux sont périodiques et moins aléatoires.

Selon la Figure III.5, la dimension fractale de Katz est la plus significative pour les quatre sous-bandes. Il existe une différence notable entre les signaux normaux et les signaux ictaux, ce qui implique que la dimension fractale de Katz est statistiquement la plus significative comparée aux autres caractéristiques.

III.4.3 Choix du vecteur d'entrée

Les matrices de dispersion sont utilisées pour démontrer le succès du processus de sélection des caractéristiques basé sur le classement. Ces matrices montrent en détail la distribution des caractéristiques classées. À l'aide d'une matrice de dispersion, la répartition des trois caractéristiques les mieux classées est représentée dans un espace 3D. La figure III.6 illustre les relations entre trois des caractéristiques extraites dans les quatre bandes de fréquences. Plus précisément, la figure est composée de trois colonnes :

- sur le côté droit, des matrices de dispersion du coefficient DFA en fonction du HFD et du MMSE ;
- sur le côté gauche, une dispersion du DFA par rapport à l'exposant de Hurst et au HFD ;

- et enfin, au centre de la figure, des diagrammes de dispersion concernant les trois coefficients de Hjorth.

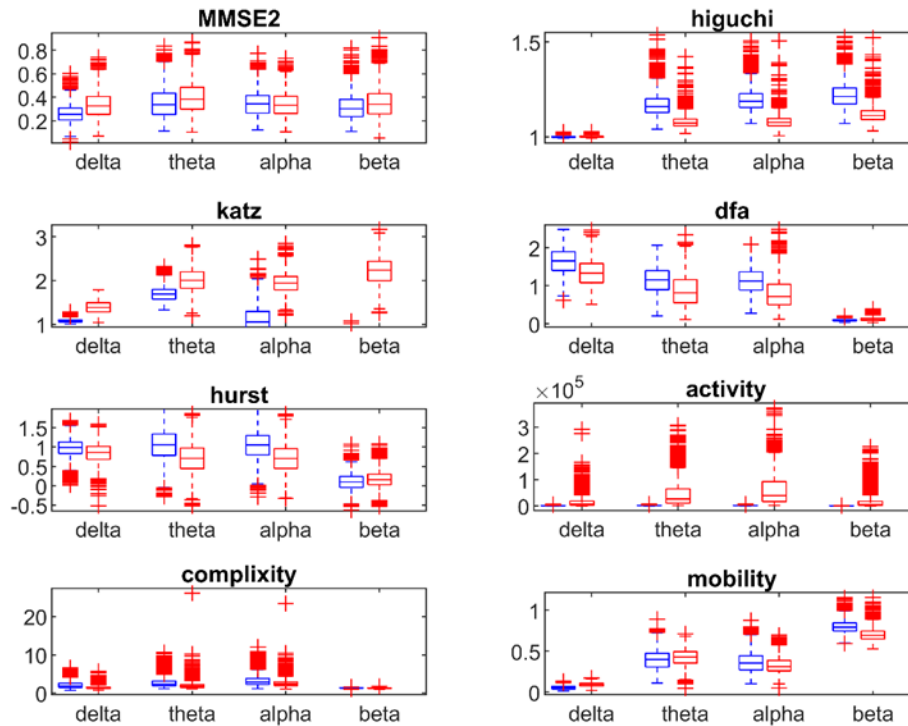


Figure III. 5. Les huit principales caractéristiques les mieux classées extraites des deux classes de signaux EEG, avec leurs valeurs moyennes et écarts-types (SD - standard deviation) correspondants pour les quatre sous-bandes (EEG normal en bleu, EEG ictal en rouge).

Il est évident que des caractéristiques bien séparées dans un espace 3D peuvent être classées facilement à l'aide du classificateur approprié. Les caractéristiques classées par filtrage possèdent une grande capacité de discrimination, comme le montre la figure III.6. Les points de données dans l'espace des caractéristiques associé se caractérisent par de grandes distances inter-classes. La capacité des algorithmes de classification à séparer les classes est démontrée par ces grandes distances inter-classes.

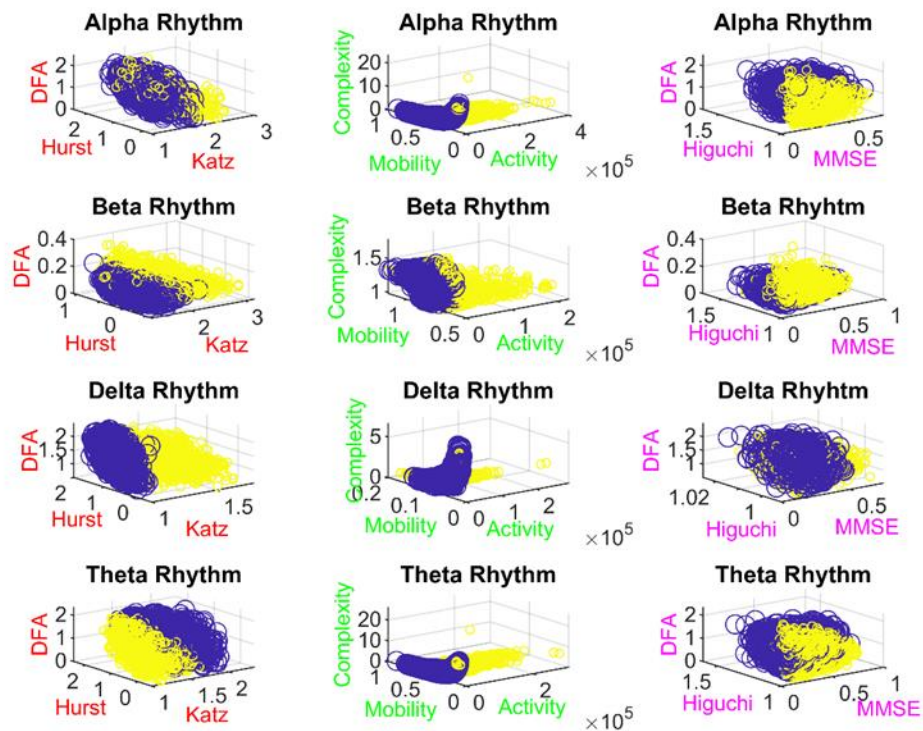


Figure III.6. Matrice de dispersion des trois fonctionnalités choisies, classées pour deux classes différentes après le filtrage en sous-bandes pour tous les rythmes EEG sélectionnés.

Comme mentionné précédemment, de nombreuses recherches ont rapporté l'utilisation des signaux EEG pour déterminer automatiquement les états sains et non sains liés à la détection et à l'identification des crises épileptiques. Les états non sains peuvent être classés comme interictaux, préictaux ou ictaux lorsqu'on emploie des techniques d'extraction de caractéristiques linéaires et non linéaires.

L'objectif principal de cette étude est d'évaluer la capacité à distinguer les signaux EEG ictaux des segments temporels EEG sains ou interictaux à l'aide de mesures non linéaires calculées sur les plages de fréquences EEG les plus dominantes. Les enregistrements EEG de l'Université de Bonn et de Hanz Khas EEG Epilepsy ont été utilisés à cette fin.

Ces deux ensembles de données incluent :

- des signaux EEG normaux enregistrés chez des sujets sains,

- des signaux EEG enregistrés pendant une activité de crise, également appelés signaux ictaux,
- et des signaux EEG acquis entre le début des crises, appelés signaux interictaux.

Après un filtrage temporel des signaux EEG dans les bandes de fréquences delta, thêta, alpha et bêta (également appelées rythmes), les caractéristiques non linéaires sont extraites et regroupées pour construire quatre différents vecteurs de caractéristiques de la manière suivante :

- i. Vecteur 1: Hjorth coefficients + Hurst + DFA+ KFD.
- ii. vecteur 2: Hjorth coefficients + MMSE2 + DFA + KFD.
- iii. Vecteur 3: Hjorth coefficients + Hurst + DFA + HFD
- iv. Vecteur 4: Hjorth coefficients + MMSE2 + DFA + HFD

Par les coefficients de Hjorth, on entend les trois paramètres suivants : l'activité, la mobilité et la complexité, calculée dans leur ensemble. Chacun des quatre vecteurs sera ensuite formé par six (06) caractéristiques multipliées par les quatre bandes de fréquence, ce qui donne vingt-quatre caractéristiques à fournir à l'algorithme de classification. Le premier algorithme de classification adopté est un réseau de neurones feedforward à trois couches, avec les couches cachées et de sortie contenant respectivement vingt (20) et deux (02) neurones, comme dans (Djemili, 2020); de plus, les fonctions du perceptron multicouche ont également été configurées selon le travail de (Djemili, 2020), avec une fonction tan-sigmoïde à la couche cachée et une fonction linéaire pure à la couche de sortie. L'algorithme d'optimisation de Levenberg–Marquardt de deuxième ordre a été utilisé pour mettre à jour les différents poids du réseau.

Les deux autres classificateurs sont liés aux nouveaux algorithmes d'apprentissage profond. Premièrement, nous avons utilisé un réseau de neurones profond (DNN) et comparé sa performance dans la classification des signaux EEG normaux par rapport aux signaux épileptiques en faisant varier deux facteurs différents et substantiels, à savoir le nombre de couches cachées formant la structure profonde et le nombre de neurones dans chaque couche cachée ; tous ces résultats sont illustrés dans la Fig. 8 et compilés dans le Tableau 5, où la performance de classification est évaluée en termes de sensibilité (SE), spécificité (SP) et précision de classification (CA). Il convient de noter que pour l'architecture DNN, (02) couches cachées avec 30 neurones dans chaque couche ont été adoptées dans nos expériences comme un bon compromis

entre la précision obtenue et les exigences en matière de temps de calcul (selon une expérience hors cadre).

Deuxièmement, le troisième algorithme de classification entrepris dans la présente étude est l'algorithme d'apprentissage profond Long Short Term Memory (LSTM) unique. Pour l'algorithme de classification binaire, l'algorithme Adaptive Moment Estimation (ADAM) est utilisé avec 100 unités cachées ; le nombre maximum d'époques a été fixé à 70, et la taille minimale du lot à 27. Comme mentionné précédemment, la détection des crises épileptiques est un problème de classification binaire dans lequel l'objectif est de classer le signal EEG d'entrée comme étant soit un signal de crise, soit un signal non de crise, qui pourrait inclure des signaux EEG de sujets sains ou des EEG acquis pendant les intervalles sans crise.

Pour chacun des classificateurs adoptés ici, la précision moyenne de classification (CA) pour six cas différents de détection de crises est calculée. Selon le jeu de données de Bonn, les six cas ont été déterminés comme suit : sous-ensemble A contre sous-ensemble E, B contre E, C contre E, D contre E, AB contre E et CD contre E. Dans chaque cas de classification, nous nous concentrons sur la détection de l'activité de crise présente intrinsèquement dans le sous-ensemble E par rapport aux segments EEG acquis pendant les intervalles sans crise, que ces segments proviennent de volontaires sains (sous-ensemble A) ou de patients non sains dans chaque cas considéré (sous-ensembles C et D). Les tableaux 1 à 4 compilent la précision moyenne de classification (CA) pour chacun des quatre vecteurs d'extraction de caractéristiques proposés, notés comme Vecteur 1, Vecteur 2, Vecteur 3 et Vecteur 4, où les résultats de performance sont présentés pour chaque classificateur et parmi les six cas différents de détection de crises. Ces résultats sont également affichés à travers la figure III.7 pour faciliter la comparaison. Le graphique à barres, comparant les résultats des trois méthodes de classification, montre que la précision de classification pour les différents classificateurs est plus élevée pour le Vecteur 2 que pour les autres vecteurs, avec une précision de classification atteignant jusqu'à 100 %. Les résultats finaux montrent donc que les caractéristiques formant le Vecteur 2 présentent des avantages clairs et peuvent améliorer efficacement la précision de classification EEG pour de nombreux cas distincts de détection de crises. Il est intéressant de noter que les données EEG du cas de détection de crise A-E conviennent mieux aux objectifs de classification que les autres cas étudiés, en raison des grandes variations des valeurs EEG enregistrées dans le sous-ensemble A ou E. En fait, en raison

de la nature des grandes différences dans les données, il est plus facile de classifier les ensembles A et E quel que soit le vecteur choisi et quel que soit le classificateur. En revanche, le cas de détection de crise C-E a produit la précision de classification la plus faible pour le vecteur 3 avec le classificateur DNN, soit 79,60 %. La précision n'est plus significative, vraisemblablement en raison des analogies intrinsèques existant dans les données EEG des sous-ensembles C et E.

Table III.1 Taux de classification pour le vecteur1

Case Problem	MLP	DNN	LSTM	SVM	KNN
A-E	99.6	99.8	95.6	99.7	99.8
B-E	99.5	99.5	94.5	99.8	100
C-E	99.5	79.6	96.2	99.7	99.7
D-E	99.5	97.6	94.4	99.5	99.5
AB-E	94.5	93.0	92.9	99.1	99.0
CD-E	98.0	98.2	94.7	97.8	97.3
Hauz Khas	100	99.6	79.0	100	99.0

Table III.2 Taux de classification pour le vecteur2

Case Problem	MLP	DNN	LSTM	SVM	KNN
A-E	100	100	100	100	99.8
B-E	100	100	99.9	100	100
C-E	100	100	99.5	99.8	99.7
D-E	100	100	100	100	99.8
AB-E	99.5	99.7	94.9	99.5	98.2
CD-E	98.0	98.8	93.2	98.6	97.7
Hauz Khas	99.0	97.9	89.3	100	98.0

Table III.3 Taux de classification pour le vecteur3

Case Problem	MLP	DNN	LSTM	SVM	KNN
A-E	99.1	99.9	95.5	99.8	98.0
B-E	99.1	99.3	89.3	99.2	96.5
C-E	99.0	79.6	95.9	99.3	99.3
D-E	96.4	97.2	94.3	99.8	99.8
AB-E	99.2	93.1	93.9	98.4	97.8
CD-E	97.1	98.1	94.9	98.1	98.2
Hauz Khas	98.6	99.5	97.0	100	100

Table III.4 Taux de classification pour le vecteur 4

Case Problem	MLP	DNN	LSTM	SVM	KNN
A-E	95.2	99.2	97.4	99.0	98.7
B-E	99.1	98.0	93.4	98.8	97.8
C-E	99.1	99.1	96.0	99.1	97.8
D-E	97.6	97.8	94.3	97.8	97.8
AB-E	98.3	99.6	98.1	99.1	97.9
CD-E	98.3	98.5	94.9	98.5	98.4
Hauz Khas	99.3	100	92.0	100	99.0

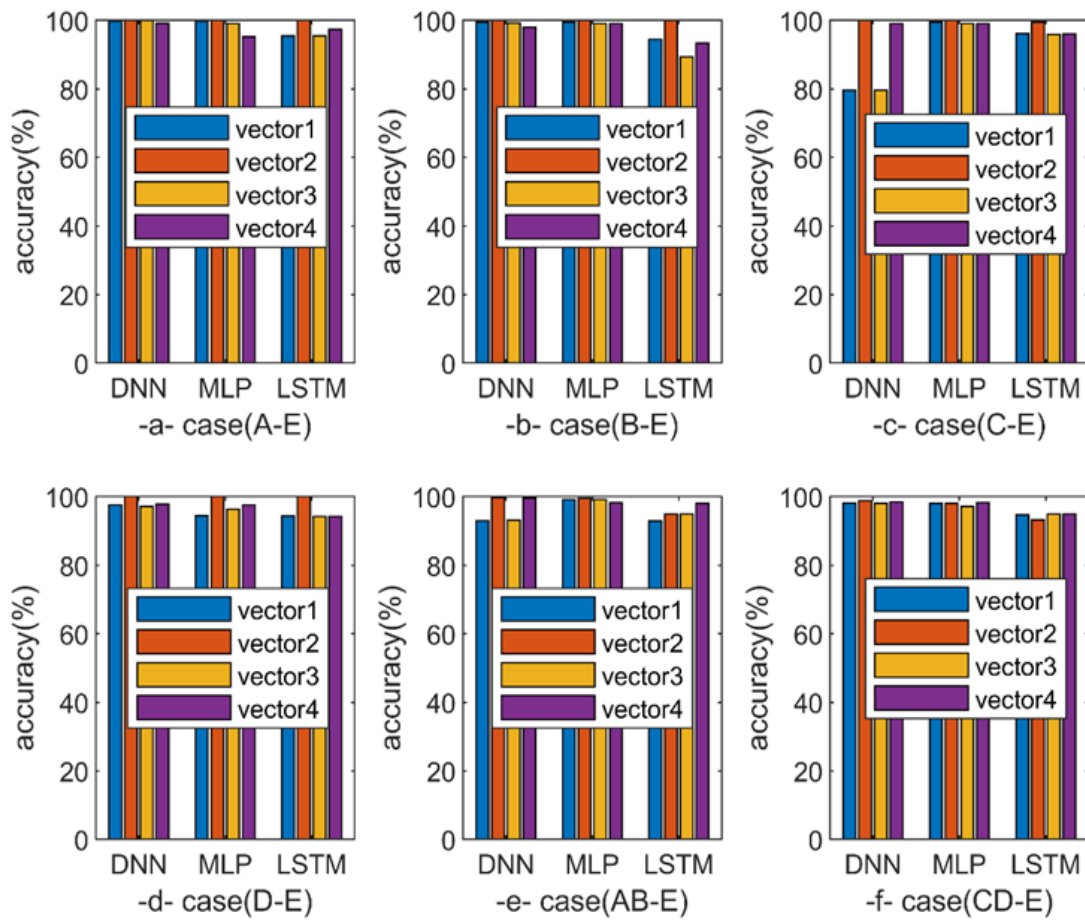


Figure III.7. Taux de classification de trois méthodes (MLP, DNN, LSTM) pour plusieurs cas : a : A-E, b : B-E, c : C-E, d : D-E, e : AB-E, f : CD-E.

Table III.5 : Meilleure taux de classification avec la sensibilité et la spécificité correspondantes pour différents cas expérimentaux.

Couche cachée	Neurones	Vecteur 1			Vecteur 2			Vecteur 3			Vecteur 4		
		SE	SP	AC	SE	SP	AC	SE	SP	AC	SE	SP	AC
2	2*10	100	99.9	99.9	100	100	100	99.9	99.0	99.6	99.8	96.3	96.6
2	2*20	100	99.9	99.9	100	100	100	99.8	97.0	98.3	99.8	99.2	99.4
2	2*30	100	100	100	100	100	100	99.9	99.6	99.7	99.7	98.6	99.2
3	3*10	93.6	96.5	93.7	100	100	100	99.8	99.7	99.8	99.8	99.0	99.5
3	3*20	100	99.9	100	100	100	100	99.8	99.4	99.6	99.9	99.0	99.4
3	3*30	100	99.9	99.9	100	100	100	99.8	99.6	99.7	99.7	98.7	99.2
4	4*10	99.9	99.9	99.9	100	100	100	99.9	99.8	99.8	99.9	99.2	99.5
4	4*20	100	99.9	100	100	100	100	99.7	99.7	99.7	99.9	99.1	99.5
4	4*30	100	99.9	99.9	100	100	100	98.3	98.5	98.5	99.9	99.1	99.5
5	5*10	100	95.2	97	100	100	100	99.9	92.7	92.7	99.7	98.5	99.1
5	5*20	99.9	99.9	99.0	100	100	100	99.9	99.7	99.7	99.6	98.6	99.1
5	5*30	100	99.9	99.9	100	100	100	99.9	99.7	99.7	99.8	98.8	99.3




Figure III.8 Sensibilité moyenne de classification (%) spécificité (%) précision (%) de tous les cas expérimentaux avec DNN.

D'après la littérature, plusieurs approches pour détecter les crises épileptiques dans les signaux EEG ont été proposées. Le tableau III.6 présente une comparaison de la meilleure précision de classification de l'article proposé par rapport aux précisions d'autres méthodes suggérées dans la littérature. Bien que la méthodologie proposée n'atteigne pas constamment une précision de classification de 100 % dans toutes les circonstances, nos résultats ont cependant pu atteindre une précision meilleure ou au moins égale à celle de certaines des méthodes existantes proposées dans la littérature.

Table III.6 Quelques résultats de classification utilisant la base données de Bonn ces dernières années.

Authors	Année	Problème de cas	Précision (%)
Guo et al. [95]	2010	A-E	100
Qiu et al. [114]	2023	A-E	100
Tawfik et al.[115]	2016	A-E	100
Kumar et al. [118]	2014	A-E	100
Djemili et al. [116]	2016	A-E	100
Nicolaou [117]	2012	A-E	93.5
Jaiswal [119]	2018	A-E	100
Zeng et al. [120]	2019	A-E	100
Liu et al. [121]	2020	A-E	99.9
Peng et al. [122]	2021	A-E	100
This work	---	A-E	100
Peng et al. [122]	2021	B-E	99
Liu et al. [121]	2020	B-E	99.7
Kumar et al. [118]	2014	B-E	82.9
Tawfik et al.[115]	2016	B-E	99.5
Nicolaou [117]	2012	B-E	82.9
Jaiswal [119]	2018	B-E	99.9
This work	---	B-E	100
Peng et al. [122]	2021	C-E	98.5
Liu et al. [121]	2020	C-E	99.3
Nicolaou [117]	2012	C-E	88.0
Jaiswal [119]	2018	C-E	99.5
Zeng et al. [120]	2019	C-E	98.5
Tawfik et al.[115]	2016	C-E	93.5
Qiu et al.[114]	2023	C-E	99.78
Zhang et al. [123]	2022	C-E	98,86
This work	---	C-E	100
Peng et al. [122]	2021	D-E	97.9
Liu et al. [121]	2020	D-E	98.8

Djemili et al. [116]	2016	D-E	97.7
Nicolaou [117]	2012	D-E	79.9
Qiu et al.[114]	2023	D-E	99.57
Zhang et al.[123]	2022	D-E	98.37
This work	---	D-E	100
Peng et al. (Peng et al., 2021)	2021	AB-E	99
Liu et al. [121]	2020	AB-E	99.7
Tawfik et al.[115]	2016	AB-E	100
Zeng et al. [120]	2019	AB-E	99.7
Jaiswal (Jaiswal and Banka, 2018)	2018	AB-E	99.7
This work	---	AB-E	99.7
Liu et al. [121]	2020	CD-E	98.8
Zeng et al. [120]	2019	CD-E	98.3
Patidar [124]	2017	CD-E	97.5
Sharma [125]	2015	CD-E	98.7
Joshi et al. [126]	2014	CD-E	95.3
Jaiswal [119]	2018	CD-E	96.7
Peng et al. [122]	2021	CD-E	98.3
Zhang et al. [123]	2022	CD-E	99.02
This work	---	CD-E	98.8

Conclusion

Ce chapitre propose un cadre de détection des crises épileptiques à haute performance qui combine le filtrage par bandes de fréquence, associé à des mesures non linéaires obtenues par les coefficients de Hjorth, l'exposant de Hurst, le paramètre de l'analyse des fluctuations détrendues (DFA), les dimensions fractales de Higuchi et Katz, et l'entropie multiscalaire modifiée (MMSE). Toutes ces caractéristiques non linéaires ont été calculées sur les bandes de fréquence les plus pertinentes liées au signal EEG et envoyées aux classificateurs Perceptron multicouche (MLP), Réseau neuronal profond (DNN) et Mémoire à long terme et à court terme (LSTM) dans le but d'identifier automatiquement les différents motifs EEG de sujets sains et épileptiques. L'approche d'extraction de caractéristiques proposée repose essentiellement sur un filtrage passe-bande, constituant la partie la plus importante du cadre d'identification des crises épileptiques à partir de la forme d'onde EEG, offrant ainsi la possibilité de visualiser les caractéristiques sans sacrifier la performance de la classification finale. Les résultats expérimentaux montrent que notre proposition

peut réussir non seulement à visualiser les caractéristiques, mais aussi à effectuer diverses tâches de classification pour différentes combinaisons d'EEG. Le filtrage est également un complément important à l'influence des rythmes du signal EEG, et les caractéristiques non linéaires basées sur le filtrage peuvent améliorer la performance de la détection des crises. La méthode proposée a atteint des performances de classification significatives, ce qui implique qu'elle est à la fois efficace et prometteuse. En conséquence, la méthode actuelle pourrait avoir plusieurs extensions potentielles. Davantage de bases de données seront nécessaires dans de futures études pour démontrer le potentiel de la méthode. De plus, nous souhaitons utiliser la méthodologie proposée pour diagnostiquer d'autres maladies cérébrales pouvant être détectées par les signaux EEG, telles que la maladie d'alzheimer ou la démence.

CHAPITRE 4

Détection des extrasystoles dans un signal ECG

Introduction

Après avoir déterminé la méthode optimale de classification du signal EEG au chapitre 3, ce chapitre se concentre sur la reconnaissance automatique des arythmies cardiaques à partir d'un signal ECG. L'ECG est un outil fondamental pour évaluer l'état du cœur et du système cardiovasculaire. Il joue un rôle clé dans le diagnostic des maladies cardiaques, permettant ainsi d'adapter les traitements et d'améliorer la qualité de vie des patients. En tant que signal physiologique, il reflète l'activité mécanique du cœur, incluant ses phases de contraction et de relâchement. La figure IV.1 illustre un tracé ECG d'un individu en bonne santé.




Figure IV.1 Tracé ECG d'un individu en bonne santé [127].

Contrairement aux battements cardiaques normaux, les extrasystoles ventriculaires (ESV) sont des contractions anormales qui prennent naissance au niveau des ventricules (foyer ectopique ventriculaire). Sur un tracé ECG, elles se manifestent par des complexes QRS prématurés, larges et dépourvus d'onde P préalable (figure IV.2). [127]

Les extrasystoles sont une irrégularité courante du rythme cardiaque. Leur impact dépend de leur fréquence d'apparition, elles peuvent être bénignes ou révéler un risque sous-jacent. Dans certains cas, elles annoncent des pathologies cardiaques graves telles que la fibrillation auriculaire, la tachycardie ventriculaire ou l'infarctus du myocarde.

Après avoir démontré l'efficacité du calcul des caractéristiques non linéaires pour la détection de l'épilepsie dans un signal EEG au chapitre 3, nous appliquons cette même approche au signal ECG. Pour cela, nous exploitons la base de données MIT-BIH, en particulier l'enregistrement ECG 119, et utilisons les mêmes classificateurs que ceux présentés

précédemment. L'objectif est d'optimiser la détection et la classification de certaines pathologies cardiaques, notamment les extrasystoles.

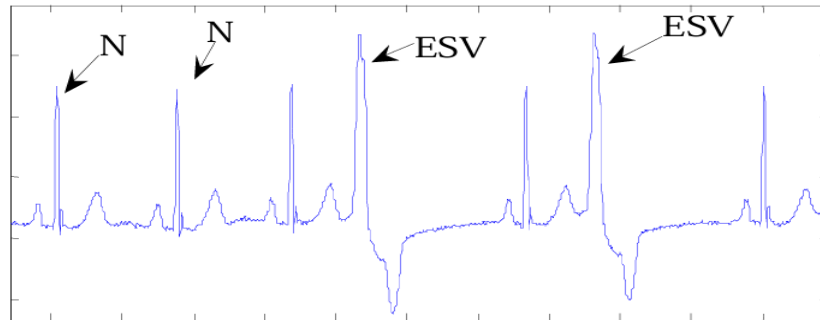


Figure IV.2 Exemple de signal présentant une déformation du complexe QRS due à une ESV
Extrasystole (ESV) [127]

IV.1 CLASSIFICATION DES EXTRASYSTOLES

Le grand nombre de battements enregistrés rend impossible une analyse manuelle ou visuelle par le cardiologue, ce qui justifie l'intérêt d'une analyse automatique. Ainsi, l'interprétation automatisée des enregistrements Holter s'est révélée être une aide précieuse au diagnostic. Une autre situation nécessitant une telle approche concerne les soins intensifs, où les médecins et infirmiers doivent surveiller en permanence l'évolution du signal ECG des patients, une tâche complexe et exigeante. L'intégration d'un classificateur automatique des arythmies cardiaques dans un système de monitoring permettrait de faciliter considérablement cette surveillance.

IV.1.1 Etat de l'art la détection et la classification des extrasystoles

Au cours de la dernière décennie, la détection automatique des arythmies cardiaques a été un domaine de recherche actif, donnant lieu à de nombreuses contributions. Certaines approches, relativement simples, visent à différencier les battements normaux des extrasystoles ventriculaires (ESV). D'autres, plus complexes, proposent une classification simultanée de plusieurs types d'arythmies. Étant donné que nous avons utilisé la base de données MIT-BIH pour valider nos résultats, seules quelques techniques récentes exploitant cette même base ont été sélectionnées pour l'étude comparative. On peut citer les travaux de De Chazal et al. [128] ont exploité les descripteurs morphologiques et temporels du signal ECG, ainsi que le rythme cardiaque, pour classifier les battements. Leur approche a abouti à une spécificité de 98,8 % et une sensibilité de

77,7 %. En se basant sur 14 enregistrements de la base de données MIT-BIH, Al-Nashash [129] a développé un classificateur basé sur les réseaux neuronaux, atteignant une sensibilité de 98,1 % et une prédictivité positive de 94,7 %. Lagerholm et Person [130] ont combiné les fonctions d'Hermite avec une carte auto-organisée de Kohonen, permettant d'obtenir un classificateur très performant, avec seulement 1,5 % de battements mal classés. De leur côté, Moreas et al. [131] ont utilisé la distance de Mahalanobis comme critère de classification pour différencier les complexes QRS. Testé sur 44 enregistrements de la base MIT-BIH, leur classificateur a atteint une sensibilité de 90,74 % et une prédictivité positive de 96,55 %. Inan et al. [132] ont proposé un classificateur neuronal combinant la transformation en ondelettes et des caractéristiques temporelles de l'ECG. Appliqué à 40 enregistrements, leur modèle a atteint une précision de 95,16 %. Wieben et al [133], qui ont mis au point une classification basée sur les caractéristiques des bancs des filtres et les arbres de décision. L'algorithme a atteint une sensibilité de 85,3% et une prédictivité positive de 85,2%. Enfin, Christov et Bortolan [8] ont conçu un classificateur neuronal intégrant 26 paramètres descripteurs extraits de deux dérivations ECG. En exploitant l'ensemble de la base MIT-BIH, ils ont obtenu une spécificité de 99,7 % et une sensibilité de 98,5 %.

V.1.2 Description du système automatique de classification du signal ECG

Le diagnostic et le suivi des patients par les médecins reposent principalement sur des systèmes automatiques intelligents. Ces derniers doivent être faciles à implémenter, précis, robustes, stables et capables de s'adapter à des situations rares. Leur objectif principal est de détecter les anomalies, telles que les extrasystoles, en analysant les signaux ECG. En outre, ces systèmes fournissent des recommandations thérapeutiques et expliquent les mécanismes sous-jacents responsables des troubles détectés. En outre, ces systèmes fournissent des recommandations thérapeutiques et expliquent les mécanismes sous-jacents responsables des troubles détectés. Ces techniques reposent sur trois phases essentielles [134] :

- **L'enregistrement** du signal ECG ainsi que des données de suivi des patients.
- **Le traitement** du signal ECG.
- **Le diagnostic**, qui vise à identifier les extrasystoles en s'appuyant sur les étapes précédentes du traitement.

La Figure VI.2 illustre le schéma général du processus d'apprentissage pour la classification des signaux ECG.




Figure VI.3 Schéma bloc du traitement du signal et de l'extraction des caractéristiques

IV.2 LES DONNÉES ECG ÉTUDIÉES

Dans cette étude, nous utilisons la base de données MIT-BIH Arrhythmia afin d'obtenir un signal ECG fiable. Ces données ont été collectées par des chercheurs dans le but de servir de référence pour la validation et la comparaison des algorithmes appliqués au signal ECG.

IV.2.1 Description de la base de données MIT-BIH

La base de données MIT-BIH Arrhythmia est une référence universelle regroupant 48 enregistrements ECG, totalisant 110 007 battements, provenant de 47 patients différents. Chaque enregistrement contient des segments ECG de 30 minutes, sélectionnés à partir d'une surveillance de 24 heures, et enregistrés sur deux dérivations (DII et V5). Parmi ces 48 fichiers :

- 23 enregistrements (numérotés de 100 à 124) ont été sélectionnés aléatoirement pour inclure une diversité de formes d'ondes.
- 25 enregistrements (numérotés de 200 à 234) ont été choisis pour représenter différentes pathologies.

Les données ont été filtrées à l'aide d'un filtre passe-bande de 0,1 à 100 Hz. Chaque enregistrement ECG est échantillonné à 360 Hz, avec une résolution de 200 échantillons par mV et un codage sur 11 bits, couvrant une plage de 10 mV.

Chaque enregistrement a été annoté indépendamment par plusieurs cardiologues, garantissant ainsi des analyses plus fiables. L'annotation indique le moment d'apparition du pic R du complexe QRS ainsi que le type de QRS (voir tableau). Environ 70 % des battements ont été

classés comme normaux [135]. L'un des principaux atouts de cette base de données est la diversité des pathologies cardiaques qu'elle contient, offrant ainsi la possibilité de valider les algorithmes sur un large éventail de cas de signaux ECG.

IV.2.2. Fichiers de la base MIT-BIH

Chaque enregistrement ECG de la base de données est associé à trois fichiers distincts, chacun ayant une extension spécifique : .dat, .hea, et .atr.

IV.2.2.1 Le fichier de données (*.dat)

Ce fichier contient les données numérisées du signal ECG. Il regroupe deux signaux distincts correspondant aux deux dérivations enregistrées, stockés dans un même fichier, par exemple : 100.dat.

IV.2.2.2. Le fichier d'en-tête (*.hea)

Ce fichier fournit les métadonnées essentielles pour interpréter les données ECG. Il comprend des informations telles que la fréquence d'échantillonnage, le gain d'amplification, les dérivations utilisées, le nombre d'échantillons et les pathologies associées. Ces paramètres permettent aux logiciels d'exploiter correctement les données du fichier correspondant.

IV.2.2.3. Le fichier d'annotations (*.atr)

Ce fichier contient les positions et instants d'apparition des pics R du complexe QRS. Ces annotations ont été établies manuellement par plusieurs cardiologues. Il inclut des informations détaillées pour chaque pic R :

- **Position en seconds**
- **Position en nombre d'échantillons**
- **Type de battement (voir Tableau I.1)**

Par exemple, dans les enregistrements 119 et 232, la première colonne représente le temps d'apparition des pics R, la deuxième colonne indique leur position en nombre d'échantillons, et la troisième précise le type d'arythmie associé.

Si l'on analyse la première ligne de cet exemple :

- À 0:00.858 (temps) et 309 (échantillon), le complexe QRS correspond à un battement normal.
- À 0:01.397 (temps) et 503 (échantillon), le complexe QRS est de type V (extrasystole ventriculaire prématurée).

- Enregistrement 119.art:

0:00.858 309 N 0 0 0
 0:01.397 503 V 0 0 0
 0:02.713 977 N 0 0 0
 0:03.652 1315 N 0 0 0
 0:04.586 1651 N 0 0 0

- Enregistrement 232.art:

0:01.363 491 R 0 0 0
 0:02.047 737 A 0 0 0
 0:02.777 1000 A 0 0 0
 0:04.608 1659 R 0 0 0
 0:05.286 1903 A 0 0 0

Table IV.1 la base de données de tests de bruit de stress MIT-BIH

Symbole	Type d'arythmie
N	Battement normal
L	Bloc de branche gauche
R	Bloc de branche droit
A	Battement auriculaire prématuré
J	Battement nodal (fonctionnel) prématuré
S	Battement supraventriculaire prématuré
V	Contraction ventriculaire prématurée
F	Fusion ventriculaire et battement normal
E	Battement d'échappement auriculaire
J	Rythme nodal d'échappement (jonction)
E	Battement d'échappement ventriculaire
F	Fusion de battements rythmé et normal
X	Non-réalisée de l'onde P
Q	Battement non classifiable
I	QRS isolé-comme l'artefact

IV.2.3 Base de données des tests de bruit de stress MIT-BIH

La base de données des tests de bruit de stress MIT-BIH a été constituée à partir d'enregistrements effectués sur des volontaires physiquement actifs, à l'aide d'enregistreurs ECG et d'électrodes standard. Elle est divisée en deux catégories d'enregistrements:

1. Enregistrements de bruit isolés

Cette catégorie comprend trois enregistrements distincts, chacun représentant un type spécifique de perturbation :

- **Baseline Wander (BW)** : fluctuations de la ligne de base
- **Muscle Artifact (MA)** : interférences dues à l'activité musculaire
- **Electrode Motion (EM)** : perturbations causées par le déplacement des électrodes

2. Enregistrements combinés avec des signaux ECG

Cette deuxième catégorie regroupe douze enregistrements obtenus en ajoutant du bruit EM à deux signaux ECG de la base MIT-BIH sur les arythmies (enregistrements 118 et 119). Chaque enregistrement a une durée de 30 minutes [11].

IV.3 TRAITEMENT DU SIGNAL ET EXTRACTION DES CARACTERISTIQUE

Après la segmentation des battements cardiaques, nous avons obtenu une séquence de complexes P-QRS-T. Ces différentes ondes constituent le cycle standard de l'ECG, et leur importance clinique est résumée dans le tableau IV.2. Bien que rarement observée, l'onde U. Cette onde positive, d'une amplitude d'un quart de celle de l'onde T, survient après celle-ci, principalement chez les individus ayant des ondes T proéminentes et un rythme cardiaque lent (généralement dans les dérivations V2–V4). Cependant, son origine reste incertaine.

. Le principe des biométriques ECG repose sur le fait que la forme d'onde des battements cardiaques est unique à chaque individu. Cependant, la durée et l'amplitude des cycles cardiaques peuvent varier, non seulement d'un sujet à l'autre, mais aussi pour un même sujet à différents moments. C'est pourquoi notre approche vise à obtenir un ensemble de caractéristiques invariantes

en termes de latence. Pour ce faire, nous effectuons une normalisation temporelle en redimensionnant chaque segment pour qu'il ait le même nombre de points, puis nous extrayons les caractéristiques à partir des signaux normalisés.

Table IV.2 Importance des différentes ondes dans le signal ECG

<u>Segment/vague</u>	<u>Durée (ms)</u>	<u>Amplitude (mV)</u>	<u>Importance clinique</u>
Onde p	80-100	0.25	Hypertrophie auriculaire, fibrillation, flutter
segment PR	120-200	Ligne de base	Péricardite, blocs cardiaques, tachycardie auriculaire
<u>Complex QRS</u>	80-120	1,60 (R)	Hypertrophie ventriculaire, infarctus du myocarde
intervalle QT	200-400	25% de l'onde (R) (onde Q)	anomalies électrolytiques, maladie coronarienne
segment ST	80-120	Ligne de base	Ischémie coronaire, infarctus du myocarde
<u>T-wave</u>	120-160	0,1-0.5	Ischémie coronaire, syndrome de Wellens, hypertrophie ventriculaire gauche, hyperkaliémie
Onde U	20-40	0,3-0,7	Hypokaliémie, hypercalcémie, thyrotoxicose

IV.3.1 Normalisation temporelle

Les variations du rythme cardiaque entraînent généralement une compression ou une expansion temporelle de la forme d'onde des battements. La normalisation du signal segmenté permet de réduire la variabilité des latences de chaque complexe. La normalisation des signaux segmentés est généralement effectuée en segmente le signal dans une fenêtre fixe centrée autour des pics R. Dans cette étude, L'algorithme ainsi conçu échantillonne ces intervalles de manière à ce que chaque motif contienne le même nombre d'échantillons, quelle que soit l'expansion ou la compression des formes d'onde des battements cardiaques. Ainsi, les signaux normalisés obtenus auront tous le même nombre d'échantillons et le pic R sera positionné au même instant temporel. Dans cette étude, nous avons fixé à **300 échantillons** le nombre de points utilisés pour représenter chaque battement cardiaque. La figure IV.3 illustre le signal utilise après la normalisation temporelle.




Figure IV.4 Segments du signal ECG utilisés (119)

IV.3.2 Méthode de détection par amplitude

L'approche par amplitude est l'un des algorithmes les plus utilisés pour identifier le pic R dans les signaux ECG. Dans un premier temps, une différenciation est effectuée afin de réduire l'influence des ondes P et T, ce qui permet de mieux distinguer le complexe QRS. Ensuite, un seuil d'amplitude est appliqué pour finaliser la détection. Cet algorithme a été exploité par Sufi et al. [136] pour mesurer la fréquence cardiaque sur des dispositifs mobiles. Par ailleurs, la combinaison du seuil d'amplitude et de la première dérivée permet d'accentuer la pente du complexe QRS, rendant ainsi sa détection plus efficace. Deux variables sont utilisées dans cette section $x(k)$, qui représente le signal ECG brut en entrée, et $y(k)$, qui correspond au signal filtré en sortie. Le calcul du seuil d'amplitude pour un segment de signal ECG est défini comme suit :

$$seuil = \alpha \times \max\{x(k)\} \quad (1.III)$$

Où α représente le pourcentage de signal ECG éliminé

Avec une valeur comprise entre $0 < \alpha < 1$. La valeur de α est optimisée une seule fois avant le prétraitement, tandis que les seuils restent constants tout au long de l'analyse. Plusieurs seuils d'amplitude sont utilisés pour la détection ultérieure des complexes QRS. Morizet et al. [135] ont proposé une méthode de détection QRS avec $l = 0.3 \times \max\{x(k)\}$, où les amplitudes

inférieures à 30 % du pic du signal sont tronquées dans $x(k)$. De son côté, Fraden [136] a employé un seuil de **seuil** = $0.4 \times \max\{x(k)\}$. L'un des principaux atouts de cette technique est sa faible charge de calcul, comparée aux autres méthodes de prétraitement, grâce à l'utilisation d'un signal ECG de courte durée pour l'analyse. En revanche, son principal inconvénient est que la longueur des segments ECG traités est fixe et définie empiriquement [135,136]. Lorsque le signal ECG est plus long, les performances peuvent se détériorer, sauf s'il est découpé en segments plus courts. Toutefois, cette segmentation peut entraîner la perte des débuts et des fins des battements cardiaques.

IV.3.3 Dérivée du premier ordre

Un différenciateur de premier ordre est couramment employé comme filtre passe-haut, permettant d'éliminer les bruits indésirables à basse fréquence ainsi que la dérive de la ligne de base du signal $x(k)$. De plus, il génère des passages par zéro au niveau du pic R et modifie la phase des signaux ECG. Plusieurs algorithmes appliquent cette dérivée à l'aide de l'équation suivante [137] :

$$y(k) = -2x(k-2) - x(k-1) + x(k+1) + 2x(k+2) \quad (\text{III.2})$$

Fonction de transfert est donnée par la relation suivante:

$$H(z) = \frac{y(z)}{x(z)} = -2z^{-2} - z^{-1} + z^{+1} + 2z^{+2} \quad (\text{III.3})$$

De plus, Holsinger et al. [136] ont adopté une approche basée sur les différences finies centrales, formulée comme suit :

$$y(k) = -x(k-1) + x(k+1) \quad (\text{III.4})$$

Un seuil optimal est déterminé et appliqué à $y(k)$ en association avec la technique de dérivée du premier ordre pour détecter les complexes QRS dans les signaux ECG. La longueur du signal traité ainsi que les seuils utilisés lors de l'analyse sont préétablis. Cette méthode présente l'avantage d'exiger une charge de calcul réduite, mais son inconvénient réside dans son incapacité à éliminer totalement les bruits haute fréquence.

V.3.4 Détection des complexes QRS

La détection des complexes QRS est une étape essentielle dans l'analyse automatique du signal ECG, car elle influence directement la précision des résultats de classification. Cette procédure permet de segmenter l'ECG en fenêtres correspondant à chaque cycle cardiaque. À première vue, on pourrait penser que la détection des complexes QRS peut être réalisée par un simple seuillage du signal, étant donné que les pics R présentent généralement une amplitude plus élevée que les autres ondes (figure IV.5).

L'évolution des systèmes informatiques dédiés à l'analyse numérique a permis la conception et l'implémentation de divers algorithmes pour la détection automatique des complexes QRS. Ce sujet a fait l'objet de nombreuses recherches et demeure un domaine d'étude en pleine expansion. La plupart de ces algorithmes se distinguent par leur grande efficacité, offrant un taux de détection et de classification très élevé.

Dans notre approche, nous avons choisi d'utiliser un seuil défini par : $seuil = 0.4 \times \max\{x(k)\}$ (figure IV.7) après l'étape de la première dérivation (voir figure IV.5).




Figure IV.5 Segment du signal utilisé en haut, Première dérivation en bas.




Figure IV.6 Détection des pics R.




Figure IV.7 Détection des complexes QRS + Seuil utilisé

IV.3.5 Extraction des Caractéristiques

Il existe plusieurs approches pour l'extraction des caractéristiques ECG. Dans notre cas, nous segmentons le signal en cycles cardiaques (battements cardiaques) à l'aide de la normalisation temporelle, discutée précédemment. Ensuite, nous appliquons la dérivée du premier ordre (équation III.2), suivie d'un seuillage permettant d'identifier plusieurs cycles du signal. Les caractéristiques extraites sont les mêmes que celles utilisées au chapitre 3, notamment:

- **L'entropie multiscale modifiée (MMSE)**
- **L'exposant de Hurst**
- **Les coefficients de Hjorth**
- **L'analyse des fluctuations sans tendance (DFA)**
- **Les dimensions fractales de Higuchi (HFD) et de Katz (KFD)**

Ces caractéristiques sont ensuite concaténées pour former un vecteur global, qui est introduit dans un classificateur adapté afin d'identifier la présence ou l'absence d'une extrasystole. Des détails supplémentaires sur les algorithmes de classification ainsi que sur les aspects théoriques des mesures non linéaires seront abordés ultérieurement.

IV.4 RÉSULTATS DES SIMULATIONS

Cette section présente les principaux résultats expérimentaux obtenus au cours de cette étude, accompagnés d'une analyse approfondie. Conformément au schéma en blocs de l'approche proposée (Figure IV.3), six caractéristiques non linéaires ont été extraites et analysées dans deux scénarios distincts :

1. Lorsque le nombre de cycles représentant des extrasystoles est égal au nombre de cycles normaux.
2. Lorsque le nombre de cycles normaux est supérieur à celui des cycles contenant des extrasystoles dans le signal ECG étudié.

Après un filtrage temporel des signaux ECG pour détecter les complexes QRS à l'aide de la dérivée du premier ordre, des caractéristiques non linéaires ont été calculées à partir des signaux filtrés, puis utilisées pour le processus de classification. La figure IV.7 illustre un boxplot des différentes caractéristiques extraites, telles que l'entropie multi-échelle modifiée, les dimensions fractales de Higuchi et de Katz, l'analyse des fluctuations dé-trendées, l'exposant de Hurst et les coefficients de Hjorth. Une distinction claire est observable entre les valeurs moyennes des signaux normaux et celles des signaux anormaux (cycles normaux vs extrasystoles). Cette différence s'explique principalement par la variation morphologique entre les cycles normaux et ceux présentant des extrasystoles.

IV.4.1 Classification des arythmies cardiaques

Dans les étapes de classification/diagnostic, quatre problèmes principaux existent: le premier est comment définir les classes de diagnostic (extraction des paramètres), le second est comment choisir le classificateur le plus approprié, le troisième est comment former le

classificateur choisi, et le quatrième est comment mesurer la qualité et les performances du classificateur.

IV.4.1.1 Choix du vecteur de classification

Selon la figure (IV.7), la dimension fractale de DFA est la plus significative. Il existe une différence notable entre les cycles normaux et les cycles qui présentent des extrasystoles, ce qui implique que la dimension fractale de DFA est statistiquement la plus significative comparée aux autres caractéristiques. Les matrices de dispersion sont utilisées pour démontrer le succès du processus de sélection des caractéristiques basé sur le classement. Ces matrices montrent en détail la distribution des caractéristiques classées. À l'aide d'une matrice de dispersion, la répartition des trois caractéristiques les mieux classées est représentée dans un espace 3D. La figure IV.8 illustre les relations entre trois des caractéristiques extraites. La figure est composée de trois colonnes :

- En haut, des matrices de dispersion du coefficient DFA en fonction du HFD et du MMSE
- En bas, une dispersion du DFA par rapport à l'exposant de Hurst et au HFD ;
- et enfin, au centre de la figure, des diagrammes de dispersion concernant les trois coefficients de Hjorth.

Comme mentionné précédemment, de nombreuses études ont exploré l'utilisation des signaux ECG pour détecter et identifier automatiquement les cycles présentant des extrasystoles. L'analyse de ces signaux permet de différencier les états sains des états pathologiques en s'appuyant sur des techniques d'extraction de caractéristiques non linéaires.

IV.4.2 Paramètres d'évaluation des performances

L'évaluation des classifieurs faite par le calcul du le taux de classification correcte

$$CA = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (IV.6)$$

Avec :

- T_p (True positive) : nombre de cycles cardiaques présentant une extrasystole « ESV » reconnu comme des « ESV ».

- Tn (True négative) : nombre de cycles cardiaques qui ne présentent pas de extrasystole « ESV » reconnu comme « Normal »
- Fp (False positive) : nombre de cycles cardiaques ne présentant pas une extrasystole « ESV » reconnu comme des ESV. Fn (False négative) : nombre de cycles cardiaque ESV non reconnu




Figure IV.7 Les huit principales caractéristiques les mieux classées extraites des deux classes de signaux ECG, avec leurs valeurs moyennes et écarts-types SD - standard déviation

IV.4.3 Choix du vecteur d'entrée

Après segmentation temporel du signal ECG, les caractéristiques non linéaires sont extraites et regroupées pour construire quatre différents vecteurs de caractéristiques de la manière suivante:

- i. Vecteur 1: Hjorth coefficients + Hurst + DFA+ KFD.
- ii. Vecteur 2: Hjorth coefficients + MMSE2 + DFA + KFD.
- iii. Vecteur 3: Hjorth coefficients + Hurst + DFA + HFD
- iv. Vecteur 4: Hjorth coefficients + MMSE2 + DFA + HFD

Par les coefficients de Hjorth, on entend les trois paramètres suivants : l'activité, la mobilité et la complexité, calculée dans leur ensemble. Chacun des quatre vecteurs sera ensuite formé par six (06) caractéristiques à fournir à l'algorithme de classification.

IV.4.4 Choix des classificateurs

Le premier algorithme de classification adopté est un réseau de neurones feedforward à trois couches, avec les couches cachées et de sortie contenant respectivement vingt (20) et deux (02) neurones; de plus, les fonctions du perceptron multicouche (MLP) ont également été configurées selon le chapitre 3, avec une fonction tan-sigmoïde à la couche cachée et une fonction linéaire pure à la couche de sortie. L'algorithme d'optimisation de Levenberg–Marquardt de deuxième ordre a été utilisé pour mettre à jour les différents poids du réseau. Les deux autres classificateurs sont liés aux nouveaux algorithmes d'apprentissage profond. à la couche de sortie. L'algorithme d'optimisation de Levenberg–Marquardt de deuxième ordre a été utilisé pour mettre à jour les différents poids du réseau. Les deux autres classificateurs sont liés aux nouveaux algorithmes d'apprentissage profond.

Premièrement, nous avons utilisé un réseau de neurones profond (DNN) et comparé sa performance dans la classification des signaux ECG normaux par rapport aux signaux qui contient des extrasystoles en faisant varier deux facteurs différents et substantiels, à savoir le nombre de couches cachées formant la structure profonde et le nombre de neurones dans chaque couche cachée ; tous ces résultats sont illustrés dans le Tableau (IV.5), où la performance de classification est évaluée en termes de précision moyenne de classification (CA). Il convient de noter que pour l'architecture DNN, (02) couches cachées avec 30 neurones dans chaque couche ont été adoptées dans nos expériences comme un bon compromis entre la précision obtenue et les exigences en matière de temps de calcul.

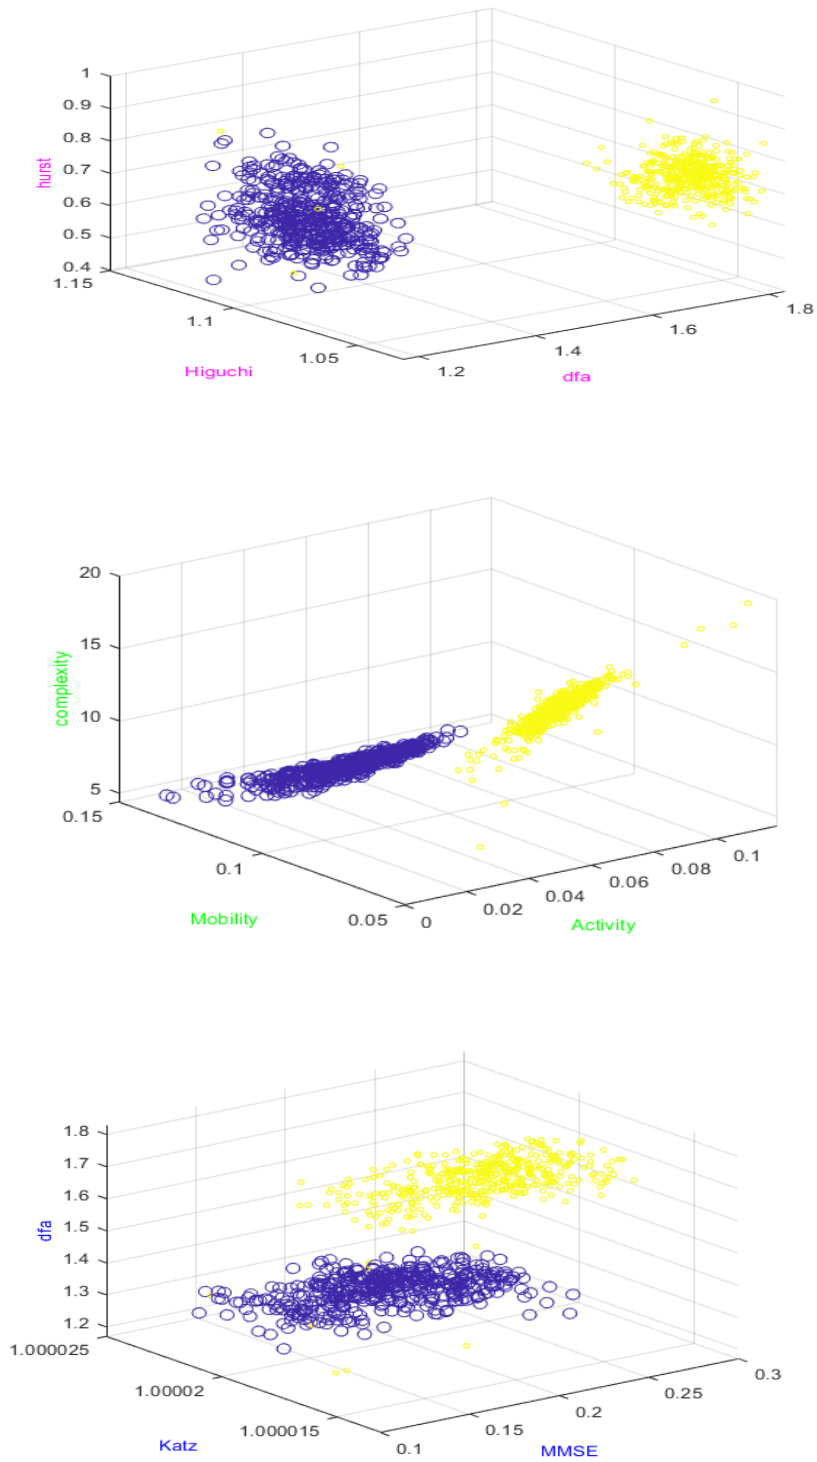


Figure IV.8 Matrice de dispersion des trois fonctionnalités choisies, classées pour deux classes pour tous l'ECG sélectionné.

Deuxièmement, le troisième algorithme de classification entrepris dans la présente étude est l'algorithme d'apprentissage profond Long Short Term Memory (LSTM) unique. Pour l'algorithme de classification binaire, l'algorithme Adaptive Moment Estimation (ADAM) est utilisé avec 100 unités cachées ; le nombre maximum d'époques a été fixé à 70, et la taille minimale du lot à 27. Comme mentionné précédemment, la détection des extrasystoles est un problème de classification binaire dans lequel l'objectif est de classer le signal ECG d'entrée comme étant soit un signal, soit un signal sans extrasystole, qui pourrait inclure des signaux ECG de sujets sains ou des ECG avec des extrasystoles.

IV.5 RÉSULTATS ET DISCUSSION

Pour chacun des classificateurs adoptés, la précision moyenne de classification (CA) a été évaluée sur deux cas distincts de détection de pathologies. D'après le jeu de données MIT-BIH, ces cas sont définis comme suit : le sous-ensemble A, regroupant les caractéristiques des cycles normaux, est comparé au sous-ensemble E, contenant les caractéristiques des cycles pathologiques (extrasystoles). Il est connu que, dans un signal ECG, le nombre de cycles normaux est généralement supérieur à celui des extrasystoles, nous avons choisi d'utiliser deux sous-ensembles, E1 et E2, au lieu d'un unique sous-ensemble E. Dans le sous-ensemble E1, les cycles normaux et les extrasystoles sont en proportions égales, tandis que dans le sous-ensemble E2, les cycles normaux sont majoritaires par rapport aux extrasystoles.

Les tableaux IV.3 à IV.6 compilent la précision moyenne de classification (CA) pour chacun des quatre vecteurs d'extraction de caractéristiques proposés, notés comme Vecteur 1, Vecteur 2, Vecteur 3 et Vecteur 4, où les résultats de performance sont présentés pour chaque classificateur et parmi les deux cas différents de détection de ESV. Ces résultats sont également affichés à travers les Figure(IV.9) et figure (IV.10) pour faciliter la comparaison. Le graphique à barres, comparant les résultats des trois méthodes de classification, montre que la précision de classification pour les différents classificateurs est plus élevée pour le Vecteur 3 que pour les autres vecteurs, avec une précision de classification atteignant jusqu'à 100 %.

Les résultats finaux montrent donc que les caractéristiques formant le Vecteur 3 présentent des avantages clairs et peuvent améliorer efficacement la précision de classification du signal ECG pour de nombreux cas distincts de détection des ESV.

Il est intéressant de noter que les données ECG du cas de détection de ESV A-E conviennent mieux aux objectifs de classification, en raison des grandes variations des valeurs ECG enregistrées dans le sous-ensemble A ou E. En fait, en raison de la nature des grandes différences dans les données, il est plus facile de classifier les ensembles A et E quel que soit le vecteur choisi et quel que soit le classificateur.

Pour bien étudier le DNN, nous avons utilisé un réseau neuronal profond (DNN) et comparé ses performances dans la classification des signaux ECG normaux et qui contient des ESV en faisant varier deux facteurs différents et substantiels : le nombre de couches cachées formant la structure profonde et le nombre de neurones dans chaque couche cachée. Tous ces résultats sont illustrés dans le Tableau IV.7, où la performance de classification est évaluée en termes de précision de classification (CA).

Il convient de noter que, pour l'architecture du DNN, nous avons adopté dans nos expériences une configuration avec deux (02) couches cachées et 30 neurones par couche, comme un bon compromis entre la précision atteinte et les exigences en temps de calcul (tel qu'indiqué par une expérimentation préliminaire).

Table IV.3 Taux de classification pour le vecteur 1

Case Problem	MLP	DNN	LSTM
A-E1	99.3	99.1	95.6
A-E2	98.2	98	97.5

Table IV.4 Taux de classification pour le vecteur 2

Case Problem	MLP	DNN	LSTM
A-E1	97.4	98.5	93.4
A-E2	99.4	98.2	89.5

Table IV.5 Taux de classification pour le vecteur 3

Case Problem	MLP	DNN	LSTM
A-E1	100	99.1	100
A-E2	99.4	98.3	90.3

Table IV.6 Taux de classification pour le vecteur 4

Case Problem	MLP	DNN	LSTM
A-E1	99.3	98.6	96.5
A-E2	98.4	99.2	97.4

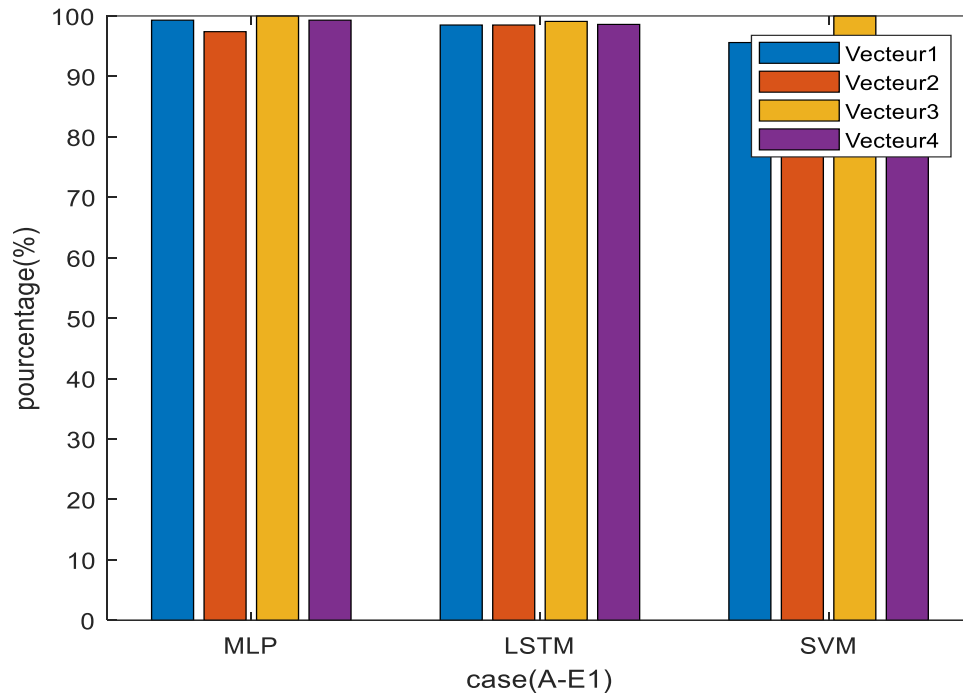


Figure IV.9 Taux de classification de trois méthodes (MLP, DNN, LSTM) pour le cas : A-E1.




Figure III.10 Taux de classification de trois méthodes (MLP, DNN, LSTM) pour le cas : A-E2.

Table.IV.7 : Meilleure taux de classification correspondante pour différents cas expérimentaux.

# Hidden layer	# Neurons	Vector 1		Vector 2		Vector 3		Vector 4	
		AC1	AC2	AC1	AC2	AC1	AC2	AC1	AC2
2	2*10	99.1	98.5	98,2	95.2	99.1	97.8	96.3	96.6
2	2*20	99.4	98.7	98,5	85.9	100	98	98.2	99.8
2	2*30	99,1	98	98,5	98.2	99.1	98.3	98.6	99.2
3	3*10	99.7	98.2	97,1	97.4	97.8	98.2	99.0	99.5
3	3*20	98.7	98.5	88,8	98,7	100	98	99.0	99.4
3	3*30	99.1	98.5	98,5	95.8	100	98.2	98.7	99.2
4	4*10	98.5	98.7	87,5	97.8	98.2	97.6	99.2	99.5
4	4*20	99.3	98.2	92,7	98,9	100	98.5	99.1	99.5
4	4*30	98.9	98.5	99,6	98.5	99.5	98.2	99.1	100
5	5*10	98.9	98.5	99,4	96.9	98.2	98.6	98.5	99.1
5	5*20	100	98.2	99,6	95	98	98	98.6	99.1
5	5*30	99.3	98.	97,8	96.9	99.6	98	98.8	99.3

Conclusion

Ce chapitre a mis en évidence l'importance de l'analyse automatique des signaux ECG pour la détection et la classification des arythmies cardiaques, en particulier les extrasystoles ventriculaires (ESV). L'utilisation de la base de données MIT-BIH a permis de valider l'approche proposée à travers différentes méthodes de classification, incluant les réseaux neuronaux feedforward et les algorithmes d'apprentissage profond (DNN et LSTM).

L'étude a démontré que l'extraction des caractéristiques non linéaires, combinée à des classificateurs performants, permet d'atteindre des taux de classification élevés, avec une précision maximale de 100 % pour certains vecteurs de caractéristiques. En particulier, le Vecteur 3 s'est révélé être le plus efficace, optimisant ainsi la classification des cycles normaux et des extrasystoles.

Ces résultats confirment l'intérêt d'intégrer des systèmes automatiques de classification dans les dispositifs de surveillance médicale pour améliorer le diagnostic et le suivi des patients. À l'avenir, l'élargissement de cette étude à d'autres types d'arythmies et l'optimisation des architectures de réseaux neuronaux pourraient encore renforcer la précision et la robustesse des modèles développés.

CONCLUSION GENERALE

L'objectif principal de cette thèse est double : d'une part, proposer de nouvelles méthodes automatiques de classification des crises épileptiques et arythmies cardiaques, et d'autre part, développer des techniques d'analyse permettant de détecter des phénomènes de synchronisation et de désynchronisation dans ces signaux. Ces approches s'appuient sur des hypothèses distinctes et moins contraignantes sur le plan théorique que celles des méthodes classiques. Dans les deux derniers chapitres, nous mettons en évidence les contributions directes de cette thèse en lien avec ces deux objectifs. Enfin, plusieurs axes d'amélioration sont proposés pour renforcer et affiner les résultats obtenus. L'extraction de caractéristiques non linéaires constitue une étape cruciale pour garantir la performance d'un système de classification automatique des arythmies cardiaques ainsi que les crises épileptiques, indispensable dans le domaine clinique. Parmi les techniques couramment utilisées pour cette extraction, on retrouve les méthodes non linéaires. Bien que ces méthodes offrent généralement de bons taux de classification, elles présentent certaines limitations importantes que nous avons identifiées :

- Les paramètres sont extraits à partir de segments EEG ou ECG des tailles fixes, sans tenir compte de la variabilité du rythme cardiaque entre les individus, voire chez un même individu.
- L'extraction des caractéristiques se fait globalement à partir des segments ECG, sans distinction des trois événements majeurs d'un cycle cardiaque.

En parallèle, cette méthode offre des solutions aux limitations des techniques traditionnelles utilisées pour l'étude des signaux EEG et ECG. Cette méthode permet de développer des outils spécifiques pour analyser les perturbations spectrales événementielles et détecter les phénomènes de synchronisation ou de désynchronisation.

Perspectives

Les travaux réalisés dans cette thèse ouvrent la voie à plusieurs perspectives prometteuses, tant sur le plan théorique qu'applicatif. D'une part, les méthodes proposées pour l'analyse des signaux EEG et ECG pourront être généralisées à d'autres types de signaux physiologiques, comme les signaux EMG ou EOG, dans le but de concevoir des systèmes de diagnostic plus complets et multi-modaux. D'autre part, l'intégration des techniques d'intelligence artificielle, notamment l'apprentissage profond, pourra être étendue à des architectures plus complexes, comme les réseaux de neurones convolutifs ou hybrides, afin d'améliorer la robustesse et la précision des systèmes de classification. Par ailleurs, une application clinique concrète de ces systèmes dans un environnement hospitalier, avec des validations sur des bases de données en temps réel, constitue une perspective importante pour garantir leur efficacité pratique. Enfin, l'implémentation embarquée de ces algorithmes dans des dispositifs portables ou implantables pourrait transformer leur utilité dans le suivi continu et personnalisé des patients.

RÉFÉRENCES

- [1] Sanei, S., & Chambers, J. A. (2013). EEG signal processing. John Wiley & Sons.
- [2] Jemaa, O., Bennour, S., Daney, D., & Romdhane, L. (2020). Experimental Analysis of Electromyography (EMG) Signal for Evaluation of Isometric Muscle Force. In Design and Modeling of Mechanical Systems-IV: Proceedings of the 8th Conference on Design and Modeling of Mechanical Systems, CMSM'2019, March 18–20, Hammamet, Tunisia (pp. 183-192). Springer International Publishing.
- [3] <http://fr.wikipedia.org/wiki/Électrocardiographie>
- [4] Bryant, H. (2007). Dehydration in older people: assessment and management. *Emergency nurse*, 15(4).
- [5] Marieb, E. N., & Hoehn, K. (2013). The muscular system. *Human Anatomy and Physiology*, 9th edition. Boston, MA: Pearson Education, 346-353.
- [6] Fan, J., Sun, C., Long, M., Chen, C., & Chen, W. (2021). Eognet: A novel deep learning model for sleep stage classification based on single-channel eog signal. *Frontiers in Neuroscience*, 15, 573194.
- [7] Picot, A. (2009). Détection d'hypovigilance chez le conducteur par fusion d'informations physiologiques et vidéo (Doctoral dissertation, Institut National Polytechnique de Grenoble-INPG).
- [8] Pan, J., & Tompkins, W. J. (1985). A real-time QRS detection algorithm. *IEEE transactions on biomedical engineering*, (3), 230-236.
- [9] Piccirillo, G., Ogawa, M., Song, J., Chong, V. J., Joung, B., Han, S., ... & Chen, P. S. (2009). Power spectral analysis of heart rate variability and autonomic nervous system activity measured directly in healthy dogs and dogs with tachycardia-induced heart failure. *Heart rhythm*, 6(4), 546-552.
- [10] AHMED, I. H. (2022). Analyse temps–fréquence à haute résolution du signal HRV: Application à la télésurveillance des arythmies cardiaques (Doctoral dissertation, Université Abou Bekr Belkaid Tlemcen (Algérie)).
- [11] Marieb, E. (2000). Anatomie et physiologie humaine. *REVUE DE L EDUCATION PHYSIQUE*, 40(1), 46-46.
- [12] Islam MK, Rastegarnia A, Yang Z. Methods for artifact detection and removal from scalp EEG: a review. *Neurophysiol Clin*. 2016;46(4–5):287–305.
- [13] Cohen MK. Analyzing neural time series data: theory and practice. Cambridge, MA: MIT Press; 2013.
- [14] Nakamura, M., & Shibasaki, H. (1987). Elimination of EKG artifacts from EEG records: a new method of non-cephalic referential EEG recording. *Electroencephalography and clinical neurophysiology*, 66(1), 89-92.
- [15] Barlow J. Clinical applications of computer analysis of EEG and other neurophysiological signals. *Handbook of EEG*. Amsterdam: Elsevier; 1986.
- [16] Hu, L., & Zhang, Z. (Eds.). (2019). EEG signal processing and feature extraction.

- [17] Blum DE. Computer-based electroencephalography: technical basics, basis for new applications, and potential pitfalls. *Electroencephalogr Clin Neurophysiol.* 1998;106(2):118–26.
- [18] Benzaid, A., Djemili, R., & Arbateni, K. (2024). Seizure detection using nonlinear measures over EEG frequency bands and deep learning classifiers. *Computer Methods in Biomechanics and Biomedical Engineering*, 1-17.
- [19] Cohen MK. *Analyzing neural time series data: theory and practice.* Cambridge, MA: MIT Press; 2013.
- [20] Stergiadis, C.; Kostaridou, V.D.; Klados, M.A. Which BSS method separates better the EEG Signals? A comparison of five different algorithms. *Biomed. Signal Process. Control* 2022, 72, 103292.
- [21]. Mijović, B.; De Vos, M.; Gligorijević, I.; Taelman, J.; Van Huffel, S. Source Separation From Single-Channel Recordings by Combining Empirical-Mode Decomposition and Independent Component Analysis. *IEEE Trans. Biomed. Eng.* 2010, 57, 2188–2196.
- [22]. Onton, J.; Westerfield, M.; Townsend, J.; Makeig, S. Imaging human EEG dynamics using independent component analysis. *Neurosci. Biobehav. Rev.* 2006, 30, 808–822.
- [23] Naik, G. R., Arjunan, S., & Kumar, D. (2011). Applications of ICA and fractal dimension in sEMG signal processing for subtle movement analysis: a review. *Australasian physical & engineering sciences in medicine*, 34, 179-193.
- [24] Pereira, L.F.; Patil, S.A.; Mahadeshwar, C.D.; Mishra, I.; D’Souza, L. Artifact removal from EEG using ANFIS-GA. In *Proceedings of the 2016 Online International Conference on Green Engineering and Technologies (IC-GET), Coimbatore, India, 19 November 2016*; IEEE: Manhattan, NY, USA, 2016; pp. 1–6. [25] Gratton, G.; Coles, M.G.; Donchin, E. A new method for off-line removal of ocular artifact. *Electroencephalogr. Clin. Neurophysiol.* 1983, 55, 468–484.
- [26] Zhang, J.H.; Janschek, K.; Böhme, J.F.; Zeng, Y.J. Multi-resolution dyadic wavelet denoising approach for extraction of visual evoked potentials in the brain. *IEE Proc. Vis. Image Signal Process.* 2004, 151, 180–186. [CrossRef]
- [27] Mamun, M.; Al-Kadi, M.; Marufuzzaman, M. Effectiveness of wavelet denoising on electroencephalogram signals. *J. Appl. Res. Technol.* 2013, 11, 156–160.
- [28] Inuso, G.; La Foresta, F.; Mammone, N.; Morabito, F.C. Brain activity investigation by EEG processing: Wavelet analysis, kurtosis and Renyi’s entropy for artifact detection. In *Proceedings of the 2007 International Conference on Information Acquisition, Seogwipo, Korea, 8–11 July 2007*; IEEE: Manhattan, NY, USA, 2007; pp. 195–200.
- [29]. Ghaderpour, E.; Pagiatakis, S.D.; Hassan, Q.K. A Survey on Change Detection and Time Series Analysis with Applications. *Appl. Sci.* 2021, 11, 6141. [CrossRef]
- [30] Grobbelaar, M., Phadikar, S., Ghaderpour, E., Struck, A. F., Sinha, N., Ghosh, R., & Ahmed, M. Z. I. (2022). A survey on denoising techniques of electroencephalogram signals using wavelet transform. *Signals*, 3(3), 577-586.
- [31] E. Callaway, P.R. Harris, Coupling between cortical potentials from different areas, *Science* 183 (4127) (1974) 873–875.
- [32] N. Pradhan, D.N. Dutt, Data compression by linear prediction for storage and transmission of EEG signals, *Int. J. Biomed. Comput.* 35 (3) (1994) 207–217.
- [33] R.O. Duda, P.E. Hart, D.G. Stork, *Pattern Classification*, second ed., John Wiley & Sons Inc., 2006.

- [34] S. Ghosh-Dastidar, H. Adeli, N. Dadmehr, Principal component analysis enhanced cosine radial basis function neural network for robust epilepsy and seizure detection, *IEEE Trans. Biomed. Eng.* 55 (2) (2008) 512–518.
- [35] A. Subasi, M.I. Gursoy, EEG Signal classification using PCA, ICA, LDA and support vector machine, *Expert Syst. Appl.* 37 (12) (2010) 8659–8686
- [36] U.R. Acharya, S. Vinitha Sree, J.S. Suri, Use of principal component analysis for automatic detection of epileptic EEG activities, *Expert Syst. Appl.* 39 (10) (2012) 9072–9078.
- [37] T.-P. Jung, S. Makeig, M.J. McKeown, A.J. Bell, T.-W. Lee, T.J. Sejnowski, Imaging brain dynamics using independent component analysis, *Proc IEEE* 89 (7) (2001) 1107–1122.
- [38] A.Y. Kaplan, Segmental structure of EEG more likely reveals the dynamic multistability of the brain tissue than the continual plasticity one, in: *Proceedings of the Sixth International Conference on Neural information processing*, vol. 2, 1999, pp. 633–638.
- [39] P.D. Welch, The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms, *IEEE Trans. Audio Electroacoust.* AU-15 (1967) 70–73.
- [40] J. Feder, *Fractals*, Plenum Press, New York, 1988.
- [41] E.D. Ubeyli, I. Güler, Spectral analysis of internal carotid arterial Doppler signals using FFT, AR, MA, and ARMA methods, *Comput. Biol. Med.* 34 (4) (2004) 293–306.
- [42] M. Vitterli, Wavelet and filter banks: theory and design, *IEEE Trans. Signal Process.* 40 (9) (1992) 2207–2232.
- [43] P. Jahankhani, V. Kodogiannis, K. Revett, EEG signal classification using wavelet feature extraction and neural networks, in: *IEEE International Symposium on Modern Computing John Vincent Atanasoff*, 2006, pp 120–124.
- [44] N. Sadati, H.R. Mohseni, A. Magshoudi, Epileptic seizure detection using neural fuzzy networks, in: *Proceedings of the IEEE International Conference on Fuzzy Systems*, 2006, pp. 596–600.
- [45] A. Subasi, EEG Signal classification using wavelet feature extraction and a mixture of expert model, *Expert Syst. Appl.* 32 (4) (2007) 1084–1093.
- [46] H. Ocak, Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy, *Expert Syst. Appl.* 36 (2) (2009) 2027–2036.
- [47] U.R. Acharya, S. Vinitha Sree, J.S. Suri, Automatic detection of epileptic EEG signals using higher order cumulant features, *Int. J. Neural Syst.* 21 (5) (2011) 1–12.
- [48] R.J. Oweis, E.W. Abdulhay, Seizure classification in EEG signals utilizing Hilbert–Huang transform, *Biomed. Eng.* 10 (2011) 38.
- [49] N.E. Huang, Z. Shen, S.R. Long, M.C. Wu, H.H. Shih, Q. Zheng, N.C. Yen, C.H.H. Tung, H.H. Liu, The empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstationary time series analysis, *Proc. Roy. Soc. Lond. A* 454 (1998) 903–995.
- [50] R.J. Martis, U.R. Acharya, J.H. Tan, A. Petznick, R. Yanti, K.C. Chua, E.Y.K. Ng, L. Tong, Application of empirical mode decomposition (EMD) for automated detection of epilepsy using EEG signals, *Int. J. Neural Syst.* 22 (6) (2012). 1250027-1-16.

- [51] K.C. Chua, V. Chandran, U.R. Acharya, C.M. Lim, Automatic identification of epileptic EEG signals using higher order spectra, *J. Eng. Med.* 223 (4) (2009) 485–495.
- [52] J. Han, M. Kamber, J. Pei, *Data Mining: Concepts and Techniques*, Morgan Kaufmann, 2005.
- [53] T.J. Ross, *Fuzzy Logic with Engineering Applications*, John Wiley & Sons Ltd., West Sussex, UK, 2004.
- [54] I.M. Kapetanovic, S. Rosenfeld, G. Izmirlian, Overview of commonly used bioinformatics methods and their applications, *Annals of the New York Academy of Sciences* 1020 (2004) 10–21.
- [55] R.Vecht, M.A.Gatzoulis, N.S.Peters, “ECG diagnosis in clinical practice”, Springer, 2009.
- [56] Gacek, A., & Pedrycz, W. (Eds.). (2011). *ECG signal processing, classification and interpretation: a comprehensive framework of computational intelligence*. Springer Science & Business Media.
- [57] G.Lu, J-S.Brittain, P.Holland, J.Yianni, A.L.Green, “Removing ECG noise from surface EMG signals using adaptive filtering”, *Neuroscience Letters*, 462, 14-19, 2009.
- [58] N.V.Thakor, Y.-S.Zhu, “Applications of adaptive filtering to ECG analysis: noise cancellation and arrhythmia detection”, *IEEE Trans. Biomed.*, 38(8), 785-794, 1991.
- [59] J.Kuzilek, V.Kremen, F.Soucek, L. Lhotska, “Independent component analysis and decision trees for ECG holter recording de-noising”, *PLoS One*, 9(6), 2014.
- [60] J.Lee, D.D. McManus, S. Merchant, K.H. Chon, “Automatic motion and noise artifact detection in holter ECG data using empirical mode decomposition and statistical approaches”, *IEEE Trans. Biomed. Eng.*, 59(6), 1499-1506, 2012.
- [61] Z. Wang, C.M. Wong, J. Nuno, F. Wan, “Muscle and electrode motion artifacts reduction in ECG using adaptive Fourier decomposition”, *IEEE Intern. Conf. on Syst., Man and Cyber.*, 2014.
- [62] M.Chakraborty, S.Das, “Determination of signal to noise ration of electrocardiograms filtered by band pass and Savitzky-Golay filters”, *Procedia Technology*, 4, 830–833, 2012.
- [63] K.Le, S.Orn, O.Kleiven, “High frequency noise detection and handling in ECG signals”, 26th European Signal Processing Conference (EUSIPCO), 46-50, 2018.
- [64] D.Panigrahy, P.K.Sahu, “Extended Kalman smoother with differential evolution technique for denoising of ECG signal”, *Australas. Phys. Eng. Sci. Med.*, 39(3), 783-795, 2016.
- [65] R.Sameni, M.Shamsollahi, C.Jutten, G.Clifford, “A nonlinear Bayesian filtering framework for ECG denoising”, *IEEE Trans. Biomed. Eng.* 54(12), 2172-2185, 2007.
- [66] M.Alfaouri, K.Daqrouq, “ECG signal denoising by wavelet transform thresholding”, *Amer. J. Appl. Sci.*, vol.5(3), 2008.
- [67] J. Rodrigues, D. Belo, H. Gamboa, “Noise detection on ECG based on agglomerative clustering of morphological features”, *Computers in Biology and Medicine*, 87, 322-334, 2017.
- [69] R.Rodrigues, P.Couto, “A neural network approach to ECG denoising”, arXiv:1212.5217v1, 2012.
- [70] P. Rajpurkar, A.Y. Hannun, M. Haghpanahi, A.Y. Ng, “CardiologistLevel Arrhythmia Detection with Convolutional Neural Networks”, arXiv:1707.01836v1, 2017.
- [71] P.Xiong, H. Wang, M. Liu, S. Zhou, Z. Hou, X. Liu, “ECG signal enhancement based on improved denoising auto-encoder”, *Engineering Applications of Artificial Intelligence*, 52, 194-202, 2016.

- [72] S.S.Mehta, N.S Lingayat, "Detection of QRS complexes in electrocardiogram using support vector machine", *J. Med. Eng. Technol.*, 32(3), 206-15, 2008.
- [73] K.Antczak, "Deep recurrent neural networks for ECG signal denoising", arXiv:1807.11551, 2018
- [74] Berkaya, S. K., Uysal, A. K., Gunal, E. S., Ergin, S., Gunal, S., & Gulmezoglu, M. B. (2018). A survey on ECG analysis. *Biomedical Signal Processing and Control*, 43, 216-235.
- [75] P. Langley, E.J. Bowers, A. Murray, Principal component analysis as a tool for analyzing beat-to-beat changes in ECG features: application to ECG-derived respiration, *IEEE Trans. Biomed. Eng.* 57 (2010) 821–829.
- [76] F. Sufi, I. Khalil, A.N. Mahmood, A clustering based system for instant detection of cardiac abnormalities from compressed ECG, *Expert Syst. Appl.* 38 (2011) 4705–4713.
- [77] Jaiswal, A. K., & Banka, H. (2018). Epileptic seizure detection in EEG signal using machine learning techniques. *Australasian physical & engineering sciences in medicine*, 41, 81-94.
- [78] San-Segundo, R., Gil-Martín, M., D'Haro-Enríquez, L. F., & Pardo, J. M. (2019). Classification of epileptic EEG recordings using signal transforms and convolutional neural networks. *Computers in biology and medicine*, 109, 148-158.
- [79] Abdulhay, E., Elamaran, V., Chandrasekar, M., Balaji, V. S., & Narasimhan, K. (2020). Automated diagnosis of epilepsy from EEG signals using ensemble learning approach. *Pattern Recognition Letters*, 139, 174-181.
- [80] Thara, D. K., PremaSudha, B. G., & Xiong, F. (2019). Auto-detection of epileptic seizure events using deep neural network with different feature scaling techniques. *Pattern Recognition Letters*, 128, 544-550.
- [81] Lehnertz, K. (2008). Epilepsy and nonlinear dynamics. *Journal of biological physics*, 34, 253-266.
- [82] Das, K., Daschakladar, D., Roy, P. P., Chatterjee, A., & Saha, S. P. (2020). Epileptic seizure prediction by the detection of seizure waveform from the pre-ictal phase of EEG signal. *Biomedical Signal Processing and Control*, 57, 101720.
- [83] Newson JJ, Thiagarajan TC. 2018. EEG frequency bands in psychiatric disorders: a review of resting state studies. *Front Hum Neurosci*.
- [84] Ramos-Aguilar, R., Olvera-López, J. A., Olmos-Pineda, I., & Sánchez-Urrieta, S. (2020). Feature extraction from EEG spectrograms for epileptic seizure detection. *Pattern Recognition Letters*, 133, 202-209.
- [85] Acharya, U. R., Hagiwara, Y., Deshpande, S. N., Suren, S., Koh, J. E. W., Oh, S. L., ... & Lim, C. M. (2019). Characterization of focal EEG signals: a review. *Future Generation Computer Systems*, 91, 290-299.
- [86] Hancer, E., & Subasi, A. (2023). EEG-based emotion recognition using dual tree complex wavelet transform and random subspace ensemble classifier. *Computer methods in biomechanics and biomedical engineering*, 26(14), 1772-1784.
- [87] Shahbakhti, M., Beiramvand, M., Eigirdas, T., Solé-Casals, J., Wierzchon, M., Broniec-Wojcik, A., ... & Marozas, V. (2022). Discrimination of wakefulness from sleep stage I using nonlinear features of a single frontal EEG channel. *IEEE Sensors Journal*, 22(7), 6975-6984.

- [88]Shamsi, E., Ahmadi-Pajouh, M. A., & Ala, T. S. (2021). Higuchi fractal dimension: An efficient approach to detection of brain entrainment to theta binaural beats. *Biomedical signal processing and control*, 68, 102580.
- [89]Yuan Q, Zhou W, Liu Y, Wang J. 2012. Epileptic seizure detection with linear and nonlinear features. *Epilepsy Behav.* 24(4):415–421.
- [90]Wu, S. D., Wu, C. W., Lee, K. Y., & Lin, S. G. (2013). Modified multiscale entropy for short-term time series analysis. *Physica A: Statistical Mechanics and its Applications*, 392(23), 5865-5873.
- [91]Safi, M. S., & Safi, S. M. M. (2021). Early detection of Alzheimer’s disease from EEG signals using Hjorth parameters. *Biomedical Signal Processing and Control*, 65, 102338.
- [92]Acharya, U. R., Sree, S. V., Swapna, G., Martis, R. J., & Suri, J. S. (2013). Automated EEG analysis of epilepsy: a review. *Knowledge-Based Systems*, 45, 147-165.
- [93]Boonyakitanont, P., Lek-Uthai, A., Chomtho, K., & Songsiri, J. (2020). A review of feature extraction and performance evaluation in epileptic seizure detection using EEG. *Biomedical Signal Processing and Control*, 57, 101702.
- [94]Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adeli, H. (2018). Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in biology and medicine*, 100, 270-278.
- [95]Guo, L., Rivero, D., & Pazos, A. (2010). Epileptic seizure detection using multiwavelet transform based approximate entropy and artificial neural networks. *Journal of neuroscience methods*, 193(1), 156-163.
- [96]Tzallas, A. T., Tsipouras, M. G., Tsalikakis, D. G., Karvounis, E. C., Astrakas, L., Konitsiotis, S., & Tzaphlidou, M. (2012). Automated epileptic seizure detection methods: a review study. *Epilepsy-histological, electroencephalographic and psychological aspects*, 75-98.
- [97]Chakrabarti, S., Swetapadma, A., Ranjan, A., & Pattnaik, P. K. (2020). Time domain implementation of pediatric epileptic seizure detection system for enhancing the performance of detection and easy monitoring of pediatric patients. *Biomedical Signal Processing and Control*, 59, 101930.
- [98] Kaleem, M., Guergachi, A., & Krishnan, S. (2018). Patient-specific seizure detection in long-term EEG using wavelet decomposition. *Biomedical Signal Processing and Control*, 46, 157-165.
- [99] Mardini, W., Yassein, M. M. B., Al-Rawashdeh, R., Aljawarneh, S., Khamayseh, Y., & Meqdadi, O. (2020). Enhanced detection of epileptic seizure using EEG signals in combination with machine learning classifiers. *IEEE Access*, 8, 24046-24055.
- [100] Ocak, H. (2009). Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Expert Systems with Applications*, 36(2), 2027-2036.
- [101] Li, Y., Zhang, X. R., Zhang, B., Lei, M. Y., Cui, W. G., & Guo, Y. Z. (2019). A channel-projection mixed-scale convolutional neural network for motor imagery EEG decoding. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(6), 1170-1180.
- [102] Lih, O. S., Jahmunah, V., Palmer, E. E., Barua, P. D., Dogan, S., Tuncer, T., ... & Acharya, U. R. (2023). EpilepsyNet: Novel automated detection of epilepsy using transformer model with EEG signals from 121 patient population. *Computers in Biology and Medicine*, 164, 107312.
- [103] Djemili, R., & Zamouche, M. (2023). An efficient deep learning-based approach for human activity recognition using smartphone inertial sensors. *International Journal of Computers and Applications*, 45(4), 323-336.

- [104] Emeksiz, C., & Tan, M. (2022). Multi-step wind speed forecasting and Hurst analysis using novel hybrid secondary decomposition approach. *Energy*, 238, 121764.
- [105] Jiang, D., Lu, Y. N., Yu, M. A., & Yuanyuan, W. A. N. G. (2019). Robust sleep stage classification with single-channel EEG signals using multimodal decomposition and HMM-based refinement. *Expert Systems with Applications*, 121, 188-203.
- [106] Humeau-Heurtier, A. (2015). The multiscale entropy algorithm and its variants: A review. *Entropy*, 17(5), 3110-3123.
- [107] Kantelhardt, J. W. (2002). Multifractal detrended fluctuation analysis of nonstationary time series. *Physica*, 316, 81-91.
- [108] Higuchi, T. (1988). Approach to an irregular time series on the basis of the fractal theory. *Physica D: Nonlinear Phenomena*, 31(2), 277-283.
- [109] Petrosian, A. (1995, June). Kolmogorov complexity of finite sequences and recognition of different preictal EEG patterns. In *Proceedings eighth IEEE symposium on computer-based medical systems* (pp. 212-217). IEEE.
- [110] Wen, T., & Cheong, K. H. (2021). The fractal dimension of complex networks: A review. *Information Fusion*, 73, 87-102.
- [111] Birjandtalab, J., Heydarzadeh, M., & Nourani, M. (2017, August). Automated EEG-based epileptic seizure detection using deep neural networks. In *2017 IEEE International Conference on Healthcare Informatics (ICHI)* (pp. 552-555). IEEE.
- [112] Xu, G., Ren, T., Chen, Y., & Che, W. (2020). A one-dimensional CNN-LSTM model for epileptic seizure recognition using EEG signal analysis. *Frontiers in neuroscience*, 14, 578126.
- [113] Djemili, R. (2020). Analysis of statistical coefficients and autoregressive parameters over intrinsic mode functions (IMFs) for epileptic seizure detection. *Biomedical Engineering/Biomedizinische Technik*, 65(6), 693-704.
- [114] Qiu, X., Yan, F., & Liu, H. (2023). A difference attention ResNet-LSTM network for epileptic seizure detection using EEG signal. *Biomedical Signal Processing and Control*, 83, 104652.
- [115] Tawfik, N. S., Youssef, S. M., & Kholief, M. (2016). A hybrid automated detection of epileptic seizures in EEG records. *Computers & Electrical Engineering*, 53, 177-190.
- [116] Djemili, R., Bourouba, H., & Korba, M. A. (2016). Application of empirical mode decomposition and artificial neural network for the classification of normal and epileptic EEG signals. *Biocybernetics and Biomedical Engineering*, 36(1), 285-291.
- [117] Nicolaou, N., & Georgiou, J. (2012). Detection of epileptic electroencephalogram based on permutation entropy and support vector machines. *Expert Systems with Applications*, 39(1), 202-209.
- [118] Kumar, Y., Dewal, M. L., & Anand, R. S. (2014). Epileptic seizure detection using DWT based fuzzy approximate entropy and support vector machine. *Neurocomputing*, 133, 271-279.
- [119] Jaiswal AK, Banka H. 2018. Epileptic seizure detection in EEG signal using machine learning techniques. *Australas Phys Eng Sci Med*. 41(1):81-94.
- [120] Zeng M, Zhao CY, Meng QH. 2019. Detecting seizures from EEG signals using the entropy of visibility heights of hierarchical neighbors. *IEEE Access*. 7:7889-7896.

- [121] Liu Y, Lin Y, Jia Z, Ma Y, Wang J. 2020. Representation based on ordinal patterns for seizure detection in EEG signals. *Comput Biol Med.* 126:104033.
- [122] Peng H, Lei C, Zheng S, Zhao C, Wu C, Sun J, Hu B. 2021. Automatic epileptic seizure detection via Stein kernel- based sparse representation. *Comput Biol Med.* 132: 104338.
- [123] Zhang S, Liu G, Xiao R, Cui W, Cai J, Hu X, et al. 2022. A combination of statistical parameters for epileptic seizure detection and classification using VMD and NLTWSVM. *Biocyber Biomed Eng.* 42(1):258–272.
- [124] Patidar S, Panigrahi T. 2017. Detection of epileptic seizure using Kraskov entropy applied on tunable-Q wavelet transform of EEG signals. *Biomed Signal Process Control.* 34:74–80.
- [125] Sharma R, Pachori RB. 2015. Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions. *Expert Syst Appl.* 42(3): 1106–1117.
- [126] Joshi V, Pachori RB, Vijesh A. 2014. Classification of ictal and seizure-free EEG signals using fractional linear prediction. *Biomed Signal Process Control.* 9:1–5.
- [127] Benali, R., & Chikh, M. A. (2009, May). Reconnaissance des Extrasystoles Ventriculaires par la Combinaison des Réseaux de Neurones et la Logique Floue. In *CIIA*.
- [128] De Chazal, P., O'Dwyer, M., & Reilly, R. B. (2004). Automatic classification of heartbeats using ECG morphology and heartbeat interval features. *IEEE transactions on biomedical engineering*, 51(7), 1196-1206. [3]H. Al-Nashash, Cardiac arrhythmia classification using neural networks, *Technol. Health Care.* (2000) 363-372.
- [129] Al-Nashash, H. (2000). Cardiac arrhythmia classification using neural networks. *Technology and Health Care*, 8(6), 363-372.
- [130] Lagerholm, M., Peterson, C., Braccini, G., Edenbrandt, L., & Sornmo, L. (2000). Clustering ECG complexes using Hermite functions and self-organizing maps. *IEEE Transactions on Biomedical Engineering*, 47(7), 838-848.
- [131] Moraes, J. C. T. D. B., Seixas, M. O., Vilani, F. N., & Costa, E. V. (2002, September). A real time QRS complex classification method using Mahalanobis distance. In *Computers in Cardiology* (pp. 201-204). IEEE.
- [132] Inan, O. T., Giovangrandi, L., & Kovacs, G. T. (2006). Robust neural-network-based classification of premature ventricular contractions using wavelet transform and timing interval features. *IEEE transactions on Biomedical Engineering*, 53(12), 2507-2515.
- [133] Wieben, O., Afonso, V. X., & Tompkins, W. J. (1999). Classification of premature ventricular complexes using filter bank features, induction of decision trees and a fuzzy rule-based system. *Medical & biological engineering & computing*, 37, 560-565.
- [134] Christov, I., & Bortolan, G. (2004). Ranking of pattern recognition parameters for premature ventricular contractions classification by neural networks. *Physiological Measurement*, 25(5), 1281.
- [135] Morizet-Mahoudeaux P, Moreau C, Moreau D, Quarante JJ (1981) Simple microprocessor based system for on-line ECG arrhythmia analysis. *Med Biol Eng Comput* 19(4):497–500
- [136] Fraden J, Neuman M (1980) QRS wave detection. *Med Biol Eng Comput* 18(2):125–132

- [137] Menrad A (1981) Dual microprocessor system for cardiovascular data acquisition, processing and recording. In: Proceedings of the 1981 IEEE international conference on industrial electronics, control and instrumentation, pp 64–69