

الجمهورية الجزائرية الديمقراطية الشعبية
REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
جامعة أبي بكر بلقايد – تلمسان –
Université Aboubakr Belkaïd – Tlemcen
Faculté de TECHNOLOGIE



THESE

Présentée pour l'obtention du **grade de DOCTORAT EN SCIENCES**

En : Génie Biomédical

Spécialité : Electronique Biomédicale

Par : **Hadj Abdelkader BENGHENIA**

Sujet

**Analyse et traitement des signaux de polysomnographie en
vue de la reconnaissance d'apnées du sommeil**

Soutenue publiquement, le 11 / 06 / 2023 , devant le jury composé de :

Mr. DJEBBARI Abdelghani	Professeur	Univ. Tlemcen	Président
Mr. HADJ SLIMANE Zine-Eddine	Professeur	Univ. Tlemcen	Directeur de Thèse
Mr. ANDRADE Alexandre	Professeur	Univ. Lisbon	Co-directeur de Thèse
Mr. MESSADI Mahammed	Professeur	Univ. Tlemcen	Examineur
Mr. MEGNAFI Hichem	MCA	ESSA. Tlemcen	Examineur
Mr. MALIKI Fouad	MCA	ESSA. Tlemcen	Examineur

Dédicaces

Je dédie ce travail à :

A ma mère et mon père,

A ma femme et ma fille,

A mes frères et ma sœur,

A toute ma famille,

A tous mes amis

A tous mes enseignants a l'université de Tlemcen.

A tous ceux que j'aime

Qu'ils trouvent ici l'expression de toute ma reconnaissance.

Remerciements

Je remercie **Dieu** tout puissant de m'avoir donné le courage et la patience pour bien mener ce travail.

Je tiens à exprimer ma très profonde gratitude à Monsieur Zine-eddine HADJ SLIMANE, professeur à l'université de Tlemcen qui n'a ménagé aucun effort pour me prendre en charge pour la réalisation de ce travail. Sa clairvoyance, sa générosité, sa gentillesse, ses connaissances, le temps qui m'a dispensé, et sa grande disponibilité dont il a fait preuve; m'ont énormément facilité ma tâche.

Je tiens aussi à remercier Monsieur Alexandre ANDRADE professeur à université de Lisboa d'avoir été disponible à toutes mes sollicitations.

J'adresse mes très sincères remerciements à Monsieur, professeur à l'université de Tlemcen et celui qui m'a donné les assises de la recherche scientifique, et aussi pour l'intérêt qu'il a accordé à ce travail en acceptant de le juger et de présider le jury.

Je tiens aussi à remercier les membres du jury qui m'ont fait l'honneur de participer à l'examen de ce travail:

- Mr, Professeur, Université
- Mr, Professeur, Université

Qu'ils trouvent ici toute ma reconnaissance.

Résumé

Le syndrome d'apnées-hypopnées du sommeil (SAHS) est un trouble respiratoire fréquent caractérisé par des pauses respiratoires pendant le sommeil en raison d'une obstruction des voies respiratoires supérieures. Cette maladie est très fréquente et a des conséquences importantes sur la santé qui entraînent une augmentation des taux de mortalité des personnes touchées, si elles ne sont pas diagnostiquées ou traitées correctement. Le test standard pour diagnostiquer cette maladie est la polysomnographie, qui consiste à enregistrer de nombreux signaux pendant une nuit entière dans des unités de sommeil spécialisées sous la supervision de personnel spécialisé. Son principal inconvénient est le prix et les ressources nécessaires pour analyser chaque patient. Cette thèse s'inscrit dans un corpus de travaux qui vise à contribuer au développement d'une méthode alternative de diagnostic basée sur un signal physiologique unique. Plus précisément, l'utilisation d'un signal électrocardiogramme (ECG) et signal électroencéphalogramme (EEG) est suggérée, car malgré le fait que l'apnée du sommeil soit un événement respiratoire, ses effets peuvent être clairement observés dans d'autres systèmes périphériques. Le premier objectif était d'approfondir la caractérisation des processus physiologiques qui sous-tendent l'apnée du sommeil, afin d'extraire des informations importantes des signaux ECG et EEG. Cela nous a permis de concevoir des systèmes d'évaluation de l'apnée du sommeil qui tirent parti du pouvoir discriminant des meilleures caractéristiques. Concrètement, des systèmes ont été développés qui évaluent, d'une part, la présence ou l'absence d'apnée toutes les événements, et d'autre part, la classification des sujets en fonction du nombre de minutes d'apnée qu'ils accordent.

Mots clés:

Syndrome d'apnées-hypopnées du sommeil, Electrocardiogramme, Electroencéphalogramme, Polysomnographie, caractéristique, classification.

Abstract

Sleep apnea-hypopnea syndrome (SAHS) is a common breathing disorder characterized by pauses in breathing during sleep due to upper airway obstruction. This disease is very common and has significant health consequences that lead to increased death rates for those affected, if not diagnosed or treated properly. The standard test for diagnosing this disease is polysomnography, which involves recording numerous signals over an entire night in specialized sleep units under the supervision of specialized personnel. Its main drawback is the price and the resources needed to analyze each patient. This thesis is part of a body of work that aims to contribute to the development of an alternative diagnostic method based on a single physiological signal. Specifically, the uses of an electrocardiogram (ECG) signal and electroencephalogram (EEG) signal is suggested, because despite the facts that sleep apnea is a respiratory event, its effects can be clearly observed in other peripheral systems. The first objective was to deepen the characterization of the physiological processes that underlie sleep apnea, in order to extract important information from ECG and EEG signals. This has allowed us to design sleep apnea assessment systems that take advantage of the discriminating power of the best features. Concretely, systems have been developed which evaluate, on the one hand, the presence or absence of apnea in all events, and on the other hand, classification of subjects according to the number of minutes of apnea that they grant.

Keywords:

Sleep apnea-hypopnea syndrome, Electrocardiogram, Electroencephalogram, Polysomnography, characteristic, classification.

ملخص الأطروحة

متلازمة نقص التنفس أثناء النوم هو اضطراب تنفسي شائع يتميز بتوقف التنفس أثناء النوم بسبب انسداد مجرى الهواء العلوي. هذا المرض شائع جداً وله عواقب صحية كبيرة تؤدي إلى زيادة معدلات الوفيات للمصابين ، إذا لم يتم تشخيصهم أو علاجهم بشكل صحيح. الاختبار القياسي لتشخيص هذا المرض هو تخطيط النوم ، والذي يتضمن تسجيل العديد من الإشارات على مدار ليلة كاملة في وحدات نوم متخصصة تحت إشراف موظفين متخصصين. عيبه الرئيسي هو السعر والموارد اللازمة لتحليل كل الإشارات الفسيولوجية المخصصة لكل مريض. هذه الأطروحة جزء من مجموعة عمل تهدف إلى المساهمة في تطوير طريقة تشخيص بديلة تعتمد على إشارة فسيولوجية واحدة. على وجه التحديد ، يُقترح استخدام إشارة مخطط كهربية القلب (ECG) وإشارة مخطط كهربية الدماغ (EEG) ، لأنه على الرغم من حقيقة أن توقف التنفس أثناء النوم هو حدث تنفسي ، يمكن ملاحظة آثاره بوضوح في الأنظمة الطرفية الأخرى. كان الهدف الأول هو تعميق توصيف العمليات الفسيولوجية التي تكمن وراء توقف التنفس أثناء النوم ، من أجل استخراج معلومات مهمة من إشارات ECG و EEG. وقد سمح لنا ذلك بتصميم أنظمة تقييم توقف التنفس أثناء النوم تستفيد من القوة التمييزية لأفضل الميزات. بشكل ملموس، تم تطوير أنظمة تقييم، من ناحية، وجود أو غياب انقطاع النفس في جميع الأحداث، ومن ناحية أخرى، التصنيف العام للمواضيع وفقاً لعدد دقائق انقطاع النفس التي تمنحها.

الكلمات المفتاحية:

متلازمة نقص التنفس أثناء النوم، مخطط كهربية القلب، مخطط كهربية الدماغ، تخطيط النوم، الخصائص، التصنيف.

LISTE DES FIGURES

LISTE DES TABLEAUX

LISTE DES ABREVIATIONS

INTRODUCTION GENERALE 1

Chapitre 1: Syndrome d'apnées-hypopnées du sommeil et son diagnostic

1.1.Introduction.....	7
1.2.Sommeil.....	7
1.2.1. Notion de sommeil.....	7
1.2.2. Les phases du sommeil.....	8
1.2.2.1.Sommeil non paradoxal.....	9
a) Phase I (Somnolence).....	9
b) Phase II (Sommeil peu profond).....	10
1.2.2.2.Sommeil paradoxal.....	10
1.3.Syndrome d'apnées-hypopnées du sommeil.....	11
1.3.1. Diagnostic du SAHS.....	15
1.3.1.1.Polysomnographie.....	15
1.3.1.2.Critères diagnostiques selon AASM.....	17
1.3.1.3.Systèmes d'autodiagnostic comme alternative à la polysomnographie.....	18
1.3.2. Options de traitement.....	20
1.4.L'électrocardiogramme et l'exploration clinique de SAHS.....	22
1.4.1. L'électrocardiogramme (ECG).....	22
1.4.2. Les ondes enregistrées sur un ECG normal.....	22
1.4.3. Le rythme cardiaque.....	23
1.4.4. L'effet du SAOS sur la variabilité de la fréquence cardiaque (HRV).....	25
1.5.Source du signal EEG.....	26
1.6.Conclusion	27
BIBLIOGRAPHIE.....	28

Chapitre 2: Matériels et méthodes d'analyse des signaux physiologiques

2.1.Introduction.....	33
2.2.Les bases de données.....	33
2.2.1. La base de données « ECG–Apnea ».....	33

2.2.2. La base de données UCD	34
2.3.Prétraitement du signal ECG.....	35
2.3.1. Algorithme Pan & Tompkins.....	35
2.4.Prétraitement du signal EEG.....	36
2.4.1. Filtrage passe haut et passe bas.....	36
2.4.2. Conception de filtre à réponse impulsionnelle finie.....	37
2.5.Les méthodes d'extraction de caractéristiques des signaux HRV.....	38
2.5.1. Transformée en Ondelettes Continue	38
2.5.2. Entropie de dispersion multi-échelle	39
2.6.Les méthodes d'extraction de caractéristiques des signaux EEG.....	42
2.6.1. Transformée empirique en ondelettes.....	42
2.6.2. Représentation temps-fréquence.....	44
2.6.3. Estimation de la densité spectrale de puissance croisée.....	46
2.7.Méthodes de sélection des caractéristiques	46
2.7.1. Test-t de Student.....	46
2.7.2. Test de Wilcoxon.....	47
2.8.Classificateurs.....	47
2.8.1. Classificateur d'arbre de décision (DT).....	47
2.8.2. Classificateur des k plus proches voisins (KNN).....	48
2.8.3. Réseaux de neurones artificiels (MLPNN).....	48
2.8.4. Machine à vecteur de support (SVM).....	49
2.9.Conclusion	50
BIBLIOGRAPHIE.....	51

Chapitre 3: Reconnaissance automatisée du SAHS à l'aide de la transformation en ondelettes continues et de l'entropie de dispersion multi-échelles des signaux ECG

3.1.Introduction.....	54
3.2.Revue de littérature.....	55
3.3.Principe de la méthode.....	57
3.3.1. Prétraitement.....	58
3.3.2. Extraction de bandes de fréquence et caractéristiques non linéaires	59
3.3.3. Sélection de caractéristiques.....	60
3.4.Résultats et discussion.....	67
3.4.1. Résultats.....	67

3.4.2. Discussion.....	75
3.5.Conclusion.....	78
BIBLIOGRAPHIE.....	80

Chapitre 4: Détection automatique du SAHS basée sur EWT et CPSD

4.1.Introduction.....	84
4.2.Revue de littérature.....	86
4.3.Principe de la méthode.....	87
4.3.1. Description de l'algorithme.....	88
4.4.Résultats.....	93
4.5.Discussion.....	102
4.6.Conclusion.....	104
BIBLIOGRAPHIE.....	105
CONCLUSION GENERALE.....	107

Liste des figures

Figure 1.1: Les bienfaits du sommeil.....	8
Figure 1.2: Hypnogramme schématisant l'organisation d'une nuit de sommeil chez l'adulte.....	11
Figure 1.3: Hypnogramme d'une personne normal	11
Figure 1.4: Indice d'apnée-hypopnée (IAH)	12
Figure 1.5: Muscles des voies respiratoires supérieures lors d'une: (a) respiration normale, (b) hypopnée et (c) apnée obstructive du sommeil.....	12
Figure.1.6: Représentation d'un polysomnogramme d'une personne atteinte apnée du sommeil obstructive	13
Figure.1.7: Représentation d'un polysomnogramme d'une personne atteinte apnée du sommeil centrale	14
Figure 1.8: Exemples de certains capteurs de polysomnographie et comment ils sont attachés au corps.....	16
Figure.1.9: ECG normal.....	23
Figure 1.10: L'activité électrique du cœur.....	24
Figure.1.11: Positionnement et identification standards des électrodes EEG selon le système international 10-20.....	27
Fig.2.1 : Les cinq opérations de l'algorithme de Pan-Tompkins.....	35
Figure.2.2: Méthode de transformation de Hilbert pour la représentation temps-fréquence.....	45
Figure.2.3: Exemple d'architecture de réseau perceptron multicouche (6 entrées, une couche cachée à 8 éléments et 4 sorties).....	49
Figure.3.1: Schéma fonctionnel de la méthode proposée pour la détection du syndrome d'apnée-hypopnée du sommeil (SAHS)	58
Figure.3.2: Segments HRV de courte durée de 5 minutes (haut). Scalogramme de puissance couleur 3D de HRV (bas). La couleur représente le scalogramme de puissance. (a, d) épisode normal ; (b, e) épisode d'hypopnée ; (c, f) épisode d'AOS...	60
Figure.3.3: Le signal de sous-bande VLF reconstruit par ICWT (à gauche). Signal de sous-bande LF reconstruit par ICWT (au centre). Signal de sous-bande HF reconstruit par ICWT (à droite). (a, d et g) appartient aux épisodes normaux ; (b, e et h) appartient aux épisodes d'hypopnée ; (c, f et i) appartient aux épisodes d'AOS.....	61

Figure.3.4 : Les courbes d'entropie de dispersion multi-échelle calculées et les graphiques à barres pour Normal & OSA (A, D), Normal & Hypopnea (B, E) et OSA & Hypopnea (C, F), qui ont été obtenus à partir du signal (VLF).....	61
Figure.3.5 : Les courbes d'entropie de dispersion multi-échelle calculées et les graphiques à barres pour Normal & OSA (A, D), Normal & Hypopnea (B, E) et OSA & Hypopnea (C, F), qui ont été obtenus à partir du signal (LF).....	62
Figure.3.6 : Les courbes d'entropie de dispersion multi-échelle calculées et les graphiques à barres pour Normal & OSA (A, D), Normal & Hypopnea (B, E) et OSA & Hypopnea (C, F), qui ont été obtenus à partir du signal (HF).....	62
Figure.3.7 : Les courbes d'entropie de dispersion multi-échelle calculées et les graphiques à barres pour Normal & OSA (A, D), Normal & Hypopnea (B, E) et OSA & Hypopnea (C, F), qui ont été obtenus à partir du signal (TP).....	63
Figure.3.8 : Statistiques des caractéristiques de MDE pour Normal, OSA et hypopnée groupées par échelles de temps courtes (1 à 5), moyennes (6 à 10) longues (11 à 20). (A, E et I) pour $DispEn_{LF/HF}$; (B, F et J) pour $DispEn_{pVLF}$; (C, G et K) pour $DispEn_{pLF}$; (D, H et L) pour $DispEn_{pHF}$	63
Figure.3.9 : Performance du système proposé utilisant divers classificateurs et sous la méthode de classification (un contre un).....	72
Figure.3.10 : Performance du système proposé utilisant divers classificateurs et sous la méthode de classification (un contre tous).....	73
Figure.3.11 : Le taux de vrais positifs (TPR) et le taux de faux positifs (FPR) de différents classificateurs: (A) DT ; (B) SVM ; (C) KNN.....	74
Figure.4.1: Représentation graphique de l'approche proposée pour identifié et classifie l'apnée du sommeil.....	88
Figure.4.2: Tracé de la série temporelle « C3A2 » de signal EEG du sujet normal: (a) Signal EEG bruité (b) Signal EEG filtré.....	89
Figure.4.3: Tracé de la série temporelle « C4A1 » de signal EEG du sujet normal: (a) Signal EEG bruité (b) Signal EEG filtré.....	89
Figure.4.4: Tracé de la série chronologique « C3A2 » de signal EEG du sujet d'apnée: (a) Signal EEG bruité (b) Signal EEG filtré.....	90
Figure.4.5: Tracé de la série chronologique « C4A1 » du signal EEG du sujet d'apnée: (a) Signal EEG bruité (b) Signal EEG filtré.....	90
Figure.4.6: (a) des limites détectées (en rouge) et du spectre FFT (en noir). (b)	91

banque de filtres (FB1-FB10) générée à partir du signal EEG "C3A2" du sujet normal.....	
Figure.4.7: (a) des limites détectées (en rouge) et du spectre FFT (en noir) (b) banque de filtres (FB1-FB10) générée à partir du signal EEG "C4A1" du sujet normal.....	92
Figure.4.8: (a) des limites détectées (en rouge) et du spectre FFT (en noir). (b) banque de filtres (FB1-FB10) générée à partir du signal EEG "C3A2" du sujet d'apnée.....	92
Figure.4.9. (a) des limites détectées (en rouge) et du spectre FFT (en noir). (b) banque de filtres (FB1-FB10) générée à partir du signal EEG "C4A1" du sujet d'apnée.....	93
Figure.4.10: Signaux de sous-bande IMF1-IMF10 extraits à l'aide de la décomposition de l'échelle-temps basée sur TOE du signal EEG "C3A2" du sujet normal.....	96
Figure.4.11: Signaux de sous-bande IMF1-IMF10 extraits à l'aide de la décomposition de l'échelle-temps basée sur TOE du signal EEG "C4A1" du sujet normal.....	96
Figure.4.12: Signaux de sous-bande IMF1-IMF10 extraits à l'aide de la décomposition de l'échelle-temps basée sur TOE du signal EEG "C3A2" du sujet d'apnée.....	97
Figure.4.13: Signaux de sous-bande IMF1-IMF10 extraits à l'aide de la décomposition de l'échelle-temps basée sur TOE du signal EEG "C4A1" du sujet d'apnée.....	97
Figure.4.14: Densité spectrale de puissance croisée (CPSD) des sous-bandes de C3A2 et C4A1 du signal EEG du sujet normal.....	98
Figure.4.15: Densité spectrale de puissance croisée (CPSD) des sous-bandes de C3A2 et C4A1 du signal EEG du sujet d'apnée.....	98
Figure.4.16: Boîte à moustaches des caractéristiques significatives du domaine fréquentiel extraites des quatre premières sous-bandes de l'apnée et de la classe normale.....	99
Figure.4.17: Courbes de caractéristique de fonctionnement du récepteur (ROC) et matrices de confusion des quatre classificateurs classés de gauche à droite : KNN, SVM, DT et MLPNN respectivement.....	101

Liste des tableaux

Tableau.1.1: Modalités de diagnostic des troubles respiratoires du sommeil..... 19

Tableau.2.1: Description de la base de données « Apnea-ECG »..... 34

Tableau.2.2: Propriétés physiologiques des sujets dans la base de données UCD..... 35

Tableau.3.1: Résumé des résultats des recherches antérieures..... 57

Tableau.3.2: Distribution de la plage (moyenne \pm écart type) des courtes, moyennes et longues échelles de temps des caractéristiques MDE extraites des signaux des sous-bandes TP, HF, LF et VLF à l'aide de la technique CWT suivie de la technique ICWT pour les épisodes normaux et OSA..... 64

Tableau.3.3: Distribution de la plage (moyenne \pm écart type) des courtes, moyennes et longues échelles de temps des caractéristiques MDE extraites des signaux des sous-bandes TP, HF, LF et VLF à l'aide de la technique CWT suivie de la technique ICWT pour les épisodes normaux et hypopnée..... 65

Tableau.3.4: Distribution de la plage (moyenne \pm écart type) des courtes, moyennes et longues échelles de temps des caractéristiques MDE extraites des signaux des sous-bandes TP, HF, LF et VLF à l'aide de la technique CWT suivie de la technique ICWT pour les épisodes AOS et hypopnée..... 66

Tableau.3.5: Performances du système proposé utilisant classificateur DT et sous la méthode de classification (un contre un)..... 70

Tableau.3.6: Performances du système proposé utilisant classificateur SVM et sous la méthode de classification (un contre un)..... 71

Tableau.3.7: Performances du système proposé utilisant classificateur KNN et sous la méthode de classification (un contre un)..... 71

Tableau.3.8: Performances du système proposé utilisant classificateur DT et sous la méthode de classification (un contre tous)..... 72

Tableau.3.9: Performances du système proposé utilisant classificateur SVM et sous la méthode de classification (un contre tous)..... 73

Tableau.3.10: Performances du système proposé utilisant classificateur KNN et sous la méthode de classification (un contre tous)..... 74

Tableau.4.1: Résumé des résultats des recherches antérieures.....	87
Tableau.4.2: Brève description des caractéristiques extraite.....	99
Tableau.4.3: Valeurs p pour les caractéristiques extraites des signaux EEG des deux classes normal et SAHS à l'aide d'un test de Wilcoxon.....	100
Table.4.4: Résumé des performances des différents modèles de classification.....	101

Liste des abréviations

AASM	American Academy of Sleep Medicine, Académie américaine de médecine du sommeil
AHI	Apnea-Hypopnea Index
AOS	Apnée obstructive du sommeil
AUC	Area Under Curve, aire sous la courbe ROC
CPSD	Cross power spectral density, densité spectrale de puissance croisée
CSA	Central Sleep Apnea, apnée centrale du sommeil
CWT	Continuous wavelet transform, transformée continue en ondelettes
DT	Decision tree, arbre de décision
ECG	Électrocardiogramme
EDR	ECG-Derived Respiratory, un signal respiratoire dérivé de l'ECG
EEG	Électroencéphalogramme
EWT	Empirical Wavelet Transform, transformée empirique en ondelettes
FFT	Fast fourier transform, Transformée de Fourier Rapide
FIR	Filtre à réponse impulsionnelle finie
HF	High Frequency, Haute fréquence
HRV	Heart rate variability
IAH	Indice d'apnée-hypopnée
ICWT	Inverse Continuous Wavelet Transform, transformée en ondelettes continue inverse
IMF	Intrinsic mode function, fonction mode intrinsèque
KNN	K-nearest neighbors, K-plus proches voisins
LF	Low Frequency, basse fréquence
MDE	Multiscale dispersion entropy, entropie de dispersion multi-échelle
MLPNN	Multiple-layer perceptron neural network, Réseau de neurones perceptrons multicouches
MONR	Mouvement oculaire non rapide
MOR	mouvement oculaire rapide

MSA	Mixed sleep apnea, apnée mixte du sommeil
OSA	Obstructive sleep apnea
PSG	Polysomnographie
RBF	Radial Basis Function, Fonction de base radiale
RII	Filtre à réponse impulsionnelle infinie
SAHS	sleep apnea-hypopnea syndrome, syndrome d'apnée-hypopnée du sommeil
SVM	Support vector machine, machine à vecteurs de support
VFC	Variabilité de la fréquence cardiaque
VLF	Very Low Frequency, très basse fréquence

Introduction générale

Le syndrome d'apnées-hypopnées du sommeil (SAHS) est un trouble respiratoire courant caractérisé par des pauses respiratoires (apnée) en raison d'une obstruction des voies respiratoires ou une diminution du débit respiratoire (hypopnées) pendant le sommeil. Sa prévalence est élevée dans la population générale, 4 % chez les hommes et 2 % chez les femmes [1]. Ces dernières années, de nombreuses études ont montré qu'il s'agit d'un problème cliniquement significatif en raison des conséquences graves qu'il a sur la santé, de la somnolence diurne excessive, de l'irritabilité, des ronflements, de la prise de poids, des problèmes de mémoire et de la diminution de la capacité de concentration et de l'apprentissage, à des problèmes cardiovasculaires importants, tels que l'hypertension et les accidents vasculaires cérébraux, la mort subite ou des altérations du métabolisme du glucose [2-4]. Toutes ces conséquences conduisent, à terme, à une augmentation du taux de mortalité des personnes atteintes si elle n'est pas diagnostiquée, ou mal traitée. Du fait à la fois de sa forte prévalence et de ses graves conséquences sur la santé, l'apnée du sommeil est aujourd'hui considérée comme un problème de santé publique.

En raison des conséquences importantes du SAHS sur la santé, un diagnostic précoce est fortement recommandé afin que les patients puissent accéder à un traitement adéquat et efficace limitant au maximum les effets à long terme. Traditionnellement, il y a eu deux façons de diagnostiquer le SAHS. Le premier est basé sur des modèles de prédiction clinique, qui utilisent l'histoire du patient, ainsi que d'autres tests d'analyse de base. Les plus grands avantages de cette méthode sont son faible coût, sa couverture universelle et sa haute spécificité, car elle exclut correctement les patients qui ne souffrent pas de SAHS. L'autre méthode est la polysomnographie, qui est le test standard permettant d'obtenir des résultats concluants sur le diagnostic de cette maladie, tant en termes de détection que de quantification de sa gravité chez chaque patient.

En polysomnographie, de nombreuses variables liées à la respiration, ainsi que des variables neurologiques, sont enregistrées. Cet enregistrement est effectué pendant une nuit entière dans des unités spécialisées du sommeil sous la supervision de personnel spécialisé dans le but de détecter les apnées. Les inconvénients majeurs de cette méthode sont les suivants : son coût élevé pour le système de santé, la durée du processus, les ressources nécessaires et les désagréments causés aux patients [5].

Dans le but de corriger tous les problèmes liés à la polysomnographie, de nombreuses expériences ont été menées au cours des 20 dernières années, dont le but a été de développer un système de diagnostic automatique simplifié basé sur un plus petit nombre de signaux [6]. Pour cela, il a été pris en compte que malgré le fait que l'apnée du sommeil soit un événement respiratoire, ses effets peuvent être clairement observés dans d'autres systèmes périphériques. Pour cette raison, il est possible de détecter les apnées sur la base de caractéristiques extraites du signal électrocardiogramme et l'électroencéphalogramme. Ces méthodes sont simples, non invasives, peu coûteuses et particulièrement adaptées au dépistage initial, contribuant à réduire les listes d'attente pour accéder à la polysomnographie.

Les signaux biomédicaux, tels que électrocardiogramme (ECG), électroencéphalogramme (EEG) sont particulièrement adaptés à cette fin, en raison des conséquences que les apnées produisent sur les systèmes cardiovasculaire et cardiorespiratoire, et sur le système nerveux autonome (SNA) [7]. Concernant le signal ECG, les apnées provoquent une augmentation de la variabilité de la fréquence cardiaque (HRV), qui se traduit par une série de périodicités détectables par analyse numérique du signal ECG. Les altérations du signal de l'électroencéphalogramme (EEG) sont l'un des changements physiologiques qui se produisent pendant l'apnée et peuvent être utilisées pour diagnostiquer et surveiller les événements d'apnée du sommeil.

Le SAHS étant considéré comme un problème de santé publique, depuis 20 ans différentes études ont été menées dans ce cadre avec deux objectifs fondamentaux : le diagnostic automatique de l'apnée du sommeil (classification par patient), et la détection en temps réel d'événements apnéiques pendant le sommeil (classification ou quantification par segment).

Les différentes méthodes proposées diffèrent par le type de signal qu'elles analysent et les informations qu'elles en extraient. Certains d'entre eux étudient le son produit par le patient [8], car l'apnée du sommeil s'accompagne souvent de ronflements sévères. D'autres étudient le flux d'air et les signaux des mouvements thoraciques et abdominaux [9].

Cependant, la plupart des études incluent la détection du SAHS basée sur des caractéristiques extraites de l'ECG à une seule dérivation et du signal EEG. Dans quelques cas, ces deux derniers signaux ont été combinés.

Cette thèse, encadrée dans un contexte multidisciplinaire, a essentiellement trois objectifs globaux. Tout d'abord, approfondir la caractérisation des processus physiologiques sous-jacents au SAHS à l'aide de techniques de traitement numérique du signal. Deuxièmement, contribuer à la simplification des méthodes de diagnostic utilisées pour cette maladie. Et enfin, appliquer la détection des événements apnéiques dans le temps pour améliorer la prise en charge des patients, et permettant de prendre des mesures correctives qui réduisent le nombre d'apnées.

Concernant le premier objectif, il faut tenir compte du fait que, malgré tout le travail qui a été fait sur l'analyse des signaux ECG et EEG dans le cadre de la détection de l'apnée du sommeil, il n'existe toujours pas de modèle défini décrivant la dynamique complexe de les systèmes cardiovasculaire, système nerveux autonome et respiratoire en cas d'apnée. C'est la raison pour laquelle nous considérons qu'il y a amplement de place pour approfondir la caractérisation des processus physiologiques associés à cette pathologie, et pour explorer de nouvelles variables qui nous permettent d'extraire autant d'informations que possible des deux signaux.

Concernant les deux autres objectifs, nous partons du principe que les signaux ECG et EEG contiennent des informations utiles qui pourraient être utilisées à des fins de diagnostic et pour la détection des épisodes apnéiques.

Les objectifs spécifiques seraient les suivants :

- Approfondir la caractérisation de la régulation cardiovasculaire qui se produit dans l'apnée du sommeil en étudiant différentes techniques d'extraction des caractéristiques du signal ECG, puisque l'inclusion de variables de nature différente peut contribuer à une meilleure compréhension du processus physiologique.
- Extraire des informations significatives du signal EEG afin d'évaluer sa capacité à faire la distinction entre les événements apnéiques et non apnéiques.
- Évaluer les systèmes du point de vue de l'identification et de classification globale des patients.

Au cours de l'élaboration de cette thèse, une série de résultats ont été obtenus, dont une partie a été publiée dans une revue scientifique.

Dans les travaux rapportés dans [10], un système de caractérisation de l'apnée du sommeil et de classification des événements apnéiques basé sur un processus de sélection des

caractéristiques de la variabilité de la fréquence cardiaque a été introduit. Le but ultime était d'approfondir la caractérisation du système sous-jacent au SAHS du point de vue de la fréquence cardiaque. À cette fin, des variables linéaires et non linéaires ont été combinées, y compris la transformée en ondelette continue (Continuous wavelet transform, CWT) et Entropie de dispersion multi-échelle (Multiscale Dispersion Entropy, MSE). La classification des épisodes apnéiques a été réalisée à l'aide de classificateurs basés sur les k plus proches voisins (k-nearest neighbors, KNN), d'arbre de décision (Decision Tree, DT) et Machine à vecteur support (Support-vector machine, SVM). Deux bases de données ont été utilisées, « Apnea-ECG », et « UCD-Dataset ». Les résultats ont amélioré ceux obtenus dans les travaux précédents avec un nombre considérablement réduit de caractéristiques. Le fait le plus remarquable est que les caractéristiques sélectionnées, qui sont celles qui décrivent le mieux les processus physiologiques associés à l'apnée du sommeil, étaient communes aux deux bases de données. Cela indique que les conclusions obtenues étaient potentiellement généralisables.

Dans la contribution suivante, la même base de données a été utilisée que dans les travaux précédents, mais cette fois deux canaux de signal EEG ont été utilisés, à savoir C3A2 et C4A1. Dans le présent travail, la classification automatique de SAHS est effectuée en analysant les signaux EEG (C3A2 et C4A1) en dix sous-bandes par la transformée en ondelettes empirique (Empirical wavelet transform, EWT), et en extrayant les caractéristiques de fréquence à l'aide de l'algorithme de densité spectrale de puissance croisée (Cross power spectral density, CPSD). Les classificateurs introduits à cette occasion étaient : KNN, SVM, DT et Réseau de neurones perceptrons multicouches (Multiple-layer perceptron neural network, MLPNN), et des résultats très similaires ont été obtenus dans les deux premiers classificateurs.

Cette thèse est structurée en quatre chapitres dont le contenu est présenté ci-dessous.

Le chapitre 1 introduit la pathologie qui forme l'axe central de la thèse, le syndrome d'apnées-hypopnées du sommeil. Plus précisément, il décrit comment les épisodes apnéiques affectent les deux signaux ECG et EEG. Enfin, les procédures traditionnelles de diagnostic de cette maladie sont analysées et des méthodes alternatives de diagnostic basées sur l'analyse automatique des signaux physiologiques sont proposées.

Le chapitre 2 est consacré à la description des matériels et méthodes communs aux deux travaux qui sont présentés dans les chapitres suivants (chapitres 3 et 4). En particulier, les

bases de données utilisées, le prétraitement appliqué aux signaux ECG et EEG, les techniques d'extraction de caractéristiques utilisées pour les deux signaux, les classificateurs et l'algorithme de sélection des caractéristiques sont présentés.

Les chapitres 3 et 4 contiennent les études menées dans cette thèse. Chacun des chapitres comporte une introduction, dans laquelle l'objet d'analyse est décrit, une section sur les méthodes et les matériaux, dans laquelle les enjeux spécifiques de chacun des travaux sont détaillés, une section sur les résultats et une section de discussion.

Enfin, la dernière étape concerne les conclusions et les orientations futures. Le document se termine par une bibliographie.

BIBLIOGRAPHIE

- [1] Shepertycky, M. R., Banno, K., & Kryger, M. H. (2005). Differences between men and women in the clinical presentation of patients diagnosed with obstructive sleep apnea syndrome. *Sleep*, 28(3), 309-314.
- [2] Punjabi, N. M. (2008). The epidemiology of adult obstructive sleep apnea. *Proceedings of the American Thoracic Society*, 5(2), 136-143.
- [3] Punjabi, N. M., & Beamer, B. A. (2009). Alterations in glucose disposal in sleep-disordered breathing. *American journal of respiratory and critical care medicine*, 179(3), 235-240.
- [4] Peppard, P. E., Young, T., Palta, M., & Skatrud, J. (2000). Prospective study of the association between sleep-disordered breathing and hypertension. *New England Journal of Medicine*, 342(19), 1378-1384.
- [5] Ríos, S. A., & Erazo, L. (2016). An automatic apnea screening algorithm for children. *Expert Systems with Applications*, 48, 42-54.
- [6] Heneghan, C., Chua, C. P., Garvey, J. F., De Chazal, P., Shouldice, R., Boyle, P., & McNicholas, W. T. (2008). A portable automated assessment tool for sleep apnea using a combined Holter-oximeter. *Sleep*, 31(10), 1432-1439.
- [7] Akşahin, M. F., Erdamar, A., Işık, A., & Karaduman, A. (2017, May). Sleep apnea detection using with EEG, ECG and respiratory signals. In *2017 25th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- [8] Penzel, T., & Sabil, A. (2017). The use of tracheal sounds for the diagnosis of sleep apnoea. *Breathe*, 13(2), e37-e45.
- [9] Maali, Y., & Al-Jumaily, A. (2013). Multi neural networks investigation based sleep apnea prediction. *Procedia Computer Science*, 24, 97-102.
- [10] Benghenia, H. A., Zine-Eddine, H. S., & Alexandre, A. (2022). Automated Recognition of Sleep Apnea-Hypopnea Syndrome Using Continuous Wavelet Transform-Based Multiscale Dispersion Entropy of Single-Lead ECG Signal. *Traitement du Signal*, 39(1).

Chapitre 1

Syndrome d'apnées-hypopnées du sommeil et son diagnostic

1.1. Introduction

Un sommeil sain est un mécanisme essentiel pour maintenir la santé mentale et physique. Le syndrome d'apnées et d'hypopnées du sommeil (SAHS) est un trouble du sommeil courant caractérisé par un arrêt ou une diminution anormale de la respiration pendant le sommeil. Ce chapitre comprend des définitions et des généralités liées au sommeil ainsi que ses différentes phases. Nous présenterons également le SAHS en évoquant sa prévalence, ses conséquences sur la santé des patients, ainsi qu'une revue des techniques actuellement utilisées dans le diagnostic. A la fin du chapitre, nous exposerons l'effet du SAHS sur la variabilité de la fréquence cardiaque.

1.2. Sommeil

1.2.1. Notion de sommeil

Le sommeil est un état comportemental réversible, accompagné d'une déconnexion de l'état de perception ; un état dynamique où des groupes de neurones sont encore actifs et jouent un rôle différent de celui de l'éveil. Ce rôle consiste à consolider les différentes formes de mémoire, réguler la température corporelle et la fonction de certains neurotransmetteurs, stocker l'énergie et maintenir l'immunocompétence (Voir figure 1.1) [1]. Nous passons environ un tiers de notre vie à dormir.

Pendant le sommeil, il y a une diminution de la conscience et de la réactivité aux stimuli externes. C'est un processus réversible (ce qui le différencie des autres états pathologiques comme la stupeur ou le coma). Il est associé à l'immobilité et au relâchement musculaire. Il se produit avec une périodicité circadienne quotidienne. De ce fait, une posture stéréotypée est acquise et son absence entraîne différentes altérations comportementales et physiologiques [1].

Il existe une relation étroite entre les processus du sommeil et l'état général de la santé physique et psychologique d'une personne. La privation chronique de sommeil est directement liée au stress émotionnel et physique, à l'anxiété, au risque cardiovasculaire, au diabète et à l'obésité [2]. Ainsi, le développement de stratégies de prévention et d'intervention qui réduisent les troubles du sommeil conduiront à une meilleure qualité de vie.

Chaque personne a besoin d'une durée de sommeil spécifique, qui dépendra, entre autres, de l'âge, de l'état de santé, du contexte culturel ou des obligations socioprofessionnelles, c'est-à-dire pas seulement de l'influence des mécanismes homéostatiques et circadiens [3].

De plus, les conditions de vie, avec les différents changements d'horaires, la disponibilité de l'électricité, les dispositifs technologiques, le rythme de travail actuel, le monde du travail et sa demande croissante, et les activités productives, ont conduit à la création de différents quarts de travail, qui rompent, à maintes reprises, le rythme biologique. L'un des changements de comportement observés dans les sociétés industrialisées est la diminution des heures de sommeil [4]. Actuellement, la population des pays industrialisés a diminué la quantité de sommeil nocturne [6]. Les données américaines montrent que les adultes et les adolescents dorment 1,5 à 2 heures de moins par nuit par rapport au siècle précédent et 30% de la population adulte déclare dormir moins de 6 heures par jour [7].

Effet du sommeil direct

- Santé physique
- Santé psychologique
- Qualité de vie

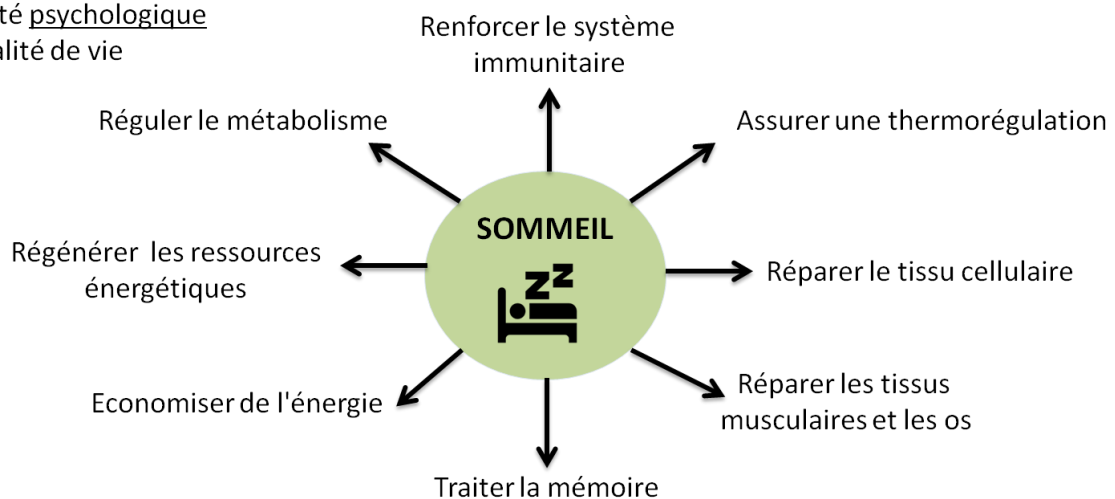


Figure 1.1. Les bienfaits du sommeil

1.2.2. Les phases du sommeil

Il y a des comportements qui facilitent l'initiation du sommeil et d'autres qui l'empêchent. Trouver un endroit calme et abrité avec peu de lumière et de stimulation sonore est un comportement facilitateur. A l'inverse, le stress, la peur, le repos, la douleur, une activité physique intense, ou la prise de stimulants peuvent le retarder.

Le meilleur indicateur du moment où commencer à s'endormir est la sensation subjective de somnolence. La somnolence s'accompagne généralement de signes extérieurs visibles, tels qu'une diminution de la mobilité, une diminution des clignements spontanés, des bâillements, qui ne sont pas toujours un indicateur de somnolence, une respiration régulière,

des difficultés à garder les yeux ouverts et une diminution de la réactivité aux stimuli externes.

La présence de certains réveils pendant le sommeil est un phénomène normal et leur fréquence varie selon l'âge de la personne (minimes dans l'enfance, épisodiques chez les jeunes, plus fréquents chez les personnes âgées). Un certain nombre de comportements de sommeil peuvent parfois apparaître chez les personnes normales et ne nécessitent pas d'évaluation particulière s'ils sont rares, tels que la somnolence, les cauchemars occasionnels, les ronflements légers sans apnée, la somnolence diurne et les mouvements occasionnels des membres [8].

Grâce à des études électro-neurophysiologiques, cinq stades représentatifs des mécanismes physiologiques alternés observés dans le sommeil ont été définis. Au moyen de l'électroencéphalogramme (EEG), de l'électroculogramme (EOG) et de l'électromyogramme (EMG), le sommeil est divisé en deux états : le sommeil paradoxal (mouvement oculaire rapide (MOR)) dans lequel l'activité cérébrale est à peu près la même que l'état de veille et le sommeil non paradoxal (mouvement oculaire non rapide (MONR)), les deux cyclant continuellement pendant une période de sommeil [9]. Le sommeil physiologique est organisé en cycles d'environ 90 minutes au cours desquels les deux se produisent et se répètent 4 à 6 fois au cours d'une période de sommeil normale.

1.2.2.1. Sommeil non paradoxal

Le sommeil non paradoxal ou MONR se divise en quatre phases qui s'approfondissent progressivement :

- a) **Phase I (Somnolence):** Phase de sommeil léger qui débute après l'éveil et dure quelques minutes. Pendant cette période de sommeil, l'EEG enregistre un rythme alpha (activité cérébrale normale pendant l'éveil) diminué en amplitude, discontinu, et finalement remplacé par une activité de basse tension avec une fréquence de 4 à 7 Hz. Des ondes bêta (13 à 50 Hz) apparaissent également et l'activité électromyographique diminue. À ce stade, le sommeil n'est pas très réparateur et une personne peut facilement se réveiller. Cette phase se caractérise également par des mouvements oculaires lents, et la température corporelle est basse. Les fonctions végétatives

commencent à décliner et le rythme cardiaque et la respiration ralentissent au cours des étapes suivantes [10].

b) Phase II (Sommeil peu profond): Commence environ dix minutes après le premier. L'EEG montre des ondes vertex aiguës, des fuseaux de sommeil (regroupement d'ondes de 12 à 14 Hz en forme de fuseau, d'une durée de 0,5 à 1,5 secondes) et de gros grapho-éléments appelés complexes K. L'activité cérébrale est caractérisée par la prédominance des ondes thêta. Les mouvements oculaires sont lents, généralement horizontaux et non conjugués, de plus grande amplitude en phase I qu'en phase II, et le tonus musculaire du menton est préservé. Au fur et à mesure que la profondeur du sommeil augmente, on enregistre les phases III et IV où l'activité delta (<4 Hz à l'EEG) de forte amplitude occupe au moins 20% en phase III, soit les 50% du temps enregistrés en phase IV. Dans cette phase, il est plus difficile de réveiller le sujet car le seuil idéationnel est augmenté. Après un réveil dans cette phase, un contenu idéationnel est généralement rapporté, plus typique des pensées que des rêves. Dans ces phases, il n'y a pas de mouvements oculaires perceptibles et le tonus musculaire, bien que diminué, est toujours présent [10].

1.2.2.2. Sommeil paradoxal

Le sommeil paradoxal apparaît généralement pour la première fois environ 90 minutes après le début du sommeil. Il suit donc le sommeil MONR et survient 4 à 5 fois au cours d'une période de sommeil normale (8 heures). Il se caractérise par un EEG d'amplitude faible à modérée avec des fréquences de 3 à 7 Hz, avec des mouvements oculaires rapides, mais avec une atonie électromyographique complète dans tous les muscles volontaires à l'exception du diaphragme. La respiration, le rythme cardiaque et la tension artérielle deviennent irréguliers et le contrôle de la température poikilothermique [11].

Les figures 1.2 et 1.3 illustrent l'hypnogramme d'une personne en bonne santé. Cependant, en réalité, les hypnogrammes diffèrent d'une personne à l'autre. L'hypnogramme est très utile pour reconnaître les personnes souffrant de sommeil.

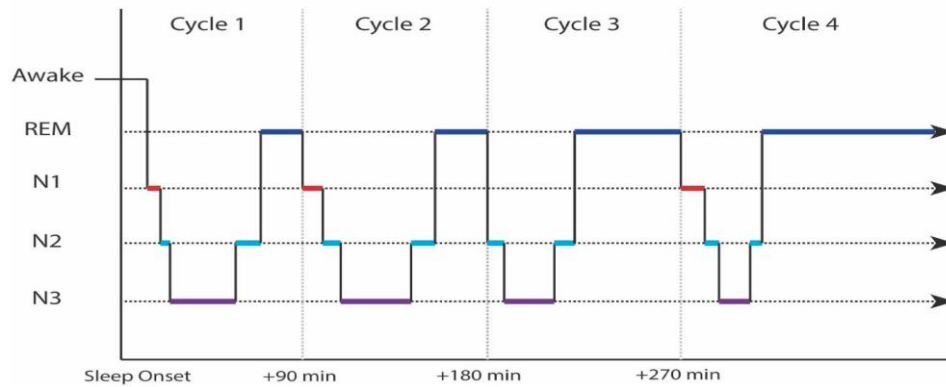


Figure 1.2. Hypnogramme schématisant l'organisation d'une nuit de sommeil chez l'adulte.

[12]




Figure 1.3. Hypnogramme d'une personne normale [12].

1.3. Syndrome d'apnée-hypopnée du sommeil

Le syndrome d'apnée-hypopnée du sommeil (SAHS) est un trouble respiratoire caractérisé par des épisodes répétés de collapsus ou d'obstruction des voies respiratoires supérieures pendant le sommeil, provoquant un arrêt partiel (hypopnée) ou complet (apnée) du flux d'air conduisant à des épisodes d'hypoxémie intermittente [13].

Ces épisodes sont définis par l'indice d'apnée-hypopnée (IAH), résultant de la somme des apnées et des hypopnées pendant la durée totale du sommeil divisée par le nombre d'heures de sommeil, exprimé en événements/heure. Sur la base de l'IAH, le SAHS est classé comme léger (IAH 5 à 14,9), modéré (IAH 15 à 29,9) ou sévère (IAH ≥ 30) (voir la figure 1.4) [14].




Figure 1.4. Indice d'apnée-hypopnée (IAH) [14]

Une apnée est définie comme l'absence ou la réduction (de plus de 90 %) du débit d'air respiratoire pendant plus de 10 secondes ; l'hypopnée consiste en une réduction de 30 % à 90 % du débit d'air, d'une durée supérieure à 10 secondes, accompagnée d'une désaturation en oxygène ($\geq 3\%$) et/ou de micro-éveils (détectés à l'électroencéphalogramme lors d'une polysomnographie) [15].

L'effondrement des voies respiratoires supérieures qui conduit au SAHS se produit à la suite d'altérations anatomo-fonctionnelles de celles-ci, dérivées de différents facteurs anatomiques, musculaires et neurologiques. La partie du pharynx entre la cloison nasale postérieure et l'épiglotte a peu de structures osseuses ou de support rigide, de sorte que sa perméabilité dépend largement de l'activité musculaire. Il existe différents facteurs anatomiques qui entraînent une diminution du calibre et une augmentation de la résistance des voies respiratoires supérieures (obésité, par exemple) qui génèrent des pressions négatives plus importantes dans le pharynx lors de l'inspiration, favorisant son affaissement.




Figure 1.5. Muscles des voies respiratoires supérieures lors d'une: (a) respiration normale, (b) hypopnée et (c) apnée obstructive du sommeil [19]

Une perte excessive de tonus musculaire dans les voies respiratoires supérieures ou une altération des mécanismes cérébraux du sommeil (en train de contrôler les muscles pharyngés) ainsi que le défaut des réflexes protecteurs sont des facteurs qui prédisposent également au collapsus des voies respiratoires et à l'interruption conséquente du débit d'air. Par la suite, l'hypoxémie et l'hypercapnie qui en résultent pendant l'apnée ou l'hypopnée stimulent l'effort respiratoire, mettant fin à l'épisode accompagné d'éveil (voir la figure 1.5) [16].

Le SAHS peut être dû à des apnées-hypopnées obstructives ou centrales. L'apnée est obstructive si elle s'accompagne d'un effort respiratoire durant celle-ci (détecté par des bandes thoraco-abdominales lors de la polysomnographie (voir la figure 1.6) ; c'est-à-dire que la commande respiratoire est maintenue) ou centrale en l'absence d'un tel effort (voir la figure 1.7). En cas d'apnée obstructive, l'effort des muscles respiratoires contre les voies respiratoires supérieures effondrées provoque une augmentation de la dépression intra-thoracique pouvant avoir des conséquences physiopathologiques sur le développement de comorbidités associées. Enfin, l'apnée peut être mixte, avec une composante obstructive et une composante centrale (généralement commençant par une composante centrale, se terminant par une composante obstructive) [17].




Figure.1.6. Représentation d'un polysomnogramme d'une personne atteinte apnée du sommeil obstructive [35].




Figure.1.7. Représentation d'un polysomnogramme d'une personne atteinte d'apnée du sommeil centrale [35].

Des épisodes répétés de collapsus des voies respiratoires supérieures, entraînant apnée et hypopnée, déforment la structure du sommeil avec de fréquents réveils asphyxiés et partiels qui entraînent une fragmentation du sommeil, un sommeil non réparateur, et donc une somnolence diurne excessive [17].

Le SAHS, selon sa gravité, a également été associé à d'autres symptômes nocturnes (tels que ronflements fréquents, nycturie, insomnie, sommeil agité, cauchemars, mouvements anormaux, etc.) et diurnes (asthénie, céphalées matinales, irritabilité, apathie, dépression), difficultés de concentration, perte de mémoire, etc.).

Les principaux facteurs de risque de développement du SAHS sont le sexe masculin, l'âge (surtout après 60 ans) et l'obésité [17].

La fréquence du SAHS dans la population semble avoir augmenté ces dernières années. Ainsi, aux États-Unis, l'analyse de « Wisconsin Sleep Cohort Study » extrapolée à la population générale, chez des individus entre 30 et 60 ans étudiés par polysomnographie nocturne et publiée au début des années 1990, a alors estimé une fréquence de SAHS de 4 % chez les hommes et 2% chez les femmes, tandis que des analyses similaires ultérieures indiquent une augmentation de la fréquence du SAHS au cours des deux dernières décennies comprise entre 14 et 55 %. Cette augmentation est très probablement liée, entre autres facteurs possibles, à l'augmentation progressive de l'obésité dans la population [18].

1.3.1. Diagnostic du SAHS

Plusieurs facteurs prédisposent au SAHS. Parmi eux figurent des facteurs anatomiques et héréditaires, le sexe, l'âge, en plus de l'excès de poids. De plus, les patients sont envoyés dans des unités de sommeil pour présenter des symptômes habituellement associés à cette maladie, tels que ronflements, somnolence diurne, etc. Pour toutes ces raisons, la première étape dans l'évaluation d'un éventuel diagnostic de SAHS repose sur un examen physique et une anamnèse. En parallèle, les patients sont généralement soumis à différents questionnaires qui évaluent la somnolence diurne, la qualité du sommeil ou la probabilité de souffrir de SAHS. Il s'agit notamment de l'échelle de somnolence d'Epworth et du questionnaire d'auto-évaluation de la qualité du sommeil et de l'éveil. Cependant, pour établir un diagnostic définitif, la technique standard dans le monde est la polysomnographie (PSG) [20].

1.3.1.1. Polysomnographie

Cette technique permet, non seulement de diagnostiquer l'existence du SAHS, mais aussi l'évaluation de sa gravité. Elle est réalisée dans des unités de sommeil, généralement situées dans des hôpitaux, tout au long de la nuit. Pour que la polysomnographie soit considérée comme valide, l'enregistrement ne doit pas être inférieur à six heures et demie et doit inclure au moins 180 minutes de sommeil [21].

Au cours de la procédure, des variables neurophysiologiques et respiratoires sont enregistrées simultanément, permettant de détecter les événements respiratoires, ainsi que d'évaluer la quantité et la qualité du sommeil. De même, afin d'établir les différentes phases du sommeil, les mouvements oculaires (électrooculogramme) et le tonus musculaire (électromyogramme, généralement sur le menton) sont enregistrés. De plus, les mouvements des membres inférieurs et la position du corps peuvent également être enregistrés avec des capteurs supplémentaires. Les paramètres respiratoires et cardiaques comprennent la saturation en hémoglobine, obtenue avec un oxymètre de pouls, l'effort respiratoire, mesuré par des sangles thoraco-abdominales, et le débit nasobuccal, mesuré avec des thermistances, qui sont particulièrement utiles pour la détection des apnées [21].

Cette section présente une vue d'ensemble des capteurs appliqués pour le PSG et est illustrée à la Figure 1.8.

- Electroencéphalogramme (EEG): L'EEG mesure l'activité électrique des régions frontale, centrale et occipitale du cortex cérébral à travers des électrodes de surface sur

le cuir chevelu. Les formes d'onde dans différentes bandes de fréquences et les modèles d'onde caractéristiques agissent comme des indicateurs pour des phases de sommeil spécifiques.

- Electro-oculogramme (EOG): L'œil agit comme un dipôle électrique et ses mouvements sont captés par l'EOG. Il aide à distinguer l'éveil du sommeil léger et à identifier les REM pendant le sommeil REM [22].
- Electromyogramme (EMG): Un EMG est placé sur le menton pour identifier les baisses de tonus musculaire comme indicateur du sommeil paradoxal et pour le discriminer de l'éveil [22]. De plus, des électrodes EMG sont fixées sur les membres pour observer les mouvements périodiques des membres (MPM).




Figure 1.8. Exemples de certains capteurs de polysomnographie et comment ils sont attachés au corps [23]

- Electrocardiogramme (ECG) : L'ECG surveille la fonction cardiaque par une électrode de dérivation II modifiée [22].
- Oxymétrie : L'oxymétrie mesure la saturation en oxygène (SpO_2) dans le sang, utilisée pour relier les baisses d'oxygénation aux événements apnéiques. Le signal est acquis en plaçant un clip autour du doigt qui transmet deux longueurs d'onde de lumière (rouge). Le niveau d'absorption de chaque longueur d'onde détermine l'oxygénation.
- Photopléthysmographie (PPG) : Le capteur PPG a le même principe de fonctionnement que l'oxymétrie, sauf qu'une seule longueur d'onde de lumière rouge est émise. Il surveille l'évolution du flux sanguin vers les artères périphériques. Le PPG peut être intégré dans l'oxymétrie.

- Respiration : Les mesures du débit d'air sont la principale source d'annotation des événements apnéiques. Les apnées sont principalement détectées par les thermistances oronasales et les hypopnées par les capteurs de pression nasale, car elles ont une sensibilité différente pour les limitations subtiles du débit [22].
- Effort respiratoire : L'effort respiratoire évalue les mouvements thoraciques et abdominaux grâce à la mise en place de ceintures RIP autour du thorax et de l'abdomen. Au cours des apnées centrales, l'effort respiratoire est absent. En tant que tel, le signal aide à discriminer les sous-types d'apnée.
- Position : La position du corps peut avoir un impact sur le développement des événements apnéiques et est donc observée avec un accéléromètre [24].
- Audio : Les enregistrements audio aident à identifier et à analyser le ronflement pour le diagnostic de l'AOS.
- Vidéo : L'enregistrement vidéo peut aider au diagnostic des troubles du sommeil, surveiller le comportement des patients ou révéler l'origine d'artefacts dans le signal.

Le problème est que l'analyse de cette énorme quantité d'informations se fait manuellement. Pour tout ce qui précède, la polysomnographie est considérée comme une technique coûteuse et complexe qui génère de longues listes d'attente. Cependant, à ce jour, malgré les avancées technologiques, la communauté médicale n'a considéré aucun des systèmes qui ont tenté d'automatiser le diagnostic du SAHS comme une alternative valable à la polysomnographie [25].

Bien que la méthode d'analyse du sommeil basée sur la PSG soit la norme de référence pour le diagnostic du SAHS, il convient de garder à l'esprit qu'elle présente une série de limites. Étant basé sur un système manuel, mis en œuvre selon les normes du technicien correspondant, il existe une composante subjective qui peut être évitée dans les systèmes automatisés. De plus, lorsque l'étude est menée en milieu hospitalier, la qualité du sommeil et la fréquence des épisodes respiratoires peuvent être affectées, et donc le conditionnement des résultats, qui peuvent ne pas refléter l'état réel du patient [26].

1.3.1.2. Critères diagnostiques selon AASM

L'AASM « American Academy of Sleep Medicine » est l'institution de référence dans ce domaine, et les règles qu'elle définit sont généralement adoptées par la communauté scientifique. Plus précisément, ils établissent les règles à appliquer tant dans la réalisation de la polysomnographie que dans l'évaluation des signaux obtenus. Selon les dernières règles

définies par l'AASM, un événement respiratoire est défini comme une apnée si les conditions suivantes sont simultanément remplies [27] :

- a) Il y a une chute qui est supérieure ou égale à 90 % de l'écart du signal de crête par rapport à la ligne de base par rapport à l'événement précédent, en utilisant un thermocapteur, le débit d'un appareil à pression d'air positive ou un autre capteur d'apnée.
- b) La durée de la chute (qui est ≥ 90 %) est supérieure ou égale à 10 secondes.

L'apnée est considérée comme obstructive si, en plus de répondre aux critères pour être considérée comme une apnée, elle est associée à un effort inspiratoire accru continu pendant toute la période d'absence de flux d'air. Cependant, en cas d'absence d'effort inspiratoire pendant toute la période, on parlera d'apnée centrale. Lorsque l'effort inspiratoire est absent dans la partie initiale de l'événement respiratoire et que l'effort inspiratoire est récupéré dans la deuxième partie de l'événement, il est défini comme une apnée mixte.

Un événement respiratoire est défini comme une hypopnée s'il répond aux trois critères suivants :

- a) Il y a une baisse supérieure ou égale à 30 % de l'écart du signal de crête par rapport à la ligne de base par rapport à l'événement précédent, en utilisant la pression nasale, le débit d'un appareil à pression d'air positive ou un autre capteur d'hypopnée.
- b) La durée de la chute (qui est ≥ 30 %) est supérieure ou égale à 10 secondes.
- c) Il y a une désaturation en oxygène supérieure ou égale à 3 % par rapport à la ligne de base de l'événement précédent, ou un micro-éveil.

1.3.1.3. Systèmes d'autodiagnostic comme alternative à la polysomnographie

En raison de tous les inconvénients exposés par rapport à la polysomnographie, il est nécessaire de développer des méthodes alternatives de diagnostic automatique moins chères et plus accessibles, et qui permettent le développement d'appareils portables permettant de diagnostiquer le patient par l'analyse du sommeil à domicile.

D'autre part, il est important de souligner que, si en plus du diagnostic, les systèmes développés permettent la détection des événements apnéiques en temps réel, il sera possible d'utiliser ces informations pour adopter des mesures correctives, encadrées dans le traitement, qui minimiser le nombre d'apnées et leur durée [28].

En général, les méthodes alternatives de diagnostic sont classées selon leur complexité technique, les moyens utilisés et les résultats obtenus.

La première classification, introduite par l'AASM, classait les systèmes portables dans les types 3 et 4 [29]. En effet, dans les systèmes de type 3, le nombre de canaux est limité entre 4 et 7.

Ce groupe comprend les polygraphes respiratoires [27], qui peuvent être réalisés aussi bien dans les unités de sommeil des hôpitaux qu'au domicile du patient, et qui analysent principalement des variables respiratoires et cardiaques. Cependant, dans les systèmes de type 4, seuls un ou deux canaux sont pris en compte. L'oxymétrie de pouls en fait généralement partie (voir tableau 1.1).

Tableau 1.1: Modalités de diagnostic des troubles respiratoires du sommeil [13].

Canaux	Type 1	Type 2	Type 3	Type 4
	PSG complet	PSG complet sans surveillance	Appareils à canaux limités	Continu simple ou double enregistrement des bioparamètres
	≥ 7	≥ 7	≥ 4	≥ 1
Paramètres	EEG EOG EMG du menton ECG Flux d'air Effort respiratoire SpO2	EEG EOG EMG du menton ECG Flux d'air Effort respiratoire SpO2	- - - ECG or VFC Flux d'air Effort respiratoire SpO2	- - - ECG ou VFC - - SpO2
Position du corps	Mesuré objectivement	Peut être mesuré objectivement	Peut être mesuré objectivement	Non mesuré
Mouvement des jambes	EMG ou capteur de mouvement (souhaitable)	EMG ou capteur de mouvement (souhaitable)	Peut être enregistré	Non enregistré
Personnel	Fréquentation constante	Pas présent	Pas présent	Pas présent

Plus récemment, le système SCOPER [30] (Sleep, Cardiovascular, Oximetry, Position, Effort and Respiratory) a été mis en place et qui classe ces appareils en fonction de paramètres liés au sommeil, au système cardiovasculaire, à l'oxymétrie, à la position, à l'effort et à la respiration.

Cependant, du fait de sa complexité, le système proposé par l'AASM continue d'être utilisé en routine.

Cette thèse s'inscrit dans le cadre des systèmes de type 4, et les études menées sont basées sur le signal électrocardiogramme, dont on extrait la VFC, puisque divers travaux ont montré que ces systèmes sont de bons marqueurs de la présence de apnées. L'étude de ce signal à l'aide de techniques de traitement du signal basées sur l'analyse statistique de leurs caractéristiques linéaires et non linéaires permet de détecter des propriétés difficilement captables par inspection visuelle. Il existe un large éventail de possibilités, des méthodes d'analyse temporelle, fréquentielle et temps-fréquence, aux méthodes non linéaires qui peuvent être appliquées pour caractériser des signaux physiologiques complexes et leur comportement.

1.3.2. Options de traitement

Il existe plusieurs méthodes de traitement pour le SAHS, selon la cause spécifique de l'obstruction, les antécédents médicaux de l'individu et la gravité du trouble. La perte de poids est le traitement le plus simple du SAHS chez les patients obèses. Une perte de poids peut éliminer les épisodes apnéiques en réduisant le niveau adipeux des tissus parapharyngés. Cependant, cette option de traitement est limitée chez les patients qui présentent également des déficits anatomiques de la mâchoire ou qui ne peuvent pas perdre de poids de façon permanente.

L'intervention thérapeutique actuelle la plus largement utilisée est la pression positive continue (PPC), dans laquelle une machine génère et pompe un flux contrôlé d'air sous pression constant à travers un masque facial porté sur le nez, la bouche ou les deux. La pression supplémentaire maintient les muscles détendus, gardant les voies respiratoires ouvertes. La bonne pression est prescrite par le technicien du patient, sur la base d'un titrage pendant la nuit dans le laboratoire du sommeil. Il existe des preuves soutenant des améliorations dans les mesures de SAHS, de la somnolence diurne et de la fonction neurocognitive avec la PPC nasale [36].

Il existe plusieurs variantes de PPC. La pression positive variable des voies respiratoires (PPV), également connue sous le nom de bilevel ou BiPAP, utilise un circuit électronique pour surveiller la respiration du patient, fournissant deux pressions différentes, une plus élevée pendant l'inspiration et une pression plus faible pendant l'expiration. Ce système est

plus coûteux et est parfois utilisé chez les patients qui ont d'autres problèmes respiratoires coexistants et/ou qui trouvent que l'expiration contre une pression accrue est inconfortable ou perturbe leur sommeil. La pression positive automatique (PPA) est la forme la plus récente de ce type de traitement. Une machine PPA intègre des capteurs de pression et un ordinateur qui surveille en permanence les performances respiratoires du patient. Il ajuste la pression en continu, en l'augmentant lorsque l'utilisateur essaie de respirer mais ne le peut pas, et en la diminuant lorsque la pression est plus élevée que nécessaire.

Malgré l'efficacité de la PPC dans le traitement de SAHS, l'adhésion au traitement continue d'être un problème majeur, et certains patients trouvent même la PPC intolérable. Ceci est en général lié au masque facial et à la pression requise pour empêcher l'affaissement des voies respiratoires. Une bonne humidification de l'air inspiré, une sélection rigoureuse du masque approprié et l'ajout d'une rampe de pression peuvent tous améliorer l'observance. De plus, l'utilisation de BiPAP ou d'un dispositif d'autotitration à réglage constant peut améliorer l'acceptation par le patient [37].

Les appareils buccaux peuvent également être envisagés pour atténuer le SAHS en repositionnant la mandibulaire antérieure. Ces appareils, préparés par un dentiste, agissent en tirant la mâchoire inférieure (et donc la langue) vers l'avant, élargissant ainsi les voies respiratoires pharyngées [38].

Les patients plus jeunes et ceux qui ne tolèrent pas la PPC peuvent également être candidats à une intervention chirurgicale pour soulager le SAHS. L'uvulo-palato-pharyngoplastie (UPPP) implique l'ablation d'une partie du palais mou, de la luette et des tissus péripharyngés redondants, y compris parfois les amygdales. Cette procédure est souvent efficace pour éliminer le ronflement, mais elle n'est pas nécessairement curative du SAHS, car des zones des voies respiratoires autres que le palais mou s'effondrent également chez la plupart des patients. L'uvulo-palato-plastie assistée par laser (UPP) peut être pratiquée chez les patients qui ont des ronflements et un SAHS léger ou chez les patients qui n'ont pas de SAHS significatif mais qui veulent atténuer le ronflement. La chirurgie gastrique pourrait être envisagée chez certains patients obèses morbides atteints de SAHS. La chirurgie de la mâchoire est la procédure chirurgicale la plus invasive utilisée pour traiter le SAHS. Les patients qui ont une petite mandibule rétrognathique et qui ont échoué à des traitements plus conservateurs peuvent être candidats à cette approche. L'intervention chirurgicale peut se limiter à tirer la langue vers l'avant (génioplastie). Une procédure extensive peut impliquer de

déplacer à la fois la mandibule et le maxillaire. La chirurgie extensive de la mâchoire a un taux de complications plus élevé et un temps de récupération plus long. Chez les patients non observants atteints de SAHS extrêmement sévères, une trachéotomie (ouverture d'une voie aérienne directe par une incision dans la trachée) peut être envisagée. En raison de sa morbidité associée élevée, cette procédure est peu utilisée [39].

1.4. L'électrocardiogramme et l'exploration clinique de SAHS

1.4.1. L'électrocardiogramme (ECG)

L'ECG est un signal bioélectrique qui enregistre l'activité électrique du cœur en fonction du temps. Par conséquent, c'est un outil de diagnostic important pour évaluer la fonction cardiaque. L'ECG est acquis en plaçant des électrodes sur la peau du patient. Le signal ECG fournit les informations suivantes sur un cœur humain :

- Troubles du rythme cardiaque et de la conduction.
- Anomalies dans la propagation des impulsions électriques à travers le cœur.
- Des informations sur une crise cardiaque antérieure.
- Signe de maladie coronarienne.
- Epaissement anormal du muscle cardiaque.
- Indication d'une diminution de l'apport d'oxygène au cœur.
- Etendue et localisation de l'ischémie myocardique.
- Changements dans les concentrations d'électrolytes.
- Effets des médicaments sur le cœur.

1.4.2. Les ondes enregistrées sur un ECG normal

La forme d'onde ECG d'un individu normal se compose de l'onde P, du complexe QRS, du segment ST, de l'onde T et de l'onde U. Les étiquettes de la figure.1.9 sont couramment utilisées dans la terminologie ECG médicale.

Onde P : lorsque l'impulsion électrique est conduite du nœud sinusal vers le nœud auriculo-ventriculaire et se propage de l'oreillette droite à gauche, la dépolarisation (contraction) des oreillettes se produit. La dépolarisation des oreillettes entraîne l'onde P dans l'ECG.




Figure.1.9. ECG normal.

Complexe QRS: Le complexe QRS se compose de trois ondes, appelées séquentiellement Q, R et S. La dépolarisation rapide des deux ventricules entraîne ce complexe. Les muscles des ventricules ont une masse musculaire plus importante que celle des oreillettes, donc son amplitude est beaucoup plus grande que celle de l'onde P.

L'onde T: Elle est le témoin électrique de la repolarisation ventriculaire, elle se développe en générale dans le même sens que QRS par rapport à la ligne isoélectrique.

L'onde U: C'est une onde de faible amplitude et elle est visible dans certaines dérivations notamment chez les athlètes. L'onde U est souvent associée aux processus de repolarisation ventriculaire tardive, mais le mécanisme de sa genèse est encore discuté

1.4.3. Le rythme cardiaque

Certaines cellules cardiaques sont auto-excitables, se contractant sans aucun signal du système nerveux. Les potentiels électriques de contraction sont causés par un groupe de cellules spécialisées dans le cœur qui contrôlent le rythme cardiaque. Ces cellules produisent des impulsions électriques qui se propagent dans le cœur, provoquant sa contraction. Le stimulateur cardiaque principal, le nœud sino-auriculaire (nœud SA), initie le rythme cardiaque en générant une impulsion électrique qui se déplace vers les oreillettes gauche et droite, provoquant leur contraction (dépolarisation auriculaire). Après le début de la dépolarisation auriculaire, l'impulsion arrive rapidement au nœud auriculo-ventriculaire (nœud AV) qui est responsable de la contraction du ventricule.

Le signal électrique traverse ensuite le faisceau de His, diverge dans les branches du faisceau droit et gauche et se propage à travers les fibres de Purkinje jusqu'aux muscles des ventricules gauche et droit. Cela provoque une dépolarisation ventriculaire (contraction). Le temps nécessaire au signal pour se déplacer du nœud AV aux fibres de Purkinje fournit un retard naturel d'environ 0,1 seconde. Ce délai garantit que les oreillettes sont complètement vides avant que les ventricules ne se contractent. La contraction est suivie d'une repolarisation ventriculaire (récupération) des cellules qui étaient excitées lors de l'onde de dépolarisation précédente.




Figure 1.10. L'activité électrique du cœur.

Le nœud SA crée l'impulsion électrique qui fait battre le cœur, mais le système nerveux autonome (SNA) contrôle la fréquence cardiaque et la force des contractions cardiaques. Le SNA se compose de deux parties, le système nerveux sympathique (SNS) et le système nerveux parasympathique (SNP). Les nerfs sympathiques augmentent la fréquence cardiaque et la force de contraction, tandis que les nerfs parasympathiques agissent de manière inverse. Une conduction idéalisée de l'impulsion électrique pour le rythme cardiaque est illustrée à la figure 1.10. Une petite partie de ce potentiel électrique s'écoule vers la surface du corps. En appliquant des électrodes sur la peau aux points sélectionnés, le potentiel électrique généré par ce courant peut être enregistré comme un signal ECG.

1.4.4. L'effet du SAHS sur la variabilité de la fréquence cardiaque (HRV)

Le signal électrocardiogramme est adapté à la détection des événements respiratoires, car il est modulé par le sommeil, la respiration et le système nerveux autonome (SNA). Au sein de ce signal, les informations relatives à la fréquence cardiaque sont particulièrement utiles pour la détection du SAHS en raison des effets que les apnées produisent sur la VFC [31] [32].

La VFC normale est basée sur la régulation neurologique autonome du cœur et du système circulatoire, et les changements qui se produisent reflètent les effets des facteurs physiologiques qui modulent le rythme cardiaque normal [33].

Pendant le sommeil normal, le contrôle sympathique et parasympathique produit des oscillations périodiques de la VFC, appelées arythmie sinusale respiratoire (ASR), dues aux phases respiratoires [27].

Plus précisément, il y a une augmentation de la fréquence cardiaque lors de l'inspiration en raison de l'action du système nerveux sympathique, et une diminution de celle-ci lors de l'expiration, en raison de l'effet inhibiteur du système parasympathique. De plus, il existe une synchronisation de phase cardiorespiratoire (SPCR) qui définit le couplage entre la fréquence cardiaque et la respiration [34].

Certains auteurs ont abordé cette question, concluant que ce moment peut changer en fonction de diverses conditions physiologiques, par exemple à différents stades ou âges du sommeil [34]. A toute cette question, il faut ajouter que, pendant le sommeil, la dynamique et la complexité de la VFC sont modifiées.

Cependant, lors d'un épisode apnéique, il y a une augmentation du contrôle sympathique du système cardiovasculaire qui modifie le schéma d'oscillation, conduisant au phénomène appelé « variation cyclique de la fréquence cardiaque » (VCFC) [34]. Ce processus conduit à une bradycardie qui commence après l'interruption du flux d'air, et se poursuit pendant l'obstruction, jusqu'à ce que l'individu se réveille. À ce moment, la respiration normale est rétablie et la tachycardie réflexe commence. Ce schéma de bradycardies et de tachycardies a été attribué au contrôle parasympathique de la fréquence cardiaque pendant le sommeil, interrompu par l'activation sympathique, qui provoque l'éveil [31] [34].

Enfin, il est important de noter que la VFC n'est pas seulement affectée par les apnées, mais qu'il existe de nombreux facteurs, tels que les stades du sommeil, d'autres maladies ou

certaines médicaments, qui pourraient masquer les schémas de variation cyclique de la fréquence cardiaque (VCFC) [31].

1.5. Source du signal EEG

L'EEG pour électroencéphalographie, est un examen reposant sur la mesure de l'activité électrique du cerveau permettant une exploration cérébrale. Celui-ci est effectué grâce à des électrodes placées sur le cuir chevelu du patient. L'électroencéphalographie est la représentation sous forme d'un tracé des variations dans le temps de l'activité électrique du cerveau appelé électroencéphalogramme. Généralement cette approche est utilisée afin de diagnostiquer certaines maladies telles que l'épilepsie, l'insomnie, différencier les différents types d'ondes cérébrale (alpha, bêta, thêta et delta) et même pour étudier le fonctionnement du cerveau d'une personne saine [40].

Comparable à l'électrocardiogramme (ECG) qui permet d'étudier le fonctionnement du cœur, l'EEG est un examen indolore et non-invasif qui renseigne sur l'activité neurophysiologique du cerveau au cours du temps et en particulier du cortex cérébral soit dans un but diagnostique en neurologie, soit dans la recherche en neurosciences cognitives. Le signal électrique à la base de l'EEG est la résultante de la sommation des potentiels d'action post-synaptiques synchrones issus d'un grand nombre de neurones [41].

Généralement, l'application principale de l'EEG est l'étude d'une manière manuelle des enregistrements, à étudier les relations des liaisons ou des troubles cérébraux, tels que l'épilepsie rapporté par Sundaram, Sadler, Young, & Pillay en 1999 [42].

En 1875, Richard Caton détecta la présence de courants électriques chez les lapins et les singes à la surface du cerveau confirmée par l'occurrence d'oscillations de l'aiguille d'un galvanomètre. Hans Berger appliqua à un homme cette approche et enregistra le premier EEG en 1929 sous variations permanentes de potentiel, enregistrées avec des électrodes impolarisables sur un crâne intact. Berger cherchait à matérialiser l'énergie physique de l'être humain afin d'identifier le support de la pensée. Cette expérience mena alors à la découverte de l'EEG chez l'être humain [43]. Les bases de certains examens diagnostiques en neurologie ont été établies depuis 1945 et sont toujours appliquées de nos jours, avec l'évolution technologique, les amplificateurs EEG peuvent supporter plusieurs canaux allant à 512 canaux sur certains appareils.

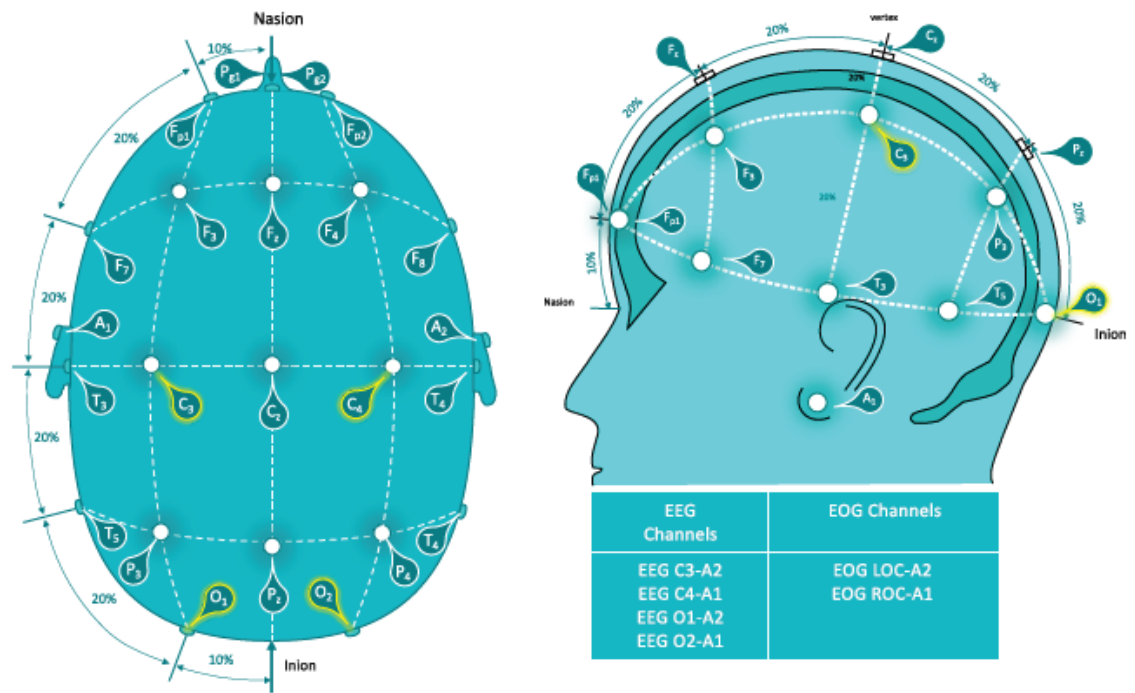


Figure.1.11. Positionnement et identification standards des électrodes EEG selon le système international 10-20 [44]

Les enregistrements effectués sont généralement basés sur une carte cérébrale comme présentée dans la figure 1.11 à l'aide des électrodes fabriquées en argent ou en chlorure d'argent placées selon des systèmes de positionnement standards afin de pouvoir visualiser l'activité cérébrale.

1.6.Conclusion

Dans ce chapitre, nous avons abordé certains concepts de base liés au sommeil, d'une part. D'autre part, le syndrome d'apnées-d'hypopnée du sommeil ainsi que leurs techniques de diagnostic sont décrits en détail. Dans ce contexte, le signal ECG et d'autres signaux principaux dans le diagnostic du SAHS ont été détaillés. En effet, diverses méthodes linéaires et non linéaires existent pour le traitement de ce genre de signaux. Ces méthodes seront abordées en détail dans le chapitre 2.

BIBLIOGRAPHIE

- [1] Vassalli, A., & Dijk, D. J. (2009). Sleep function: current questions and new approaches. *European Journal of Neuroscience*, 29(9), 1830-1841.
- [2] Xie, D., Li, W., Wang, Y., Gu, H., Teo, K., Liu, L., & Yusuf, S. (2014). Sleep duration, snoring habits and risk of acute myocardial infarction in China population: results of the INTERHEART study. *BMC Public Health*, 14(1), 1-10.
- [3] McKenna, H. T., Reiss, I. K., & Martin, D. S. (2017). The significance of circadian rhythms and dysrhythmias in critical illness. *Journal of the Intensive Care Society*, 18(2), 121-129.
- [4] Kishi, A., Van Dongen, H. P., Natelson, B. H., Bender, A. M., Palombini, L. O., Bittencourt, L., ... & Rapoport, D. M. (2017). Sleep continuity is positively correlated with sleep duration in laboratory nighttime sleep recordings. *PloS one*, 12(4), e0175504.
- [5] Facco, F. (2021). Sleep Duration, Sleep Timing and Sleep Disordered Breathing-Associations with Obesity and Gestational Diabetes in Pregnancy. *Clinical obstetrics and gynecology*, 64(1), 196.
- [6] Patel, S. R. (2009). Reduced sleep as an obesity risk factor. *Obesity Reviews*, 10, 61-68.
- [7] Peppard, P. E., Young, T., Barnet, J. H., Palta, M., Hagen, E. W., & Hla, K. M. (2013). Increased prevalence of sleep-disordered breathing in adults. *American journal of epidemiology*, 177(9), 1006-1014.
- [8] Åkerstedt, T., Billiard, M., Bonnet, M., Ficca, G., Garma, L., Mariotti, M., ... & Schulz, H. (2002). Awakening from sleep. *Sleep medicine reviews*, 6(4), 267-286.
- [9] McCarley, R. W. (2007). Neurobiology of REM and NREM sleep. *Sleep medicine*, 8(4), 302-330.
- [10] Seifpour, S., Niknazar, H., Mikaeili, M., & Nasrabadi, A. M. (2018). A new automatic sleep staging system based on statistical behavior of local extrema using single channel EEG signal. *Expert Systems with Applications*, 104, 277-293.
- [11] Chokroverty, S. (2017). Overview of Normal Sleep. In: Chokroverty, S. (eds) *Sleep Disorders Medicine*. Springer, New York, NY.

- [12] Lavery, M. J., Stull, C., Kinney, M. O., & Yosipovitch, G. (2016). Nocturnal pruritus: the battle for a peaceful night's sleep. *International journal of molecular sciences*, 17(3), 425.
- [13] Punjabi, N. M. (2008). The epidemiology of adult obstructive sleep apnea. *Proceedings of the American Thoracic Society*, 5(2), 136-143.
- [14] Samieirad, S., Khoshsirat, A., Rezaeetalab, F., Mianbandi, V., Tohidi, E., & Eshghpour, M. (2020). Will obstructive sleep apnea and apnea/hypopnea index Be corrected following alveolar cleft reconstruction?. *World Journal of Plastic Surgery*, 9(2), 146.
- [15] Ruehland, W. R., Rochford, P. D., O'Donoghue, F. J., Pierce, R. J., Singh, P., & Thornton, A. T. (2009). The new AASM criteria for scoring hypopneas: impact on the apnea hypopnea index. *sleep*, 32(2), 150-157.
- [16] Dewan, N. A., Nieto, F. J., & Somers, V. K. (2015). Intermittent hypoxemia and OSA: implications for comorbidities. *Chest*, 147(1), 266-274.
- [17] Filtness, A. J., Armstrong, K. A., Watson, A., & Smith, S. S. (2017). Sleep-related crash characteristics: Implications for applying a fatigue definition to crash reports. *Accident Analysis & Prevention*, 99, 440-444.
- [18] Peppard, P. E., Young, T., Barnet, J. H., Palta, M., Hagen, E. W., & Hla, K. M. (2013). Increased prevalence of sleep-disordered breathing in adults. *American journal of epidemiology*, 177(9), 1006-1014.
- [19] Chyad, M. H., Gharghan, S. K., Hamood, H. Q., Altayyar, A. S. H., Zubaidi, S. L., & Ridha, H. M. (2022). Hybridization of soft-computing algorithms with neural network for prediction obstructive sleep apnea using biomedical sensor measurements. *Neural Computing and Applications*, 34(11), 8933-8957.
- [20] Chiu, H. Y., Chen, P. Y., Chuang, L. P., Chen, N. H., Tu, Y. K., Hsieh, Y. J., ... & Guilleminault, C. (2017). Diagnostic accuracy of the Berlin questionnaire, STOP-BANG, STOP, and Epworth sleepiness scale in detecting obstructive sleep apnea: a bivariate meta-analysis. *Sleep medicine reviews*, 36, 57-70.
- [21] Penzel, T., Zhang, X., & Fietze, I. (2013). Inter-scorer reliability between sleep centers can teach us what to improve in the scoring rules. *Journal of Clinical Sleep Medicine*, 9(1), 89-91.

- [22] Vaughn, B. V., & Giallanza, P. (2008). Technical review of polysomnography. *Chest*, 134(6), 1310-1319.
- [23] Pandi-Perumal, S. R., Spence, D. W., & BaHammam, A. S. (2014). Polysomnography: an overview. *Primary care sleep medicine*, 29-42.
- [24] Roebuck, A., Monasterio, V., Gederi, E., Osipov, M., Behar, J., Malhotra, A., ... & Clifford, G. D. (2013). A review of signals used in sleep analysis. *Physiological measurement*, 35(1), R1.
- [25] Heneghan, C., Chua, C. P., Garvey, J. F., De Chazal, P., Shouldice, R., Boyle, P., & McNicholas, W. T. (2008). A portable automated assessment tool for sleep apnea using a combined Holter-oximeter. *Sleep*, 31(10), 1432-1439.
- [26] Rosen, I. M., Kirsch, D. B., Carden, K. A., Malhotra, R. K., Ramar, K., Aurora, R. N., ... & Shelgikar, A. V. (2018). American Academy of Sleep Medicine Board of Directors. Clinical use of a home sleep apnea test: an updated American Academy of Sleep Medicine position statement. *J Clin Sleep Med*, 14(12), 2075-2077.
- [27] Berry, R. B., Brooks, R., Gamaldo, C., Harding, S. M., Lloyd, R. M., Quan, S. F., ... & Vaughn, B. V. (2017). AASM scoring manual updates for 2017 (version 2.4). *Journal of Clinical Sleep Medicine*, 13(5), 665-666.
- [28] Zhang, J., Zhang, Q., Wang, Y., & Qiu, C. (2013, April). A real-time auto-adjustable smart pillow system for sleep apnea detection and treatment. In *2013 ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN)* (pp. 179-190). IEEE.
- [29] Bernardini, A., Brunello, A., Gigli, G. L., Montanari, A., & Saccomanno, N. (2021). AIOSA: An approach to the automatic identification of obstructive sleep apnea events based on deep learning. *Artificial Intelligence in Medicine*, 118, 102133.
- [30] Serrano Alarcón, Á., Martínez Madrid, N., & Seepold, R. (2021). A Minimum Set of Physiological Parameters to Diagnose Obstructive Sleep Apnea Syndrome Using Non-Invasive Portable Monitors. A Systematic Review. *Life*, 11(11), 1249.

- [31] Penzel, T., Kantelhardt, J. W., Grote, L., Peter, J. H., & Bunde, A. (2003). Comparison of detrended fluctuation analysis and spectral analysis for heart rate variability in sleep and sleep apnea. *IEEE Transactions on biomedical engineering*, 50(10), 1143-1151.
- [32] Mendez, M. O., Bianchi, A. M., Matteucci, M., Cerutti, S., & Penzel, T. (2009). Sleep apnea screening by autoregressive models from a single ECG lead. *IEEE transactions on biomedical engineering*, 56(12), 2838-2850.
- [33] Rajendra Acharya, U., Paul Joseph, K., Kannathal, N., Lim, C. M., & Suri, J. S. (2006). Heart rate variability: a review. *Medical and biological engineering and computing*, 44(12), 1031-1051.
- [34] Tsou, C. H., Pon, L. S., Liang, J. Z., Chan, Y. H., Chen, K. J., Cheng, F. S., ... & Yang, S. W. (2021). Response of heart rate variability and cardiorespiratory phase synchronization to routine bronchodilator test in patients with asthma. *Chinese Journal of Physiology*, 64(4), 177.
- [35] Nguyen-Hoang, Y., & Nguyen-Thi, B. (2018). Laboratory techniques for diagnosis of obstructive sleep apnea (OSA) in children. *J Func Vent Pulm*, 27(9), 2-10.
- [36] Ferini-Strambi, L., Baietto, C., Di Gioia, M. R., Castaldi, P., Castronovo, C., Zucconi, M., & Cappa, S. F. (2003). Cognitive dysfunction in patients with obstructive sleep apnea (OSA): partial reversibility after continuous positive airway pressure (CPAP). *Brain research bulletin*, 61(1), 87-92.
- [37] Collard, P. H., Pieters, T. H., Aubert, G., Delguste, P., & Rodenstein, D. O. (1997). Compliance with nasal CPAP in obstructive sleep apnea patients. *Sleep medicine reviews*, 1(1), 33-44.
- [38] Lowe, A. A. (1993). Can we predict the success of dental appliance therapy for the treatment of obstructive sleep apnea based on anatomic considerations?. *SLEEP-NEW YORK-*, 16, S93-S93.
- [39] Coito, A. L., & Sanches, J. (2011, March). Assessment of Obstructive Sleep Apnea Syndrome by spectral analysis of physiological parameters. In 1st Portuguese Biomedical Engineering Meeting (pp. 1-6). IEEE.
- [40] <http://www.cinq.ulaval.ca/EEG> consulté janvier 2022

[41] <https://lnc.univ-amu.fr/fr/techniques-utilisees> consulté janvier 2022.

[42] Sundaram, M., Sadler, R. M., Young, G. B., & Pillay, N. (1999). EEG in epilepsy: current perspectives. *Canadian Journal of Neurological Sciences*, 26(4), 255-262.

[43] Millett, D. (2001). Hans Berger: From psychic energy to the EEG. *Perspectives in biology and medicine*, 44(4), 522-542.

[44] NIROSAHNA, S. M. I. (2021). Sleep Stage Classification and Obstructive Sleep Apnea detection using Deep Learning (Doctoral dissertation, The University of Aizu).

Chapitre 2

Matériels et méthodes d'analyse des signaux physiologiques

2.1. Introduction

Une fois le syndrome d'apnées-hypopnées du sommeil (SAHS) introduit au chapitre 1 et la nécessité de plans et d'outils de diagnostic alternatifs pour aider les cliniciens dans leur diagnostic, dans ce chapitre les techniques et matériels de traitement utilisés dans cette thèse et les méthodes de classification à suivre dans la conception d'une solution basée sur les signaux ECG et EEG sont décrites. Tout d'abord, la description des bases de données contenant les signaux ECG et EEG utilisé pour l'apprentissage et le test de différentes méthodes de détection du SAHS. Deuxièmement, une revue des techniques nécessaires pour extraire un ensemble approprié de caractéristiques est incluse. Finalement, une brève revue des techniques d'intelligence artificielle les plus utilisées dans le diagnostic du SAHS.

2.2. Les bases de données

Dans toutes les expériences proposées dans cette thèse, deux bases de données ont été utilisées pour donner aux résultats un caractère plus généralisable. Ainsi, les résultats ne seront pas limités à un seul type de base de données. La plus célèbre d'entre elles est la très connue base de données Physionet : "Apnea-ECG" contenant les enregistrements ECG de 70 patients, dont une partie importante souffrant avec apnée obstructive du sommeil (AOS) [1]. Il n'y a pas de distinction entre l'apnée et hypopnée dans la base de données "Apnea-ECG", qui sont toutes considérées comme de l'apnée. La deuxième base de données sur l'apnée du sommeil (UCD) [2] du St. Vincent's University Hospital / University College Dublin contient 25 enregistrements PSG d'une nuit complète. Les enregistrements ont été collectés sur des sujets sous diagnostic de ronflement primaire et d'apnée du sommeil. Nous avons utilisé les deux canaux EEG (C3-A2 et C4-A1) dans nos expériences.

2.2.1. La base de données Apnea-ECG

Les données utilisées dans cette thèse proviennent de la base de données PhysioNet [3], et la description détaillée de la base de données peut être consultée sur le site Web (<https://physionet.org/>). Dans ce travail, l'ensemble de données « Apnea-ECG » de la base de données PhysioNet a été utilisé [1]. La base de données Apnée-ECG contient 70 enregistrements, chaque enregistrement contient un seul signal ECG numérisé à 100 Hz avec une résolution de 12 bits. Et il est annoté chaque minute, indiquant s'il y avait une apnée du sommeil dans le corps à cette minute. Selon le temps d'apnée du sommeil de chaque enregistrement, 70 enregistrements ont été divisés en trois catégories. La catégorie A

contenait un total de 40 enregistrements de 15 hommes et 1 femme, âgés en moyenne de 50 ans (29 à 63 ans). Les enregistrements ont été définis comme ayant 100 minutes ou plus avec apnée. La catégorie C comprenait 20 enregistrements de 6 sujets masculins et 5 sujets féminins, âgés en moyenne de 33 ans (27 à 42 ans). Les enregistrements ont été définis comme ayant moins de 5 minutes d'apnée. La catégorie B contenait 10 enregistrements de 4 sujets masculins et 1 sujet féminin, avec un âge moyen de 46 ans (39–53 ans), chaque enregistrement avec 10 à 96 min d'apnée. Dans l'étude de cette thèse, un total de 60 enregistrements de catégorie A et de catégorie C sont utilisés comme données expérimentales, description détaillée comme indiqué dans le tableau 2.1.

Tableau.2.1. Description de la base de données « Apnea-ECG ».

	Normal	ASO
Nombre d'enregistrements	20	60
Sexe (hommes/femmes)	6/5	15/1
Age (années)	33 ± 5.8	50 ± 6.6
IMC (kg/m ²)	21.5 ± 2.4	30.7 ± 4.6
IAH (events/h)	0.2 ± 0.2	37.1 ± 13.4
Durée de l'apnée (minutes)	3.3 ± 4.9	250.5 ± 77.6

AOS: apnée obstructive du sommeil ; IMC: indice de masse corporelle ; IAH: indice d'apnée-hypopnée.

2.2.2. La base de données UCD

La tâche de détection des apnées et des hypopnées est effectuée sur la base de données du St. Vincent's University Hospital/University College Dublin (base de données UCD) [2] disponible en ligne sur PhysioNet [3] qui fournit une variété de signaux physiologiques pour la recherche biomédicale. La disponibilité de la base de données UCD facilite la validation et l'évaluation de notre approche. Vingt-cinq (21 hommes et 4 femmes) les enregistrements PSG complets de nuit de suspects souffrant de troubles respiratoires sont enregistrés dans la base de données. Chaque enregistrement contient des signaux ECG et EEG de 5,9 à 7,7 h ainsi qu'un fichier d'annotation avec l'heure de début et la durée détaillées de chaque événement d'apnée/hypopnée. Les polysomnogrammes ont été obtenus à l'aide du système Jaeger-Toennies (Erich Jaeger GmbH, Allemagne). En particulier, le signal ECG a été enregistré via une dérivation V2 et les enregistrements EEG de deux canaux (C3–A2 et C4–A1) sont disponibles. Les propriétés physiologiques générales des sujets sont répertoriées dans le tableau 2.2, tandis qu'une description plus détaillée peut être trouvée en ligne [2].

Tableau 2.2. Propriétés physiologiques des sujets dans la base de données UCD

	Lavaleur moyenne	Intervalle
Age (années)	50 ± 10	28 - 68
IMC (kg/m ²)	31.6 ± 4.0	25.1 - 42.5
IAH (events/h)	0.2 ± 0.2	1.7 - 90.9

2.3. Prétraitement du signal ECG

2.3.1. Algorithme Pan & Tompkins

Puisque notre contribution porte sur l'amélioration de l'algorithme de Pan-Tompkins, nous commençons par décrire les principales étapes impliquées dans cet algorithme. Les principales étapes de l'algorithme original de Pan-Tompkins sont représentées sur la figure 2.1. L'algorithme comprend cinq étapes que nous décrirons brièvement dans ce qui suit [4] :

Le filtre passe-bande élimine le bruit du signal ECG brut d'entrée. Le différenciateur est introduit pour détecter les variations brusques du signal. La transformation non linéaire est le carré du signal différencié utilisé pour réduire les amplitudes des ondes T et P par rapport à l'onde d'amplitude crête R (après normalisation) et rendre positives les valeurs du signal. Le but de l'intégration de la fenêtre mobile est de faire apparaître les pics P, Q, R, S et T ensemble dans un pic unique afin de réduire le nombre de fausses détections.

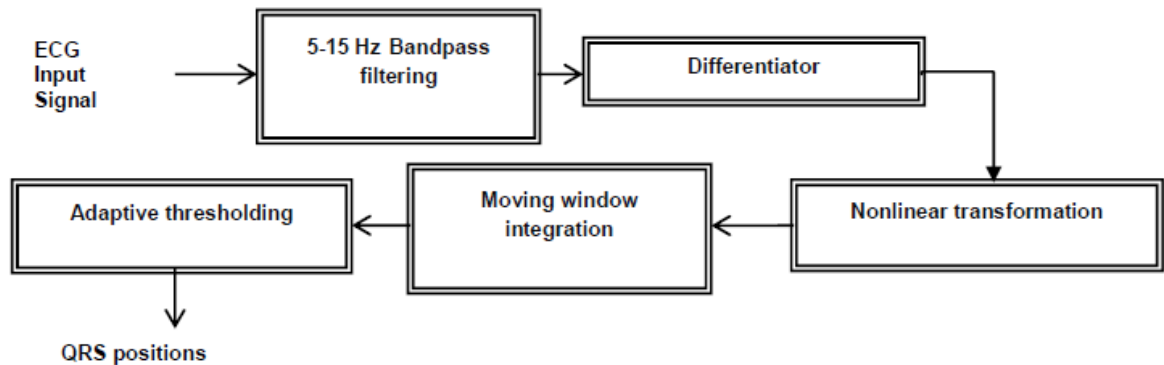


Fig.2.1. Les cinq opérations de l'algorithme de Pan-Tompkins.

La stratégie de décision repose sur l'utilisation de deux paramètres principaux qui sont le niveau de signal et le niveau de bruit. Le premier est calculé à partir d'une estimation du niveau de signal tandis que le second est calculé à partir d'une estimation du niveau de bruit. En particulier, le premier type de seuillage qui est un niveau de la séparation entre les amplitudes du signal et les amplitudes du bruit est formé en combinant les niveaux estimés du

signal et du bruit. Ce type est utilisé dans les cas normaux. Lorsqu'aucun pic R n'est détecté depuis longtemps avec le premier type de seuillage, une procédure de recherche arrière est lancée avec un autre type de seuillage. Ce deuxième type de seuillage utilise de nouvelles règles pour la détection des pics R.

Dans la phase d'apprentissage de notre algorithme d'optimisation, nous estimons les niveaux de seuil du signal et du bruit à partir des quelques premières secondes du signal d'entrée ECG. Tout d'abord, nous recherchons tous les pics présents dans cet intervalle de temps et l'intervalle minimum entre eux. On décide qu'un pic est une onde R si son amplitude est supérieure au niveau seuil, et on met à jour le niveau du signal. Sinon, si l'amplitude du pic est supérieure au niveau de seuil et que la moyenne des amplitudes dans cette région est inférieure ou égale à un certain pourcentage de la moyenne des amplitudes dans la région de l'onde R précédemment détectée, et l'intervalle entre le pic actuel et le dernier pic R détecté sont dans une certaine valeur, alors le pic actuel est une onde T et nous mettons à jour le niveau de bruit. Si l'amplitude du pic est inférieure au niveau du seuil de recherche arrière, c'est un pic de bruit ; nous mettons à jour le niveau de bruit ensuite. A chaque pic, nous testons si une recherche arrière est nécessaire, et nous mettons à jour les niveaux de seuil en fonction des niveaux du signal et du bruit.

La procédure de recherche arrière vérifie si l'intervalle RR actuel se situe dans un intervalle prédéfini. Sinon, on réduit le niveau du signal, si l'intervalle RR est supérieur à une limite prédéfinie, alors une recherche en arrière est nécessaire, on met à jour le niveau du signal. Si l'amplitude maximale entre le dernier pic détecté et le pic courant est supérieure ou égale au niveau de seuil de la procédure de recherche arrière, la position correspondante est considérée comme un pic R.

2.4. Prétraitement du signal EEG

2.4.1. Filtrage passe haut et passe bas

Ce travail applique un filtrage passe-bas et passe-haut au signal EEG. Le filtrage passe-bas consiste à rejeter les fréquences supérieures à un seuil de fréquence défini. Le filtre passe-bas ne modifie pas les fréquences inférieures à la limite de coupure. Les fréquences supérieures à 50 Hz dans les signaux EEG contiennent généralement des fluctuations de bruit non pertinentes. La littérature indique le filtre passe-bas pour atténuer ces signaux.

Le filtrage passe-haut consiste à l'opposé du filtrage passe-bas car il rejette les fréquences inférieures à une fréquence de coupure, mais il ne modifie pas les fréquences supérieures. La littérature indique le filtrage passe-haut pour atténuer les fréquences lentes contenant des composantes DC et des déviations négatives représentant des pointes de neurones uniques.

Ce travail établit des fréquences de coupure spécifiques pour les filtres passe-bas et passe-haut. Cependant, les filtres peuvent différer dans leur conception. Les chercheurs conçoivent généralement ces filtres à l'aide des méthodes FIR et IIR. Nous introduisons quelques concepts de base sur la conception FIR dans la section suivante.

2.4.2. Conception de filtre à réponse impulsionnelle finie

En particulier, il existe deux principaux types de conception de filtre, le filtre à réponse impulsionnelle finie (FIR) et le filtre à réponse impulsionnelle infinie (RII) [5]. La réponse impulsionnelle infinie (RII) filtre le signal d'impulsion indéfiniment, c'est-à-dire pendant que le signal se produit. Le calcul d'un filtre RII est récursif et combine la somme des entrées avec les sorties des derniers signaux. En revanche, la réponse impulsionnelle finie (RIF) filtre chaque signal d'impulsion dans une réponse finie. Le filtre RIF additionne une plage finie de signaux pondérés en entrée. La somme de convolution ci-dessous représente le filtre RIF :

$$y(n) = \sum_{m=n}^{n-N+1} h(n-m)x(m) \quad (2.1)$$

Où $y(n)$ est le signal de sortie, $x(m)$ est le signal d'entrée et $h(n-m)$ est la réponse impulsionnelle à l'instant $n-m$.

Dans ce travail, nous avons conçu un filtre RIF avec une méthode de fenêtre de Hamming. L'équation 2.2 définit la fenêtre de Hamming que nous avons utilisée.

$$W(n) = 0.54 - 0.46 \cos \frac{2\pi n}{N-1} \quad (2.2)$$

La fréquence de coupure (ω_c) du filtre passe-bas dans ce travail est de 50Hz, et la coupure du filtre passe-haut de ce travail est de 1Hz. Étant donné que $|\omega|$ est la fonction de

fenêtre dans une plage particulière du signal EEG, cette fonction de fenêtre est multipliée par le filtre passe-bas souhaité lorsque la condition $|\omega| \leq \omega_c$ est satisfait. La fonction fenêtre est multipliée par le signal lorsque la condition $\omega_c \leq |\omega|$ [6].

2.5. Les méthodes d'extraction de caractéristiques des signaux HRV

2.5.1. Transformée en Ondelettes Continue

La transformée en ondelettes (TO) est un outil mathématique adapté au traitement de signaux non stationnaires dont le contenu spectral varie avec le temps [7] [8]. L'analyse d'une série temporelle par la TO nécessite un ensemble de fonctions générées à partir d'une fonction de base $\psi(t)$ nommée ondelette mère. Le développement de $\psi(t)$ est obtenu en faisant varier ses paramètres d'échelle (s) et de translation (τ) selon l'équation 2.3,

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (2.3)$$

où le facteur $(\sqrt{s})^{-1}$ normalise l'énergie de l'expansion avec les échelles.

Étant donné une ondelette mère, la transformée en ondelettes continue (Continuous wavelet transform, CWT) d'un signal $f(t)$ est définie comme la convolution de $f(t)$ avec le conjugué complexe de la famille d'ondelettes $\psi_{s,\tau}(t)$ comme cela est exprimé dans l'équation 2.4,

$$W(s, \tau) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (2.4)$$

Les coefficients obtenus à partir de l'équation 2.4, appelés coefficients d'ondelettes, représentent le degré de similarité entre $f(t)$ et $\psi(t)$. Bien que le TO donne une décomposition temporelle du signal $f(t)$, il est possible d'obtenir une représentation temps-fréquence en substituant les échelles par des pseudo-fréquences. La relation entre échelles et pseudo-fréquences dépend de la fréquence centrale de la fonction ondelette, de l'échelle évaluée et de la période d'échantillonnage, la fréquence centrale étant celle qui maximise le spectre d'une fonction ondelette à une échelle donnée. L'association entre ces paramètres est donnée par l'équation 2.5:

$$f_s = \frac{f_c}{s \cdot \Delta} \quad (2.5)$$

où f_c représente la fréquence centrale, Δ est la période d'échantillonnage et f_s est la pseudo-fréquence résultante.

La synthèse de l'ensemble des signaux ou d'une partie de ceux-ci à bande limitée est obtenue à partir des coefficients d'ondelettes en appliquant la transformée en ondelettes continue inverse (Inverse continuous wavelet transform, ICWT), définie par l'équation 2.6 comme,

$$f(t) = \frac{1}{C_\psi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} W(s, \tau) \psi_{s,\tau}(t) \frac{dsd\tau}{s^2} \quad (2.6)$$

2.5.2. Entropie de dispersion multi-échelle

Entropie de dispersion (Dispersion entropy, DispEn) est une méthode d'analyse dynamique non linéaire pour la mesure de l'irrégularité des séries temporelles. La relation des valeurs d'amplitude voisines des données d'origine ignorées dans PE sera prise en compte par DispEn. De plus, l'opération de calcul de rang vectoriel et de distance entre deux vecteurs de retard différents dans l'entropie de shannon est abandonnée par DispEn. En particulier, l'EnDis a une capacité anti-bruit plus forte que l'entropie de permutation car le petit changement d'amplitude ne modifie pas l'étiquette de classe correspondante dans DispEn. Pour une série temporelle univariée donnée $X = \{x_1, x_2, \dots, x_N\}$ de longueur N , les étapes de EnDis peuvent être décrites comme suit [9] [10]:

- La série chronologique d'origine X est mappée en $Y = \{y_1, y_2, \dots, y_N\}$ en utilisant une fonction de distribution cumulative normale (Normal cumulative distribution function, NCDF) représentée par:

$$y_j = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^{x_j} e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt \quad (2.7)$$

où $y_j \in (0, 1)$, et μ et σ représentent la moyenne et l'écart type de la série temporelle X , respectivement.

- Pour chaque membre du signal mappé, tous les éléments de Y ($y_j, j = 1, 2, \dots, N$) sont mappés sur c classes avec des indices entiers de 1 à c en utilisant la transformée linéaire :

$$z_j^c = R(c \cdot y_j + 0.5) \quad (2.8)$$

où z_j^c désigne le $j^{\text{ième}}$ membre de la série chronologique classifiée, c désigne le nombre de classes et $R(\cdot)$ représente la fonction d'arrondi. Bien que l'étape (2) soit linéaire, l'ensemble de la procédure de mappage est non linéaire pour l'utilisation de NCDF à l'étape (1).

- Pour la dimension d'intégration m et le délai d donnés, la série temporelle $z_i^{m,c}$ peut être obtenue selon $z_i^{m,c} = \{z_i^c, z_{i+d}^c, \dots, z_{i+(m-1)d}^c\}$, $j = 1, 2, \dots, N - (m - 1)d$. Chaque série temporelle $z_i^{m,c}$ peut être associée à un modèle de dispersion $\pi_{v_0 v_1 \dots v_{m-1}}$, où $z_i^c = v_0, z_{i+d}^c = v_1, \dots, z_{i+(m-1)d}^c = v_{m-1}$. Le nombre de motifs de dispersion possibles pouvant être attribués à chaque série temporelle $z_i^{m,c}$ est égal à c^m car le signal comporte m membres, et chaque membre peut être l'un des nombres entiers de 1 à c .
- Pour chaque modèle de dispersion de potentiel $\pi_{v_0 v_1 \dots v_{m-1}}$, la fréquence relative peut être obtenue par :

$$p(\pi_{v_0 v_1 \dots v_{m-1}}) = \frac{\text{Nombre}\{i | i \leq N - (m - 1)d, z_i^{m,c} \text{ a le type } \pi_{v_0 v_1 \dots v_{m-1}}\}}{N - (m - 1)d} \quad (2.9)$$

où le 'Nombre' dans la formule ci-dessus signifie compter le nombre de i qui remplit les conditions dans les accolades et $p(\pi_{v_0 v_1 \dots v_{m-1}})$ montre le nombre de modèles de dispersion de $\pi_{v_0 v_1 \dots v_{m-1}}$ qui est attribué à $z_i^{m,c}$, divisé par le nombre total de signaux intégrés de dimension d'intégration m .

- Sur la base de la définition de l'entropie de Shannon, le DisEn de X est calculé par:

$$\text{DisEn}(X, m, c, d) = - \sum_{\pi=1}^{c^m} p(\pi_{v_0 v_1 \dots v_{m-1}}) \ln \left(p(\pi_{v_0 v_1 \dots v_{m-1}}) \right) \quad (2.10)$$

On peut trouver à partir de l'algorithme de EnDis que lorsque tous les modèles de distribution $p(\pi_{v_0 v_1 \dots v_{m-1}})$ ont des probabilités égales, EnDis acquiert la plus grande valeur d'entropie $\ln(c^m)$, et un exemple typique est le bruit blanc gaussien. En revanche, lorsque la probabilité du modèle de distribution $p(\pi_{v_0 v_1 \dots v_{m-1}})$ est unitaire, c'est-à-dire qu'une seule valeur n'est pas nulle, DisEn obtient la plus petite valeur, ce qui indique que la série temporelle est complètement prévisible et qu'un exemple est le signal périodique à basse fréquence.

Basé sur DisEn, l'algorithme d'entropie de dispersion multi-échelle peut être décrit comme suit [10,11]:

- Pour une donnée univariée normalisée $W = \{w_1, w_2, \dots, w_L\}$ de longueur L , le signal d'origine W est d'abord divisé en $\lfloor L/\tau \rfloor$ segments non superposés de longueur τ . Ensuite, la moyenne de chaque segment est calculée pour dériver la série temporelle de granularité grossière. Ce processus, appelé granulation grossière, peut être représenté comme suit :

$$y_j^{(\tau)} = \frac{1}{\tau} \sum_{a=(j-1)\tau+1}^{j\tau} w_a, 1 \leq j \leq \lfloor L/\tau \rfloor \quad (2.11)$$

où τ est appelé le facteur d'échelle et $y^{(1)}$ (c'est-à-dire $\tau = 1$) est la donnée d'origine. Lorsque $\tau > 1$, les données d'origine sont divisées en τ séries chronologiques à gros grains $y^{(\tau)}$ de longueur $\lfloor N/\tau \rfloor$ (où $\lfloor N/\tau \rfloor$ représente la plus grande intégrale inférieure à N/τ).

- DisEn est calculé pour chaque donnée à gros grains sous les mêmes paramètres que

$$EDM(W, \tau, m, c, d) = ED(y^{(\tau)}, m, c, d) \quad (2.12)$$

Le DisEn sur différentes échelles de temps sont dessinées en fonction du facteur d'échelle, et ce processus est appelé analyse de MDE. Le MDE surmonte les défauts de DisEn, qui ne mesure l'irrégularité de la série temporelle que sur une seule échelle. Cependant, le processus multi-échelle basé sur le grain grossier utilisé dans le MDE dépend fortement de la longueur de la série chronologique, et la fluctuation d'entropie sur plusieurs échelles augmentera avec l'augmentation du facteur d'échelle. De plus, les valeurs d'amplitude de la série temporelle de granularité grossière sont obtenues en calculant la moyenne de tous

les points de données dans chaque segment qui ne se chevauche pas, ce qui conduit inévitablement à la perte d'informations potentiellement utiles.

2.6. Les méthodes d'extraction de caractéristiques des signaux EEG

2.6.1. Transformée empirique en ondelettes

La transformée empirique en ondelettes (Empirical Wavelet Transform, EWT) est une nouvelle transformée en ondelettes adaptative capable de décomposer un signal de série temporelle $f(t)$ en sous-bandes temps-fréquence adaptatives en fonction de ses informations de fréquence contenues [12]. Cet avantage permet de générer des sous-bandes temps-fréquence étroites, contrairement à la transformée en ondelettes discrète où les sous-bandes temps-fréquence calculées dépendent de la fréquence d'échantillonnage du signal temporel. Pour fournir une ondelette adaptative par rapport au signal analysé, la segmentation du signal est une étape importante dans EWT. Elle peut être effectuée soit manuellement, soit au moyen du spectre de Fourier. Si le signal est segmenté manuellement, les limites des filtres d'ondelettes peuvent être sélectionnées par l'utilisateur en tant que segments contigus.

Dans ce travail, l'EWT utilisée pour la séparation du rythme est discutée en détail. L'EWT est utilisé pour extraire divers modes du spectre de Fourier du signal EEG en construisant une banque de filtres à ondelettes adaptatives. Les différentes étapes importantes utilisées par cette méthode sont décrites comme suit [13]:

Étape 1) Appliquer la FFT au signal $f(t)$, où $f(t)$ est un signal discret, $t = \{t_i\}$, $i = 1, 2, 3, \dots, n$, n désigne le nombre d'échantillons, le spectre de fréquence $X(w)$ est calculé, puis trouver l'ensemble des maxima $n = \{n_i\}$, $i = 1, 2, 3, \dots, m$ dans le spectre de Fourier et en déduire leurs fréquences correspondantes $w = \{w_i\}$, $i = 1, 2, \dots, m$. Ici, m désigne le nombre de maxima.

Étape 2) Le spectre de Fourier du signal EEG est correctement séparé par la méthode de détection des limites. La frontière de chaque segment peut être définie en prenant le milieu de deux maxima locaux progressifs exprimés par l'équation 2.13 Où W_i et W_{i+1} sont deux fréquences et l'ensemble des frontières est noté $\Omega = \{\Omega_1, \Omega_2, \dots, \Omega_{N-1}\}$

$$\Omega_i = \frac{W_i + W_{i+1}}{2} \quad (2.13)$$

Étape 3) Cette étape définit un banc de filtres adaptatifs de m filtre à ondelettes, qui est composé d'un filtre passe-bas et de $m - 1$ filtre passe-bande, basé sur les frontières. Les expressions de la transformée de Fourier d'une fonction d'échelle $\varphi_1(w)$ et des ondelettes empiriques $\psi_i(w)$ sont données par l'équation. 2.14 et 2.15.

$$\varphi = \begin{cases} 1, & |w| \leq (1 - \gamma)\Omega_i \\ \cos\left(\frac{\pi}{2} \alpha(\gamma, \Omega_1)\right) & (1 - \gamma)\Omega_1 < |w| \leq (1 + \gamma)\Omega_1 \\ 0, & \text{Par ailleurs} \end{cases} \quad (2.14)$$

$$\psi_i = \begin{cases} 1(1 + \gamma)\Omega_i < |w| < (1 - \gamma)\Omega_{i+1} \\ \cos\left(\frac{\pi}{2} \alpha(\gamma, \Omega_{i+1})\right) & (1 - \gamma)\Omega_{i+1} \leq |w| \leq (1 + \gamma)\Omega_{i+1} \\ \sin\left(\frac{\pi}{2} \alpha(\gamma, \Omega_i)\right) & (1 - \gamma)\Omega_i \leq |w| \leq (1 + \gamma)\Omega_i \\ 0, & \text{Par ailleurs} \end{cases} \quad (2.15)$$

Ou, $\alpha(\gamma, \Omega_{i+1}) = \beta\left(\left(\frac{1}{2\gamma\Omega_i}\right)(|w| - (1 - \gamma)\Omega_i)\right)$, γ garantit qu'il n'y a pas de chevauchement entre deux transitions successives et forme également le cadre serré entre la fonction d'échelle empirique et les ondelettes empiriques, l'expression de γ est formulée dans l'équation 2.16 et $\beta(x)$ est une fonction aléatoire définie dans l'équation 2.17. L'équation du cadre serré peut être définie comme suit [30] :

$$\gamma < \min_i \left(\frac{\Omega_{i+1} - \Omega_i}{\Omega_{i+1} + \Omega_i} \right) \quad (2.16)$$

$$\beta(x) = \begin{cases} 0 & x \leq 0 \\ 1 & x \geq 1 \\ \beta(x) + \beta(1 - x) = 1, & x \in (0,1) \end{cases} \quad (2.17)$$

Étape 4) pour extraire IA et IF de chaque mise à l'échelle du mode IMF, et des fonctions d'ondelettes sont exécutées. Dans l'équation 2.18 coefficients approximatifs, qui sont le produit de la fonction d'échelle avec le signal analysé f sont définis.

$$W_f(0, t) = \langle f, \phi_i \rangle = \int f(\tau) \overline{\phi_i(\tau - t)} d\tau \quad (2.18)$$

De même, lorsque le signal analysé f est multiplié par une ondelette empirique, nous obtenons des coefficients détaillés du signal défini dans l'équation 2.19.

$$W_f(i, t) = \langle f, \psi_i \rangle = \int f(\tau) \overline{\psi_i(\tau - t)} d\tau \quad (2.19)$$

Ou, $W_f(i, t)$ désigne les coefficients détaillés pour le $i^{\text{ème}}$ banc de filtres au $t^{\text{ème}}$ instant.

Enfin, la reconstruction des signaux de sous-bandes peut être définie dans l'équation 2.20

$$f(t) = W_f(0, t) * \Phi_1(t) + \sum_{i=1}^N W_f(i, t) * \Psi_i(t) \quad (2.20)$$

2.6.2. Représentation temps-fréquence

La représentation temps-fréquence encapsule les informations temporelles et spectrales dans une seule représentation. La méthode de la transformée de Hilbert (HT) est utilisée pour la représentation temps-fréquence des signaux EEG. Soit $y(t)$ le signal analysé qui se décompose en nombre N de signaux de sous-bandes $y_i(t) : i = 1, 2, 3, \dots, N$. Ces signaux en sous-bande ne sont rien d'autre qu'une modulation à bande étroite [14]. Le TH est appliqué pour résoudre les composantes d'amplitude instantanée (IA) et de fréquence instantanée (IF) à partir de chaque N de signaux de sous-bande. Expression de la représentation du signal analytique de chaque signal de sous-bande en termes de fonction de transformée de Hilbert (HT) [15] comme indiqué dans l'équation 2.21. Le terme conjugué dans l'équation 2.21 définit la fonction de Hilbert. La figure 2.2 montre la fonction de travail de la transformée de Hilbert.




Figure.2.2. Méthode de transformation de Hilbert pour la représentation temps-fréquence.

$$y_{+i}(t) = y_i(t) + jH[y_i(t)] \quad (2.21)$$

Une autre forme d'équation 2.21 peut être représenté par l'équation 2.22.

$$y_{+i}(t) = A_i(t)e^{j\Phi_i(t)} \quad (2.22)$$

$A_i(t)$ Amplitude Instantanée (AI) est formulée par l'équation 2.23.

$$A_i(t) = \sqrt{(jH[y_i(t)])^2 + y_i^2(t)} \quad (2.23)$$

Phase instantanée $\Phi_i(t)$ exprimée en l'équation 2.24.

$$\Phi_i(t) = \arctan\left(\frac{H[y_i(t)]}{y_i(t)}\right) \quad (2.24)$$

La fréquence instantanée (FI) est exprimée en termes de $f_i(t)$ dans l'équation 2.25.

$$f_i(t) = \frac{1}{2\pi} \frac{d}{dt} [\Phi_i(t)] \quad (2.25)$$

Les coefficients du temps-fréquence de chaque niveau de décomposition sont exprimés comme suit [16]:

$$Tf_i(f, t) = A_i(t)\delta[f - f_i(t)] \quad (2.26)$$

2.6.3. Estimation de la densité spectrale de puissance croisée

La densité spectrale de puissance croisée (Cross power spectral density, *CPSD*), (ou fonction spectrale d'intercorrélacion) de deux fonctions aléatoires $X(t)$ et $Y(t)$ stationnaires et ergodiques h l'ordre deux est, d'après le théorème de Wiener-Kintchine, la transformée de Fourier (TF) de la fonction d'intercorrélacion [17,18]:

$$CCF_{xy} = \frac{1}{N} \sum_{k=0}^{N-k-1} (x_k - \bar{x})(y_{k+\tau} - \bar{y}), \quad k = 0, \dots, N - 1, \quad (2.27)$$

$$CPSD_{xy}(f) = FFT\{CCF_{xy}(\tau)\} = \frac{1}{N\Delta t} X(f) \cdot Y^*(f) \quad (2.28)$$

où CCF_{xy} est la fonction de corrélation croisée de x et y , \bar{x} est la moyenne de x , N est la taille de l'échantillon de la série temporelle, FFT désigne la transformation de Fourier rapide, Δt est l'intervalle d'échantillonnage, $X(f)$ est la transformée de Fourier de x , et $Y^*(f)$ est le complexe conjugué de $X(f)$. La plage de sommation dans le calcul du CCF_{xy} était limitée à la plage de données superposées disponibles des séries temporelles x et y . Le $CPSD_{xy}$ affiche les crêtes aux fréquences qui sont présente dans les deux signaux comparés et peut ainsi être utilisé pour détecter les rythmes communs dans les deux signaux.

2.7. Méthodes de sélection des caractéristiques

Les méthodes de classement sont l'une des méthodes les plus rapides dans le problème de sélection de fonctionnalités. Le classement des caractéristiques est utilisé pour sélectionner un sous-ensemble de fonctionnalités, ce qui réduira la complication des classificateurs sans faire de différence dans ses performances. Dans notre travail, les différentes méthodes de sélection des caractéristiques, à savoir l'algorithme test-t et le test de Wilcoxon, sont utilisées pour classer les caractéristiques significatives.

2.7.1. Test-t de Student

La méthode du test-t de Student est utilisée pour déterminer si la moyenne de deux ensembles est différente ou non. Le test donne les valeurs p et t des caractéristiques extraites pour les deux groupes de données. Statistiquement, une valeur p faible est préférée ($p < 0,05$) et une valeur t plus élevée améliore le classement. Par conséquent, dans ce travail, les caractéristiques à faible valeur p sont sélectionnées et les valeurs t sont utilisées pour les classer. Ces méthodes de classement des caractéristiques sont brièvement expliquées ci-dessous [27].

2.7.2. Test de Wilcoxon

Le test de Wilcoxon appartient à la classe des tests non paramétriques, qui utilise une procédure basée sur les rangs. Dans cette méthode, le test de Wilcoxon non apparié à deux échantillons est appliqué pour le classement des caractéristiques. La méthode est également appelée test de Wilcoxon-Mann-Whitney et utilise l'ampleur des statistiques U résultantes pour classer les caractéristiques [28].

2.8. Classificateurs

Pour évaluer les classificateurs, la technique de validation croisée de dix fois est utilisée [19]. Dans cette technique, l'ensemble des caractéristiques est divisé en dix parties égales. Pour la formation du classificateur, neuf parties des données sont utilisées et le classificateur formé est évalué à l'aide de la partie restante (test). Le processus est répété dix fois (plis) en utilisant différentes parties de l'ensemble de données d'entraînement et de test. La moyenne des dix plis donne la mesure de performance réelle. L'objectif d'une technique d'exploration de données est de déterminer la combinaison optimale d'ensemble de caractéristiques et de classificateur qui donne la meilleure précision de classification. Dans ce travail, nous avons évalué les classificateurs KNN, DT, SVM et MLPNN.

2.8.1. Classificateur d'arbre de décision (DT)

L'apprentissage par arbre de décision est l'une des méthodes d'inférence inductive les plus utilisées et les plus pratiques [20-22]. Le classificateur d'arbre de décision est une méthode d'approximation de fonctions à valeurs discrètes, dans laquelle la fonction apprise est représentée par un arbre de décision. Les arbres appris peuvent également être représentés comme des ensembles de règles si-alors qui peuvent améliorer la lisibilité humaine. De plus, les résultats des classificateurs d'arbres de décision peuvent être directement comparés aux règles utilisées par les médecins lors de l'évaluation de l'EEG. Comme dans le cas du classificateur par arbre de décision, nous pouvons également dériver des règles d'association [23] qui peuvent être utilisées pour découvrir des relations intéressantes entre les caractéristiques calculées et les stades neurophysiologiques. Nous avons utilisé l'algorithme ID3 pour créer un arbre de décision. Il utilise la procédure de recherche gourmande et la stratégie d'apprentissage à partir d'exemples. Bien qu'il existe des algorithmes plus avancés (IDA), l'algorithme ID3 est très utile pour faire des arbres de décision simples.

2.8.2. Classificateur des k plus proches voisins (KNN)

K-plus proche voisin (K-NN) est un classificateur simple et robuste. Le classificateur fonctionne en comparant les données de test avec les données d'apprentissage. Le classificateur trouve le voisinage K dans les données d'apprentissage et attribue la classe qui apparaît le plus fréquemment dans le voisinage de K [24]. La valeur par défaut de K est 1 et le paramètre de similarité d'objet de voisinage par défaut est la distance euclidienne, comme indiqué dans l'équation 2.29. Dans cette thèse, la valeur de K est fixée à 1.

$$d(X_i, X_j) = \sqrt{\sum_i (X_i, X_j)^2} \quad (2.29)$$

2.8.3. Réseaux de neurones artificiels (MLPNN)

Dans la thèse, nous avons également utilisé le réseau de neurones artificiels (ANN) à des fins de comparaison. Le représentant le plus couramment utilisé des ANN est le perceptron multicouche (MLP) [98]. MLP est l'ANN prédictif le plus couramment utilisé, en raison de sa facilité de mise en œuvre et de ses exigences d'ensemble de formation plus petites. Le modèle MLP mappe des ensembles de données d'entrée sur un ensemble de sorties appropriées. MLP peut résoudre des tâches de classification complexes, mais il risque de surajuster les données d'apprentissage et cela prend beaucoup de temps. Le schéma illustré à la figure 2.3 illustre un réseau MLP à trois couches.

Toutes les configurations testées avaient 10 à 30 entrées (selon le nombre d'entités d'entrée NF), une couche cachée et 2 à 10 sorties (selon le nombre de classes NC). La couche cachée était constituée d'éléments NH, où $NH = NF + NC$. Les poids initiaux ont été définis de manière aléatoire et toutes les caractéristiques en entrée ont été normalisées. Le nombre de cycles pour entraîner un réseau de neurones a été défini entre 100 et 500, selon la taille de l'ensemble de données.

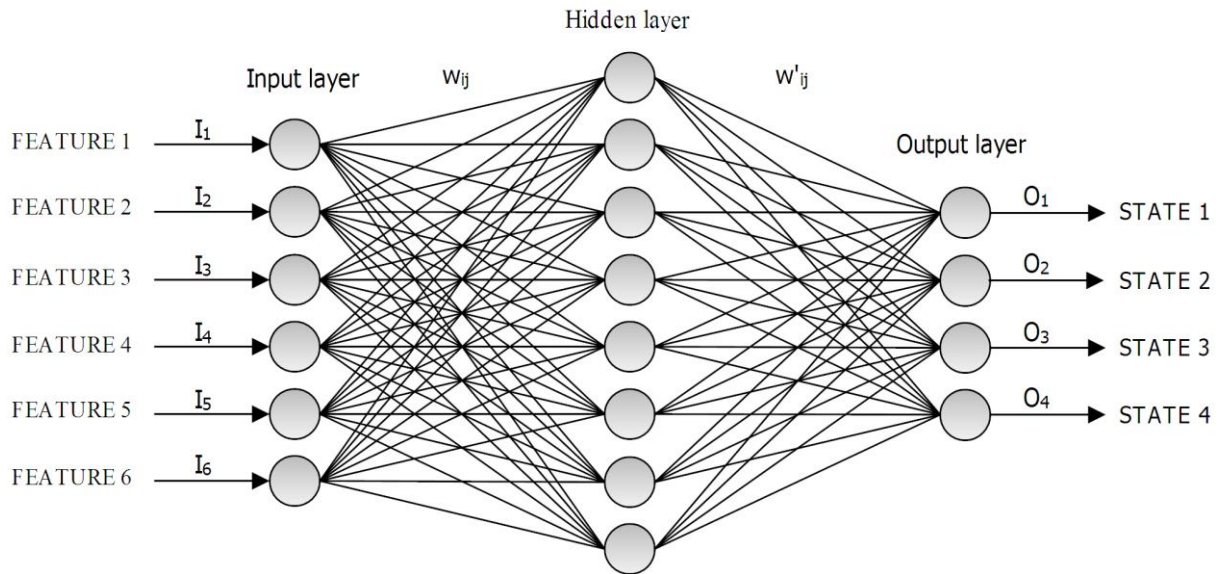


Figure.2.3. Exemple d'architecture de réseau perceptron multicouche (6 entrées, une couche cachée à 8 éléments et 4 sorties).

2.8.4. Machine à vecteur de support (SVM)

SVM est un réseau monocouche hautement non linéaire qui optimise la limite de séparation des classes de sorte que la distance entre les entités appartenant à une classe donnée et l'hyperplan soit simultanément maximisée [25]. SVM est un classificateur supervisé qui a une capacité de généralisation dans le sens où il peut classer correctement un motif invisible [26]. Si $(x_i, y_i), i = 1: N$ est l'ensemble de données, x_i est le i ème point du motif et y_i est l'étiquette de classe correspondante, alors soit $c +$ et $c -$ les centroïdes pour deux classes dans le problème de classification binaire. La sortie du classificateur sera:

$$y_i = \text{sgn}((x - c) \cdot W) = \text{sgn}((x \cdot c +) - (x \cdot c -) + b) \quad (2.30)$$

Avec :

$$b = \frac{1}{2} (\|c -\|^2 - \|c +\|^2) \quad (2.31)$$

L'hyperplan optimal séparant les deux classes et satisfaisant la condition donnée dans l'équation. 2. 30 est:

$$\text{minimize}_{w,b} \frac{1}{2} \|W\|^2 \quad (2.32)$$

tel que :

$$y_i((W \cdot x_i) + b) \geq 1, i = 1, \dots, N. \quad (2.33)$$

Le dual lagrangien de l'équation 2.32 est un problème de programmation quadratique utilisé pour trouver l'hyperplan optimal séparant les deux classes.

2.9. Conclusion

Dans ce chapitre, nous avons abordé les différentes principales étapes constituant un système de classification le syndrome d'apnées-hypopnées du sommeil ainsi que les approches les plus utilisées dans chaque étape. Ces étapes sont à savoir : Le débruitage des signaux ECG et EEG, la détection du complexe QRS, l'extraction des caractéristiques et la classification). Cet état de l'art nous met en position pour détailler les chapitres 3 et 4 dédié à les méthodes proposée pour l'identification du SAHS.

BIBLIOGRAPHIE

[1] Penzel, T., Moody, G. B., Mark, R. G., Goldberger, A. L., & Peter, J. H. (2000, September). The apnea-ECG database. In *Computers in Cardiology 2000*. Vol. 27 (Cat. 00CH37163) (pp. 255-258). IEEE.

- [2] Heneghan, C. (2011). St. Vincent's University Hospital/University College Dublin Sleep Apnea Database.
- [3] Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov PCh, M. R., Mietus, J. E., ... & Stanley, H. E. (2000). Components of new research resources for physiologic signals PhysioBank, Physio Toolkit. *Circulation*, 101, e215-e220.
- [4] Fariha, M. A. Z., Ikeura, R., Hayakawa, S., & Tsutsumi, S. (2020, June). Analysis of Pan-Tompkins algorithm performance with noisy ECG signals. In *Journal of Physics: Conference Series*(Vol. 1532, No. 1, p. 012022). IOP Publishing.
- [5] de Cheveigné, A., & Nelken, I. (2019). Filters: when, why, and how (not) to use them. *Neuron*, 102(2), 280-293.
- [6] Gonçalves, L. J., Farias, K., Kupssinskü, L., & Segalotto, M. (2021). The effects of applying filters on EEG signals for classifying developers' code comprehension. *Journal of applied research and technology*, 19(6), 584-602.
- [7] Pichot, V. (1999). Gaspoz JM, Molliex S, Antoniadis A, Busso T, Roche F, Costes F, Quintin L, Lacour JR, and Barthelemy JC. Wavelet transform to quantify heart rate variability and to assess its instantaneous changes. *J Appl Physiol*, 86, 1081-1091.
- [8] Gamero, L. G., Vila, J., & Palacios, F. (2002). Wavelet transform analysis of heart rate variability during myocardial ischaemia. *Medical and Biological Engineering and Computing*, 40(1), 72-78.
- [9] Rostaghi, M., & Azami, H. (2016). Dispersion entropy: A measure for time-series analysis. *IEEE Signal Processing Letters*, 23(5), 610-614.
- [10] Zheng, J., Pan, H., Liu, Q., & Ding, K. (2020). Refined time-shift multiscale normalised dispersion entropy and its application to fault diagnosis of rolling bearing. *Physica A: Statistical Mechanics and its Applications*, 545, 123641.
- [11] Azami, H., & Escudero, J. (2018). Coarse-graining approaches in univariate multiscale sample and dispersion entropy. *Entropy*, 20(2), 138.
- [12] Gilles, J. (2013). Empirical wavelet transform. *IEEE transactions on signal processing*, 61(16), 3999-4010.

- [13] Anuragi, A., & Sisodia, D. S. (2020). Empirical wavelet transform based automated alcoholism detecting using EEG signal features. *Biomedical Signal Processing and Control*, 57, 101777.
- [14] Bhattacharyya, A., Gupta, V., & Pachori, R. B. (2017, August). Automated identification of epileptic seizure EEG signals using empirical wavelet transform based Hilbert marginal spectrum. In *2017 22nd International Conference on Digital Signal Processing (DSP)* (pp. 1-5). IEEE.
- [15] Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... & Liu, H. H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, 454(1971), 903-995.
- [16] Ahrabian, A., Looney, D., Stanković, L., & Mandic, D. P. (2015). Synchrosqueezing-based time-frequency analysis of multivariate data. *Signal Processing*, 106, 331-341.
- [17] Knob, A., & Lacoume, J. L. (1977, July). Étude de la précision de l'estimation de la densité spectrale de puissance croisée, obtenue par transformation de fourier de la fonction de corrélation. In *Annales des Télécommunications* (Vol. 32, No. 7, pp. 248-256). Springer-Verlag.
- [18] Lu, W. A., Lin, J. F., Wang, C. H., Chen, Y. S., Shieh, Y. H., & Kuo, C. D. (2021). Cross-Spectral Analysis of Electrocardiographic and Nostril Airflow Signals Identifies Two Respiratory Frequencies of Heart Rate Modulation. *Journal of Healthcare Engineering*, 2021.
- [19] Lavesson, N., & Davidsson, P. (2007). Evaluating learning algorithms and classifiers. *International Journal of Intelligent Information and Database Systems*, 1(1), 37-52.
- [20] Polat, K., & Güneş, S. (2007). Classification of epileptiform EEG using a hybrid system based on decision tree classifier and fast Fourier transform. *Applied Mathematics and Computation*, 187(2), 1017-1026.
- [21] Schetinin, V., (2001). A Neural Network Decision Tree for Learning Concepts from EEG Data. , NIMIA-SC.

- [22] Yamada, Y., Suzuki, E., Yokoi, H., & Takabayashi, K. (2003). Decision-tree induction from time-series data based on a standard-example split test. In Proceedings of the 20th international conference on machine learning (ICML-03) (pp. 840-847).
- [23] Haselsteiner, E., & Pfurtscheller, G. (2000). Using time-dependent neural networks for EEG classification. *IEEE transactions on rehabilitation engineering*, 8(4), 457-463.
- [24] Sulaiman, N., Taib, M. N., Lias, S., Murat, Z. H., Aris, S. A. M., & Hamid, N. H. A. (2011, March). EEG-based stress features using spectral centroids technique and k-nearest neighbor classifier. In 2011 UkSim 13th international conference on computer modelling and simulation (pp. 69-74). IEEE.
- [25] Cristianini, N. Shawe-Taylor, J.(2000). An introduction to support vector machines: And other kernel-based learning methods.
- [26] Gunn, S. R. (1998). Support vector machines for classification and regression. *ISIS technical report*, 14(1), 5-16.
- [27] Acharya, U. R., Vidya, K. S., Ghista, D. N., Lim, W. J. E., Molinari, F., & Sankaranarayanan, M. (2015). Computer-aided diagnosis of diabetic subjects by heart rate variability signals using discrete wavelet transform method. *Knowledge-based systems*, 81, 56-64.
- [28] Derryberry, D. R., Schou, S. B., & Conover, W. J. (2010). Teaching rank-based tests by emphasizing structural similarities to corresponding parametric tests. *Journal of Statistics Education*, 18(1).

Chapitre 3

Reconnaissance automatisée du SAHS à l'aide de la transformation en ondelettes continues et de l'entropie de dispersion multi-échelles des signaux ECG

3.1. Introduction

Le syndrome d'apnée-hypopnée du sommeil (SAHS) est une maladie respiratoire qui provoque une fermeture partielle ou totale des voies respiratoires supérieures pendant le sommeil [1, 2]. L'apnée obstructive du sommeil s'accompagne d'une diminution du taux d'oxygène dans le sang, avec une obstruction des voies respiratoires (fermeture partielle ou complète) durant au moins 10 secondes et jusqu'à 3 minutes. Par conséquent, le corps fait un effort important pour respirer, mais l'air ne le traverse pas [3]. L'hypopnée est une réduction de 50 % du débit respiratoire pendant au moins 10 secondes, accompagnée d'une réduction minimale de 3 % de la saturation en oxygène [4]. L'indice d'apnée-hypopnée du sommeil mesure le nombre et les limites d'apnées par heure pendant le sommeil. La sévérité de l'apnée du sommeil peut être évaluée : normale (<5), légère (5-15), modérée (15-30) et sévère (>30) [5].

La polysomnographie (PSG) est l'examen médical le plus complet et le plus précis conçu pour enregistrer les différentes étapes du sommeil en captant les rythmes électriques du corps [6]. Le PSG comprend généralement l'électrocardiogramme (ECG), l'électrocardiogramme (EOG), l'électromyographie (EMG), l'électroencéphalographie (EEG), l'oxymétrie, le débit d'air nasal, le débit d'air oral, les sons de la cavité trachéale et thoracique. Cependant, il présente certains inconvénients, tels que le coût et l'inconfort du patient [7].

En conséquence, des dispositifs et des technologies pouvant en quelque sorte remplacer le PSG est nécessaires pour détecter le SAHS. Un électrocardiogramme (ECG) est l'un des principaux signaux utilisés pour dépister le SAHS [8]. Les effets de l'apnée du sommeil sur le système cardiovasculaire ont été observés indirectement. Par conséquent, il est possible de détecter les conséquences de l'apnée obstructive du sommeil sur le système cardiovasculaire via le signal ECG. Les changements causés par des facteurs neurologiques automatiques et mécaniques dans un électrocardiogramme (ECG) pourraient être un signe d'apnée récurrente.

Dans ce cas, il existe des modifications périodiques de la fréquence cardiaque et de l'amplitude de l'électrocardiogramme ou de la morphologie [9]. Plus précisément, des études ont montré que le signal de la variabilité de la fréquence cardiaque (HRV) contient des informations pertinentes sur l'apnée obstructive du sommeil (AOS).

3.2. Revue de littérature

de Chazal et al ont proposé un algorithme de classification automatique des périodes d'apnée du sommeil à l'aide de signaux ECG. La méthodologie de cette étude était basée sur la collecte de 70 résultats d'ECG à dérivation unique, dont la moitié a été utilisée pour la formation et l'autre moitié pour les données de test. Les 128 caractéristiques dérivées basées sur des estimations des domaines temporel et spectral du signal HRV se sont révélées plus pertinentes [10]. de Chazal et al ont ensuite utilisé les signaux HRV et EDR pour dériver 88 caractéristiques simultanées dans les domaines temporel et spectral. Les deux classificateurs utilisés dans cette étude sont la discrimination linéaire (LD) et la discrimination quadratique (QD) [11]. Hossen et al ont annoncé une méthode automatisée pour détecter l'apnée du sommeil à partir des signaux HRV basée sur un algorithme de décision souple de décomposition en sous-bandes [12]. Khandoker et al ont proposé un algorithme utilisant la décomposition en ondelettes du signal ECG et un réseau de neurones à réaction directe (NN) à deux étages et ont rapporté une précision de 94,84 % dans la classification de l'AOS [13]. Dans une autre étude, Mendez et al (2010) ont utilisé une décomposition de mode empirique des signaux ECG pour la détection d'apnée et ont rapporté une précision de 85 % pour les classificateurs LD et QD [14]. BSoul et al ont présenté une application pour les systèmes d'exploitation Android basée sur un classificateur de machine à vecteurs de support (SVM) capable de détecter l'AOS au niveau national. En utilisant un large éventail de fonctionnalités dans les domaines temporel et fréquentiel, un classificateur SVM a été formé et il en est résulté une précision de 89,88 % [15]. Nguyen et al utiliser une technique non linéaire pour analyser le signal HRV afin de détecter l'AOS. L'analyse de quantification de la récurrence (AQR) est utilisée pour extraire la complexité cachée présente dans le signal HRV [16]. Atri et Mohebbi ont démontré l'efficacité de la combinaison de méthodes linéaires et non linéaires dans l'analyse des signaux HR et EDR. Ils ont développé un algorithme pour la détection AOS utilisant de nouvelles fonctionnalités basées sur l'analyse bispectrale et spectrale des signaux HRV et EDR [17]. Janbakhshi et Shamsollahi ont proposé une approche pour détecter l'apnée du sommeil à partir de caractéristiques qui reposent sur des signaux respiratoires dérivés d'un électrocardiogramme (EDR) en utilisant diverses caractéristiques dans les domaines temporel et fréquentiel et le classificateur ANN [18]. Les propriétés de fluctuation de la HRV ont été examinées à l'aide de l'entropie d'approximation floue sur des segments de HRV de 5 minutes de patients d'AOS [19]. Feng et al suggéré un apprentissage non supervisé des fonctionnalités

à l'aide d'un modèle d'encodeur automatique. Ils ont utilisé le modèle de Markov caché (HMM) comme classificateur et ont atteint une précision de 85 % [20].

Les auteurs	Nombre de caractéristiques extraites	Méthode	Précision	Sensibilité	Spécificité
[11]	84	Fonctionnalités de domaine temporel et PSD des signaux HRV et EDR avec classificateurs LD et QD	90%	86.4%	92.3%
[13]	45	Modèle de réseau de neurones à réaction en deux étapes utilisant des caractéristiques d'ondelettes à partir de signaux ECG	94.84%	/	/
[21]	72	Dépistage de l'apnée du sommeil par modèles autorégressifs à partir d'une seule dérivation ECG	88%	85%	90%
[22]	510	Analyse par paquets d'ondelettes des signaux ECG à court terme	91.08%	91.02%	91.09%
[15]	111	Caractéristiques temporelles et spectrales de HRV	91.16%	89.12%	92.35%

		et EDR			
[16]	72	Quantification de la récurrence du signal HRV	85.26%	83.47%	86.37%
[17]	22	Analyse bispectrale et spectrale des signaux HRV et EDR	95.57%	98.64%	92.51%
[23]	12	Fonctions de bande intrinsèques (IBF) des signaux EDR et HRV	/	78.02%	74.64%
[24]	12	Extraction du signal EDR de l'algorithme PCA	85%	86%	85%
Notre étude [25]	24	CWT + MSE	98% * 95% ** 87% *** 93% #	98% * 94% ** 89% *** 96% #	98% * 95% ** 84% *** 93% #

* : N vs ASO ; ** : N vs Hyp ; *** :ASO vs Hyp ; # :N vs (ASO & Hyp)

Tableau.3.1. Résumé des résultats des recherches antérieures.

3.3. Principe de la méthode

La figure 3.1 illustre la structure générale de la technique suggérée dans cette recherche pour identifier le SAHS à l'aide du signal HRV. Dans ce travail, vingt-quatre nouveaux indices de signal HRV sont présentés pour la reconnaissance SAHS. Ces indices sont calculés en prenant la moyenne des échelles de temps petite (1 à 5), moyenne (6 à 10) et grande (11 à 20) de la MDE des signaux de sous-bande décrits dans cette étude. La méthode suggérée commence par estimer le spectre de puissance du signal HRV à l'aide de la méthodologie CWT, à partir de laquelle l'image du spectre temps-fréquence est générée. Deuxièmement, sur la base de l'importance physiologique du signal HRV, l'image CWT est divisée en plusieurs bandes de fréquences, produisant quatre sous-scalogrammes. Troisièmement, la méthode

ICWT est utilisée pour convertir les sous-scalogrammes en sous-bandes. Enfin, vingt-quatre indices uniques sont dérivés en examinant la moyenne des petites, moyennes et grandes échelles de temps du MDE de divers signaux de sous-bandes. Afin d'évaluer les performances de la méthode proposée pour identifier SAHS, l'arbre de décision (DT), la machine à vecteurs de support (SVM-RBF) et les classificateurs K-plus proche voisin (KNN) sont appliqués aux vingt-quatre nouveaux indices.

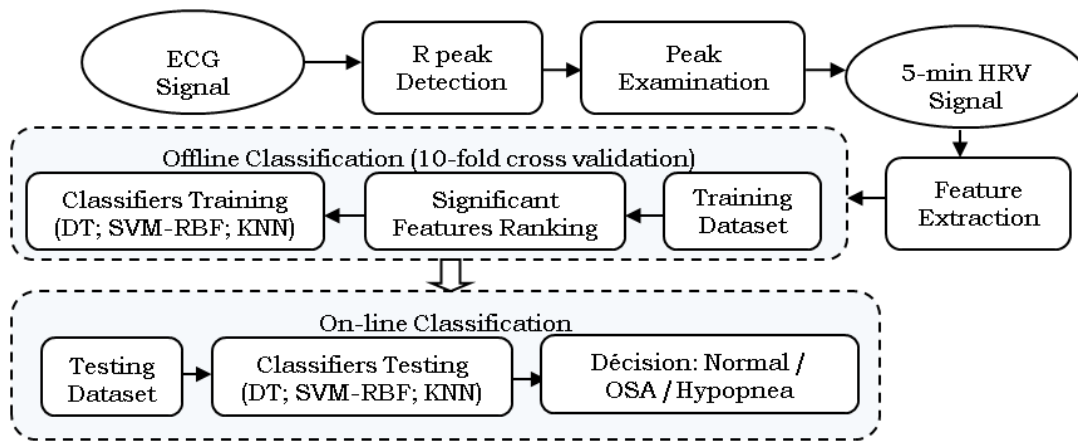


Figure.3.1. Schéma fonctionnel de la méthode proposée pour la détection du syndrome d'apnée-hypopnée du sommeil (SAHS)

3.3.1. Prétraitement

La détection précise du complexe QRS est essentielle pour produire un signal HRV optimal à partir des enregistrements ECG. La méthode que nous proposons pour la délimitation des complexes QRS est basée sur une analyse multi-résolution par la transformée en ondelettes. Dans les applications en ondelettes, l'ondelette mère choisie est extrêmement importante. En réalité, il n'existe pas de critère bien défini pour sélectionner l'ondelette mère, et cette décision est fortement dépendante de la nature de l'application et varie d'une application à l'autre. Plusieurs études d'analyse en ondelettes du signal ECG ont découvert que la famille des ondelettes « Daubechies », en particulier l'ondelette « db6 », est la mieux adaptée pour le traitement du signal ECG puisque sa forme est comparable au complexe QRS [26]. En conséquence, l'ondelette mère de Daubechies "db6" sera utilisée pour décomposer le signal ECG tout au long de ce travail. Le niveau de décomposition choisi est également un facteur à considérer. Dans cet algorithme, nous avons divisé le signal ECG en neuf niveaux [27]. Ce choix judicieux permet de bien distinguer le complexe QRS, les ondes P, les ondes T

et la ligne de base. La détection du pic R est l'étape la plus cruciale dans l'identification du complexe QRS puisque la précision des ondes suivantes dépend de cette étape initiale. L'ondelette db6 est utilisée pour produire neuf niveaux de décomposition en ondelettes sur les données ECG prétraitées. Toutes les informations sauf D3 à D6 sont conservées, tandis que le reste est effacé. Le signal est donc reconstruit à partir des détails D3-D6, permettant de conserver les complexes QRS du signal tandis que les autres composantes aux basses et hautes fréquences sont éliminées. La méthode de Pan-Tompkins a été utilisée pour identifier le complexe QRS à partir du signal préalablement filtré [28]. Une fois que les pics R ont été identifiés, le signal HRV peut être généré facilement et précisément. La variation des intervalles RR successifs produit un signal HRV.

3.3.2. Extraction de bandes de fréquence et caractéristiques non linéaires

CWT et ICWT ont été appliqués séquentiellement pour extraire les bandes VLF, LF et HF du signal HRV. Contrairement à la transformée en ondelettes discrète, la CWT a une gradation plus fine pour le paramètre d'échelle, ce qui permet une identification plus précise des limites de largeur de bande [29]. De plus, la suppression des coefficients sélectionnés en dessous de 0,003 Hz avant la transformation inverse permet d'éliminer la tendance et la composante continue en une seule étape. Le CWT a d'abord été utilisé pour générer les coefficients d'ondelettes dans la représentation temps-fréquence. Les limites inférieure et supérieure de fréquence obtenues à partir de cette transformation dépendent de la fonction d'ondelettes utilisée, de la durée de l'enregistrement et de sa fréquence d'échantillonnage.

Avant d'effectuer ICWT, les coefficients d'ondelettes résultants ont été limités en fréquence en mettant à zéro tous les coefficients situés en dessous et au-dessus des largeurs de bande d'intérêt. Les coefficients non masqués résultants ont été retransformés dans le domaine temporel en appliquant ICWT pour récupérer les bandes VLF, LF et HF [30]. Le masquage des coefficients indésirables et la transformation inverse ont été effectués trois fois pour chaque signal HRV. Ce processus équivaut à utiliser trois filtres passe-bande différents avec des fréquences de coupure nettes pour extraire les trois largeurs de bande d'intérêt. The wavelet function we used was the Morse wavelet, which is a family of exactly analytic complex valued functions useful for analyzing signals modulated in amplitude and frequency [31].

Les caractéristiques non linéaires, telles que l'entropie de dispersion multi-échelle (MDE), sont calculées à partir de chaque signal de sous-bande. Nous avons calculé la moyenne des valeurs MDE pour chaque signal de sous-bande sur trois échelles de temps : petite (1 à 5), moyenne (6 à 10) et grande (11 à 20).

3.3.3. Sélection de caractéristiques

La sélection de caractéristiques est utilisée pour sélectionner un sous-ensemble de fonctionnalités. Cela réduit la complexité du classificateur sans faire de différence dans les performances. Dans notre travail, la méthode de sélection de caractéristiques que nous avons adoptée est le test-t de Student. La méthode du test-t de Student est utilisée pour déterminer si la moyenne des deux groupes est différente. Le résultat de ce test est la valeur p des caractéristiques calculées des deux classes. La valeur de p est utilisée pour classer les caractéristiques. Les caractéristiques avec une faible valeur de p sont considérées comme plus discriminantes [32]. La sélection du test-t de Student a été utilisé pour confirmer les différences entre les groupes normaux et SAHS. À une valeur $p < 0,001$, la signification de l'indice a été supposée. Après classement à l'aide de la technique du test t, 24 caractéristiques d'identification des épisodes de syndrome d'apnée-hypopnée du sommeil (SAHS) ont été extraites des bases de données « Apnea-ECG dataset » et « UCD dataset ».

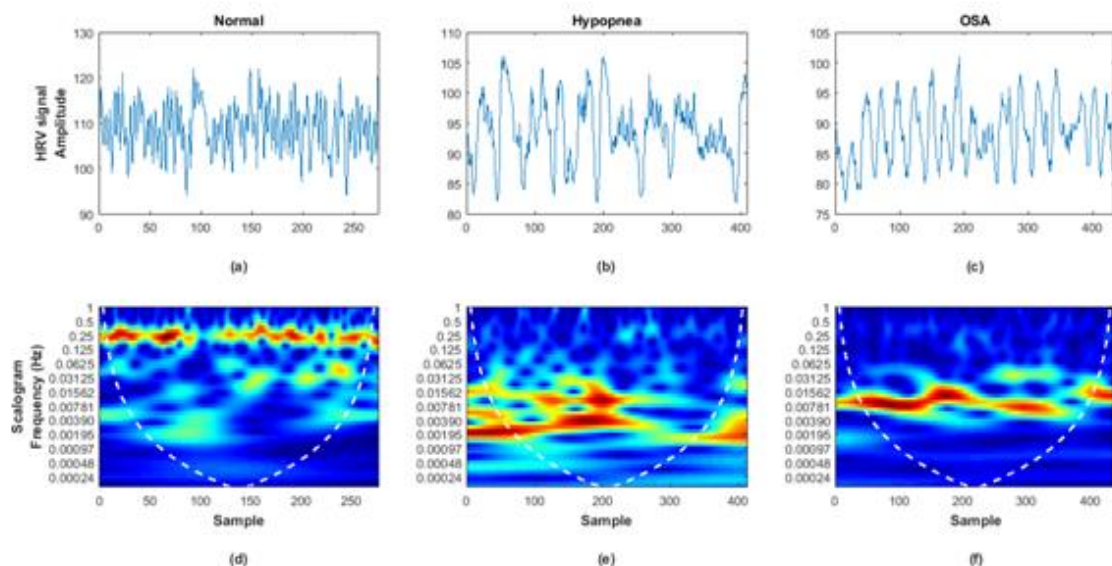


Figure.3.2. Segments HRV de courte durée de 5 minutes (haut). Scalogramme de puissance couleur 3D de HRV (bas). La couleur représente le scalogramme de puissance. (a, d) épisode normal ; (b, e) épisode d'hypopnée ; (c, f) épisode d'AOS

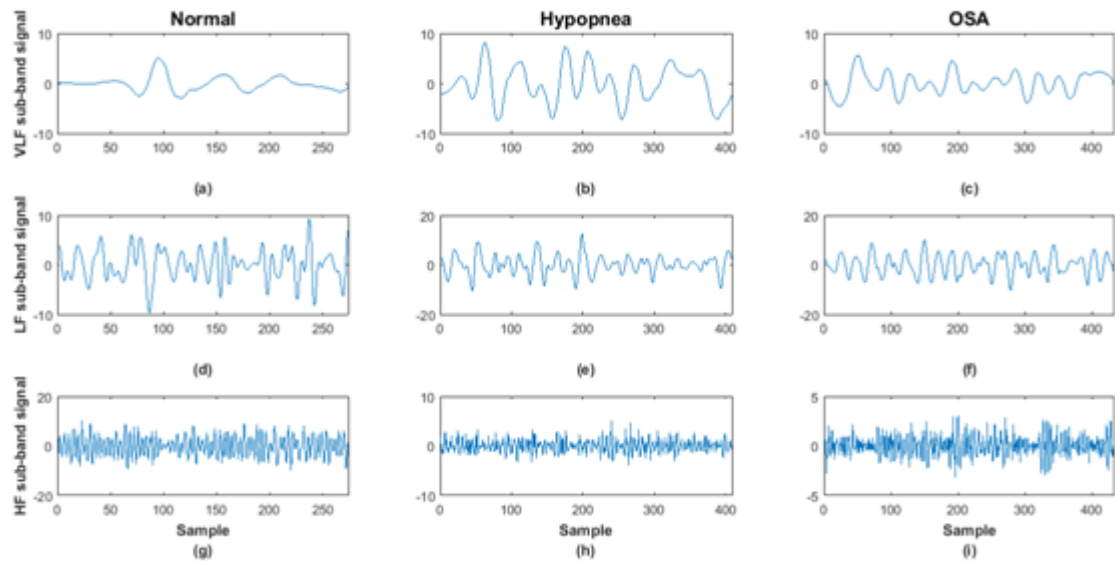


Figure.3.3. Le signal de sous-bande VLF reconstruit par ICWT (à gauche). Signal de sous-bande LF reconstruit par ICWT (au centre). Signal de sous-bande HF reconstruit par ICWT (à droite). (a, d et g) appartient aux épisodes normaux ; (b, e et h) appartient aux épisodes d'hypopnée ; (c, f et i) appartient aux épisodes d'AOS




Figure.3.4. Les courbes d'entropie de dispersion multi-échelle calculées et les graphiques à barres pour Normal & OSA (A, D), Normal & Hypopnea (B, E) et OSA & Hypopnea (C, F), qui ont été obtenus à partir du signal (VLF)

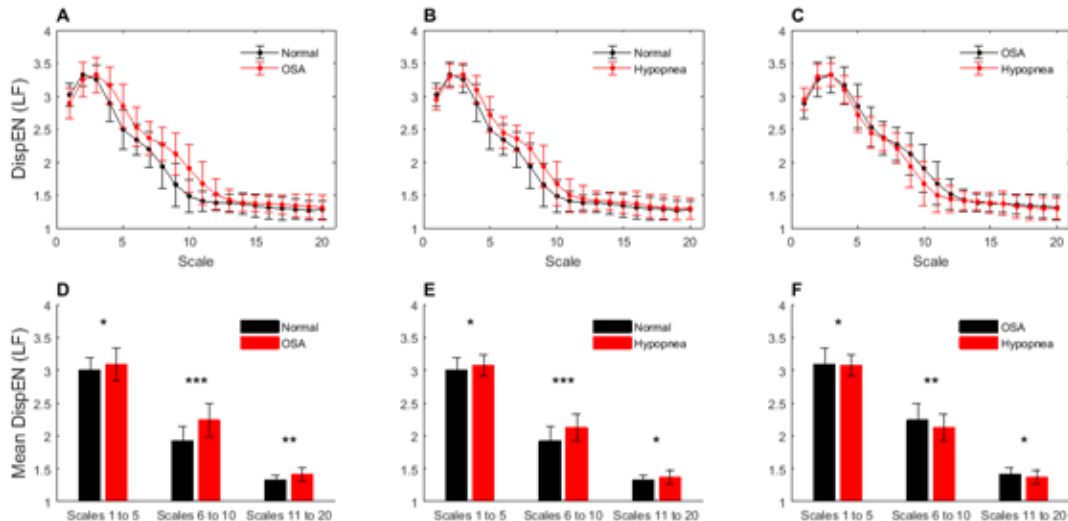


Figure.3.5. Les courbes d'entropie de dispersion multi-échelle calculées et les graphiques à barres pour Normal & OSA (A, D), Normal & Hypopnea (B, E) et OSA & Hypopnea (C, F), qui ont été obtenus à partir du signal (LF)

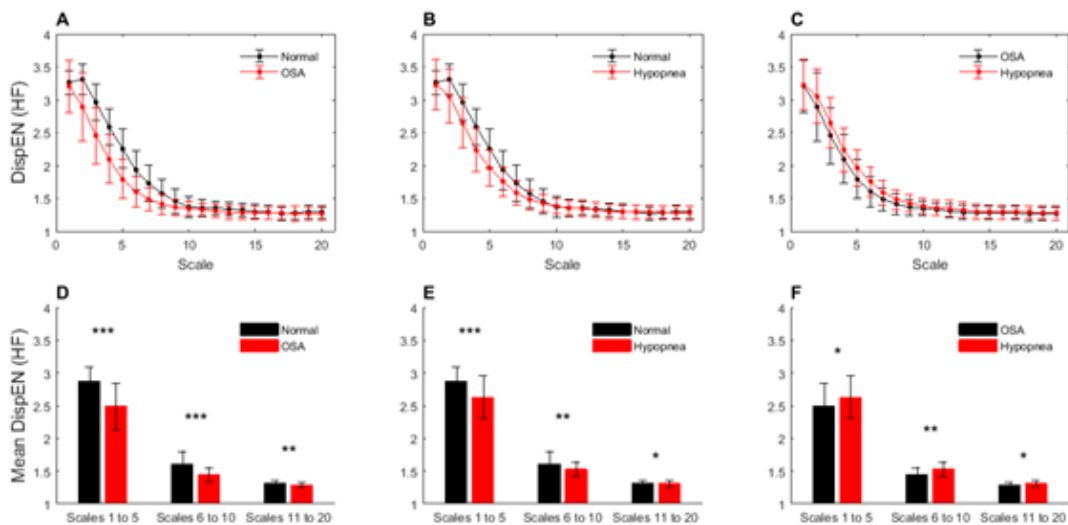


Figure.3.6. Les courbes d'entropie de dispersion multi-échelle calculées et les graphiques à barres pour Normal & OSA (A, D), Normal & Hypopnea (B, E) et OSA & Hypopnea (C, F), qui ont été obtenus à partir du signal (HF)




Figure.3.7. Les courbes d'entropie de dispersion multi-échelle calculées et les graphiques à barres pour Normal & OSA (A, D), Normal & Hypopnea (B, E) et OSA & Hypopnea (C, F), qui ont été obtenus à partir du signal (TP)

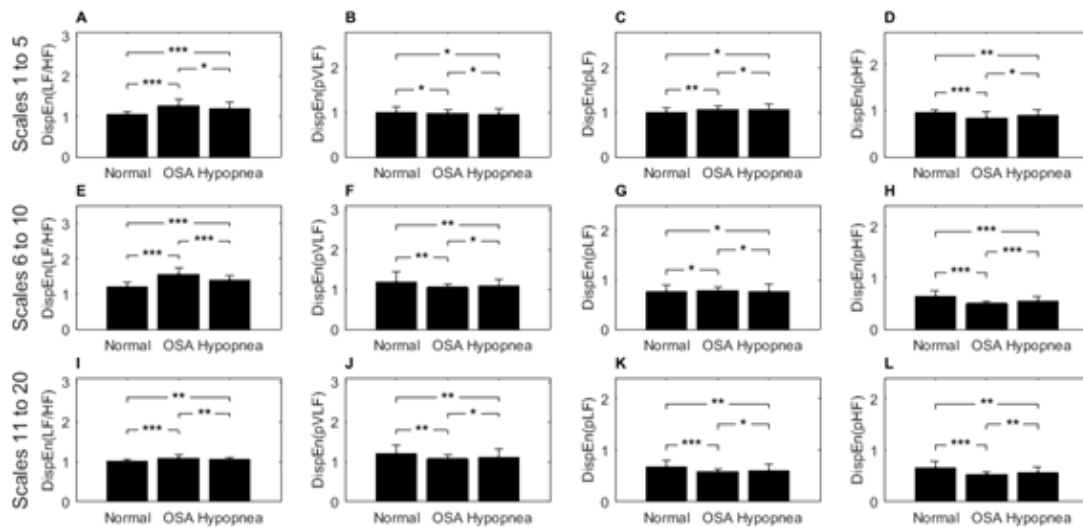


Figure.3.8. Statistiques des caractéristiques de MDE pour Normal, OSA et Hypopnée groupées par échelles de temps courtes (1 à 5), moyennes (6 à 10) longues (11 à 20). (A, E et I) pour $DispEn_{LF/HF}$; (B, F et J) pour $DispEn_{pVLF}$; (C, G et K) pour $DispEn_{pLF}$; (D, H et L) pour $DispEn_{pHF}$. *, **, *** représentent $p < 0,01$, $p < 0,001$, $p < 0,0001$, respectivement.

Indice	Moyenne	Normal (Mean ± SD)	OSA (Mean ± SD)	p-value Normal –OSA
DispEn_VLF		2.9865 ± 0.1197	2.8563 ± 0.1827	0***
DispEn_LF		2.9996 ± 0.1885	3.0955 ± 0.2464	0*
DispEn_HF		2.8755 ± 0.2198	2.4879 ± 0.3608	0***
DispEn_TP	Échelles	3.0280 ± 0.3043	2.9509 ± 0.1414	0*
DispEn_LF/HF	1 to 5	1.0464 ± 0.0721	1.2643 ± 0.1730	0***
DispEn_pVLF		0.9985 ± 0.1321	0.9707 ± 0.0839	0*
DispEn_pLF		0.9984 ± 0.0952	1.0516 ± 0.0995	0*
DispEn_pHF		0.9553 ± 0.0745	0.8450 ± 0.1286	0***
DispEn_VLF		2.9685 ± 0.1243	3.0360 ± 0.1649	0**
DispEn_LF		1.9218 ± 0.2185	2.2381 ± 0.2492	0***
DispEn_HF		1.6115 ± 0.1852	1.4437 ± 0.1088	0***
DispEn_TP	Échelles	2.5821 ± 0.4007	2.8954 ± 0.1401	0***
DispEn_LF/HF	6 to 10	1.1990 ± 0.1251	1.5547 ± 0.1747	0***
DispEn_pVLF		1.1859 ± 0.2500	1.0508 ± 0.0739	0**
DispEn_pLF		0.7594 ± 0.1260	0.7741 ± 0.0891	0.1770*
DispEn_pHF		0.6372 ± 0.1054	0.4997 ± 0.0438	0***
DispEn_VLF		2.3984 ± 0.1990	2.6003 ± 0.1695	0***
DispEn_LF		1.3330 ± 0.0667	1.4093 ± 0.1024	0**
DispEn_HF		1.3117 ± 0.0422	1.2860 ± 0.0382	0**
DispEn_TP	Échelles	2.0588 ± 0.3697	2.4288 ± 0.1642	0***
DispEn_LF/HF	11 to 20	1.0166 ± 0.0481	1.0959 ± 0.0736	0***
DispEn_pVLF		1.1975 ± 0.2120	1.0753 ± 0.1000	0**
DispEn_pLF		0.6703 ± 0.1346	0.5828 ± 0.0574	0***
DispEn_pHF		0.6601 ± 0.1323	0.5320 ± 0.0416	0***

*, ** and *** = $p < 0.01$, $p < 0.001$ and $p < 0.0001$, respectivement.

Tableau.3.2. Distribution de la plage (moyenne ± écart type) des courtes, moyennes et longues échelles de temps des caractéristiques MDE extraites des signaux des sous-bandes TP, HF, LF et VLF à l'aide de la technique CWT suivie de la technique ICWT pour les épisodes normaux et OSA

Indice	Moyenne	Normal (Mean \pm SD)	Hypopnée (Mean \pm SD)	p-value Normal -Hypopnée
DispEn_VLF		2.9865 \pm 0.1197	2.8171 \pm 0.1232	0***
DispEn_LF		2.9996 \pm 0.1885	3.0807 \pm 0.1588	0*
DispEn_HF		2.8755 \pm 0.2198	2.6272 \pm 0.3297	0***
DispEn_TP	Échelles	3.0280 \pm 0.3043	2.9634 \pm 0.2592	0*
DispEn_LF/HF	1 to 5	1.0464 \pm 0.0721	1.1906 \pm 0.1602	0***
DispEn_pVLF		0.9985 \pm 0.1321	0.9603 \pm 0.1192	0*
DispEn_pLF		0.9984 \pm 0.0952	1.0495 \pm 0.1282	0*
DispEn_pHF		0.9553 \pm 0.0745	0.8928 \pm 0.1344	0**
DispEn_VLF		2.9685 \pm 0.1243	2.9777 \pm 0.1305	0.1958*
DispEn_LF		1.9218 \pm 0.2185	2.1263 \pm 0.2062	0**
DispEn_HF		1.6115 \pm 0.1852	1.5277 \pm 0.1072	0**
DispEn_TP	Échelles	2.5821 \pm 0.4007	2.8121 \pm 0.3077	0**
DispEn_LF/HF	6 to 10	1.1990 \pm 0.1251	1.3948 \pm 0.1299	0***
DispEn_pVLF		1.1859 \pm 0.2500	1.0761 \pm 0.1674	0**
DispEn_pLF		0.7594 \pm 0.1260	0.7682 \pm 0.1369	0.2603*
DispEn_pHF		0.6372 \pm 0.1054	0.5516 \pm 0.0869	0***
DispEn_VLF		2.3984 \pm 0.1990	2.5259 \pm 0.1415	0**
DispEn_LF		1.3330 \pm 0.0667	1.3753 \pm 0.1014	0*
DispEn_HF		1.3117 \pm 0.0422	1.3065 \pm 0.0484	0.5170*
DispEn_TP	Échelles	2.0588 \pm 0.3697	2.3457 \pm 0.3148	0***
DispEn_LF/HF	11 to 20	1.0166 \pm 0.0481	1.0526 \pm 0.0644	0**
DispEn_pVLF		1.1975 \pm 0.2120	1.1030 \pm 0.2105	0**
DispEn_pLF		0.6703 \pm 0.1346	0.6014 \pm 0.1254	0**
DispEn_pHF		0.6601 \pm 0.1323	0.5703 \pm 0.1038	0**

*, ** and *** = $p < 0.01$, $p < 0.001$ and $p < 0.0001$, respectivement.

Tableau.3.3. Distribution de la plage (moyenne \pm écart type) des courtes, moyennes et longues échelles de temps des caractéristiques MDE extraites des signaux des sous-bandes TP, HF, LF et VLF à l'aide de la technique CWT suivie de la technique ICWT pour les épisodes normaux et hypopnée.

Indice	Moyenne	ASO (Mean ± SD)	Hypopnée (Mean ± SD)	p-value ASO – Hypopnée
DispEn_VLF		2.8563 ± 0.1827	2.8171 ± 0.1232	0*
DispEn_LF		3.0955 ± 0.2464	3.0807 ± 0.1588	0.2050*
DispEn_HF		2.4879 ± 0.3608	2.6272 ± 0.3297	0*
DispEn_TP	Échelles (1 – 5)	2.9509 ± 0.1414	2.9634 ± 0.2592	0.3151*
DispEn_LF/HF		1.2643 ± 0.1730	1.1906 ± 0.1602	0*
DispEn_pVLF		0.9707 ± 0.0839	0.9603 ± 0.1192	0.1774*
DispEn_pLF		1.0516 ± 0.0995	1.0495 ± 0.1282	0.8063*
DispEn_pHF		0.8450 ± 0.1286	0.8928 ± 0.1344	0*
DispEn_VLF		3.0360 ± 0.1649	2.9777 ± 0.1305	0**
DispEn_LF		2.2381 ± 0.2492	2.1263 ± 0.2062	0**
DispEn_HF		1.4437 ± 0.1088	1.5277 ± 0.1072	0**
DispEn_TP	Échelles (6 – 10)	2.8954 ± 0.1401	2.8121 ± 0.3077	0*
DispEn_LF/HF		1.5547 ± 0.1747	1.3948 ± 0.1299	0***
DispEn_pVLF		1.0508 ± 0.0739	1.0761 ± 0.1674	0.4000*
DispEn_pLF		0.7741 ± 0.0891	0.7682 ± 0.1369	0.4301*
DispEn_pHF		0.4997 ± 0.0438	0.5516 ± 0.0869	0***
DispEn_VLF		2.6003 ± 0.1695	2.5259 ± 0.1415	0**
DispEn_LF		1.4093 ± 0.1024	1.3753 ± 0.1014	0*
DispEn_HF		1.2860 ± 0.0382	1.3065 ± 0.0484	0*
DispEn_TP	Échelles (11 – 20)	2.4288 ± 0.1642	2.3457 ± 0.3148	0*
DispEn_LF/HF		1.0959 ± 0.0736	1.0526 ± 0.0644	0**
DispEn_pVLF		1.0753 ± 0.1000	1.1030 ± 0.2105	0.1390*
DispEn_pLF		0.5828 ± 0.0574	0.6014 ± 0.1254	0.1900*
DispEn_pHF		0.5320 ± 0.0416	0.5703 ± 0.1038	0**

*, ** and *** = $p < 0.01$, $p < 0.001$ and $p < 0.0001$, respectivement.

Tableau.3.4. Distribution de la plage (moyenne ± écart type) des courtes, moyennes et longues échelles de temps des caractéristiques MDE extraites des signaux des sous-bandes TP, HF, LF et VLF à l'aide de la technique CWT suivie de la technique ICWT pour les épisodes AOS et hypopnée.

3.4. Résultats et discussion

Les signaux HRV dans les trois classes : normal, AOS et hypopnée ont été examinés à l'aide des indices recommandés basés sur la combinaison des deux méthodes CWT et MDE. Pour commencer, tous les indices ont été évalués par différence à l'aide du test t. Ces 24 caractéristiques significatives ont ensuite été évaluées par trois classificateurs. Ces classificateurs comprenaient l'arbre de décision (DT), la machine à vecteurs de support (SVM-RBF) et le K-plus proche voisin (KNN). Pour donner des résultats plus fiables et stables, les éléments ont été divisés en ensembles de test et de formation en utilisant une validation croisée de 10 fois, et la moyenne de validation croisée de 10 fois a été déterminée comme résultats de classification. De plus, trois indices de précision (Pre), de spécificité (Spe) et de sensibilité (Sen) ont été utilisés pour évaluer les résultats de la catégorisation, qui sont décrits comme suit :

$$\text{Précision (Pre)} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.1)$$

$$\text{Specificity (Spe)} = \frac{VN}{VN + FP} \quad (3.2)$$

$$\text{Sensitivity (Sen)} = \frac{VP}{VP + FN} \quad (3.3)$$

où VN est le nombre de vrais négatifs ; VP est le nombre de vrais positifs ; FN est le nombre de faux négatifs ; FP est le nombre de faux positifs. De plus, 1000 minutes ont été choisies au hasard dans chaque groupe pour chaque expérience afin d'augmenter la fiabilité des résultats (5430 minutes pour l'AOS, 3000 minutes pour l'hypopnée et 9200 minutes pour la normale). Dans le dernier, la méthode a été effectuée 100 fois et la valeur moyenne des résultats était le résultat final de la classification.

3.4.1. Résultats

L'implémentation de la méthode proposée a été réalisée dans le logiciel MATLAB. Un total de 14 630 épisodes comprenant des épisodes normaux et AOS, chaque épisode d'une durée d'une minute est extrait de 35 sujets de la base de données ECG d'apnée (20 sujets avec des enregistrements de plus de 100 minutes d'AOS, 5 sujets avec des enregistrements de 10 à 96 minutes d'AOS et 10 sujets avec moins de 5 minutes d'AOS), comme pour l'épisode

d'hypopnée, 3000 minutes ont été sélectionnées à partir de la base de données UCD. Le bruit pour chaque minute du signal ECG a été supprimé à l'aide d'une technique de réduction du bruit basée sur les ondelettes. Après réduction du bruit, la détection du complexe QRS a été réalisée à l'aide de l'algorithme de Pan-Tompkins. Après détection du complexe QRS, le signal HRV a été obtenu en calculant le temps entre deux pics R successifs.

Les signaux des sous-bandes TP, HF, LF et VLF ont été obtenus en appliquant ces trois étapes : premièrement, convertir le signal HRV dans le domaine temps-fréquence à l'aide d'une technique CWT, comme illustré dans la figure 3.2 (d, e et f). Deuxièmement, nous avons éliminé les coefficients d'onde en dehors des bandes VLF (0 à 0,04 Hz) ou LF (0,04 à 0,15 Hz) ou HF (0,15 à 0,4 Hz) ou Total (0 à 0,4 Hz) en les mettant à zéro. Enfin, les coefficients résiduels non nuls ont été convertis dans le domaine temporel à l'aide de la technique ICWT pour récupérer les composantes spectrales. Les signaux de sous-bande HF, LF et VLF obtenus en séquençant CWT et ICWT pour une personne normale et une personne souffrant d'AOS ou d'hypopnée sont présentés dans la figure 3.3.

L'utilisation du CWT proposé suivi de la méthode ICWT avec analyse MDE a donné un total de 24 indices. Huit indices sont tirés de la moyenne des petites échelles de temps (1 à 5) et les autres sont tirés de la moyenne des moyennes (6 à 10) et des grandes échelles de temps (11 à 20). Les tableaux 3.2, 3.3 et 3.4 montre les valeurs moyennes et d'écart type (SD) pour tous les groupes. De plus, nous avons calculé la valeur p pour les deux groupes en utilisant la méthode du test-t. Les figures 3.4-3.7 (D-F) et la figure 8 représentent la moyenne et l'écart-type des indices selon la méthode de calcul de l'EMD dans les petites (1 à 5), moyennes (6 à 10) et grandes (11 à 20) échelles de temps des signaux de sous-bande.

Les 24 indices : DispEnVLF, DispEnLF, DispEnHF, DispEnTP, DispEnLF/HF, DispEnpVLF, DispEnpLF et DispEnpHF dans les trois échelles de temps : petit, moyen et grand étaient significativement différents et variaient comme suit:

- Entre épisodes normaux et AOS : 14 indices ($p < 0,0001$), 5 indices ($p < 0,001$) et 5 indices ($p < 0,01$).
- Entre les épisodes normaux et hypopnées : 6 indices ($p < 0,0001$), 10 indices ($p < 0,001$) et 8 indices ($p < 0,01$).
- Entre les épisodes de AOS et d'hypopnées : 2 indices ($p < 0,0001$), 6 indices ($p < 0,001$) et 16 indices ($p < 0,01$).

On pense que les indices DispEnVLF, DispEnLF, DispEnHF, DispEnTotal, DispEnLF/HF, DispEnpVLF, DispEnpLF et DispEnpHF dans les trois échelles de temps petit (1 à 5), moyen (6 à 10) et grand (11 à 20) les indices les plus significatifs statistiquement pour discriminer les épisodes normaux et AOS, les épisodes normaux et hypopnés, selon la valeur p du test t. Les indices DispEnVLF, DispEnLF, DispEnHF, DispEnTotal, DispEnLF/HF, DispEnpVLF, DispEnpLF et DispEnpHF dans les échelles de temps moyennes (6 à 10) sont considérés comme les indices les plus statistiquement significatifs pour discriminer les épisodes d'AOS et d'hypopnées, selon le valeur p du test t.

Les épisodes normaux et d'AOS, les épisodes normaux et d'hypopnée, et les épisodes d'AOS et d'hypopnée ont été classés à l'aide des techniques de classification DT, SVM-RBF et KNN, respectivement. Les tableaux 3.5 à 3.7 et la figure 3.9 comparent la précision, la spécificité et la sensibilité de plusieurs techniques de catégorisation à travers différents épisodes. Les tableaux 3.5 à 3.7 et la figure 3.9 démontrent que SVM a la meilleure précision et spécificité pour les épisodes normaux et l'AOS, les épisodes normaux et hypopnées, et les épisodes d'AOS et hypopnée, avec 98,58 % et 98,34 %, 95,69 % et 94,74 %, 87,04 % et 89,96. %, respectivement.

Les épisodes normaux, d'AOS et hypopnée ont également été classés à l'aide de la méthode de classification un contre tous afin d'évaluer plus avant la capacité de la méthode proposée pour la reconnaissance du SAHS. Les trois groupes ont été examinés à l'aide des classificateurs DT, SVM-RBF et KNN, et la précision, la spécificité et la sensibilité sont présentées dans le tableau 3.8 à 3.10 et la figure 3.10. D'après les résultats, on peut voir qu'en combinant les indices du petites (1 à 5), moyennes (6 à 10) et grandes (11 à 20) échelles de temps dans le cas de SVM, nous avons atteint la moyenne la plus élevée pour la précision, la spécificité et la sensibilité étant de 93,94 %, 96,92 % et 93,91 % sur droit.

La figure 3.11 montre également les taux de vrais positifs (VP) et de faux positifs (FP) pour tous les classificateurs, y compris DT, SVM et KNN, pour chaque classe. Comme le montre la figure 3.11, la probabilité maximale que des épisodes normaux (classe prédite) soient classés comme épisodes normaux (classe vraie) est de 98,01 % (SVM), et les échantillons sont classés en épisodes d'AOS et hypopnée (classe vraie) avec un probabilité minimale de 0,17 % et 1,82 % (SVM), respectivement. La probabilité que les épisodes AOS (classe prédite) soient au maximum classés comme épisodes AOS (classe réelle) est de 93,33 % (KNN). Les épisodes AOS (classe prédite) sont plus susceptibles d'être classés à tort

comme des épisodes d'hypopnée (classe réelle) (DT : 17,08 %, SVM: 7,46 %, KNN : 6,80 %). La probabilité que les épisodes d'hypopnée (classe prédite) soient au maximum classés comme épisodes d'hypopnée (classe réelle) est de 86,10 % (SVM).

Object	Mean Scales	DT		
		Acc (%)	Spe (%)	Sen (%)
Normal & OSA		92.4419	91.5447	93.3786
Normal & Hypo	1 to 5	88.0399	86.8167	89.3471
OSA & Hypo		73.5050	72.6400	74.4387
Normal & OSA		90.6146	91.3706	89.8858
Normal & Hypo	6 to 10	82.3920	81.9672	82.8283
OSA & Hypo		77.5748	76.6026	78.6207
Normal & OSA		86.0465	84.7756	87.4138
Normal & Hypo	11 to 20	75.6645	78.3486	73.4446
OSA & Hypo		69.8505	71.0018	68.8189
Normal & OSA		95.6811	95.8333	95.5298
Normal & Hypo	All	90.8638	90.7663	90.5693
OSA & Hypo		78.9867	79.6265	78.3740

Tableau.3.5. Performances du système proposé utilisant classificateur DT et sous la méthode de classification (un contre un).

Object	Mean Scales	SVM		
		Acc (%)	Spe (%)	Sen (%)
Normal & OSA		94.2691	92.2345	96.5096
Normal & Hypo	1 to 5	89.7010	87.1118	92.6786
OSA & Hypo		73.6711	73.4761	73.8693
Normal & OSA		93.8538	93.4211	94.2953
Normal & Hypo	6 to 10	86.7110	85.6452	87.8425
OSA & Hypo		79.7342	79.8333	79.6358
Normal & OSA		85.3821	82.4695	88.8686
Normal & Hypo	11 to 20	77.4917	77.4461	77.5374

OSA & Hypo		72.4252	73.3564	71.5655
Normal & OSA		98.5880	98.3471	98.8314
Normal & Hypo	All	95.6997	94.7455	95.7298
OSA & Hypo		87.0432	89.9642	84.0201

Tableau.3.6. Performances du système proposé utilisant classificateur SVM et sous la méthode de classification (un contre un).

Object	Mean Scales	KNN		
		Acc (%)	Spe (%)	Sen (%)
Normal & OSA		94.1860	92.6282	95.8621
Normal & Hypo	1 to 5	90.4485	89.0851	91.9105
OSA & Hypo		76.5781	75.8065	77.3973
Normal & OSA		94.8505	95.0000	94.7020
Normal & Hypo	6 to 10	85.6312	85.4545	85.8097
OSA & Hypo		78.3223	78.5595	78.0890
Normal & OSA		85.2159	83.4385	87.1930
Normal & Hypo	11 to 20	76.9103	76.6447	77.1812
OSA & Hypo		71.6777	72.3842	71.0145
Normal & OSA		98.3389	97.7049	98.9899
Normal & Hypo	All	95.2658	93.5795	96.7983
OSA & Hypo		86.5449	89.4265	84.5557

Tableau.3.7. Performances du système proposé utilisant classificateur KNN et sous la méthode de classification (un contre un).

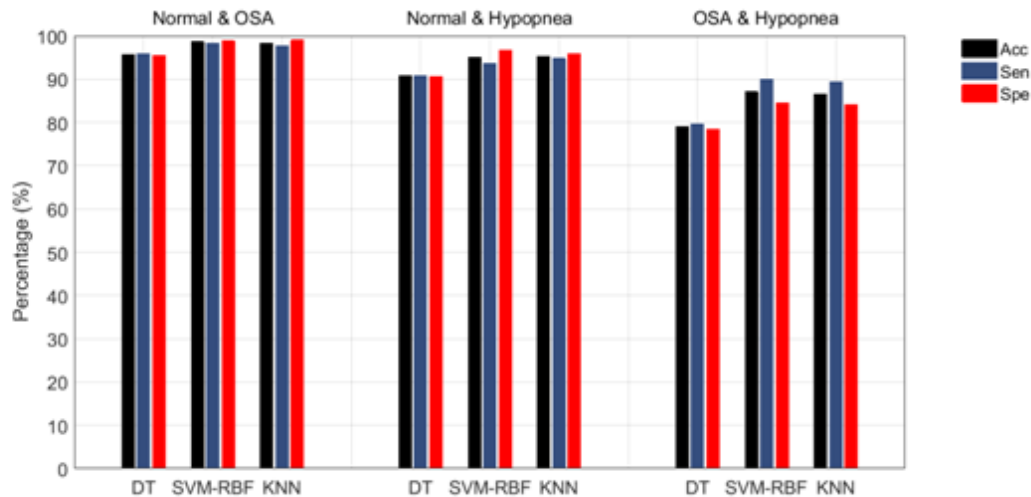


Figure.3.9. Performance du système proposé utilisant divers classificateurs et sous la méthode de classification (un contre un).

Object	Mean Scales	DT		
		Acc (%)	Spe (%)	Sen (%)
Normal	1 - 5	92.8571	95.7916	90.5473
ASO		82.3328	90.8444	79.6020
Hypopnée		74.6082	86.3636	78.9386
Moyenne		83.2660	90.9999	83.0293
Normal	6 - 10	88.0342	92.8571	85.4063
ASO		78.3694	88.0074	78.1095
Hypopnée		70.4655	84.2735	72.8027
Moyenne		78.9564	88.3793	78.7728
Normal	11 - 20	86.5646	91.6842	84.4113
ASO		75.8621	85.3333	80.2653
Hypopnée		66.3808	83.5156	64.1791
Moyenne		76.2692	86.8444	76.2852
Normal	All	93.4211	96.1014	94.1957
ASO		86.4111	93.1338	82.2554
Hypopnée		78.1499	88.5928	81.2604
Moyenne		85.9940	92.6093	85.9038

Tableau.3.8. Performances du système proposé utilisant classificateur DT et sous la méthode de classification (un contre tous).

Object	Moyenne	SVM		
		Acc (%)	Spe (%)	Sen (%)
Normal		95.8478	97.6308	91.8740
ASO	1 - 5	83.9316	91.7976	81.4262
Hypopnée		77.0898	87.5943	82.5871
moyenne		85.6231	92.3409	85.2957
Normal		88.9621	93.3267	89.5522
ASO	6 - 10	82.0380	90.5967	78.7728
Hypopnée		74.1573	86.3095	76.6169
moyenne		81.7191	90.0777	81.6473
Normal		90.2896	94.0126	87.8939
ASO	11 - 20	76.8740	86.6728	79.9337
Hypopnée		69.4118	84.7571	68.4909
moyenne		78.8585	88.4808	78.7728
Normal		98.9950	99.4614	98.0100
ASO	All	92.0661	95.9664	92.3715
Hypopnée		90.7743	95.3488	91.3765
moyenne		93.9451	96.9255	93.9193

Tableau.3.9. Performances du système proposé utilisant classificateur SVM et sous la méthode de classification (un contre tous).




Figure.3.10. Performance du système proposé utilisant divers classificateurs et sous la méthode de classification (un contre tous).

Object	Moyenne	KNN		
		Acc (%)	Spe (%)	Sen (%)
Normal	1 - 5	94.4257	96.7000	92.7032
ASO		81.9398	90.5594	81.2604
Hypopnée		77.0598	88.0772	79.1045
Moyenne		84.4751	91.7789	84.3560
Normal	6 - 10	85.4430	90.8640	89.5522
ASO		80.7047	89.4399	79.7678
Hypopnée		74.6988	87.4144	71.9735
Moyenne		80.2822	89.2394	80.4312
Normal	11 - 20	86.2069	91.1672	87.0647
ASO		75.1166	85.0327	80.0995
Hypopnée		68.9408	85.3514	63.6816
Moyenne		76.7548	87.1838	76.9486
Normal	All	97.8188	98.8095	96.6833
ASO		88.0691	93.5429	93.0348
Hypopnée		89.9306	95.1747	85.9038
Moyenne		91.9395	95.8424	91.8740

Tableau.3.10. Performances du système proposé utilisant classificateur KNN et sous la méthode de classification (un contre tous).

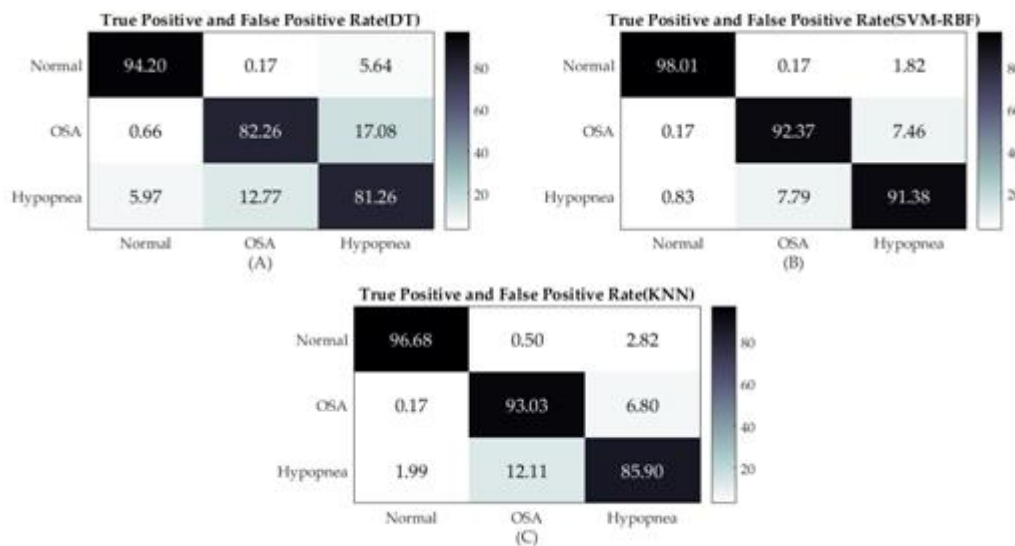


Figure.3.11. Le taux de vrais positifs (TPR) et le taux de faux positifs (FPR) de différents classificateurs: (A) DT ; (B) SVM ; (C) KNN.

3.4.2. Discussion

Le présent article décrit une nouvelle méthode de détection et de classification des épisodes d'apnées et d'hypopnées obstructives du sommeil à l'aide du signal ECG. Cette méthode est basée sur l'extraction de la moyenne calculée des petites (1 à 5), moyennes (6 à 10) et grandes (11 à 20) échelles de temps de l'entropie de dispersion multi-échelle (MDE) directement à partir des signaux de sous-bande TP, HF, LF et VLF. Ainsi, les signaux des sous-bandes VLF, LF et HF ont été obtenus en analysant le signal HRV à l'aide de la technique CWT suivie par la technique ICWT. Le CWT permet une analyse du signal à plusieurs échelles et des traductions en fonction du problème (il permet d'extraire chaque bande entre des bandes de fréquences spécifiques). L'approche ICWT nous a aidés dans la réduction du bruit, à mettre en œuvre dans le domaine des ondelettes et dans la reconstruction du signal qui en a résulté après traitement. Les figures 3.4-3.7 (D-F) et la figure 8 représentent la moyenne et l'écart-type des indices selon la méthode de calcul de l'EMD en petit (1 à 5), moyen (6 à 10) et grand (11 à 20) temps échelles des signaux de sous-bande. Comme on peut le voir, les indices DispEnLF et DispEnLF/HF indiquent une tendance à la hausse parmi les épisodes normaux, hypopnée et AOS. Entre les épisodes normaux, hypopnée et l'AOS, les indices DispEnHF et DispEnpHF indiquent une tendance à la baisse. Dans les épisodes normaux, hypopnée et AOS, les indices DispEnVLF et DispEnpVLF présentent une volatilité dans les trois échelles de temps de MDE.

Étant donné que LF est associée à l'activité du système nerveux sympathique, les variations du signal de la sous-bande LF du HRV changent de manière significative dans le système nerveux sympathique. HF est pensé d'autre part pour être associée à l'activité parasympathique. La signification physiologique du facteur de très basse fréquence (VLF) n'est cependant pas encore claire et a simplement été déterminée à l'aide de rythmes à long terme [33].

Étant donné que l'activité parasympathique des personnes normaux augmente pendant le sommeil nocturne, les schémas de fluctuation de la HRV augmentent à l'intérieur de la bande HF, la texture de la sous-image HF du CWT et du sous-signal de l'ICWT est compliquée.

La composante HF inhibant l'activité sympathique diminue, c'est-à-dire que dans les épisodes normaux, les fluctuations de HRV diminuent avec la bande LF, simplifiant ainsi la texture de l'image de sous-bande CWT et du signal de sous-bande ICWT de LF. L'activité parasympathique est cependant inhibée chez les patients AOS en raison de l'activité

sympathique prédominante. Ainsi, les caractéristiques d'oscillation du HRV sont réduites dans la bande HF, tandis que la gamme de LF est augmentée par rapport aux épisodes ordinaires. En conséquence, les indices DispEnLF et DispEnLF/HF montrent une tendance à la hausse entre les épisodes normaux, hypopnée et l'AOS, tandis que les indices DispEnHF et DispEnHF/HF montrent une tendance à la baisse entre les épisodes normaux, hypopnée et AOS dans les deux échelles de temps : petit, moyen et grand.

Comme la variation des signaux HRV des épisodes normaux à AOS et normaux à hypopnés était largement représentée dans la bande HF et LF, il y avait donc des disparités substantielles dans les épisodes normaux avec AOS ou hypopnées, et il n'y avait pas de différence significative entre AOS avec des épisodes d'hypopnées.

Comme vous le savez d'après les tableaux 3.5 à 3.7 et la figure 3.9, la précision de classification la plus élevée entre les épisodes normaux et AOS est de 98,58 % en utilisant le classificateur SVM avec le noyau de la fonction de base radiale (RBF) et les indices de combinaison des échelles de temps petites, moyennes et grandes. Parce que l'AOS provoque des troubles respiratoires pendant le sommeil et augmente l'activité du système nerveux sympathique, il est plus simple de faire la distinction entre les deux types d'épisodes normaux et AOS. Dans les épisodes d'AOS et les hypopnées, le signal HRV a des propriétés vibrationnelles plus turbulentes, alors que le signal HRV chez un individu en bonne santé a des qualités plus régulières et accordées. Cette différence peut être vue par la distribution de la puissance spectrale des ondelettes dans le domaine temps-fréquence du signal HRV. La précision pour les épisodes normaux et d'hypopnée est de 95,69 % en utilisant le classificateur SVM-RBF et la combinaison des indices des échelles de temps petite, moyenne et grande, ce qui est inférieur aux épisodes normaux et AOS en raison de la diminution des propriétés vibrationnelles turbulentes de le signal HRV dans les épisodes d'hypopnée.

La précision entre l'AOS et l'hypopnée est de 87,04 %, au moyen du classificateur SVM-RBF et combinant des échelles de temps petites, moyennes et grandes, ce qui est inférieur aux deux exemples précédents. Les caractéristiques fluctuantes du signal HRV montrent certains similarités entre les épisodes AOS et hypopnée. L'activité du système nerveux sympathique, qui peut produire des épisodes AOS, est plus importante que l'activité des épisodes d'hypopnées, ce qui entraîne une différence entre les deux épisodes d'AOS et d'hypopnées.

La précision moyenne de la classification de trois épisodes (normal, AOS et hypopnée) dans les tableaux 3.8 à 3.10 et la figure 3.10 est de 93,94 % en utilisant la technique de classification un contre tous du classificateur SVM-RBF et en combinant des indices à petite, moyenne et grande échelle de temps. La diminution de la précision est due à l'augmentation des types de catégorisation, ce qui augmente la probabilité de catégoriser les données en groupes similaires.

Plusieurs tests de classification ont été effectués dans l'étude proposée, avec l'ensemble de données ECG à trois catégories (épisodes normaux, AOS et hypopnée), de sorte que les plus difficiles à classer avec précision étaient les épisodes AOS et l'hypopnée. L'approche traditionnelle de détection et de classification AOS est basée sur l'utilisation de l'analyse des signaux HRV en utilisant les domaines temporel et fréquentiel seuls ou en combinaison.

Khandoker et al [13] ont démontré les meilleurs résultats pour l'identification de l'AOS en utilisant l'approche classique de détection et de classification de l'AOS, qui utilise l'analyse du domaine temps-fréquence et un classificateur ANN. Ils ont pu détecter les épisodes d'apnée avec une précision de 94,84 %, ce qui est inférieur à celui obtenu par notre méthode proposée. En réalité, exploiter les caractéristiques temporelles du signal dans des applications temps réel pourrait être bénéfiques car elles sont simples à extraire et fournissent un calcul peu complexe. Cependant, afin de répondre aux critères établis, ils doivent diviser le signal d'origine en segments courts (5 secondes). Le fractionnement du signal en petits morceaux entraîne souvent une perte et une détérioration de la dynamique générale du signal. De plus, il n'existe pas d'équation mathématique permettant de déterminer les niveaux de seuil afin de séparer les hausses brutales du bruit. De plus, le signal ECG est une sorte de signal faible et instable qui est facilement impacté par le bruit, et l'analyse de la bande de fréquence n'est pas une solution puisque le signal n'est pas stable. En conséquence, nous avons concentré nos efforts dans cette étude sur le signal HRV, qui peut être utilisé comme marqueurs de la coordination du rythme cardio-respiratoire pendant le SAHS, et nous avons cherché à découvrir leurs caractéristiques non linéaires telles que l'entropie de dispersion multi-échelle.

D'autres recherches qui ont utilisé la même base de données (la base de données Apnea-ECG) pour la formation et les tests ont été comparées à la méthodologie de détection automatisée suggérée de l'AOS. Chazal et al [10] et McNames et Frazer [34] sont tous deux très précis. Les auteurs de [10] ont utilisé une matrice de caractéristiques de grande dimension (128 caractéristiques), ce qui se traduit par une technique compliquée. De plus, [34] le défaut

fondamental est que leurs processus de classification ne sont pas automatisés. Aussi, dans l'étape de classification, ils ont supprimé les enregistrements limites (10 participants), ce qui n'est pas le cas dans notre travail de classification. Varon et al. [35] et Bali et al. [36] ont obtenu les meilleurs résultats (100 % de précision) parmi les approches d'identification automatisée de l'AOS. Les méthodes mentionnées dans [17] [18] ont dérivé différentes caractéristiques des intervalles RR et du signal EDR avec une précision de 85,26 % et 82,07 %, respectivement. En outre, plusieurs autres recherches, telles que [37] [34], ont rejeté certains des enregistrements bruyants avec une mauvaise qualité des données dans le processus. En raison de la nature bruyante des signaux physiologiques, ces techniques nécessitent des ensembles de données de haute qualité, qui ne sont pas facilement disponibles. En résumé, la nouveauté de l'étude provient principalement de l'utilisation des caractéristiques d'entropie multi-échelles des signaux des sous-bandes HF, LF, VLF et TP dans la détection SAHS. Les 24 nouveaux indices de cet article permettent de reconnaître le SAOS et l'hypopnée. De plus, cet article bénéficie du fait que l'épisode AOS et hypopnée peut être reconnu avec seulement 5 minutes de signal ECG, et que le SAHS peut être dépisté par l'épisode AOS, mais aussi l'épisode hypopnée. Il existe peu d'études permettant de différencier les épisodes d'apnée obstructive du sommeil des épisodes d'hypopnée. À la suite de cette recherche, les nouveaux indices suggérés basés sur le CWT et le MDE peuvent différencier les épisodes AOS et les épisodes d'hypopnée, et ces indices fonctionnent bien: Précision, Sensibilité et Spécificité, respectivement, sont de 89,87 %, 87,13 % et 92,86 %.

3.5. Conclusion

Dans ce travail, vingt-quatre nouveaux indices basés sur CWT et MDE sont suggérés pour l'identification SAHS, qui sont accomplis en évaluant le signal HRV. Les indices sont extraits par les petites, moyennes et grandes échelles de temps de la méthode MDE. Dans la méthode proposée, premièrement, le spectre de puissance de HRV est estimé par la méthode CWT, puis les signaux de sous-bande TP, HF, LF et VLF sont obtenus en utilisant la technique ICWT. Enfin, les caractéristiques vibratoires des signaux HRV sont évaluées et l'identification SAHS est réalisée en calculant la moyenne des valeurs MDE pour chaque signal de sous-bande sur trois échelles de temps : petite (1 à 5), moyenne (6 à 10) et grande (11 à 20) et leurs relations entre eux. Les enregistrements de la base de données Physionet « Apnea-ECG » et la base de données « UCD dataset » ont été utilisés pour tester les

performances des indices basés sur la combinaison des deux méthodes CWT et MDE, et chaque segment HRV a été classé à l'aide des techniques de classification DT, SVM et KNN. Pour la reconnaissance SAHS, la technique de classification SVM-RBF avait la précision la plus élevée, avec une moyenne de 93,94 %, une sensibilité moyenne de 93,91 et une spécificité moyenne de 96,92 %. On ne peut nier que les indices basés sur la combinaison des deux méthodes CWT et MDE proposés dans cet article offrent une nouvelle étape pour la détection du SAHS. À l'avenir, nous pourrions soutenir la méthode proposée avec d'autres propriétés non linéaires, telles que l'entropie floue et de permutation, pouvant être utilisées pour améliorer davantage la technique suggérée.

BIBLIOGRAPHIE

- [1] Penzel, T., McNames, J., De Chazal, P., Raymond, B., Murray, A., & Moody, G. (2002). Systematic comparison of different algorithms for apnoea detection based on electrocardiogram recordings. *Medical and Biological Engineering and Computing*, 40(4), 402-407.
- [2] Duarte, R., & Rabahi, M. F. (2019). Magalhães-da-Silveira FJ, et al. Comparative performance of screening instruments for obstructive sleep apnea in morbidly obese patients referred to a sleep laboratory: a prospective cross-sectional study. *Sleep Breath*, 23(4), 1123-1132.
- [3] White, D. P., & Younes, M. K. (2012). Obstructive sleep apnea. *Comprehensive Physiology*, 2(4), 2541-2594.
- [4] Gutiérrez-Tobal, G. C., Alonso-Álvarez, M. L., Álvarez, D., del Campo, F., Terán-Santos, J., & Hornero, R. (2015). Diagnosis of pediatric obstructive sleep apnea: Preliminary findings using automatic analysis of airflow and oximetry recordings obtained at patients' home. *Biomedical Signal Processing and Control*, 18, 401-407.
- [5] Hudgel, D. W. (2016). Sleep apnea severity classification—revisited. *Sleep*, 39(5), 1165-1166.
- [6] KapurVK, B. R. B. B. R. G. D. J. (2012). MarcusCL MehraR ParthasarathyS QuanSFet al.; American Academy of Sleep Medicine. Rules for scoring respiratory events in sleep: update of the 2007 AASM Manual for the Scoring of Sleep and Associated Events. Deliberations of the Sleep Apnea Definitions Task Force of the American Academy of Sleep Medicine. *J. Clin. Sleep Med*, 8, 597-619.
- [7] Deutsch, P. A., Simmons 2, M. S., & Wallace, J. M. (2006). Cost-effectiveness of split-night polysomnography and home studies in the evaluation of obstructive sleep apnea syndrome. *Journal of Clinical Sleep Medicine*, 2(02), 145-153.
- [8] Penzel, T., Moody, G. B., Mark, R. G., Goldberger, A. L., & Peter, J. H. (2000, September). The apnea-ECG database. In *Computers in Cardiology 2000*. Vol. 27 (Cat. 00CH37163) (pp. 255-258). IEEE.

- [9] Guilleminault, C., Winkle, R., Connolly, S., Melvin, K., & Tilkian, A. (1984). Cyclical variation of the heart rate in sleep apnoea syndrome: mechanisms, and usefulness of 24 h electrocardiography as a screening technique. *The Lancet*, 323(8369), 126-131.
- [10] De Chazal, P., Heneghan, C., Sheridan, E., Reilly, R., Nolan, P., & O'Malley, M. (2000, September). Automatic classification of sleep apnea epochs using the electrocardiogram. In *Computers in Cardiology 2000*. Vol. 27 (Cat. 00CH37163) (pp. 745-748). IEEE.
- [11] De Chazal, P., Heneghan, C., Sheridan, E., Reilly, R., Nolan, P., & O'Malley, M. (2003). Automated processing of the single-lead electrocardiogram for the detection of obstructive sleep apnoea. *IEEE transactions on biomedical engineering*, 50(6), 686-696.
- [12] Hossen, A., Al Ghunaimi, B., & Hassan, M. O. (2005). Subband decomposition soft-decision algorithm for heart rate variability analysis in patients with obstructive sleep apnea and normal controls. *Signal Processing*, 85(1), 95-106.
- [13] Khandoker, A. H., Gubbi, J., & Palaniswami, M. (2009). Automated scoring of obstructive sleep apnea and hypopnea events using short-term electrocardiogram recordings. *IEEE Transactions on Information Technology in Biomedicine*, 13(6), 1057-1067.
- [14] Corthout, J., Van Huffel, S., Mendez, M. O., Bianchi, A. M., Penzel, T., & Cerutti, S. (2008, August). Automatic screening of obstructive sleep apnea from the ECG based on empirical mode decomposition and wavelet analysis. In *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 3608-3611). IEEE.
- [15] Bsoul, M., Minn, H., & Tamil, L. (2010). Apnea MedAssist: real-time sleep apnea monitor using single-lead ECG. *IEEE transactions on information technology in biomedicine*, 15(3), 416-427.
- [16] Nguyen, H. D., Wilkins, B. A., Cheng, Q., & Benjamin, B. A. (2013). An online sleep apnea detection method based on recurrence quantification analysis. *IEEE journal of biomedical and health informatics*, 18(4), 1285-1293.
- [17] Atri, R., & Mohebbi, M. (2015). Obstructive sleep apnea detection using spectrum and bispectrum analysis of single-lead ECG signal. *Physiological measurement*, 36(9), 1963.

- [18] Janbakhshi, P., & Shamsollahi, M. B. (1959). Sleep Apnea Detection from Single-Lead ECG Using Features Based on ECG-Derived Respiration (EDR) Signals, *IRBM*, Volume 39, Issue 3, 2018. ISSN, 318, 206-218.
- [19] Xie, B., Qiu, W., Minn, H., Tamil, L., & Nourani, M. (2011, January). An improved approach for real-time detection of sleep apnea. In *BIOSIGNALS* (pp. 169-175).
- [20] Feng, K., Qin, H., Wu, S., Pan, W., & Liu, G. (2020). A sleep apnea detection method based on unsupervised feature learning and single-lead electrocardiogram. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-12.
- [21] Mendez, M., BIANCHI, A., MATTEUCCI, M., CERUTTI, S., & Penzel, T. (2009). Sleep Apnea Screening by Autoregressive Models from a Single ECG Lead. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, 56(12), 2838-2850.
- [22] Gubbi, J., Khandoker, A., & Palaniswami, M. (2012). Classification of sleep apnea types using wavelet packet analysis of short-term ECG signals. *Journal of clinical monitoring and computing*, 26(1), 1-11.
- [23] Tripathy, R. K. (2018). Application of intrinsic band function technique for automated detection of sleep apnea using HRV and EDR signals. *Biocybernetics and Biomedical Engineering*, 38(1), 136-144.
- [24] Bozkurt, F., Uçar, M. K., Bozkurt, M. R., & Bilgin, C. (2020). Detection of abnormal respiratory events with single channel ECG and hybrid machine learning model in patients with obstructive sleep apnea. *Irbm*, 41(5), 241-251.
- [25] Benghenia, H. A., Zine-Eddine, H. S., & Alexandre, A. (2022). Automated Recognition of Sleep Apnea-Hypopnea Syndrome Using Continuous Wavelet Transform-Based Multiscale Dispersion Entropy of Single-Lead ECG Signal. *Traitement du Signal*, 39(1).
- [26] Bouaziz, F., Boutana, D., & Benidir, M. (2012, December). Automatic detection method of R-wave positions in electrocardiographic signals. In *2012 24th International Conference on Microelectronics (ICM)* (pp. 1-4). IEEE.
- [27] Martis, R. J., Acharya, U. R., & Min, L. C. (2013). ECG beat classification using PCA, LDA, ICA and discrete wavelet transform. *Biomedical Signal Processing and Control*, 8(5), 437-448.

- [28] Pan, T. (1985). Pan J., Tompkins WJ. A real-time qrs detection algorithm, *IEEE Transactions on Biomedical Engineering*, 32(3), 230-236.
- [29] Rioul, O., & Duhamel, P. (1992). Fast algorithms for discrete and continuous wavelet transforms. *IEEE transactions on information theory*, 38(2), 569-586.
- [30] Cartas-Rosado, R., Becerra-Luna, B., Martínez-Memije, R., Infante-Vazquez, O., Lerma, C., Pérez-Grovas, H., & Rodríguez-Chagolla, J. M. (2020). Continuous wavelet transform based processing for estimating the power spectrum content of heart rate variability during hemodiafiltration. *Biomedical Signal Processing and Control*, 62, 102031.
- [31] Lilly, J. M., & Olhede, S. C. (2012). Generalized Morse wavelets as a superfamily of analytic wavelets. *IEEE Transactions on Signal Processing*, 60(11), 6036-6041.
- [32] Acharya, U. R., Vidya, K. S., Ghista, D. N., Lim, W. J. E., Molinari, F., & Sankaranarayanan, M. (2015). Computer-aided diagnosis of diabetic subjects by heart rate variability signals using discrete wavelet transform method. *Knowledge-based systems*, 81, 56-64.
- [33] Sztajzel, J. (2004). Heart rate variability: a noninvasive electrocardiographic method to measure the autonomic nervous system. *Swiss medical weekly*, 134(35-36), 514-522.
- [34] McNames, J. N., & Fraser, A. M. (2000, September). Obstructive sleep apnea classification based on spectrogram patterns in the electrocardiogram. In *Computers in Cardiology 2000*. vol. 27 (Cat. 00CH37163) (pp. 749-752). IEEE.
- [35] Varon, C., Caicedo, A., Testelmans, D., Buyse, B., & Van Huffel, S. (2015). A novel algorithm for the automatic detection of sleep apnea from single-lead ECG. *IEEE Transactions on Biomedical Engineering*, 62(9), 2269-2278.
- [36] Bali, J., Nandi, A., & Hiremath, P. S. (2020). Efficient ANN algorithms for sleep apnea detection using transform methods. In *Advancement of Machine Intelligence in Interactive Medical Image Analysis* (pp. 99-152). Springer, Singapore.
- [37] Li, Y., Pan, W., Li, K., Jiang, Q., & Liu, G. (2018). Sliding trend fuzzy approximate entropy as a novel descriptor of heart rate variability in obstructive sleep apnea. *IEEE journal of biomedical and health informatics*, 23(1), 175-183.

Chapitre 4

Détection automatique du SAHS basée sur EWT et CPSD

4.1. Introduction

Le syndrome d'apnée-hypopnée du sommeil (SAHS) est une maladie respiratoire qui provoque une fermeture partielle ou totale des voies respiratoires supérieures pendant le sommeil [1,2]. Un sommeil insuffisant et l'épuisement mental pendant la journée peuvent tous deux avoir un impact négatif important sur nos vies lorsque des interruptions de sommeil se produisent. La notation des stades de sommeil et l'identification des apnées et hypopnées sont deux des défis les plus difficiles dans l'analyse du sommeil [3]. Les cardiopathies ischémiques, les dysfonctionnements circulatoires et les accidents vasculaires cérébraux ont tous été associés à un SAHS non traité [4].

Par conséquent, la détection précoce de l'existence d'un syndrome d'apnée-hypopnée du sommeil est essentielle. La définition standard de l'apnée est l'arrêt du flux d'air pendant au moins 10 secondes ou le nombre moyen d'hypoventilations par heure (indice de trouble respiratoire) supérieur à 5 fois. Cependant, l'hypopnée fait référence à une diminution de 30 % du débit d'air pendant au moins 10 secondes avec une diminution de la saturation en oxygène du sang de 4 % [5].

L'apnée obstructive du sommeil (OSA), l'apnée centrale du sommeil (CSA) et l'apnée mixte du sommeil (MSA) sont les trois types d'apnée du sommeil [6]. OSA est le type d'apnée le plus répandu dans la pratique clinique. Il ferme complètement les voies respiratoires supérieures et détend les muscles de la gorge, empêchant le passage de la respiration pendant le sommeil [7]. Le processus par lequel le centre du cerveau cesse de diriger les muscles qui contrôlent la respiration est connu sous le nom de CSA, provoquant l'arrêt du flux respiratoire. MSA est un mélange de ces deux types, avec une apnée obstructive dans la première moitié et une apnée centrale dans la seconde, ou vice versa. Le nombre d'apnées et d'hypopnées par heure de sommeil est appelé indice d'apnée hypopnée du sommeil (AHI) et est lié à la gravité des apnées [5].

La polysomnographie (PSG) est actuellement considérée comme l'étalon-or pour le diagnostic du SAHS. La PSG nécessite l'enregistrement nocturne d'une variété de données physiologiques des patients, y compris l'électroencéphalogramme (EEG), l'électrocardiogramme (ECG), l'électromyogramme (EMG), l'électrooculogramme (EOG), les mouvements respiratoires thoraciques et abdominaux, la saturation en oxygène (SpO₂) et le débit d'air [3]. Cependant, afin de surveiller et de détecter les cas de SAHS, un technicien du sommeil est nécessaire, mais cela est difficile, coûteux et prend du temps.

Plusieurs études ont été menées afin d'établir une approche automatisée de détection des événements SAHS qui utilise plusieurs biosignaux tels que l'ECG, l'EEG, l'EMG et l'EOG [3]. Ces dernières années, de plus en plus d'études se sont concentrées sur l'utilisation d'une fonction de signal unique pour diagnostiquer automatiquement la présence de SAHS. Parmi ceux-ci, le signal EEG a beaucoup retenu l'attention. La raison en est que les lectures EEG représentent l'activité électrique du cerveau, qui est fortement associée aux phases de sommeil et à la qualité du sommeil, et que les occurrences d'apnée perturbent gravement la qualité du sommeil [8].

En résumé, l'objectif principal de cette étude est de reconnaître SAHS en utilisant uniquement des signaux EEG. De nombreuses études sur le sommeil montrent que les troubles du sommeil peuvent être identifiés et prédits grâce aux deux canaux (C3-A2 ou C4-A1) du signal EEG [9].

Dans le présent travail, la classification automatique de SAHS est effectuée en analysant les deux signaux EEG (C3A2 & C4A1) en dix sous-bandes par la technique de la transformation empirique en ondelettes (EWT) et en extrayant les caractéristiques fréquentiels à l'aide de la densité spectrale de puissance croisée (CPSD). L'utilisation d'une procédure de sélection des caractéristiques est proposée afin de déterminer les variables qui discriminent le mieux les événements apnéiques et normaux et par conséquent, donnent lieu aux meilleurs taux de reconnaissance.

Enfin, l'ensemble des caractéristiques sélectionnées est entré dans quatre classificateurs différents tels que la machine à vecteurs de support (SVM), l'algorithme des K plus proches voisins (KNN), l'arbre de décision (DT) et réseau de neurones perceptrons multicouches (MLPNN). Toutes les combinaisons possibles de stratégies d'extraction de caractéristiques et de classificateurs nous permettront de trouver celui qui présente les meilleures performances dans le processus de quantification.

Dans ce travail, la classification est effectuée de manière par des événements. Dans la classification par des événements, également appelée quantification, le classificateur binaire décide si l'événement évalué montre ou non une apnée.

4.2. Revue de littérature

Dans l'étude de [9], les signaux EEG ont été filtrés à l'aide des filtres passe-bande Butterworth à réponse impulsionnelle infinie (IIR). Les caractéristiques extraites comme l'énergie et la variance ont été utilisées comme bases pour la classification sur le SVM, les réseaux de neurones artificiels, l'analyse discriminante linéaire et les bayes naïfs. Le système développé avait la précision la plus élevée de 97,14% sur le SVM.

Dans [7], les signaux EEG ont été filtrés par un filtre passe-bande Infinite Impulse Butterworth et Hilbert Huang Transform. Les caractéristiques extraites telles que l'énergie, la variance et l'entropie ont été introduites dans des classificateurs tels que SVM, Artificial Neural Network et K-Nearest Neighbors.

L'entropie des signaux EEG à bande de fréquence limitée était la seule caractéristique de classification de l'apnée dans [10]. Les signaux limités en bande de fréquence ont été obtenus par transformée de Fourier rapide (FFT), puis l'entropie de chaque signal EEG limité en bande de fréquence a ensuite été extraite, mise en cascade et classée à l'aide du classificateur KNN. Le résultat a montré une précision moyenne de 87 %.

Tout en améliorant cette méthode, [11] a proposé l'utilisation de sous-bands des signaux EEG à la place de la trame complète précédente et l'utilisation de la variation temporelle de l'énergie de la bande bêta est utilisée pour classer les événements d'apnée dans le classificateur KNN. Les performances ont considérablement augmenté.

Des études ont également été menées dans le domaine de l'application de l'apprentissage en profondeur aux signaux EEG pour détecter automatiquement les événements d'apnée, [12] ont utilisé le concept de division des trames de signaux EEG en sous-trames. Chaque sous-trame est introduite dans un réseau neuronal convolutif (CNN). Les vecteurs de caractéristiques de chaque sous-trame sont concaténés ensemble et transmis à un classificateur dense (réseau neuronal profond) pour générer les caractéristiques finales pour détecter les événements d'apnée et de non-apnée. Une précision moyenne de 77,14 % a été obtenue.

Le nom de l'auteur	Caractéristiques utilisées	Classificateurs	Signal & Base de données	Performance		
				Se (%)	Sp (%)	Pr (%)
[9]	Énergie, Variance	SVM, KNN, ANN, LDA, Bayes naïf	EEG/ MIT-BIH Polysomnographie	97	97	97
[7]	Énergie, Entropie, Variance	SVM, KNN	EEG/ MIT-BIH Polysomnographie	100	98	99
[10]	Entropie multibande	KNN	EEG/ St. Vincent University Database	89	86	88
[11]	Énergie inter-bandes	KNN	EEG/ St. Vincent University Database	90	94	92
[12]	Sous-bandes	CNN	EEG/ St. Vincent University Database	77	78	76
Notre étude	EWT + CPSD	KNN	EEG/ St. Vincent University Database	93	92	93

Tableau.4.1. Résumé des résultats des recherches antérieures.

4.3. Principe de la méthode

L'organigramme suivant décrit les différentes étapes de l'algorithme utilisé pour l'identification du syndrome d'apnées-hypopnées du sommeil (SAHS) basée sur la représentation fréquentielle des signaux de sous-bande IMF1-IMF10 extraits à l'aide de la décomposition de l'échelle-temps basée sur la transformation empirique en ondelettes (EWT) des deux signaux EEG tels que « C3A2 & C4A1 ». (Voir la figure.4.1)

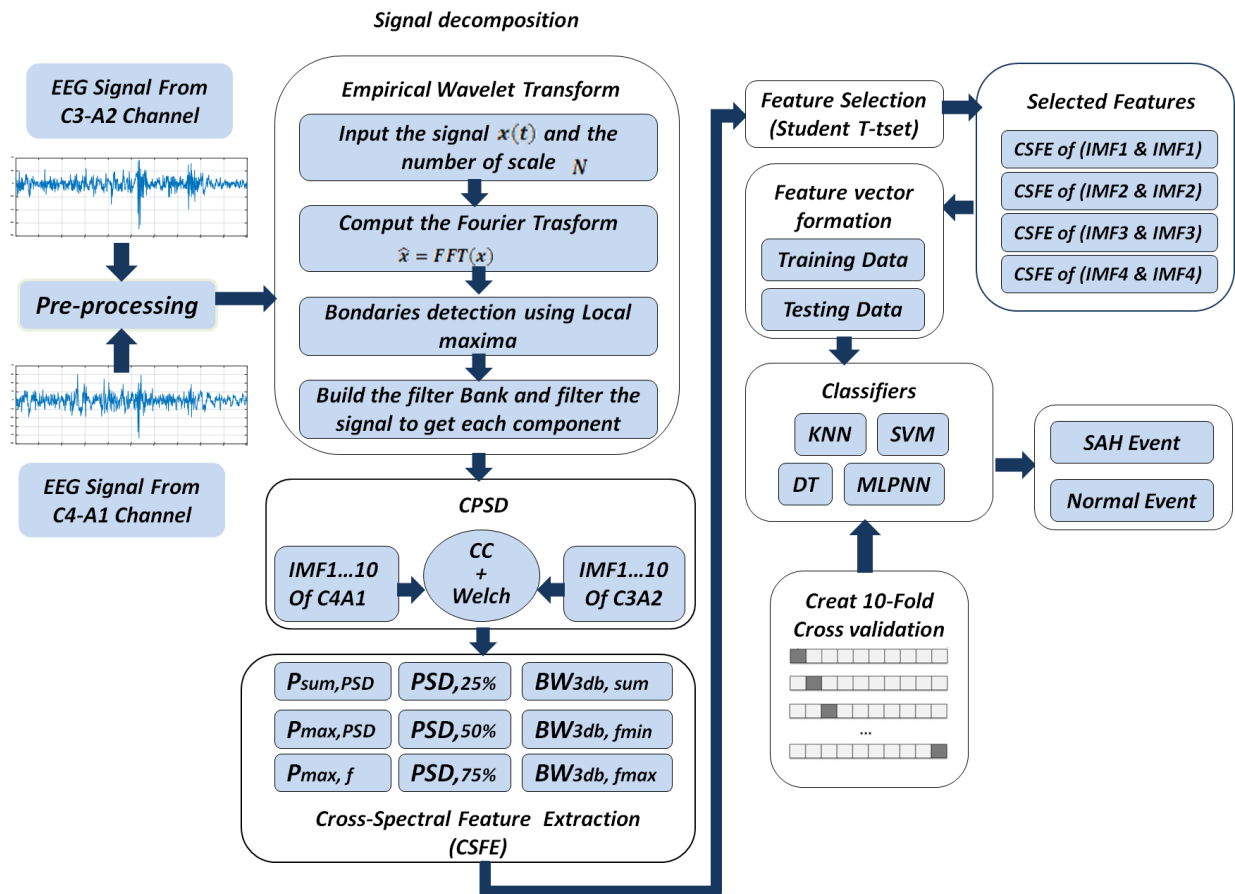


Figure.4.1. Représentation graphique de l'approche proposée pour identifier et classifie l'apnée du sommeil.

4.3.1. Description de l'algorithme

La première étape dans ce travail commence par le prétraitement des données des signaux EEG. Les signaux EEG obtenus à partir de la base de données PhysioNet Bank « UCD dataset » ont été échantillonnés à 128 Hz. Le décalage DC dans les deux signaux EEG (C3A2 & C4A1) a été supprimé en utilisant un filtre passe-haut à réponse impulsionnelle finie (FIR) d'ordre 200. Les signaux EEG sans décalage ont ensuite été filtrés à l'aide d'un filtre passe-bande FIR avec des fréquences de coupure de 0,15 à 50 Hz. Les signaux EEG ont été divisés en segments de 10 secondes pendant et autour du moment des événements de l'apnée du sommeil notés par le spécialiste du sommeil et annotés dans la base de données de PhysioNet Bank « UCD dataset » pour une analyse plus approfondie (Voir les figures 4.2 à 4.5).




Figure.4.2. Tracé de la série temporelle « C3A2 » de signal EEG du sujet normal: (a) Signal EEG bruité (b) Signal EEG filtré.




Figure.4.3. Tracé de la série temporelle « C4A1 » de signal EEG du sujet normal: (a) Signal EEG bruité (b) Signal EEG filtré.




Figure.4.4. Tracé de la série chronologique « C3A2 » de signal EEG du sujet d'apnée: (a) Signal EEG bruité (b) Signal EEG filtré.




Figure.4.5. Tracé de la série chronologique « C4A1 » du signal EEG du sujet d'apnée: (a) Signal EEG bruité (b) Signal EEG filtré.

L'étape suivante consiste à extraire les informations temps-fréquence du signal à l'aide de la transformation empirique en ondelettes (EWT). EWT travaille sur des bancs de filtrage adaptatifs, qui segmentent le signal à l'aide d'informations spectrales (Voir les figures 4.6 a 4.9). En utilisant la technique de représentation échelle-espace, la détection des limites du spectre de fréquences est effectuée. Chaque segment passe par le filtre passe-bande, qui est bien défini par la mise à l'échelle et la fonction d'ondelettes. Des sous-bandes sont extraites de chaque signal. Ensuite, en utilisant la transformée de Hilbert, l'amplitude instantanée (IA) et la fréquence instantanée (IF) sont calculées pour la représentation temps-fréquence. Cette représentation montre le niveau d'oscillation du signal. Chaque signal est divisé en 10 sous-bandes (Voir les figures 4.10 a 4.13). Des techniques d'extraction de caractéristiques sont ensuite utilisées pour extraire certaines des caractéristiques communes des représentations temps-fréquence des deux classes.

La densité spectrale de puissance croisée compare les domaines de fréquence de chacun des sous-signaux (IMF) pour les dérives C3A2 avec C4A1, permettant la détection des rythmes partagés par les deux sous-bandes. Plusieurs caractéristiques ont été dérivées des signaux CPSD. Pour la classification, le total de quatre-vingt-dix (9×10) caractéristiques de densité spectrale de puissance croisée de chaque sous-bande est récupéré. Le tableau.4.2 résume la brève explication utilisée pour calculer toutes les caractéristiques de fréquence.




Figure.4.6. (a) des limites détectées (en rouge) et du spectre FFT (en noir). (b) banque de filtres (FB1-FB10) générée à partir du signal EEG "C3A2" du sujet normal.




Figure.4.7. (a) des limites détectées (en rouge) et du spectre FFT (en noir) (b) banque de filtres (FB1-FB10) générée à partir du signal EEG "C4A1" du sujet normal.




Figure.4.8. (a) des limites détectées (en rouge) et du spectre FFT (en noir). (b) banque de filtres (FB1-FB10) générée à partir du signal EEG "C3A2" du sujet d'apnée.




Figure.4.9. (a) des limites détectées (en rouge) et du spectre FFT (en noir). (b) banque de filtres (FB1-FB10) générée à partir du signal EEG "C4A1" du sujet d'apnée.

4.4. Résultats

Des expériences sont réalisées en implémentant la méthode proposée dans MATLAB pour l'identification du syndrome d'apnées-hypopnées du sommeil (SAHS). L'implémentation MATLAB de la transformée empirique en ondelettes (EWT) pour décomposer le signal EEG dans l'IMF est accessible au public à (<https://in.mathworks.com/matlabcentral/fileexchange/42141-empirical-wavelet-transforms>). Dix sous-bandes IMF sont extraites de deux signaux EEG (C3A2 & C4A1) de chaque de chaque événement normal et apnéique à l'aide d'une méthode de détection des limites.

Les limites de fréquence détectées de l'apnée du sommeil et des signaux EEG normaux de tous les modes sont illustrées dans les figures 4.6 (a) à 4.9 (a) où les lignes pointillées rouges indiquent les limites détectées et la ligne épaisse noire indique le spectre de fréquence du signal. Alors que les figures 4.6 (b) à 4.9 (b) montrent la construction de bandes de filtres (FB) des signaux EEG basées sur les ondelettes de Littlewood–Paley et Meyer, FB1 à FB10, montrent les dix bancs de filtres basés sur EWT obtenus.

Dix IMF sont obtenues après décomposition du signal pour les deux classes de la décomposition de haut en bas (sens de bas en haut dans le graphique) et illustrées dans les

figures 4.10 à 4.13. Le graphique est tracé entre la fréquence en fonction de l'amplitude dans l'axe du temps des sous bandes d'événements normaux et d'apnée du sommeil.

La figure 4.14 et figure 4.15 montrent la densité spectrale de puissance croisée (CPSD) des IMFs du signal C3A2 avec C4A1. Huit types différents de caractéristiques statistiques et basées sur le domaine fréquentiel sont extraits des signaux CPSD des deux classes normale et apnéique, comme indiqué dans le tableau 4.2. Après l'extraction des caractéristiques, un vecteur de caractéristiques de dimension 80 (8×10) est formé. Si ce vecteur de caractéristiques de grande dimension est passé tel quel au classificateur, alors les performances de l'apprenant peuvent être dégradées, donc pour optimiser les performances du classificateur, seules les caractéristiques les plus significatives sont utilisées.

Trente-deux caractéristiques extraites de quatre premiers signaux CPSD des IMFs des signaux C3A2 avec C4A1 ont été identifiées comme des caractéristiques importantes et utilisées pour former des classificateurs pour des performances optimales. Il ressort du tableau 4.3 que les caractéristiques statistiques telles que la somme des amplitudes du DSP, DSP maximale, la fréquence où la DSP est maximale, la fréquence contenant 25% du signal DSP, la fréquence contenant 50% du signal DSP, la fréquence contenant 75% du signal DSP, la somme de l'amplitude du DSP de différence de bande passante (3db), la fréquence minimal de différence de bande passante et la fréquence maximal de différence de bande passante sont les caractéristiques les plus significatives et très utiles pour différencier les événements normaux et d'apnée du sommeil.

La représentation en boîte à moustaches des caractéristiques les plus significatives pour différentes CPSD des IMFs des signaux C3A2 avec C4A1 est illustrée à la figure 4.16, où sur l'axe des abscisses SAHE désignent les signaux de l'apnée du sommeil et N pour les signaux EEG de classe normale. La figure 4.16 a également montré comment deux classes sont différentes en ce qui concerne les caractéristiques significatives. La visualisation des caractéristiques par le biais de boîtes à moustaches a conclu que l'apnée du sommeil et les classes normales se distinguent bien les unes des autres par les caractéristiques les plus significatives. Le « o » rouge et bleu indique les valeurs aberrantes présentes dans les données.

Après avoir effectué le test de signification (test de Wilcoxon), les caractéristiques les plus significatives extraites à travers les quatre signaux CPSD sont sélectionnées. Ces caractéristiques sélectionnées sont utilisées pour former un vecteur de caractéristiques de 32

(4*8) et fournies au classificateur pour la formation et les tests. Différents modèles d'apprentissage automatique tels que la machine à vecteurs de support (SVM), l'algorithme des K plus proches voisins (KNN), l'arbre de décision (DT) et réseau de neurones perceptrons multicouches (MLPNN) sont utilisés pour la classification. La performance des modèles de classification est évaluée à l'aide de la précision, de la sensibilité, de la spécificité, du score F1 et des valeurs prédictives positives et négatives (PPV). Le résumé des mesures de performance évaluées des modèles de classification est présenté dans le tableau 4.4.

Pour assurer la robustesse des performances des modèles de classification binaire, les courbes ROC sont également tracées entre le taux de vrais positifs (TPR) et le taux de faux positifs (FPR) comme le montre la figure 4.17. Dans la littérature, la courbe ROC est également tracée entre sensibilité vs spécificité. La meilleure performance de classification est démontrée dans le coin supérieur gauche de la courbe ROC car elle classe correctement tous les échantillons positifs et négatifs et l'aire sous les valeurs de la courbe [13].

Dans nos expériences, le KNN fonctionne le mieux, comme le montre la figure 4.17. Nous avons également calculé l'aire sous la courbe ROC sur une échelle de 0 à 1 en tant que valeurs AUC. Les valeurs AUC obtenues par KNN sont de 0,9847, ce qui est le plus élevé parmi tous les classificateurs. Ainsi, il est conclu que KNN est le meilleur classificateur parmi tous les autres classificateurs utilisés ici pour identifier l'apnée du sommeil. Les petites valeurs d'AUC indiquent les mauvaises performances du modèle, et ici le classificateur d'arbre de décision montre les valeurs les plus basses 0,9380 est censé être le classificateur le plus moins de cette expérience.

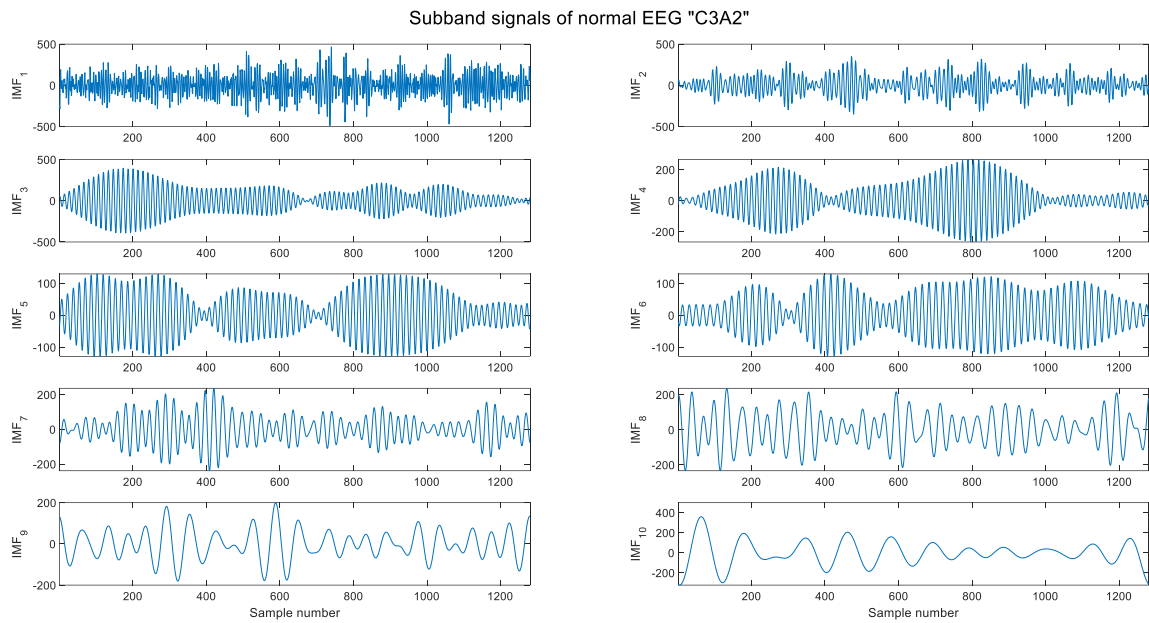


Figure.4.10. Signaux de sous-bande IMF1-IMF10 extraits à l'aide de la décomposition de l'échelle-temps basée sur TOE du signal EEG "C3A2" du sujet normal.

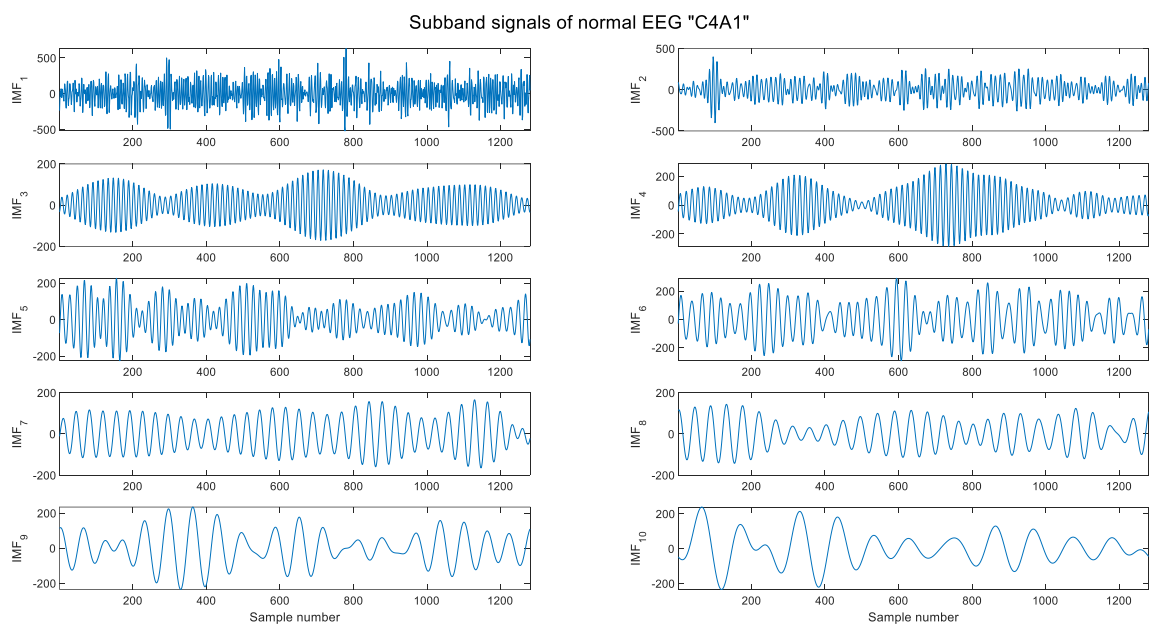


Figure.4.11. Signaux de sous-bande IMF1-IMF10 extraits à l'aide de la décomposition de l'échelle-temps basée sur TOE du signal EEG "C4A1" du sujet normal.




Figure.4.12. Signaux de sous-bande IMF1-IMF10 extraits à l'aide de la décomposition de l'échelle-temps basée sur TOE du signal EEG "C3A2" du sujet d'apnée.




Figure.4.13. Signaux de sous-bande IMF1-IMF10 extraits à l'aide de la décomposition de l'échelle-temps basée sur TOE du signal EEG "C4A1" du sujet d'apnée.

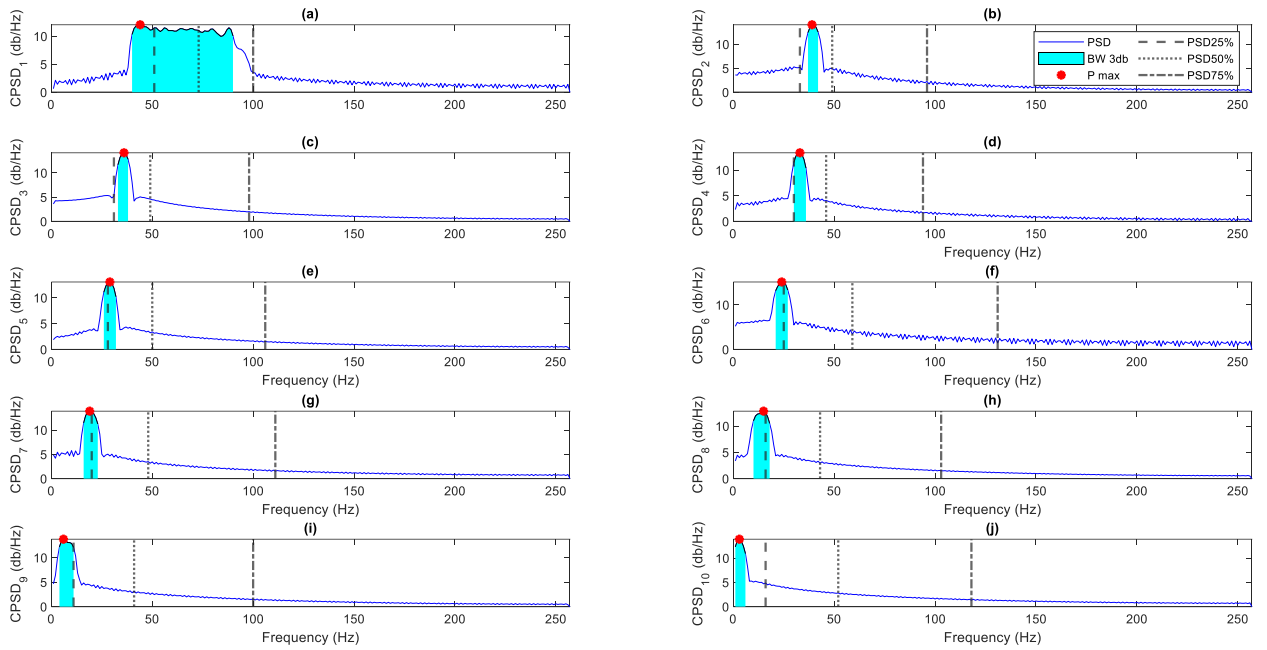


Figure.4.14. Densité spectrale de puissance croisée (CPSD) des sous-bandes de C3A2 et C4A1 du signal EEG du sujet normal.

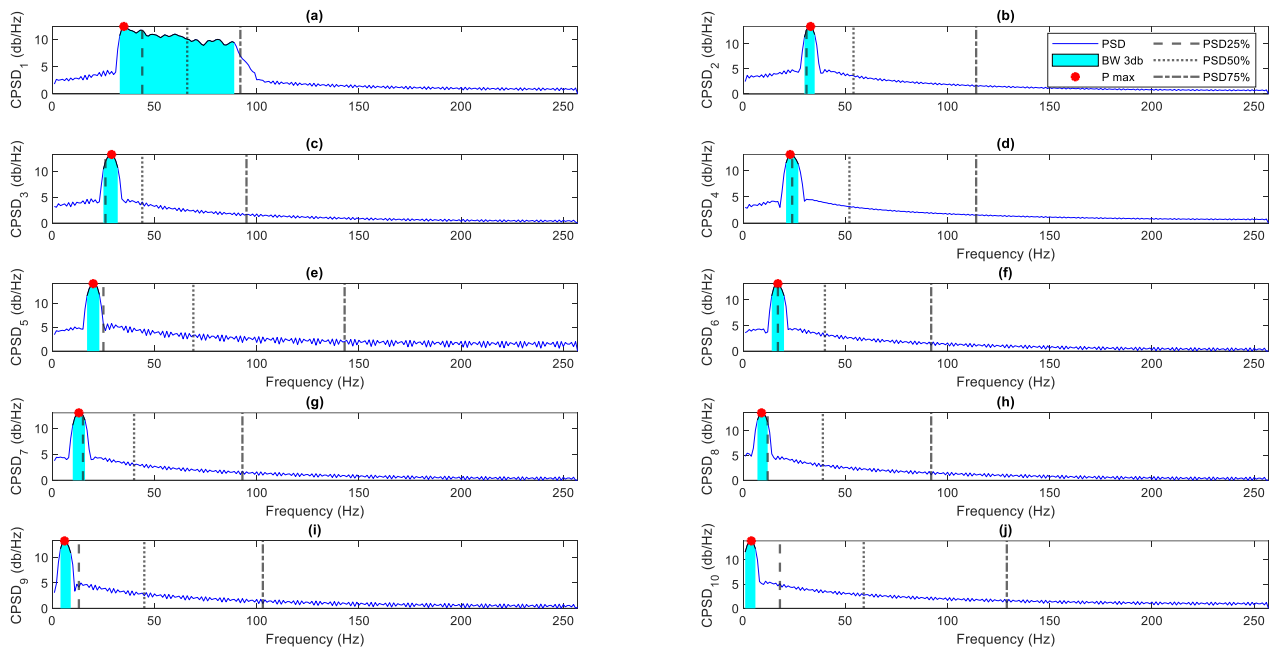


Figure.4.15. Densité spectrale de puissance croisée (CPSD) des sous-bandes de C3A2 et C4A1 du signal EEG du sujet d'apnée.

Sr. No	Caractéristique	Détail
1	$P_{sum, DSP}$	La somme des amplitudes du signal de densité spectrale de puissance (DSP)
2	$P_{max, DSP}$	La densité spectrale de puissance maximale
3	$P_{max, f}$ (Hz)	La fréquence où la densité spectrale de puissance (DSP) est maximale
4	$DSP_{25\%}$ (Hz)	La fréquence contenant 25% du signal DSP
5	$DSP_{50\%}$ (Hz)	La fréquence contenant 50% du signal DSP
6	$BW_{3db, sum}$	La somme de l'amplitude du signal de densité spectrale de puissance DSP entre les fréquences supérieure et inférieure de la bande où se trouve la DSP en utilisant un seuil de 3 dB
7	$BW_{3db, f min}$ (Hz)	La fréquence inférieure de BW_{3db} .
8	$BW_{3db, f max}$ (Hz)	La fréquence supérieure de BW_{3db} .

Tableau.4.2. Brève description des caractéristiques extraite.

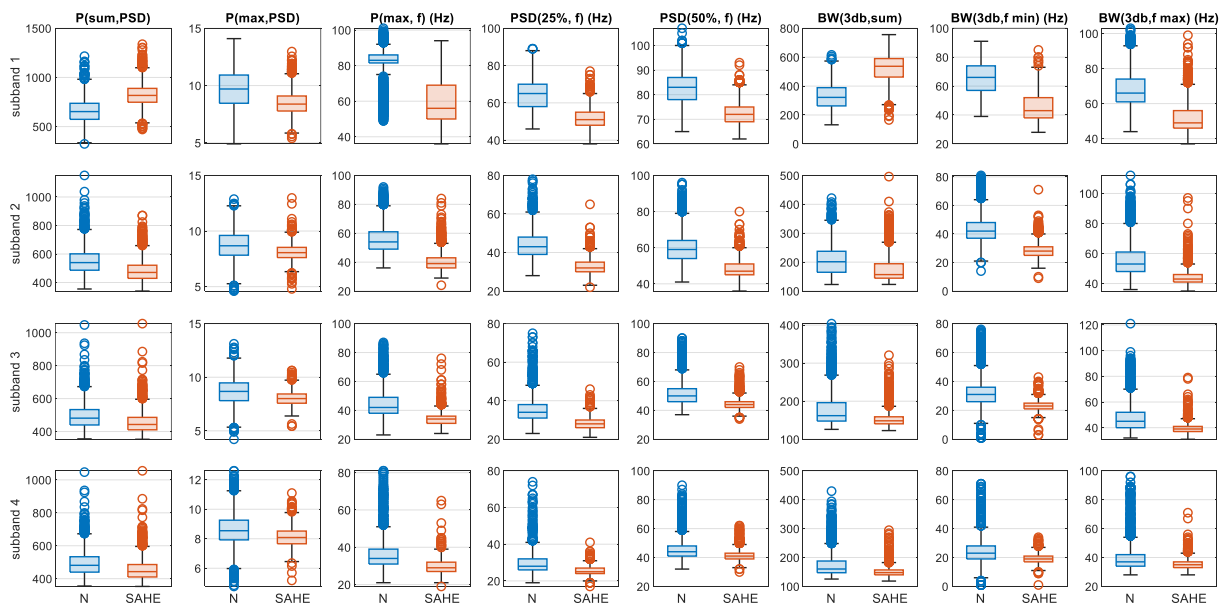


Figure.4.16. Boîte à moustaches des caractéristiques significatives du domaine fréquentiel extraites des quatre premières sous-bandes de l'apnée et de la classe normale.

IMF Modes	p-value				
	$P_{sum, PSD}$	$P_{max, PSD}$	$P_{max, f}$	$PSD_{25\%}$	$PSD_{50\%}$
IMF1	1.8141e-290	2.5103e-126	0	0	0
IMF2	2.9629e-109	2.9606e-63	0	0	0
IMF3	2.5412e-58	1.4140e-71	1.7271e-289	2.5277e-285	5.5156e-214
IMF4	1.5969e-53	2.1443e-55	6.9760e-176	2.1095e-157	8.9001e-85
IMF5	2.5416e-26	1.5807e-14	1.4728e-36	5.6374e-33	1.1402e-12
IMF6	4.9699e-11	2.0745e-05	5.7845e-16	1.2532e-09	0.6722
IMF7	0.3353	0.0313	0.2172	0.7979	0.3661
IMF8	0.7073	0.1294	0.6029	0.0950	0.9633
IMF9	0.6449	1.5945e-11	7.0415e-10	1.6675e-11	6.4727e-06
IMF10	6.9452e-08	0.0449	6.6854e-07	0.0011	0.0063
.....					
				Result	
	$BW_{3db, sum}$	$BW_{3db, f min}$	$BW_{3db, f max}$		
	0	0	0	S	
	2.7576e-79	0	3.7336e-280	S	
	2.9230e-99	1.5441e-234	4.8858e-160	S	
	5.6214e-105	2.4666e-122	1.3204e-59	S	
	1.8591e-20	6.6585e-24	1.0417e-27	NS	
	1.7900e-17	2.5530e-07	2.3569e-16	NS	
	4.2490e-07	0.2304	0.0028	NS	
	0.0089	5.7036e-05	0.3759	NS	
	0.2395	6.8342e-05	6.8123e-04	NS	
	1.6641e-15	0.1024	3.3980e-07	NS	

S, NS represent: Significant, Not Significant, respectively

Tableau.4.3. Valeurs p pour les caractéristiques extraites des signaux EEG des deux classes normal et SAHS à l'aide d'un test de Wilcoxon.

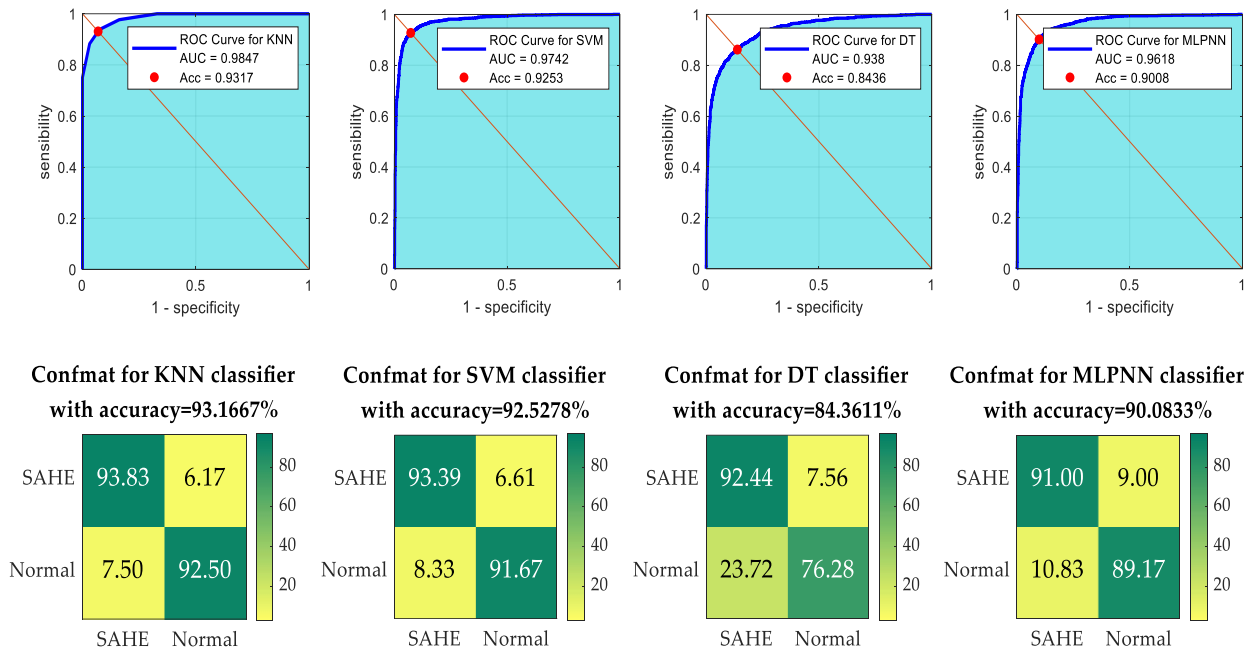


Figure.4.17. Courbes de caractéristique de fonctionnement du récepteur (ROC) et matrices de confusion des quatre classificateurs classés de gauche à droite : KNN, SVM, DT et MLPNN respectivement.

Performance	Popular Classifiers			
	KNN	SVM	DT	MLPNN
AUC	0.9847	0.9742	0.9380	0.9618
Accuracy, %	93.1667	92.5278	84.3611	90.0833
Sensitivity, %	93.8333	93.3889	92.4444	91.0000
Specificity, %	92.5000	91.6667	76.2778	89.1667
PPV, %	92.5987	91.8078	79.5791	89.3617
F1 Score, %	93.2119	92.5916	85.5307	90.1734

Table.4.4. Résumé des performances des différents modèles de classification.

4.5. Discussion

Dans cette étude, la transformée en ondelettes empirique (EWT) a été utilisée pour décomposer les deux signaux EEG « C3A2 & C4A1 » d'apnée du sommeil et normaux en dix sous-bandes IMF. EWT est une méthode adaptative utilise les informations de fréquence du spectre du signal pour décomposer les signaux EEG non stationnaires et non linéaires.

La transformée de Fourier rapide (FFT) est utilisée pour calculer le spectre de fréquence (FT spe.) des signaux, comme indiqué avec la ligne de couleur noir sur les figures 4.6(a), 4.7(a), 4.8(a) et 4.9(a) pour les signaux EEG d'apnée du sommeil et normaux respectivement. Les fréquences limites sont détectées à partir du spectre de fréquences et des bancs de filtres à ondelettes étroits sans chevauchement (FB1-FB10), comme illustré aux figures 4.6(b), 4.7(b), 4.8(b) et 4.9(b) sont utilisés pour décomposer les signaux en dix modes IMF (IMF1-IMF10).

Les sous-bandes de l'IMF sont représentées sur les figures 4.10 à 4.13 pour l'apnée du sommeil et les signaux EEG normaux respectivement. On observe à partir de les figures 4.10 à 4.13 que chaque mode IMF est agencé par ordre croissant de fréquence, dans lequel la première rangée de la figure est associée à la fréquence la plus basse.

L'analyse spectrale croisée est connue pour être capable d'extraire les caractéristiques communes de deux signaux et de trouver la dépendance d'un signal par rapport à l'autre. Cette étude a utilisé une analyse spectrale croisée de ces deux signaux pour étudier l'effet de l'apnée du sommeil sur les sous-bandes EEG. Les caractéristiques basées sur la densité spectrale de puissance croisée (domaine fréquentiel) telles que la somme des amplitudes du DSP, DSP maximale, la fréquence où la DSP est maximale, la fréquence contenant 25% du signal DSP, la fréquence contenant 50% du signal DSP, la fréquence contenant 75% du signal DSP, la somme de l'amplitude du DSP de différence de bande passante (3db), la fréquence minimal de différence de bande passante et la fréquence maximal de différence de bande passante sont extraites des signaux CPSD obtenues qui forment un vecteur de caractéristiques de 80 (10 * 8).

Un test de Wilcoxon statistique a été effectué pour tester la signification des caractéristiques extraites, comme indiqué dans le tableau 4.3. Le test significatif est utilisé pour évaluer quelles caractéristiques sont les plus discriminantes pour dire si l'événement d'apnée du sommeil est ou normal en utilisant des valeurs de p (<0,001). Les résultats des tests de signification suggèrent que les caractéristiques basées sur les six dernies CPSD ne

sont pas bien discriminantes, car la plupart des valeurs p obtenues de chaque CPSD sont supérieures à ce que nous pouvons laisser de côté. On observe à partir des boîtes à moustaches des caractéristiques significatives (comme illustré à la figure 4.16) que la plupart des caractéristiques de domaine fréquentiel des quatre premiers des signaux CPSD montrent des valeurs plus élevées pour les signaux EEG normaux par rapport aux signaux EEG d'apnée du sommeil.

Les caractéristiques significatives discriminatoires ayant une matrice de caractéristiques de (4×8) sont transmises au quatre classificateurs tels que la machine à vecteurs de support (SVM), l'algorithme des K plus proches voisins (KNN), l'arbre de décision (DT) et réseau de neurones perceptrons multicouches (MLPNN).

Les performances du modèle de classification utilisant des mesures d'évaluation largement utilisées (tableau 4.4) suggèrent que KNN avec un hyper paramètre ($K=1$) fonctionne mieux avec précision (93,16 %), sensibilité (93,83 %), spécificité (92,50 %), PPV (92,59 %) et F1-score (93,21 %). Alors que les performances avec SVM avec le noyau RBF sont moindres en raison du caractère aléatoire ou de la nature non stationnaire du signal EEG. Les performances les plus moins précis (84.36% de précision) sont signalé par le classificateur d'arbre de décision, car il suppose que chaque caractéristique est indépendante et classe chaque instance avec une certaine probabilité, ce qui augmente les risques de taux d'erreur de classification.

Le résultat de la présente étude est également comparé aux travaux déjà rapportés dans la littérature, comme indiqué dans le tableau 4.1. La comparaison a utilisé la même base de données « UCD dataset » mais des ensembles de caractéristiques et des classificateurs différents pour la détection automatisée des événements EEG d'apnée du sommeil et normaux. Cette comparaison montre que la classification basée sur l'EWT et CPSD surpasse les autres et atteint la précision la plus élevée de 93,16 % avec KNN.

L'EWT analyse la multi-composante des signaux en extrayant des sous-bandes de décomposition plus cohérentes par rapport aux autres méthodes d'ondelettes. Il existe une grande variabilité des signaux EEG entre les individus. Par conséquent, nous ne pouvons pas prétendre que la méthode proposée est généralisée à d'autres signaux EEG telle quelle. Cependant, en raison de l'indisponibilité d'autres base de données publics sur ce sujet, nous restreignons à démontrer les performances sur une seul base de données « UCD dataset » uniquement.

4.6. Conclusion

Dans le but de détecter le syndrome d'apnées-hypopnées du sommeil (SAHS) à l'aide de des signaux EEG (C3A2 & C4A1), ce chapitre traite d'une architecture d'apprentissage automatique basée sur la transformée en ondelettes empirique (EWT). Pour évaluer les données EEG dans le domaine temps-fréquence, les sous-bandes du signal sont divisées à l'aide de EWT, et l'amplitude instantanée (AI) et la fréquence instantanée (FI) sont calculées à l'aide de la transformée de Hilbert-Huang (HHT). Les caractéristiques basées sur le domaine fréquentiel sont extraites de AI et FI de chaque sous-bande. Les caractéristiques extraites sont la somme des amplitudes du DSP, DSP maximale, la fréquence où la DSP est maximale, la fréquence contenant 25% du signal DSP, la fréquence contenant 50% du signal DSP, la fréquence contenant 75% du signal DSP, la somme de l'amplitude du DSP de différence de bande passante (3db), la fréquence minimal de différence de bande passante et la fréquence maximal de différence de bande passante. Les caractéristiques extraites sont évaluées à l'aide du test de Wilcoxon, et les caractéristiques statistiques sont jugées plus significatives pour un examen plus approfondi. Ces fonctionnalités importantes sont utilisées pour préparer des vecteurs de fonctionnalités pour la formation des différents modèles d'apprentissage automatique. Les performances du modèle de classification ont été évaluées à l'aide de diverses mesures et également visualisées en traçant le ROC. Les résultats suggèrent que le KNN fonctionne mieux avec une précision de 93,16 %, tandis que le SVM avec le noyau RBF a atteint une précision de 92,52 %. Les résultats suggèrent que le modèle proposé est très efficace pour la détection de l'apnée du sommeil.

BIBLIOGRAPHIE

- [1] Liu, Y. T., Zhang, H. X., Li, H. J., Chen, T., Huang, Y. Q., Zhang, L., ... & Yang, M. (2018). aberrant interhemispheric connectivity in Obstructive sleep apnea–hypopnea syndrome. *Frontiers in neurology*, 9, 314.
- [2] Torabi-Nami, M., Mehrabi, S., Borhani-Haghighi, A., & Derman, S. (2015). Withstanding the obstructive sleep apnea syndrome at the expense of arousal instability, altered cerebral autoregulation and neurocognitive decline. *Journal of integrative neuroscience*, 14(02), 169-193.
- [3] Schlüter, T., & Conrad, S. (2012). An approach for automatic sleep stage scoring and apnea-hypopnea detection. *Frontiers of Computer Science*, 6(2), 230-241.
- [4] Ancoli-Israel, S., DuHamel, E. R., Stepnowsky, C., Engler, R., Cohen-Zion, M., & Marler, M. (2003). The relationship between congestive heart failure, sleep apnea, and mortality in older men. *Chest*, 124(4), 1400-1405.
- [5] Won, C. H., Qin, L., Selim, B., & Yaggi, H. K. (2018). Varying hypopnea definitions affect obstructive sleep apnea severity classification and association with cardiovascular disease. *Journal of Clinical Sleep Medicine*, 14(12), 1987-1994.
- [6] Peppard, P. E. (2000). young T, Palta m, Skatrud J. Prospective study of the association between sleep-disordered breathing and hypertension. *N Engl J Med*, 342, 1378-1384.
- [7] Vimala, V., Ramar, K., & Ettappan, M. (2019). An intelligent sleep apnea classification system based on EEG signals. *Journal of medical systems*, 43(2), 1-9.
- [8] Saha, S., Bhattacharjee, A., & Fattah, S. A. (2019). Automatic detection of sleep apnea events based on inter-band energy ratio obtained from multi-band EEG signal. *Healthcare technology letters*, 6(3), 82-86.
- [9] Almuhammadi, W. S., Aboalayon, K. A., & Faezipour, M. (2015, May). Efficient obstructive sleep apnea classification based on EEG signals. In *2015 Long Island Systems, Applications and Technology* (pp. 1-6). IEEE.
- [10] Saha, S., Bhattacharjee, A., Ansary, M. A. A., & Fattah, S. A. (2016, November). An approach for automatic sleep apnea detection based on entropy of multi-band EEG signal. In *2016 IEEE Region 10 Conference (TENCON)* (pp. 420-423). IEEE.

[11] Ahmed, F., Paromita, P., Bhattacharjee, A., Saha, S., Azad, S., & Fattah, S. A. (2016, December). Detection of sleep apnea using sub-frame based temporal variation of energy in beta band in EEG. In 2016 IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE) (pp. 258-261). IEEE.

[12] Mahmud, T., Khan, I. A., Mahmud, T. I., Fattah, S. A., Zhu, W. P., & Ahmad, M. O. (2020, July). Sleep apnea event detection from sub-frame based feature variation in EEG signal using deep convolutional neural network. In 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) (pp. 5580-5583). IEEE.

[13] Rizk, Y., Hajj, N., Mitri, N., & Awad, M. (2019). Deep belief networks and cortical algorithms: A comparative study for supervised classification. *Applied computing and informatics*, 15(2), 81-93.

Conclusion et perspectives

Conclusion et perspectives

1. Conclusion

Enfin, cette partie présente les principales conclusions des travaux menés, et les pistes futures possibles qui pourraient être développées. Comme indiqué dans l'introduction générale, les objectifs de cette thèse étaient axés sur l'amélioration de la caractérisation des processus physiologiques associés au SAHS, et sur la simplification des méthodes de diagnostic utilisées pour cette maladie. Ensuite, les conclusions tirées des travaux présentés dans les chapitres 3 et 4 sont passées en revue par rapport aux objectifs susmentionnés.

Identification du syndrome d'apnées-hypopnées du sommeil basée sur l'analyse d'entropie de dispersion multi-échelle des sous-bandes extrait de la fréquence cardiaque :

Une méthodologie pour la détection automatique du SAHS à partir du signal ECG d'une seule dérivation a été présentée. Avec seulement 24 caractéristiques, extraites de la série RR, nous avons pu atteindre des performances comparables ou supérieures à celles rapportées dans d'autres travaux de la littérature présentant des algorithmes entièrement automatiques dans le cadre d'identification SAHS. Ainsi, il a été possible de caractériser le processus sous-jacent du point de vue de la fréquence cardiaque en combinant un très petit nombre de caractéristiques provenant de différentes sous-bandes (VLF, LF and HF). En particulier, les résultats suggèrent que la combinaison entre CWT et MSE sont particulièrement intéressants lorsqu'il s'agit d'extraire des informations pertinentes permettant de détecter les épisodes apnéiques. De plus, selon les classificateurs utilisés, le système proposé montre un bon équilibre entre performance et complexité, ce qui le rend particulièrement intéressant pour son implémentation matérielle.

Concernant les prestations, dans la base de données « ECG-Apnea » un taux de précision de 98,58% a été atteint pour la classification par segments (Normale Vs OSA). Dans le cas de la base de données « UCD-Dataset », les résultats étaient de 95,69 % pour la classification par segments (Normale Vs Hypopnée).

Le fait que les résultats obtenus dans les expériences étaient très similaires dans deux bases de données différentes soutient l'idée que les conclusions atteintes sont potentiellement généralisables, et qu'elles ne seraient pas limitées par la variabilité entre les bases de données, ce que nous considérons comme une contribution par rapport à d'autres travaux de l'état de

l'art. Par conséquent, les résultats indiquent que l'utilisation de signaux ECG à dérivation unique peut atteindre de bonnes performances dans la détection de l'apnée du sommeil et encourager le développement d'appareils de dépistage automatique du SAHS à utiliser à domicile.

Détection du syndrome d'apnées-hypopnées du sommeil à partir des caractéristiques extraites des signaux EEG (C3A2 & C4A1).

A notre connaissance, cette étude est la première à être réalisée dans le cadre de détection du SAHS centrée sur l'analyse des deux signaux EEG (C3A2 & C4A1) en utilisant la transformée empirique en ondelettes et la densité spectrale de puissance croisée. Pour cela, l'effet de l'utilisation des caractéristiques extraites des signaux EEG(C3A2) et EEG(C4A1) conjointement a été évalué. Nous concluons que la meilleure méthode, tant pour la détection des événements apnéiques que pour le diagnostic global des patients, est la combinaison des deux signaux.

Dans ce cas, pour Physionet « UCD-Dataset », un taux de précision de 93,16 %, une sensibilité de 93,83 % , une spécificité de 92,50 % et (AUC: 0,98) ont été obtenus.

En résumé, nous pouvons conclure que le système proposé offre de bonnes performances pour le diagnostic du SAHS, en particulier lors de l'utilisation des deux signaux, EEG(C3A2) et EEG(C4A1). Compte tenu des grandes avancées technologiques survenues ces derniers temps dans les systèmes portables, les deux signaux pourraient être enregistrés sans fil au domicile du patient, ce qui éviterait les problèmes associés à la polysomnographie.

De plus, la détection en temps réel des événements apnéiques permettrait d'améliorer le traitement, puisque, en présence d'un épisode d'apnée, des mesures conduisant au rétablissement d'une respiration normale pourraient être adoptées. Compte tenu des conséquences importantes du SAHS sur la santé à long terme du patient, cela permettrait de réduire les taux de mortalité associés à cette pathologie.

2. Perspectives

- Comme mentionné dans les limites liées aux bases de données, « Physionet » peut être considéré, à ce jour, comme la base de données la plus représentative dans le contexte de l'apnée du sommeil. Cependant, il présente un certain nombre d'inconvénients qui empêchent la réalisation d'études plus générales incluant, entre autres, un plus grand nombre de patients et de femmes, ou des patients atteints de diverses pathologies

cardiovasculaires. En ce sens, la création d'une nouvelle base de données corrigeant les limitations susmentionnées permettrait une validation clinique plus complète des études réalisées. De plus, cela permettrait une comparaison plus significative des bénéfices obtenus par chacun d'entre eux.

- Nous considérons en revanche que, malgré tout le travail qui a été fait pour améliorer la quantification des événements apnéiques, et la classification globale des patients, il reste encore beaucoup à faire pour caractériser le comportement des différents systèmes impliqués dans les pauses respiratoires qui surviennent dans le SAHS. En ce sens, il serait nécessaire d'étudier de nouvelles techniques d'extraction de caractéristiques, à la fois pour le signal ECG et pour le signal EEG, ce qui nous conduirait finalement à la définition d'un modèle.
- Un autre enjeu à prendre en compte serait l'introduction de méthodes de classification plus sophistiquées afin d'analyser si l'augmentation de la complexité se traduit effectivement par une amélioration des performances des systèmes proposés.
- Nous considérons également qu'il serait opportun d'évaluer de nouveaux algorithmes de sélection de caractéristiques, afin de comparer les résultats avec ceux obtenus à partir du système proposé dans cette thèse.
- L'objectif ultime sera d'obtenir un dispositif à faible coût pour la détection des événements respiratoires et le diagnostic du SAHS.

L'autre axe de travail serait fondamentalement orienté vers l'amélioration de la caractérisation du système sous-jacent à l'apnée du sommeil. Au cours de la préparation de la thèse, nous avons pu vérifier comment le nombre d'auteurs qui étudient les questions liées à la causalité et au couplage des différents systèmes impliqués dans diverses pathologies est en augmentation. En ce sens, nous considérons que l'étude de ces aspects au sein de l'apnée du sommeil pourrait représenter une grande avancée dans la définition du modèle que nous avons mentionné ci-dessus.