



MEMOIRE

Présenté par

DINE Manare

Pour l'obtention de diplôme de

MASTER

Filière : Informatique

Spécialité : Systèmes Informatiques Intelligents

Thème

**UN RESEAU DE NEURONES CONVOLUTIF
POUR LA DETECTION DE L'APNEE DU
SOMMEIL**

Soutenu le : 23 / 06 / 2024

Devant le Jury composé de :

Qualité	Nom et Prénom	Grade	Université
Président	Mr.BENMACHICHE A	MCA	Chadli Bendjedid El-Tarf
Rapporteur	Mme. MILOUD AOUIDATE- TACHOUCHE A	MCB	Chadli Bendjedid El-Tarf
Examineur	Mme. MAKHLOUF A	MCB	Chadli Bendjedid El-Tarf

Année Universitaire : 2023/2024

Remerciements

Je souhaite exprimer ma profonde gratitude à **ALLAH** pour Sa guidance constante et Ses bénédictions qui ont éclairé mon chemin tout au long de mon parcours académique.

Je tiens à remercier chaleureusement le **Dr. TACHOUCHE AMAL** pour son précieux mentorat, ses conseils avisés et son soutien indéfectible. Son expertise et sa dévotion ont été essentielles pour façonner la direction et la qualité de ce travail.

Je suis également reconnaissant envers toutes les personnes qui ont contribué, directement ou indirectement, à la réalisation de cette recherche. Je tiens particulièrement à exprimer ma gratitude envers **Houdna, Oumaima, Nada, ZO, Aymen, Ahmed, Djaber**, pour leur coopération précieuse et informative.

Mes amies, et ma famille méritent également une mention spéciale pour leur soutien constant, leur encouragement et leur compréhension tout au long de ce périple académique exigeant.

Je tiens à remercier les membres du jury pour avoir accepté d'évaluer ce travail. Votre participation est grandement appréciée.

Enfin, un sincère hommage à tous les chercheurs, érudits et auteurs dont les travaux ont servi de fondement à cette étude, ainsi qu'à tous ceux qui ont joué un rôle, qu'il soit visible ou non, dans cette aventure intellectuelle.

En conclusion, je suis profondément reconnaissante envers chacune des personnes qui ont enrichi ce voyage de recherche de leur présence, de leur expertise et de leur soutien, qu'ils soient nommés dans ces lignes ou restent anonymes.

Dine Manare

Je souhaite dédier humblement ce travail à :

Mon cher **père**, dont l'amour, le soutien et l'inspiration continus ont façonné ma personne. Votre guidance et vos encouragements ont forgé la voie de qui je suis aujourd'hui.

Ma **mère**, la lumière et pilier de patience dans ma vie. Votre amour inflexible, vos sacrifices et votre foi inébranlable en moi m'ont donné la force et la détermination tout au long de ce chemin.

Ma meilleur amie **Hadjer**, accompagnante fidèle toujours présente pour m'apporter soutien, encouragement et camaraderie. Ta présence a enrichi ma vie et lui a donné une profondeur supplémentaire.

Puissent les bénédictions d'Allah vous envelopper tous, vous accordant bonheur, succès et épanouissement tout au long de votre parcours.

This thesis presents the development and evaluation of a sleep apnea detection system based on the analysis of electrocardiographic (ECG) signals. Sleep apnea is a serious disorder characterized by repeated interruptions of breathing during sleep, which has negative effects on the health of affected individuals. Early and accurate detection of this disorder is crucial for effective management.

In this work, we use recent advances in machine learning, notably convolutional neural networks (CNN) and the k-nearest neighbors (KNN) algorithm. We have designed a combination CNN-KNN model, combining the data processing power of CNNs with the simplicity and efficiency of KNNs to improve the accuracy of classifying apneic events.

The results show that our combination CNN-KNN approach offers improved accuracy compared to using CNN or KNN alone.

In conclusion, this thesis makes a significant contribution to the detection of sleep apnea, proposing a non-invasive and effective solution that could improve the quality of life for patients. The advancements made open new perspectives for the application of machine learning in healthcare, particularly for the diagnosis and management of sleep disorders.

Keywords: Sleep apnea, ECG, Apnea detection, Diagnosis, CNN, KNN, Deep learning, combination of models, Classification.

Ce mémoire de fin d'études présente le développement et l'évaluation d'un modèle de détection de l'apnée du sommeil basé sur l'analyse de signaux électrocardiographiques (ECG). L'apnée du sommeil est un trouble grave caractérisé par des interruptions répétées de la respiration pendant le sommeil, ayant des effets délétères sur la santé des individus affectés. La détection précoce et précise de ce trouble est cruciale pour une prise en charge efficace.

Dans ce travail, nous exploitons les avancées récentes en apprentissage automatique, notamment les réseaux de neurones convolutionnels (CNN) et l'algorithme des k plus proches voisins (KNN). Nous avons conçu un modèle combine CNN-KNN, combinant la puissance de traitement de données des CNN avec la simplicité et l'efficacité des KNN pour améliorer la précision de la classification des événements apnéiques.

Finalement les résultats montrent que notre approche combine CNN-KNN offre une précision améliorée par rapport à l'utilisation de CNN ou de KNN seuls.

En conclusion, ce mémoire apporte une contribution significative à la détection de l'apnée du sommeil, proposant une solution non invasive et efficace qui pourrait améliorer la qualité de vie des patients. Les avancées réalisées ouvrent de nouvelles perspectives pour l'application de l'apprentissage automatique dans le domaine de la santé, en particulier pour le diagnostic et la gestion des troubles du sommeil.

Mots clés : Apnée du sommeil, ECG, Détection de l'apnée, Diagnostic, CNN, KNN, Apprentissage profond, combinaison des modèles, Classification,

يقدم هذا البحث تطوير وتقييم نظام للكشف عن انقطاع النفس أثناء النوم استنادًا إلى تحليل إشارات تخطيط القلب. يُعتبر انقطاع النفس أثناء النوم اضطرابًا خطيرًا يتميز بانقطاعات متكررة في التنفس أثناء النوم، مما يترك آثارًا ضارة على صحة الأفراد المصابين. الكشف المبكر والدقيق عن هذا الاضطراب أمر حيوي للإدارة الفعالة.

في هذا العمل، نستفيد من التقدمات الحديثة في التعلم الآلي، خاصةً الشبكات العصبية التلافيفية وخوارزمية أقرب الجيران. لقد صممنا نموذجًا مزيجا يجمع بين قوة معالجة البيانات للشبكات العصبية التلافيفية مع بساطة وكفاءة خوارزمية أقرب الجيران لتحسين دقة تصنيف أحداث انقطاع النفس.

النتائج تُظهر أن نهجنا المزيج باستخدام للشبكات العصبية التلافيفية وخوارزمية أقرب الجيران يقدم دقة محسنة مقارنةً باستخدام كل منهما بمفرده.

في الختام، يساهم هذا البحث بشكل كبير في الكشف عن انقطاع النفس أثناء النوم، مقدماً حلاً غير جراحي وفعال يمكن أن يحسن جودة حياة المرضى. التقدمات المحققة تفتح آفاقًا جديدة لتطبيق التعلم الآلي في مجال الرعاية الصحية، خاصةً لتشخيص وإدارة اضطرابات النوم.

الكلمات الرئيسية: انقطاع النفس أثناء النوم، تخطيط القلب، الكشف عن انقطاع النفس، التشخيص، الشبكات العصبية التلافيفية، أقرب الجيران، التعلم العميق، مزيج من النماذج، التصنيف.

Table des matières

Remerciements	2
Dédicace	3
Abstract	4
Résumé	5
المخلص	6
Table des matières	7
Liste des figures	10
Liste des tableaux	12
Liste des acronymes	13
Introduction Générale	14
1. Contexte du projet et problématique	14
2. Motivations	15
3. Objectifs	15
4. Contenu du mémoire	16
Chapitre 1 : L'APNEE DU SOMMEIL	17
1.1. Introduction	17
1.2. Le sommeil	17
1.3. L'apnée du sommeil	18
1.3.1. Définitions	18
1.3.2. Les niveaux de gravité de l'Apnées du sommeil	19
1.4. Les signes de l'apnée du sommeil.....	19
1.5. Les conséquences d'SAOS	20
1.6. Les méthodes de diagnostic	20
1.6.1. La polysomnographie (PSG) :.....	20
1.6.2. La polygraphie (PG) :.....	22
1.7. L'Électrocardiogramme	23
1.7.1. Signal ECG à une seule dérivation.....	24

1.8. Conclusion.....	26
Chapitre 2 : LES MÉTHODES DE CLASSIFICATION.....	27
2.1. Introduction	27
2.2. Les méthodes de classification utilisées	27
2.2.1. L'apprentissage profond	28
2.2.2. Réseaux de neurones convolutifs (CNN).....	30
2.2.3. L'algorithme K plus proches voisins (KNN).....	33
2.3. Travaux relatif	35
2.4. Conclusion.....	38
Chapitre 3 : ASPECT TECHNIQUE, OUTILS & LANGAGE DE PROGRAMMATION	39
3.1. Introduction	39
3.2. Environnement physique (Hardware).....	39
3.3. L'environnement logique (Software)	40
3.3.1. Visual Studio Code.....	40
3.3.2. Google Colaboratory.....	40
3.4. Langage de programmation	41
3.4.1. Python.....	41
3.5. Les bibliothèques utilisées.....	42
3.6. Dataset ECG d'apnée du sommeil.....	44
3.7. Filtre passe-bande FIR.....	47
3.8. L'algorithme de segmentation de Hamilton	48
3.9. La technique de sur-échantillonnage aléatoire	48
3.10. L'optimiseur.....	48
3.10.1. L'algorithme d'optimisation Adam	49
3.11. Les métriques d'évaluation du modèle	50
3.12. Conclusion	53
Chapitre 4 : DÉVELOPPEMENT, DISCUSSION & ÉVALUATION.....	54
4.1. Introduction	54
4.2. Conception du système.....	54
4.3. Préparation du dataset.....	56

4.4.	Diviser les données en Train et Test.....	58
4.5.	La méthodologie proposée.....	58
4.6.	Choix du modèle CNN	63
4.7.	Architecture du modèle CNN	68
4.8.	Discussion et évaluation des résultats obtenus	72
4.8.1.	Résultats et évaluation du modèle AS (CNN).....	72
4.8.2.	Résultats et évaluation du modèle KNN	77
4.8.3.	Résultats et évaluation du modèle CNN+KNN.....	80
4.9.	Comparaison de nos résultats obtenus.....	86
4.10.	Comparaison entre nos résultats et les résultats des travaux relatifs	87
4.11.	Conclusion	88
Conclusion et Perspectives.....		89
Références		91
	Références Bibliographiques	91
	Références Web.....	94

Liste des figures

Figure 1. Le sommeil	17
Figure 2. Les mécanismes de l'apnée obstructive du sommeil	18
Figure 3. La polysomnographie (PSG)	21
Figure 4. Exemple de page d'enregistrement de polysomnographie nocturne	22
Figure 5. Exemple d'une page d'enregistrement polygraphique montrant des SOA.....	23
Figure 6. La Position de l'électrode / Vue d'un axe vertical	24
Figure 7. Les caractéristiques du signal ECG à une seule dérivation	25
Figure 8. Architecture de deep learning multi-couches	28
Figure 9. Un modèle mathématique d'un neurone artificiel	29
Figure 10. Architecture de base de CNN	30
Figure 11. La procédure de l'algorithme KNN.....	33
Figure 12. Visual studio code.....	40
Figure 13. Google Colaboratory.....	40
Figure 14. Python	41
Figure 15. L'ensemble de données apnée ECG.	44
Figure 16. Les différent format de fichier pour l'enregistrement a01	45
Figure 17. Filtre passe-bande FIR.....	47
Figure 18. Conception du système	54
Figure 19. Représentation de l'intervalle R-R dans un signal ECG.....	57
Figure 20. Le flux de travail avec le KNN	59
Figure 21. Le paramétrage du nombre des voisins pour KNN.....	60
Figure 22. Le flux de travail avec le CNN.	61
Figure 23. Le flux de travail du CNN+KNN	62
Figure 24. La précision du modèle 1	63
Figure 25. La perte du modèle 1	63
Figure 26. La précision du modèle 2.....	64
Figure 27. La perte du modèle 2.	64
Figure 28. La précision du modèle 3.....	65
Figure 29. La perte du modèle 3	65
Figure 30. La précision du modèle 4.....	66
Figure 31. La perte du modèle 4	67
Figure 32. L'architecture du modèle AS (CNN).....	68
Figure 33. Configuration et paramétrage du modèle AS	70

Figure 34. La matrix de confusion du Model CNN	74
Figure 35. La courbe ROC CNN.....	75
Figure 36. La courbe Précision-Rappel CNN	76
Figure 37. La courbe Roc du model KNN	78
Figure 38. La courbe Précision-Rappel du model KNN	79
Figure 39. L'augmentation de précision avec 21-NN.....	82
Figure 40. La matrice de confusion de la combinaison CNN+KNN.	83
Figure 41. La courbe Roc CNN-KNN.	84
Figure 42. La courbe précision - Rappel CNN+KNN.....	85

Liste des tableaux

Table 1. Méthodes de classification utilisées par les chercheurs.	37
Table 2. Matériel de bureau.....	39
Table 3. La matrix de confusion	52
Table 4. Évaluation du modèle AS.....	73
Table 5. Évaluation de la combinaison.	81
Table 6. Comparaison de nos résultats obtenus	86
Table 7. Comparaison avec les travaux relatifs.....	87

Liste des acronymes

SAHOS	Syndrome d'apnées–hypopnées obstructives du sommeil
IHA	Index d'apnée-hypopnée
PSG	Polysomnographie
PG	Polygraphie
KNN	K-Nearest Neighbors
CNN	Convolutional Neural Networks
EEG	Electroencéphalographie
EMG	Electromyographie
EOG	Electro-oculographie
ECG	Electrocardiographie
ANN	Electrocardiographie
SVM	Support Vector Machine
LR	Logistic Regression
MLP	Multi-Layer Perceptron
BN	Batch Normalization
TW-MLP	Time Window Multilayer Perceptron
LDA	Linear Discriminant Analysis
FIR	Finite Impulse Response

Dans un monde où les avancées technologiques transforment continuellement notre quotidien, la santé demeure un domaine d'intérêt majeur. Parmi les multiples facettes de la santé, le sommeil occupe une place prépondérante, car il influence directement notre bien-être physique et mental. Cependant, des troubles du sommeil tels que l'apnée du sommeil peuvent altérer cette fonction vitale, entraînant des conséquences néfastes sur la santé des individus concernés. L'apnée du sommeil, caractérisée par des interruptions respiratoires récurrentes pendant le sommeil, nécessite une détection précoce et précise pour permettre une prise en charge efficace.

Dans ce contexte, notre projet de fin d'études se concentre sur l'élaboration d'un modèle novateur de détection de l'apnée du sommeil en utilisant des signaux électrocardiographiques (ECG).

1. Contexte du projet et problématique

Le projet d'un modèle de détection de l'apnée du sommeil s'inscrit dans le contexte de la santé et de la technologie, fusionnant ainsi deux domaines essentiels. L'apnée du sommeil est un trouble respiratoire courant, mais sous-diagnostiqué, qui peut avoir de graves conséquences sur la santé. La problématique principale réside dans le fait que certaines personnes atteintes d'apnée du sommeil sévère ne reçoivent pas les signaux pour reprendre leur respiration lorsqu'elles cessent de respirer et d'autre problème dans la détection précoce et précise de l'apnée du sommeil, permettant ainsi une intervention médicale appropriée. Les approches actuelles, souvent basées sur des méthodes de détection traditionnelles et subjectives, telles que l'analyse manuelle des enregistrements polysomnographiques « PSG ». Cette méthode est non seulement coûteuse, et invasive, mais également sujette à des erreurs humaines et des interprétations subjectives.

2. Motivations

Les motivations sous-jacentes à la recherche d'une solution à la problématique de la détection de l'apnée du sommeil sont multiples et essentielles. Tout d'abord, il y a l'impératif de santé publique, car l'apnée du sommeil est un trouble courant, mais souvent négligé, qui peut avoir des répercussions graves sur la santé à long terme. Ensuite, il y a la volonté d'améliorer la qualité de vie des personnes touchées par ce trouble en leur offrant des outils de diagnostic plus accessibles et moins invasifs. De plus, il y a un intérêt croissant pour l'application de technologies innovantes, telles que l'intelligence artificielle et l'apprentissage automatique, dans le domaine médical pour améliorer les diagnostics et les soins. Enfin, il y a un besoin de combler les lacunes des approches actuelles en offrant des solutions plus précises, fiables et économiquement viables pour la détection de l'apnée du sommeil.

3. Objectifs

En exploitant les progrès de la technologie et des méthodes d'analyse du signal, notre objectif est de concevoir une solution capable d'identifier avec précision les schémas caractéristiques de l'apnée du sommeil dans les données ECG. Cette approche non invasive pourrait offrir une alternative prometteuse aux méthodes traditionnelles de diagnostic, facilitant ainsi une intervention précoce et ciblée pour améliorer la qualité de vie des patients.

Plus précisément, les objectifs de ce projet convoitent à utiliser l'intelligence artificielle. En appliquant des algorithmes d'apprentissage profond sur les « données ECG », nous visons à développer un système pour détecter automatiquement les épisodes d'apnée du sommeil. Cette approche permet une surveillance non invasive, en temps réel et à domicile, rendant le dépistage plus accessible, pratique et fiable. Par développer un modèle de détection d'apnée du sommeil robuste et efficace. Dans un premier temps, nous visons la conception des algorithmes de traitement de signal et des modèles d'apprentissage automatique, notamment des réseaux de neurones convolutionnels (CNN) et des classificateurs K plus proches voisins (KNN), pour analyser les données d'électrocardiogramme (ECG) et détecter les signaux d'apnée. Ensuite, comme perspectives, nous irons vers l'intégration de ces algorithmes dans une application conviviale et accessible, permettant aux utilisateurs de surveiller leur santé du sommeil de manière autonome. Enfin, l'objectif final serait d'évaluer la précision, la sensibilité et la spécificité du modèle développé par rapport aux méthodes existantes, en utilisant des jeux de données réels et en collaboration avec des professionnels de la santé.

4. Contenu du mémoire

Le mémoire se compose de quatre chapitres, chacun traitant l'un des aspects spécifiques liés au modèle de détection d'apnée du sommeil.

Le premier chapitre, intitulé "L'apnée du sommeil", présente une revue de la littérature sur le sommeil, l'apnée du sommeil, ses signes, ses conséquences, les méthodes de diagnostic, ainsi que l'importance de l'électrocardiogramme dans ce contexte.

Le deuxième chapitre, "Les méthodes de classification", explore les différentes méthodes de classification utilisées dans le domaine de la détection de l'apnée du sommeil, en mettant en évidence les travaux relatifs.

Le troisième chapitre, "Aspect technique, outils & langage de programmation", se concentre sur les aspects techniques du projet, y compris l'environnement matériel et logiciel, les langages de programmation utilisés, les bibliothèques, le dataset ECG d'apnée du sommeil, ainsi que les techniques de traitement de signal et d'optimisation.

Le quatrième et dernier chapitre, "Développement, Discussion et Évaluation ", détaille l'architecture du modèle, la préparation du dataset, la méthodologie proposée, le choix et l'architecture des modèles CNN, ainsi que l'évaluation des résultats obtenus pour chaque modèle, y compris CNN, KNN, et la combinaison du CNN+KNN. Il propose également une comparaison entre les résultats obtenus dans notre étude et ceux des travaux relatifs.

Enfin, nous clôturerons ce document par une conclusion générale.

Chapitre 1 : L'APNEE DU SOMMEIL

1.1. Introduction

Le sommeil, pilier essentiel de notre bien-être, est souvent perturbé par des troubles tels que l'Apnée du Sommeil (SAOS), un trouble caractérisé par des interruptions temporaires de la respiration pendant le sommeil. Ces épisodes récurrents peuvent avoir des implications profondes sur la santé, allant au-delà des simples perturbations du sommeil. En effet, la SAOS est associée à divers problèmes de santé.

Ce chapitre se penche sur l'importance cruciale d'une détection efficace de la SAOS. En comprenant l'impact significatif de la SAOS sur la santé globale, nous jetterons les bases d'une exploration approfondie des méthodes de détection, offrant ainsi des solutions précieuses pour améliorer la qualité de vie des individus affectés.

1.2. Le sommeil

Le sommeil est le contraire de l'éveil et est une perte provisoire de conscience, mais pas d'ambiguïté sensorielle. [W13]



Figure 1. Le sommeil. [W8]

Il occupe plus d'un tiers de notre vie. Il est extrêmement important pour notre croissance, la maturation cérébrale ainsi que le développement et le maintien des capacités cognitives. Le sommeil est aussi important pour réguler la sécrétion de nombreuses hormones et maintenir la température interne du corps. Nous savons que réduire la durée du sommeil ou modifier la qualité du sommeil est susceptible de favoriser la prise de poids et l'obésité. [20]

Parmi les conditions auxquelles nous pouvons être exposés et qui modifient la qualité de notre sommeil, il y a le syndrome d'apnées–hypopnées obstructives du sommeil.

1.3. L'apnée du sommeil

1.3.1. Définitions

Le syndrome d'apnées du sommeil, également connu sous le nom de syndrome d'apnées obstructives du sommeil (SAOS), est une affection courante caractérisée par de fréquentes interruptions de la respiration pendant le sommeil « 10 à 30 secondes, cela arrive le minimum 5 fois par heure ». Cette affection est souvent associée à un collapsus pharyngé et à une obstruction des voies respiratoires, conduisant à une hypoxie. En réponse, le cerveau avertira la personne éveillée de continuer à respirer. Elles sont souvent classées en trois stades, de l'apnée du sommeil légère vers l'apnée du sommeil sévère. [W1]

La figure n°2 montre les mécanismes de l'apnée obstructive du sommeil :

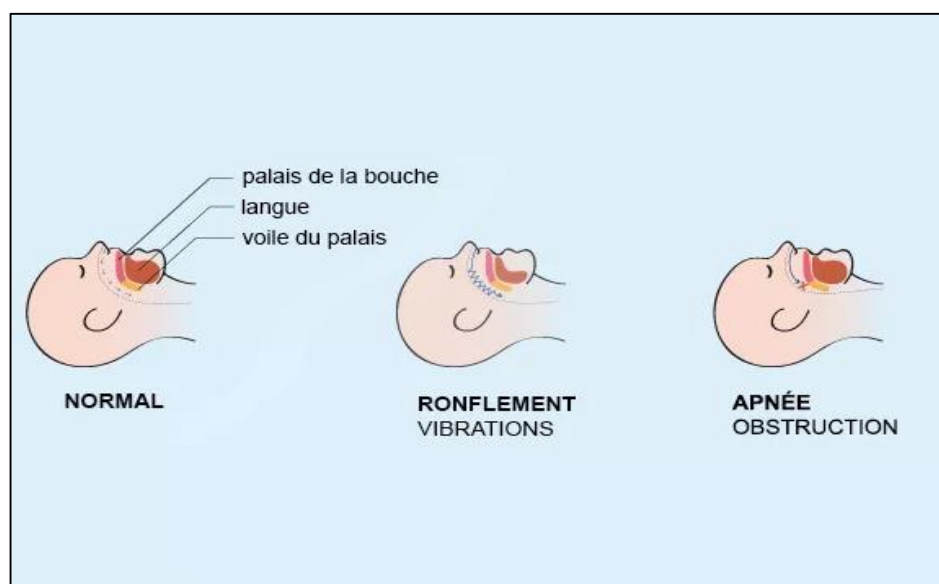


Figure 2. Les mécanismes de l'apnée obstructive du sommeil. [W3]

1.3.2. Les niveaux de gravité de l'Apnées du sommeil

L'Indice d'Apnée-Hypopnée (IAH) mesure le nombre total d'épisodes d'apnée et d'hypopnée divisé par la durée totale du sommeil pendant laquelle ces événements sont produits. [9]

$$IAH = \frac{Nb \text{ d'apnées} + Nb \text{ d'hypopnées}}{\text{Durée du Sommeil (min)}} \times 60$$

Cet indice permet de classer la sévérité d'Apnées du Sommeil (AS) en trois niveaux distincts :

- Si IAH entre 5 et 15 alors l'apnée du sommeil est légère.
- Si IAH entre 15 et 30 alors l'apnée du sommeil est moyenne.
- Si IAH > 30 alors l'apnée du sommeil est sévère. [9]

Étant donné que les apnées et les hypopnées peuvent avoir des conséquences néfastes sur l'organisme, il est crucial de prendre conscience de ces problèmes et de reconnaître les symptômes associés à cette condition.

1.4. Les signes de l'apnée du sommeil

L'apnée du sommeil présente des différences dans ses manifestations entre les hommes et les femmes. Ces distinctions rendent parfois le diagnostic plus complexe, car les signes peuvent varier en intensité et en nature : [2]

A. Chez l'homme :

Chez l'homme, les symptômes les plus courants du syndrome d'apnée du sommeil apparaissent au cours de la journée par :

- Une somnolence diurne.
- Un ressenti de fatigue importante durant la journée.
- Des troubles de la concentration.
- Des troubles de l'attention. [2]

A. Chez la femme :

Il est plus difficile de déceler un SAOS chez une personne de sexe féminin, cependant il présente les symptômes les suivants :

- Des somnolences diurnes.
- Des maux de tête le matin.
- Des troubles digestifs.
- Des troubles de l'humeur.
- Une dépression. [2]

1.5. Les conséquences d'SAOS

L'apnée du sommeil (SAOS) peut avoir des conséquences significatives sur la santé et le bien-être des individus qui en souffrent. En raison des interruptions répétées de la respiration pendant le sommeil, les personnes atteintes d'apnée du sommeil peuvent éprouver tous les symptômes que nous avons mentionnés précédemment. Ces effets peuvent également se traduire par des difficultés dans la vie quotidienne, que ce soit au travail, à l'école ou dans les activités journalières. De plus, le SAOS est associé à un risque accumulé de problèmes de santé tels que : [2]

- Les maladies cardiaques.
- L'hypertension.
- Des accidents vasculaires cérébraux.
- Le diabète.

Ils peuvent également accroître le risque d'accidents de la route en raison de la somnolence diurne qu'ils provoquent. [2]

Et pour prévenir l'apparition de ces affections, il est crucial de consulter un professionnel pour obtenir un diagnostic précis de l'apnée du sommeil, comme nous le détaillerons par la suite.

1.6. Les méthodes de diagnostic

Conventionnellement, le diagnostic du SAOS repose sur une polysomnographie (PSG) réalisée au laboratoire du sommeil ou une polygraphie ventilatoire (PG) réalisée en ambulatoire [18] :

1.6.1. La polysomnographie (PSG) :

La polysomnographie enregistre et aide à classer les stades du sommeil, et la survenue et la durée des périodes d'apnée et d'hypopnée. Elle est idéale pour confirmer le diagnostic d'apnée obstructive du sommeil et quantifier la gravité de l'apnée obstructive du sommeil. Cependant, elle nécessite une nuit au laboratoire du sommeil et est donc compliquée et coûteuse. La polysomnographie comprend généralement la mesure continue de : [11]

- L'architecture du sommeil par EEG (électroencéphalographie).
- Électromyographie du menton pour détecter une hypotonie (EMG).
- Électro-oculographie (EOG) pour évaluer la fréquence des mouvements oculaires rapides.
- Capteurs de débit d'air au niveau du nez et un capteur de ronflement pour détecter les apnées et les hypopnées.
- Capteurs thoraciques et/ou abdominaux pour détecter l'effort respiratoire
- Saturation en oxygène par oxymétrie pulsée
- Surveillance ECG pour détecter les troubles du rythme associés à des épisodes apnéiques
- Boîtier d'enregistrements de la PSG pour analyser les mouvements et positions et enregistre les différentes informations. [10]

D'autres variables évaluées comprennent l'activité musculaire des membres « afin d'évaluer les causes non respiratoires des réveils pendant le sommeil, tels que le syndrome des jambes sans repos et le syndrome des mouvements périodiques des membres », ainsi que la position corporelle « l'apnée peut ne survenir qu'en décubitus dorsal (sur le dos) ». Les figures n°3 et n°4 suivantes montrent la polysomnographie « PSG » (en haut) et un exemple de page d'enregistrement de polysomnographie nocturne (en bas) : [10]




Figure 3. La polysomnographie (PSG). [W4]

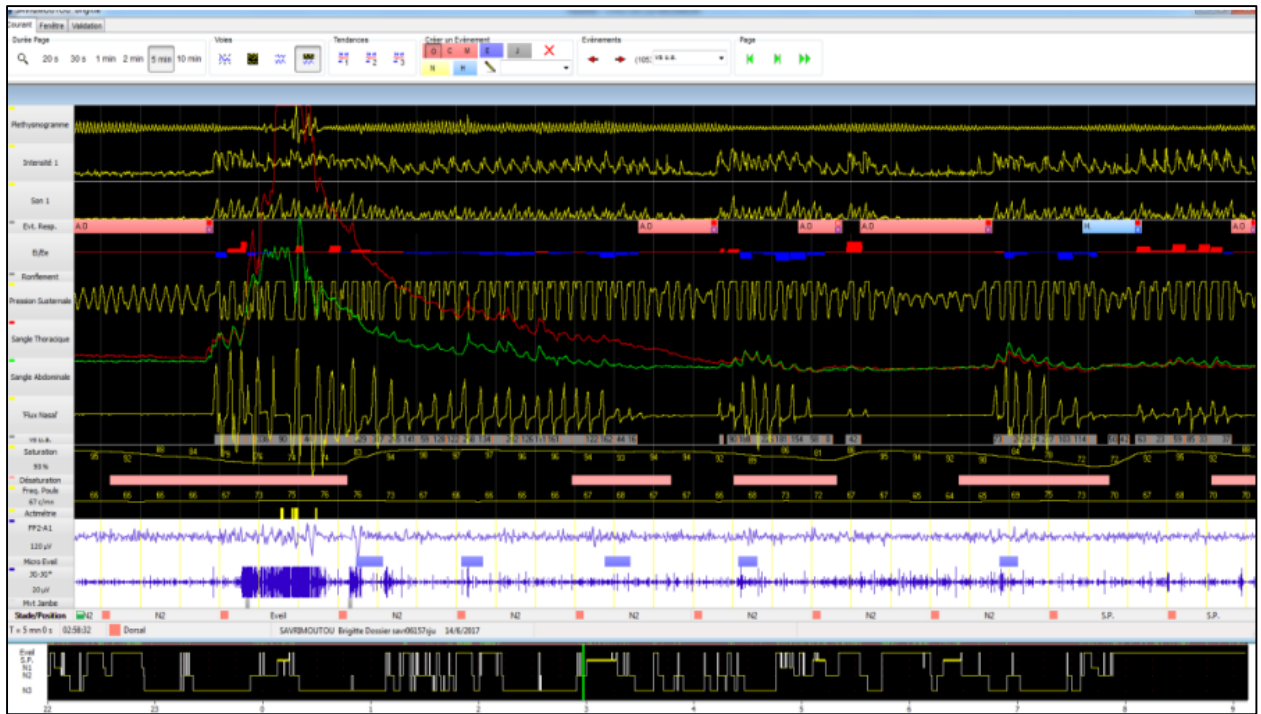


Figure 4. Exemple de page d'enregistrement de polysomnographie nocturne. [12]

1.6.2. La polygraphie (PG) :

Il s'agit d'une polysomnographie simplifiée, qui mesure au moins 4 signaux. Elle inclut simultanément les éléments de mesure suivants :

- Capteurs de débit d'air au niveau du nez.
- Capteur de renflement.
- Capteurs thoraciques et/ou abdominaux.
- Saturation en oxygène par oxymétrie pulsée.
- Boîtier d'enregistrements de la PG pour analyser et enregistrer les différentes informations. [12]

Voici un exemple d'une page d'enregistrement polygraphique montrant des SOA dans la figure n°5 suivante :




Figure 5. Exemple d'une page d'enregistrement polygraphique montrant des SOA. [12]

La polygraphie offre une solution plus conviviale et économique, et peut être effectuée en dehors de l'environnement hospitalier. Elle peut être choisie en première intention lorsque le diagnostic de syndrome d'apnées obstructives du sommeil (SAOS) est fortement suspecté, notamment en cas de sommeil peu perturbé et en l'absence d'autres troubles du sommeil associés. Cependant, en cas de résultats contradictoires entre la polygraphie ventilatoire et l'évaluation clinique, une polysomnographie devrait être envisagée pour confirmer ou infirmer le diagnostic de SAOS. [12]

1.7. L'Électrocardiogramme

L'électrocardiogramme (ECG) est une technique d'examen non invasif qui enregistre l'activité électrique du cœur à travers la surface du corps. Cet enregistrement se présente sous la forme d'un tracé graphique composé de plusieurs dérivations, reflétant les variations de potentiel électrique générées par les cellules myocardiques au cours du cycle cardiaque. L'ECG permet d'évaluer la régularité du rythme cardiaque, la conduction électrique à travers les différentes structures cardiaques, et d'identifier d'éventuelles anomalies telles que des troubles du rythme, des blocages de conduction ou des lésions cardiaques. Cet outil de diagnostic essentiel est largement utilisé en cardiologie pour le dépistage, le suivi et la prise en charge des pathologies cardiaques, et un parmi les ECG utilisé couramment on trouve : [23]

1.7.1. Signal ECG à une seule dérivation

Le signal ECG à une seule dérivation est une représentation visuelle de l'activité électrique du cœur enregistrée à partir d'une seule électrode positionnée sur le corps. Ce type de signal offre des données sur les cycles cardiaques, les intervalles RR, les amplitudes des ondes et d'autres aspects électriques du cœur. Son analyse est fréquemment utilisée en médecine pour identifier les problèmes cardiaques, y compris l'apnée du sommeil, en fournissant des indications précieuses sur la santé cardiaque d'un individu. Les deux figures suivantes montrent la position de l'électrode une vue d'un axe vertical sans axe horizontal (en haut) puis le tracé du signal ECG avec ses caractéristiques (en bas) : [22]

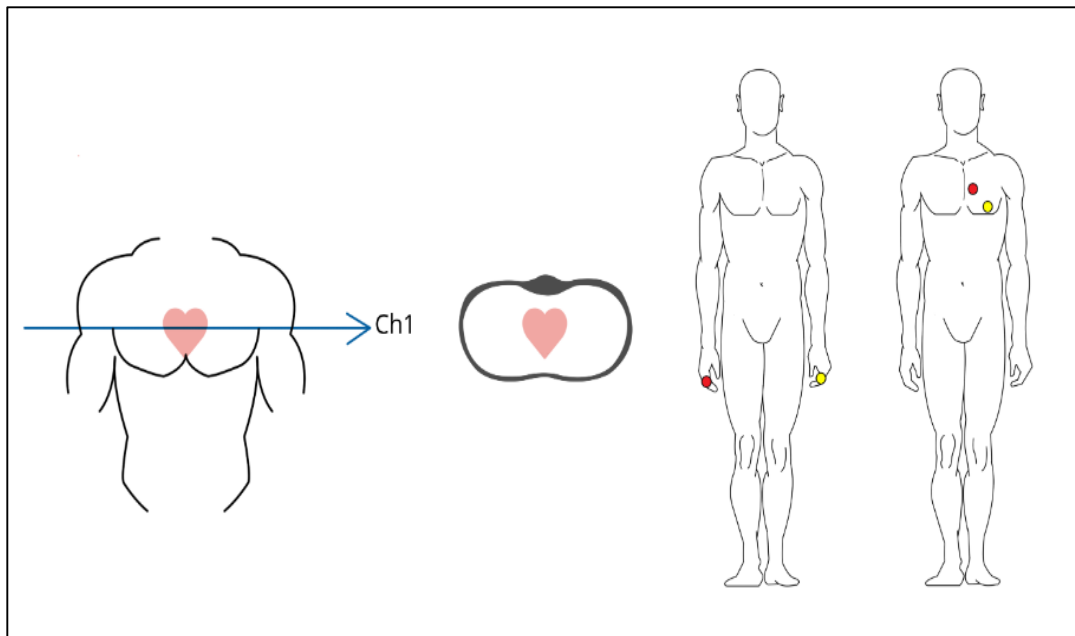


Figure 6. La Position de l'électrode / Vue d'un axe vertical. [W15]




Figure 7. Les caractéristiques du signal ECG à une seule dérivation. [W16]

L'image n°7 présentée offre une vue détaillée du signal ECG à une seule dérivation avec ses principales caractéristiques qui sont clairement identifiables :

- **Les ondes P, Q, R, S, T et U :** Ces ondes reflètent les différentes phases du cycle cardiaque. L'onde P marque la dépolarisation auriculaire, suivie par le complexe QRS représentant la dépolarisation ventriculaire. Ensuite, l'onde T représente la repolarisation ventriculaire, tandis que l'onde U, moins prononcée, indique la repolarisation des cellules musculaires papillaires. [13]
- **Les segments P-R, S-T :** Ces segments correspondent aux intervalles entre les différentes ondes. Le segment P-R mesure le temps entre le début de l'onde P et le début du complexe QRS, reflétant la conduction auriculo-ventriculaire. Le segment S-T indique le temps entre la fin du complexe QRS et le début de l'onde T, représentant la période de repolarisation ventriculaire. [13]
- **Les intervalles P-R, Q-T, R-R, QRS :** Ces intervalles quantifient la durée des différentes phases du cycle cardiaque. L'intervalle P-R mesure le temps total de la conduction auriculo-ventriculaire. L'intervalle Q-T représente le temps nécessaire à la dépolarisation et à la repolarisation ventriculaire, l'intervalle R-R représente le temps écoulé entre deux battements cardiaques consécutifs. Enfin, l'intervalle QRS indique le temps nécessaire à la dépolarisation des ventricules. [13]

Cette visualisation détaillée du signal ECG permet aux cliniciens de détecter les anomalies cardiaques, d'évaluer la santé cardiaque d'un patient et d'identifier les potentiels troubles respiratoires liés à l'apnée du sommeil. En combinant l'analyse de quelques caractéristiques du signal ECG comme les ondes R, l'intervalles R-R et les ondes des amplitudes, avec d'autres données physiologiques, il est possible d'améliorer la précision du diagnostic et de guider le traitement des patients souffrant d'apnée du sommeil.

1.8. Conclusion

Dans ce chapitre nous avons tenté d'éclairer les concepts d'apnée et d'hypopnée du sommeil. Nous avons défini ces deux concepts et essayé de présenter leur gravité en introduisant les effets qu'ils ont sur la santé quotidienne des individus. Enfin nous avons, aussi, présenté les outils de mesures et de diagnostic, et dans le chapitre suivant, nous décrirons et expliquerons les méthodes de classification que nous avons choisies pour créer notre système de détection de ce syndrome.

Chapitre 2 : LES MÉTHODES DE CLASSIFICATION

2.1. Introduction

Ce deuxième chapitre explore les méthodes de classification qui seront utilisées dans la conception de notre modèle de détection de l'apnée du sommeil. Parmi ces méthodes, nous nous pencherons notamment sur l'apprentissage profond, représenté par les réseaux de neurones convolutionnels (CNN), ainsi que sur l'algorithme des k plus proches voisins (KNN). Cette section vise à présenter en détail ces approches de classification, à explorer leurs principes fondamentaux et à discuter de leur pertinence dans le contexte de la détection des épisodes d'apnée du sommeil. En outre, nous examinerons les travaux de recherche pertinents qui ont précédemment utilisé ces méthodes dans des applications similaires, ce qui nous permettra de mieux comprendre leur potentiel et leurs limitations.

2.2. Les méthodes de classification utilisées

Dans le cadre de la détection de l'apnée du sommeil à partir d'un signal ECG à dérivation unique, différentes méthodes de classification sont utilisées pour interpréter efficacement les données et identifier les patterns associés aux épisodes d'apnée. Ces méthodes permettent de distinguer les périodes normales de respiration des périodes anormales caractéristiques de l'apnée. Parmi ces approches, nous explorons notamment l'apprentissage profond, représenté par les réseaux de neurones convolutionnels (CNN), et l'algorithme des k plus proches voisins (KNN). Chacune de ces méthodes présente des caractéristiques uniques et des avantages spécifiques en termes de précision, de robustesse et de vitesse d'exécution. En examinant en détail ces approches de classification, nous pourrons mieux comprendre leur fonctionnement, leurs limitations et leur applicabilité dans le contexte de la détection de l'apnée du sommeil.

2.2.1. L'apprentissage profond

L'apprentissage profond, également connu sous le nom de deep learning, est une approche de l'apprentissage automatique qui enseigne aux ordinateurs à réaliser des tâches en imitant le processus d'apprentissage humain. Dans ce contexte, un modèle informatique apprend à effectuer des classifications directement à partir de données telles que des images, du texte ou des sons. Les modèles d'apprentissage profond peuvent souvent obtenir des performances de pointe, parfois même surpasser celles des humains. Pour ce faire, ces modèles sont entraînés sur de vastes ensembles de données annotées, utilisant des architectures de réseaux neuronaux composées de multiples couches. La figure suivante n°8 illustre l'architecture typique de cette méthode : [1]




Figure 8. Architecture de deep learning multi-couches. [W5]

La technologie d'apprentissage profond (DL) découle des réseaux neuronaux artificiels (ANN). Un réseau neuronal classique est essentiellement constitué de multiples unités de traitement interconnectées, appelées neurones, chacune produisant une série d'activations pour obtenir le résultat souhaité. La Figure n°9 présente une représentation schématique du modèle mathématique d'un neurone artificiel, illustrant ses composants tels que l'entrée (X_i), le poids (w), le biais (b), la sommation des entrées (Σ), la fonction d'activation (f), et la sortie correspondante (y). Aujourd'hui, l'apprentissage profond, qui repose sur les réseaux neuronaux, est largement utilisé dans divers domaines de recherche et d'application, notamment : [8]

- La santé.
- L'analyse des sentiments.
- Le traitement du langage naturel.
- La reconnaissance visuelle.
- L'intelligence d'affaires.
- La cyber sécurité, etc. [8]

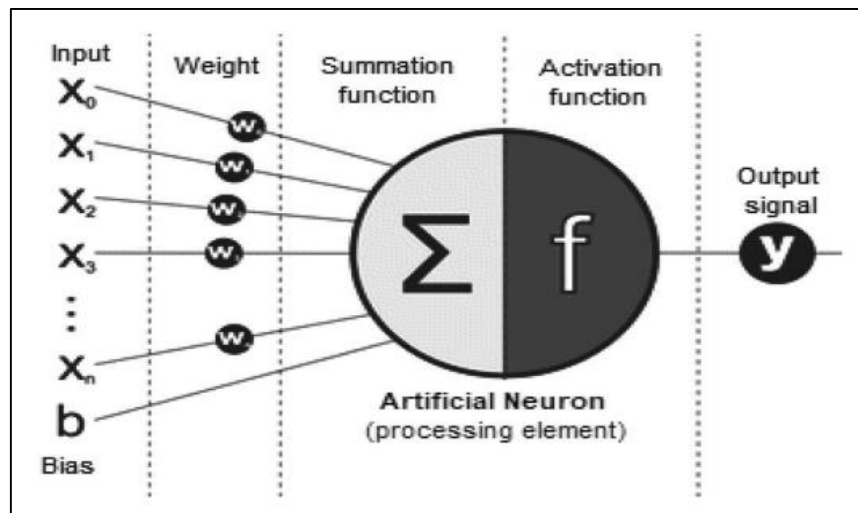


Figure 9. Un modèle mathématique d'un neurone artificiel. [17]

Ces dernières années, l'application de la technologie d'apprentissage profond a connu une croissance rapide. Les avancées dans ce domaine permettent désormais aux systèmes d'apprentissage profond de reproduire de manière de plus en plus fidèle les capacités cognitives humaines telles que l'apprentissage, la résolution de problèmes et la prise de décision. [17]

En effet, l'apprentissage profond permet généralement une auto-formation sans nécessiter une programmation répétitive de la part des humains. Parmi les différentes approches d'apprentissage profond, le CNN se démarque particulièrement pour son efficacité à extraire des caractéristiques complexes à partir de données spatiales. Il s'avère être un choix judicieux pour apprendre des représentations significatives des signaux liés à l'apnée du sommeil à partir de données physiologiques telles que les enregistrements d'électrocardiogrammes (ECG). [17]

A la lumière de ces définitions, nous proposons d'utiliser le CNN sur une base de données homologuées afin de créer un algorithme polyvalent qui pourra être utilisé sur des signaux ECG au niveau laboratoire ou bien chez le spécialiste (le médecin).

2.2.2. Réseaux de neurones convolutifs (CNN)

Le CNN, ou Réseau de Neurones Convolutif, est un type spécifique de Réseau de Neurones Artificiels (RNA), connu également sous le nom de ConvNet. Doté d'une architecture à alimentation avant profonde, il se distingue par sa capacité de généralisation remarquable par rapport aux autres réseaux, notamment ceux comportant des couches entièrement connectées. Sa capacité à apprendre des caractéristiques hautement abstraites des objets, en particulier à partir de données spatiales, lui confère une efficacité notable dans l'identification de ces caractéristiques. Un modèle de CNN profond est constitué d'un ensemble défini de couches de traitement, permettant ainsi l'apprentissage de différentes caractéristiques des données d'entrée, telles que les images, à plusieurs niveaux d'abstraction. [3]

L'architecture de base de CNN est illustrée dans la figure n°10 suivante, avec ses différents types de couches :

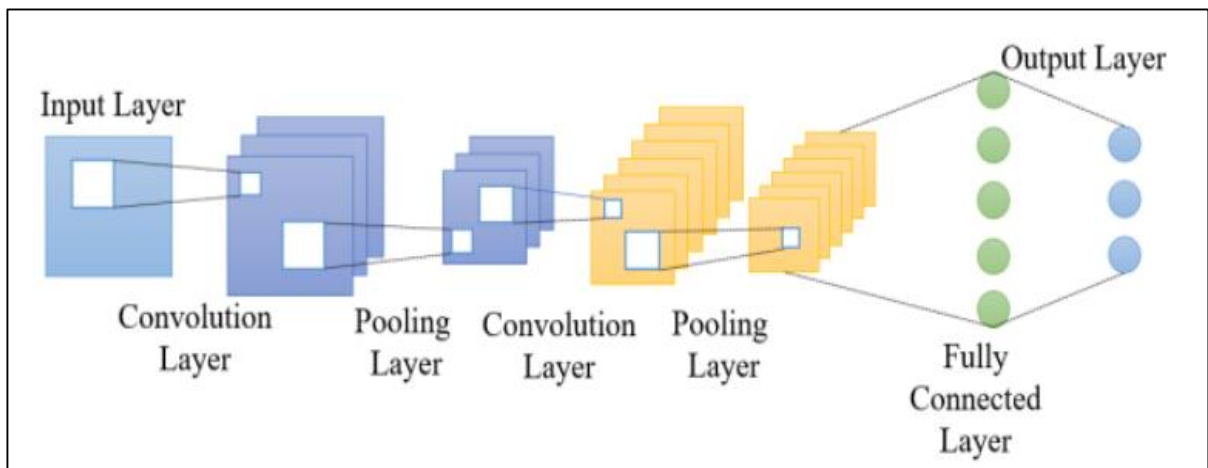


Figure 10. Architecture de base du CNN. [5]

Comme le montre la figure n°10, la composition de base de l'architecture du CNN peut être divisée en cinq parties : la couche d'entrée, la couche de convolution, la couche de sous-échantillonnage, la couche entièrement connectée et la couche de sortie. La description détaillée de chaque partie est expliquée ci-dessous :

- **Couche d'entrée (Input Layer) :** Cette couche reçoit les données brutes en entrée, telles que les valeurs de pixels d'une image, et les introduit dans le réseau. [5]
- **Couche de convolution (Convolutional Layer) :** Également appelée couche de sur-échantillonnage, cette couche extrait des caractéristiques des données d'entrée à l'aide de noyaux de convolution. Chaque noyau de convolution extrait des caractéristiques spécifiques, et le nombre de caractéristiques extraites dépend du nombre de noyaux inclus dans la couche. [5]
- **Couche de sous-échantillonnage (Down-sampling layer) :** Également appelée couche de pooling, cette couche complète l'extraction des caractéristiques après la convolution. En général, une architecture CNN contient plusieurs couches de convolution et de pooling, ce qui permet une extraction de caractéristiques plus approfondie. [5]
- **Couche entièrement connectée (Fully connected layer) :** Dans cette couche, toutes les cartes de caractéristiques sont connectées en tant qu'entrée. Les neurones dans cette couche sont connectés à ceux de la couche précédente, mais pas entre eux. Cette couche intègre et normalise les caractéristiques abstraites des convolutions précédentes pour produire une probabilité pour différentes classes. [5]
- **Couche de sortie (Output layer) :** Le nombre de neurones dans cette couche dépend du nombre de catégories à classer. Si la tâche est la classification, le nombre de neurones correspond généralement au nombre de catégories possibles. [5]

Dans le cadre de la construction de notre modèle de détection d'apnée du sommeil, nous avons pris la décision d'opter pour l'architecture de réseau de neurones convolutifs Le Net5. Parmi les divers types de CNN disponibles, le choix du Net5 s'est avéré judicieux pour plusieurs raisons : [22]

- **Extraction automatique des caractéristiques :** LeNet-5 est reconnu pour sa capacité à effectuer une extraction automatique des caractéristiques à partir des données en entrée, ce qui est crucial pour la détection de l'apnée du sommeil à partir du signal ECG sans nécessiter une extraction manuelle des caractéristiques. [22]
- **Adaptabilité aux données de petite taille :** Avec relativement peu de paramètres et une bonne performance, LeNet-5 est adapté aux ensembles de données de petite taille, ce qui est pertinent pour l'étude qui se concentre sur un ensemble de données relativement restreint. [22]

- **Succès antérieurs dans d'autres domaines :** LeNet-5 a démontré son efficacité dans des domaines tels que la reconnaissance d'images et la classification de caractères, ce qui nous a motivé à explorer son utilisation pour la détection de l'apnée du sommeil à partir du signal ECG. [22]

Malgré la puissance des modèles de réseau de neurone convolutionnel pour le traitement d'images et d'autres types de données structurées en grille. Cependant, ils présentent également plusieurs inconvénients :

- Les CNN nécessitent souvent une grande puissance de calcul pour l'entraînement, ce qui implique l'utilisation de GPU ou de clusters de calcul.
- Les performances des CNN dépendent fortement du choix des hyperparamètres (comme le nombre de couches, la taille des filtres, le taux d'apprentissage, etc.), ce qui nécessite souvent de nombreux essais et erreurs.
- L'entraînement des CNN peut être long, peuvent devenir très complexes, ce qui rend leur interprétation difficile.
- Les CNN peuvent facilement sur-apprendre les détails et le bruit présents dans les données d'entraînement, surtout s'il y a un manque de régularisation ou de données suffisantes.
- Même après l'entraînement, les CNN peuvent nécessiter des ressources de calcul importantes pour l'inférence, ce qui peut être un obstacle pour les applications en temps réel ou sur des appareils embarqués. [3]

En somme, bien que les CNN soient extrêmement puissants pour de nombreuses tâches de vision par ordinateur, ils nécessitent des ressources importantes et présentent des défis en termes de complexité, de besoins en données, et de robustesse.

2.2.3. L'algorithme K plus proches voisins (KNN)

L'algorithme des K plus proches voisins (KNN) est couramment utilisé en apprentissage supervisé pour la classification en raison de sa simplicité et de son efficacité. Il prédit la classe d'une instance en se basant sur les classes de ses K voisins les plus proches dans l'espace des caractéristiques. [10]

Le paramètre K représente le nombre de voisins les plus proches pris en compte lors de la prédiction. L'algorithme calcule les distances entre cette instance et toutes les instances d'entraînement dans l'espace des caractéristiques pour classer une nouvelle instance (voir Fig. 11). Ensuite, il identifie les K voisins les plus proches en utilisant une mesure de distance telle que la distance euclidienne, définie par l'équation suivante : [10]

$$\sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Ou bien la distance de Manhattan, définie par l'équation suivante :

$$\sum_{i=1}^n |x_i - y_i|$$




Figure 11. La procédure de l'algorithme KNN. [10]

Une fois les K voisins les plus proches identifiés, la classe majoritaire parmi eux est attribuée à la nouvelle instance. En cas d'égalité, un mécanisme de vote peut être utilisé pour déterminer la classe attribuée. Une caractéristique remarquable du KNN est son caractère paresseux, car il réalise la classification lors de l'exécution sans nécessiter de phase d'entraînement explicite. [10]

- **Les avantages du KNN :**

L'algorithme KNN est adaptable, capable de gérer à la fois les problèmes de classification binaire et multi classe avec succès. De plus, il est capable de capturer efficacement des frontières de décision complexes et de traiter des données bruyantes. Cependant, le choix de la valeur de K et de la mesure de distance est crucial, car ces paramètres ont un impact significatif sur les performances de l'algorithme, et il est performant avec des données de faible dimension et avec une quantité modérée de bruit. [10]

- **Les inconvénients du KNN :**

La phase de prédiction avec l'algorithme KNN peut être lente pour de grands ensembles de données, car elle nécessite le calcul des distances pour chaque point de données dans l'ensemble d'entraînement. Et aussi il nécessite de stocker tous les exemples de l'ensemble d'entraînement, ce qui peut être coûteux en mémoire pour de grandes bases de données. Les caractéristiques doivent être normalisées, sinon les résultats peuvent être biaisés par les caractéristiques ayant des échelles plus grandes. [10]

Et grâce à sa simplicité et ses capacités de classification et d'optimisation, nous entendons faire appel à cet algorithme pour améliorer l'algorithme basé sur le CNN que nous avons présenté précédemment.

2.3. Travaux relatif

Dans le domaine de la détection de l'apnée du sommeil à travers l'utilisation de réseaux de neurones convolutifs (CNN), d'importantes investigations ont été menées pour améliorer la fiabilité et l'efficacité des systèmes de détection. Les chercheurs ont exploré diverses méthodes d'extraction de caractéristiques et de classification visant à identifier et interpréter les signaux associés à l'apnée du sommeil. Cette synthèse présente quelques travaux pertinents dans le domaine de la détection de l'apnée du sommeil, en se concentrant sur les auteurs, les années de publication, ainsi que les méthodes d'extraction de caractéristiques et de classification adoptées dans chaque étude et les résultats :

A. Etude 1

Tao Wang et Changhua ont mené une étude qui a comparé les méthodes d'extraction de caractéristiques et de classification. Les méthodes traditionnelles reposaient sur l'ingénierie des caractéristiques, utilisant des algorithmes tels que SVM, KNN, LR et MLP avec des caractéristiques spécifiques extraites des intervalles RR et des amplitudes. En revanche, l'approche novatrice a impliqué un réseau de neurones convolutif modifié LeNet-5 pour une extraction automatique des caractéristiques. Les résultats ont montré que LeNet-5 surpassait les méthodes traditionnelles en termes de performances, avec une précision, une sensibilité et une spécificité plus élevées, démontrant ainsi le potentiel de cette méthode pour une détection précise et efficace de l'apnée du sommeil. [22]

B. Etude 2

Dans l'étude de Yunxiang Bai sur la détection du syndrome d'apnée du sommeil à l'aide d'un CNN basé sur l'ECG, les méthodes d'extraction de caractéristiques comprennent l'utilisation de la convolution 1D pour extraire des caractéristiques intrinsèques des signaux ECG. Le modèle CNN est composé de deux blocs de convolution, de couches de normalisation de lot (BN) et de dropout pour éviter le sur ajustement. Après l'extraction des caractéristiques, les données sont envoyées à des couches entièrement connectées pour la classification. La fonction de perte d'entropie croisée est utilisée pour mettre à jour le réseau, et des hyper paramètres tels que le taux d'apprentissage sont réglés pour optimiser les performances du modèle. [23]

C. Etude 3

Les auteurs en ont développé une méthode de détection de l'apnée du sommeil basée sur un réseau de neurones artificiels à fenêtre temporelle (TW-MLP) pour exploiter la dépendance temporelle des segments de signal ECG. L'extraction des caractéristiques s'est appuyée sur des techniques spécifiques à l'ECG pour identifier les paramètres pertinents. La classification a été réalisée en utilisant le TW-MLP, qui a surpassé les méthodes traditionnelles en termes de performances de détection de l'apnée du sommeil. [21]

D. Etude 4

Des chercheurs ont mené une étude qui a comparé les méthodes traditionnelles d'extraction de caractéristiques telles que SVM, KNN, LR et MLP, qui reposent sur l'ingénierie des caractéristiques extraites des intervalles RR et des amplitudes, avec une approche novatrice utilisant le SE-ResNext 50 pour une extraction automatique des caractéristiques. [15]

E. Etude 5

Hung-Yu Chang [7] et son équipe ont proposé un modèle AlexNet 2D pré-entraîné pour extraire des caractéristiques des images temps-fréquence 2D des signaux ECG, suivi d'une méthode de fusion de décision avec des classificateurs KNN, SVM, LDA et Ensemble pour améliorer la sensibilité de la détection des événements d'apnée. Dans cette étude, un modèle CNN 1D profond est utilisé avec des signaux ECG 1D en entrée, évitant la détection des complexes QRS et l'analyse des fréquences cardiaques dérivées de l'ECG. Le prétraitement du signal se limite à un filtrage passe-bande Butterworth et une normalisation z-score. Le modèle CNN comprend 10 couches d'extraction de caractéristiques identiques, 4 couches de classification et une couche softmax FC, permettant l'extraction automatique des caractéristiques et la classification des événements d'apnée avec une précision de 87,9%. [7]

Dans le tableau n°1 suivant, nous résumerons les travaux connexes dans le domaine de la détection de l'apnée du sommeil à partir d'un signal ECG à une seule dérivation, en spécifiant les méthodes de classification utilisées par les chercheurs :

Les auteurs, l'années de publication	Les méthodes	Les techniques	Les résultats
Tao Wang, Changhua Lu, Guohao Shen et Feng Hong. (2019)	Intervalles R-R et Amplitudes des pics R du signal ECG	CNN modifié Le Net-5	97,1%
		SVM	88,6%
		KNN	82,9%
		LR	88,6%
		MLP	85,7%
Yunxiang Bai, Luqiao Zhang, Dechao Wan, Yu Xie et Hanghang Deng. (2021)	Convolution 1D Filtrage de bruit et l'auto-encodeur	CNN	94%
		LSTM	
Tao Wang, Changhua Lu, Guohao Shen. (2019)	Analyse des ondes ECG mesure des intervalles temporels et la fréquence cardiaque	TW-MLP	87,3%
		SVM	80,6%
		LDA	81,8%
		LR	81,5%
		MLP	81,4%
Nguyen A, Nguyen T, Le H, Pham H et Do C. (2022)	Amplitude des pics R, Amplitude des pics S, Intervalles RR et Intervalles SS	SE-ResNext 50	90.28%
Hung-Yu Chang, Cheng-Yu Yeh, Chung-Te Lee et Chun-Cheng Lin. (2020)	filtrage passe-bande Butterworth et une normalisation z-score	CNN 1D	97,1%
		KNN	
		SVM	
		LDA	
		ANN	

Tableau 1. Méthodes de classification utilisées par les chercheurs.

L'objectif de l'examen des travaux antérieurs et similaires est de proposer un aperçu des différentes approches déployées pour résoudre le problème de la détection de l'apnée du sommeil. Une compréhension approfondie de ces travaux connexes permettra d'identifier les lacunes et les défis actuels, ouvrant ainsi la voie à de futures recherches novatrices dans ce domaine.

2.4. Conclusion

En conclusion, dans ce deuxième chapitre, nous avons examiné en profondeur les méthodes de classification utilisées dans la création d'un modèle de détection de l'apnée du sommeil. À travers l'exploration de l'apprentissage profond avec les CNN et de l'algorithme des k plus proches voisins (KNN), nous avons exploré les principes et les caractéristiques de ces approches, ainsi que leur applicabilité potentielle dans notre projet en essayant aussi la combinaison de ses deux approches riches. En analysant également les travaux de recherche antérieurs, nous avons pu mettre en évidence les tendances et les défis rencontrés dans l'utilisation de ces méthodes dans des contextes similaires. Ce chapitre jette ainsi les bases nécessaires pour la mise en œuvre et l'évaluation des méthodes de classification dans notre modèle de détection d'apnée du sommeil, tout en soulignant l'importance de choisir des approches adaptées et efficaces pour atteindre nos objectifs de manière optimale.

Enfin, nous allons présenter dans l'aspect technique, les outils et le langage de programmation dans le chapitre suivant qui ont été la base de notre étude.

Chapitre 3 : ASPECT TECHNIQUE, OUTILS & LANGAGE DE PROGRAMMATION

3.1. Introduction

Ce chapitre plonge dans l'aspect technique, les outils et le langage de programmation qui ont été au cœur de notre étude. Nous explorerons les fondations matérielles et logicielles nécessaires à nos recherches, mettant en lumière les environnements physiques et logiques dans lesquels nous avons opéré. De plus, nous présenterons les outils spécifiques, notamment Visual Studio Code et Colab, ainsi que le langage de programmation Python, qui ont été essentiels à notre méthodologie. Nous décrirons également les bibliothèques utilisées et introduirons bien la dataset ECG d'apnée du sommeil, une composante cruciale de notre analyse. Enfin, nous aborderons plusieurs aspects techniques clés, tels que le filtre passe-bande FIR, l'algorithme de segmentation de Hamilton, la technique de sur-échantillonnage aléatoire, l'optimiseur utilisé et finalement les métriques d'évaluations de notre modèle.

3.2. Environnement physique (Hardware)

Pour les processus d'entraînement et de test et la création de tous les modèles, nous utilisons le matériel expliqué dans le tableau n°2 suivant :

Composant	Modèle de marque	spécification
CPU	Intel (R) Core (TM)	i5-8350U CPU @ 1.70GHz 1.90 GHz
GPU	Intel UHD Graphics 620 (HP)	
RAM		16,0 Go,DDR-4
Carte mère	HP 83B2 (U3E1)	KBC 04.6E.00, Chipset: Intel Kaby Lake, Southbridge: Intel Coffee
Stockage	SSD	256 G

Tableau 2. Matériel de bureau.

3.3. L'environnement logiciel (Software)

Notre environnement de développement se compose du système d'exploitation Windows 11, 64 bits, et de Visual Studio Code en local, que nous avons choisi pour sa convivialité, ses fonctionnalités avancées et sa grande flexibilité. De plus, nous avons utilisé Google Colab pour bénéficier de ses avantages en matière de calcul GPU et de son intégration transparente avec les bibliothèques Python couramment utilisées pour l'apprentissage profond.

3.3.1. Visual Studio Code

Nous avons utilisé Visual Studio Code pour développer nos modèles et les paramétrer.

Visual Studio Code, est un éditeur de code léger et polyvalent. Il est compatible avec divers systèmes d'exploitation, notamment Windows, macOS et Linux. Il offre une prise en charge native pour JavaScript, TypeScript et Node.js, et bénéficie également d'une large gamme d'extensions pour d'autres langages de programmation comme C++, C#, Java, Python, PHP, Go et .NET. Son interface intuitive et ses nombreuses extensions personnalisables en font un choix idéal pour construire efficacement le modèle de détection d'apnée du sommeil. [W17]




Figure 12. Visual studio code. [W21]

3.3.2. Google Colaboratory

Nous avons fait appel à Google Colaboratory, plus communément appelé Google Colab, pour tester et optimiser nos algorithmes. Et ce en raison des performances qu'il offre.

Colab est une plateforme de notebooks Jupyter, hébergée, qui offre un accès sans configuration à des ressources informatiques telles que les GPU et les TPU, et ce, gratuitement. Elle est particulièrement bien adaptée pour les projets de machine learning, d'analyse de données et l'enseignement, offrant ainsi une solution pratique et efficace pour le développement et l'exécution de code Python collaboratif et expérimental. [W18]




Figure 13. Google Colaboratory. [W18]

3.4. Langage de programmation

Pour concevoir notre modèle de détection d'apnée du sommeil, nous avons choisi d'utiliser le langage de programmation Python. Ce choix s'est imposé en raison de la popularité de Python dans les domaines de l'apprentissage automatique et de l'analyse de données. Sa syntaxe claire et concise, ainsi que sa grande polyvalence et la richesse de ses bibliothèques, en font un outil privilégié pour ce type de projets.

3.4.1. Python

Python est un langage de programmation polyvalent et largement utilisé, créé par Guido Van Rossum. Son développement a commencé en 1989, et depuis lors, il est devenu l'un des langages les plus populaires et bien plus encore il est en croissance continue et en évolution. [19]

La simplicité de sa syntaxe en fait un excellent choix pour les débutants en programmation, tandis que sa puissance et sa flexibilité en font un outil précieux pour les développeurs expérimentés. Il est moderne, open source, accessible et adapté à une grande variété d'applications. Il peut être exécuté sur différentes plateformes sans nécessiter de modifications, et il est associé à la science des données, à l'apprentissage automatique, et profond, etc. Il dispose de nombreuses fonctions de bibliothèque liées à ces domaines, nous allons les citer par la suite, facilitant ainsi le travail des programmeurs qui peuvent réutiliser ces bibliothèques, ce qui en fait un choix idéal pour moi de l'utiliser pour créer et développer notre modèle avec les nouveautés de ce langage de programmation. Voici la figure n°14 qui montre le logo du python : [19]



Figure 14. Python. [W19]

3.5. Les bibliothèques utilisées

Dans le développement de notre modèle de détection d'apnée du sommeil, nous avons fait appel à plusieurs bibliothèques Python spécialisées dans le traitement des données physiologiques et la mise en œuvre d'algorithmes d'apprentissage automatique. Parmi ces bibliothèques figurent notamment :


- **Pickle** : est une bibliothèque Python qui permet de sérialiser et désérialiser des objets Python. Elle a été utilisée pour charger et sauvegarder des données, notamment le dataset dans un format binaire. [W23]
- **Sys** : Le module « sys » fournit des fonctions et des variables utilisées pour interagir avec le système d'exploitation. [W24]
- **Os** : Le module « os » fournit des fonctionnalités pour interagir avec le système d'exploitation, telles que la manipulation de fichiers et de répertoires, la gestion des chemins d'accès, etc. elle a été invoquée pour permettre le travail avec des fichiers et des répertoires dans notre système de fichiers. [W25]
- **Concurrent Futures** : cette bibliothèque est pour exécuter des tâches de manière asynchrone et parallèle, améliorant ainsi l'efficacité du prétraitement des données pour la détection de l'apnée du sommeil. [W26]
- **Biosppy** : est une bibliothèque Python pour le traitement des signaux biomédicaux. Nous l'avons utilisée pour effectuer des opérations de traitement du signal sur nos données d'ECG, telles que la détection des pics R. [W7]
- **Numpy** : est une bibliothèque fondamentale pour le calcul numérique en Python. Nous y avons fait appel pour manipuler et effectuer des opérations sur des tableaux multidimensionnels, ce qui est courant dans le traitement des données. [W11]
- **Wfdb** : est une bibliothèque Python pour la lecture et l'écriture de fichiers de données d'ECG au format PhysioNet. Nous l'avons utilisée pour accéder à des enregistrements d'ECG à partir de la base de données de PhysioNet. [W27]
- **Tqdm** : est une bibliothèque Python qui permet de créer des barres de progression pour les boucles itératives. Nous l'avons utilisée pour afficher une barre de progression pendant le prétraitement de mes données, ce qui permet de suivre facilement l'avancement du processus. [W28]

- **SciPy** : cette bibliothèque est utilisée dans le prétraitement des données pour appliquer un filtre médian avec `medfilt` et pour réaliser une interpolation de courbe avec les fonctions `splev` et `splrep`, améliorant ainsi la qualité des données ECG pour l'entraînement du modèle de détection de l'apnée du sommeil. [W12]
- **TensorFlow** : est une bibliothèque open source conçue pour le calcul numérique, le machine learning à grande échelle, le deep learning, ainsi que d'autres tâches liées à la statistique et à l'analyse prédictive. Elle simplifie et accélère le développement de modèles de machine learning en prenant en charge des fonctionnalités telles que l'acquisition de données, le déploiement de prédictions à grande échelle et l'amélioration des performances futures. [W14]
- **Keras** : est une bibliothèque Python pour l'apprentissage automatique et profond. Elle a été utilisée pour construire, entraîner et évaluer des modèles de réseaux de neurones convolutifs pour la détection d'apnée du sommeil. [W10]
- **Sklearn** : est une bibliothèque Python pour l'apprentissage automatique et l'analyse de données. Elle nous a servi pour le calcul de la matrice de confusion, la courbe roc, AUC, la précision, le rappel, f1 score, pour évaluer les performances du modèle de détection d'apnée du sommeil. [W29]
- **Imbalanced-Learn** : est une bibliothèque compatible avec Scikit-Learn pour traiter les problèmes de déséquilibre de classes dans les ensembles de données. `Random Over Sampler` permet de sur-échantillonner les classes minoritaires pour équilibrer les données. [W32]
- **Matplotlib** : est une bibliothèque de traçage pour créer des visualisations statiques, animées et interactives en Python. `pyplot` est un module de Matplotlib qui fournit une interface de type MATLAB. [W33]
- **Seaborn** : est une bibliothèque de visualisation de données basée sur Matplotlib. Elle fournit une interface de haut niveau pour dessiner des graphiques statistiques attrayants et informatifs. [W34]

En combinant ces bibliothèques, nous sommes parvenus à manipuler des fichiers, effectuer des calculs numériques, entraîner des modèles de réseaux de neurones, et effectuer diverses opérations mathématiques et scientifiques sur le dataset qui sera présenté par la suite.

3.6. Dataset ECG d'apnée du sommeil

A travers la plateforme de recherche publique PhysioNet qui offre un accès gratuit à de grandes collections de données biomédicales, physiologique suivante :



Base de données Accès libre

Base de données Apnée-ECG

Georges Maugrey , Roger Marc 

Publié : 10 février 2000. Version : 1.0.0

Lorsque vous utilisez cette ressource, veuillez citer la publication originale :
T Penzel, GB Moody, RG Mark, AL Goldberger, JH Peter. La base de données Apnea-ECG. *Computers in Cardiology* 2000;27:255-258.

Veuillez inclure la citation standard pour PhysioNet : (afficher plus d'options)
Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, PC, Mark, R., ... & Stanley, HE (2000). PhysioBank, PhysioToolkit et PhysioNet : composants d'une nouvelle ressource de recherche pour les signaux physiologiques complexes. *Circulation [en ligne]*. 101 (23), pp. e215-e220.

Figure 15. L'ensemble de données apnée ECG. [W6]

On a utilisé l'ensemble de donnée Apnée-ECG qui offre un ensemble riche de 70 enregistrements, soigneusement divisés en deux groupes distincts pour une analyse approfondie :

- Le premier groupe, comprenant 35 enregistrements de a01 à a20, b01 à b05, et c01 à c10, constitue notre ensemble d'apprentissage.
- Le second groupe, également composé de 35 enregistrements de x01 à x35, représente notre ensemble de test. [W6]

Il faut noter que chacun des 70 enregistrements est constitué d'un ensemble de douze fichiers à traiter. Ce qui donne un total de 840 fichiers. [W6] La figure n°16, montre un aperçu des différents fichiers du dataset, et cela pour l'enregistrement a01 :

a01.apn	06/02/2024 23:47	Fichier APN	4 Ko
a01.dat	06/02/2024 23:47	Fichier DAT	5 776 Ko
a01.hea	06/02/2024 23:47	Fichier HEA	1 Ko
a01.qrs	06/02/2024 23:47	Fichier QRS	59 Ko
a01.xws	06/02/2024 23:47	Fichier XWS	1 Ko
a01er.apn	06/02/2024 23:47	Fichier APN	4 Ko
a01er.hea	06/02/2024 23:47	Fichier HEA	1 Ko
a01er.qrs	06/02/2024 23:47	Fichier QRS	59 Ko
a01er.xws	06/02/2024 23:47	Fichier XWS	1 Ko
a01r.apn	06/02/2024 23:47	Fichier APN	4 Ko
a01r.dat	06/02/2024 23:47	Fichier DAT	23 100 Ko
a01r.hea	06/02/2024 23:47	Fichier HEA	1 Ko

Figure 16. Les différents formats de fichiers pour l'enregistrement a01.

Le fichier d'enregistrement a01 comprend plusieurs fichiers de grande importance, dont certains, comme les données au format .dat, sont volumineux, dont la taille varie entre 5 et 23 Mo. Des tailles similaires de fichiers sont également observées dans les enregistrements similaires contenant des signaux ECG. Ces fichiers existent pour faciliter le traitement et l'interprétation :

- Les fichiers .dat contiennent les ECG numérisés.
- Les fichiers .hea spécifient les noms et les formats des fichiers de signaux associés.
- Les annotations binaires sont fournies dans les fichiers .apn, indiquant la présence ou l'absence d'apnée à chaque minute de l'enregistrement, exclusivement pour les 35 enregistrements de l'ensemble d'apprentissage.
- Les fichiers .xws contiennent des métadonnées telles que le nom de l'enregistrement, la durée, la fréquence d'échantillonnage, etc.
- Enfin, les fichiers .qrs contiennent des annotations binaires automatiquement générées pour faciliter l'analyse. [W6]

En plus des signaux ECG, huit enregistrements de l'ensemble d'apprentissage « a01 à a04, b01 et c01 à c03 » sont accompagnés de quatre signaux supplémentaires cruciaux pour une analyse approfondie. Ces signaux comprennent des mesures de l'effort respiratoire thoracique, des mouvements abdominaux obtenus par une pléthysmographie inductive, le débit d'air oronasal mesuré à l'aide de thermistances nasales, et enfin, un signal de saturation en oxygène. [W6]

Chaque enregistrement comprend des données démographiques telles que l'âge, le sexe, la taille, le poids, l'indice d'apnée (AI), l'indice d'hypopnée (HI) et l'indice d'apnée-hypopnée (AHI) de la personne de ces enregistrements et ils sont des hommes et des femmes âgées de 27 à 63 ans, avec des poids entre 53 et 135 kg, et L'AHI varie de (0 à 93,5), Et la durée totale des enregistrements varie entre 7 heures et 10 heures. Chaque enregistrement contient : [W6]

- **Un signal ECG numérique continu.**
- **Un ensemble d'annotations d'apnée :** ces annotations sont dérivées par des experts humains sur la base de la respiration enregistrée simultanément et des signaux associés.
- **Un ensemble d'annotations QRS :** ces annotations sont générées par machine dans lesquelles tous les battements, quel que soit leur type, ont été étiquetés normal. [W6]

A. Les classes de données

Les enregistrements sont classés en trois catégories :

- **Classe A (Apnée) :** Elle comprend au moins une heure avec un indice d'apnée (AI) supérieur ou égal à 10, et au moins 100 minutes d'apnée pendant l'enregistrement, ce qui signifie que ces enregistrements répondent à tous les critères définis. [W6]
- **Classe B (Limite) :** Elle comprend au moins une heure avec un indice d'apnée de 5 ou plus, et entre 5 et 99 minutes avec apnée pendant l'enregistrement, c'est-à-dire que ces enregistrements répondent à certains critères mais pas à tous. [W6]
- **Classe C (Contrôle) :** Elle contient moins de 5 minutes avec apnée pendant l'enregistrement et avec un indice d'apnée de 0. Donc ces enregistrements ne répondent à aucun des critères définis et peuvent être considérés comme normaux. [W6]

Notre objectif est de développer un modèle capable de classer les enregistrements de l'ensemble de tests en groupes de classe A (apnée) et de classe N (non apnée). Cette classification sera réalisée en utilisant le signal ECG pour détecter la présence éventuelle d'une apnée du sommeil significative. [W6]

3.7. Filtre passe-bande FIR

Un filtre passe-bande FIR (Finite Impulse Response) est un type de filtre numérique utilisé pour filtrer un signal en laissant passer uniquement les fréquences situées dans une certaine bande passante spécifiée. [W30]

La figure n°17 ci-dessous montre comment la fréquence de signal est filtrée pour le type de filtre passe-bande FIR :




Figure 17. Filtre passe-bande FIR. [W20]

Il est conçu en spécifiant les caractéristiques de la bande passante, telles que la fréquence de coupure inférieure et supérieure, dans notre cas, ils sont entre 3 Hz et 45 Hz, ce qui correspond aux fréquences typiques des signaux cardiaques, ainsi que les paramètres de conception tels que l'ordre du filtre, un ordre plus élevé pourrait être utilisé pour capturer des détails fins dans les variations de fréquence cardiaque, et une fenêtre pour concevoir la réponse en fréquence souhaitée. [6]

La réponse impulsionnelle $h(k)$ permet de calculer la sortie du filtre $y(k)$ à toute entrée $e(k)$ via le produit de convolution discret :

$$Y(k) = h(k) * e(k)$$

$$\sum_{m=-\infty}^{+\infty} h(m) * e(k - m)$$

$$\sum_{m=-\infty}^{+\infty} h(k - m) * e(m)$$

Cette formule représente la convolution discrète entre le signal d'entrée $e[m]$ et les coefficients du filtre $h[k]$ pour produire le signal de sortie $y[k]$ à l'instant de temps n . [6]

Où :

- $y[k]$ est la valeur du signal de sortie à l'instant de temps k .
- La sommation est effectuée sur tous les indices m possibles, c'est-à-dire de moins l'infini à plus l'infini.
- À chaque indice m , la valeur du signal d'entrée $e[m]$ est multipliée par le coefficient correspondant du filtre $h[k-m]$.
- Ces produits sont ensuite sommés pour obtenir la valeur de $y[k]$. [6]

3.8. L'algorithme de segmentation de Hamilton

L'algorithme de segmentation de Hamilton est une méthode utilisée dans le domaine du traitement du signal pour détecter et localiser les pics R dans un signal électrocardiographique (ECG). Cet algorithme, nommé d'après son inventeur Robert S. Hamilton, vise à automatiser le processus de détection des complexes QRS dans un ECG, ce qui est essentiel pour de nombreuses applications médicales telles que la surveillance cardiaque et le diagnostic des troubles du rythme cardiaque. [16]

3.9. La technique de sur-échantillonnage aléatoire

La technique de sur-échantillonnage aléatoire (Random Over Sampler) est une méthode utilisée dans le domaine de l'apprentissage automatique pour résoudre le problème de déséquilibre de classes dans un ensemble de données. Lorsqu'un ensemble de données présente un déséquilibre entre les différentes classes, c'est-à-dire que certaines classes ont beaucoup moins d'exemples que d'autres, cela peut entraîner des performances médiocres des modèles d'apprentissage automatique, car le modèle peut être biaisé vers les classes majoritaires. [W31]

3.10. L'optimiseur

Dans le domaine de l'apprentissage automatique, un optimiseur désigne un algorithme spécifique employé pour ajuster les paramètres d'un modèle. Son objectif est de minimiser la fonction d'erreur ou de perte associée. Cette fonction de perte quantifie la disparité entre les prédictions du modèle et les valeurs réelles. L'optimiseur s'emploie alors à déterminer le jeu de paramètres du modèle qui conduira à la perte la plus réduite possible, nous avons utilisé un optimiseur populaire Adam pour améliorer l'efficacité et l'efficacité de l'optimisation. [4]

3.10.1. L'algorithme d'optimisation Adam

Il est largement employé pour entraîner des modèles d'apprentissage profond. Il représente une extension de la descente de gradient stochastique, une technique fondamentale dans ce domaine. Contrairement à la descente de gradient classique, Adam utilise les moyennes mobiles des gradients ainsi que des seconds moments des gradients. Ces informations sont alors exploitées pour calculer des taux d'apprentissage adaptatifs pour chaque paramètre du modèle. [W9]

Nous avons utilisé l'optimiseur Adam avec une configuration spécifique. Les paramètres choisis sont les suivants : un taux d'apprentissage (`learning_rate`) de 0.0001, des taux de décroissance exponentielle pour les moyennes mobiles des gradients (`beta_1`) de 0.9, des taux de décroissance exponentielle pour les moyennes mobiles des carrés des gradients (`beta_2`) de 0.999, un epsilon de $1e-7$ et l'AMSGrad est désactivé (`amsgrad=False`). [W2]

L'algorithme de mise à jour pour Adam peut être exprimé comme suit :

$$m_t = \beta_1 * m_{t-1} + (1-\beta_1) * g$$

$$v_t = \beta_2 * v_{t-1} + (1-\beta_2) * g^2$$

$$m_{\text{that}} = m_t / (1-\beta_1^t)$$

$$v_{\text{that}} = v_t / (1-\beta_2^t)$$

$$\theta_{t+1} = \theta_t - (\eta / (\sqrt{v_{\text{that}}} + \epsilon)) * m_{\text{that}}$$

Où :

- θ est le vecteur des paramètres.
- g est le vecteur du gradient.
- m est la moyenne mobile exponentiellement pondérée du gradient.
- v est la moyenne mobile exponentiellement pondérée du carré du gradient.
- η est le taux d'apprentissage.
- β_1 et β_2 sont les taux de décroissance exponentielle pour les moyennes mobiles.
- t est l'étape de l'itération actuelle.
- ϵ est une petite constante ajoutée pour la stabilité numérique afin d'éviter la division par zéro. [W2]

L'optimiseur Adam calcule le taux d'apprentissage pour chaque paramètre en divisant le taux d'apprentissage initial η par la racine carrée de l'estimation du second moment corrigé biaisé v_t . La première estimation du moment m_t est également corrigée pour compenser son initialisation à zéro. [W2]

Adam est un optimiseur populaire pour l'apprentissage profond car il peut gérer les gradients clairsemés, les données bruyantes et les objectifs non stationnaires. En adaptant les taux d'apprentissage pour chaque paramètre en fonction des premiers et deuxièmes moments des gradients, Adam peut converger plus rapidement et de manière plus fiable. [W2]

3.11. Les métriques d'évaluation du modèle

Nous avons utilisé la perte d'entropie croisée catégorielle et la précision pour évaluer le modèle. Pour analyser les résultats de prédiction, nous générons systématiquement une matrice de confusion et un rapport de classification afin de comprendre les erreurs de type I (faux positifs) et de type II (faux négatifs).

A. Loss : Categorical Crossentropy

La perte d'entropie croisée catégorielle mesure la performance d'un modèle de classification dont les sorties sont des probabilités entre 0 et 1. La fonction de perte compare la distribution prédite p et la distribution réelle q :

$$\text{Loss} = - \sum_{i=1}^N \sum_{c=1}^C q_{i,c} \log(p_{i,c})$$

Où :

- N est le nombre d'exemples.
- C est le nombre de classes.
- $q_{i,c}$ est la vraie étiquette (1 si l'exemple i appartient à la classe c , sinon 0).
- $p_{i,c}$ est la probabilité prédite que l'exemple i appartient à la classe c .

B. Accuracy (Précision)

La précision est le ratio du nombre de prédictions correctes au nombre total d'exemples évalués :

$$Accuracy = \frac{\text{Nombre de Predictions Correctes}}{\text{Nombre Total d'Exemples}}$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Où : TP (vrais positifs), TN (vrais négatifs), FP (faux positifs), et FN (faux négatifs).

C. Précision (Précision)

La précision est le ratio du nombre de vraies prédictions positives sur le nombre total de prédictions positives :

$$Précision = \frac{TP}{TP + FP}$$

D. Recall (Rappel)

Le rappel est le ratio du nombre de vraies prédictions positives sur le nombre total de vrais positifs réels.

$$Précision = \frac{TP}{TP + FN}$$

E. F1-Score

Le F1-score est la moyenne harmonique de la précision et du rappel. Il est particulièrement utile pour évaluer des modèles sur des données déséquilibrées :

$$F1 = 2 \cdot \left(\frac{\text{Précision} \cdot \text{Recall}}{\text{Précision} + \text{Recall}} \right)$$

F. Courbe ROC

La courbe ROC est un graphique montrant le taux de vrais positifs (TPR) en fonction du taux de faux positifs (FPR) à différents seuils de classification :

$$TPR = \frac{TP}{TP + FN}$$

$$FPR = \frac{FP}{FP + TN}$$

G. AUC « Area Under the Precision-Recall Curve »

L'aire est une mesure utilisée pour évaluer la performance des modèles de classification, surtout dans les cas où les classes sont déséquilibrées. Il est calculé, en utilisant la méthode des trapèzes pour approximer l'intégrale de la courbe de précision-rappel. La formule de l'aire entre deux points (r_i, p_i) et (r_{i+1}, p_{i+1}) sous la courbe de précision-rappel est la suivante :

$$AUC = \sum_{i=1}^{n-1} \frac{(r_{i+1} - r_i) \times (p_i + p_{i+1})}{2}$$

Où r et p sont les coordonnées des points de la courbe. Dans le cas de la courbe précision-rappel, r représente le rappel et p représente la précision.

H. Confusion Matrix (Matrice de Confusion)

C'est un tableau qui résume les performances d'un modèle de classification sur un ensemble de données de tests pour lesquelles les véritables étiquettes sont connues. Il s'agit d'un outil utile pour évaluer les performances d'un modèle de classification et fournir des informations sur les types d'erreurs commises par le modèle.

	Positif	Négatif	Total
Positif	TP	FN	$TP+FN$
Négatif	FP	TN	$FP+TN$
Total	$TP+FP$	$FN+TN$	N

Tableau 3. La matrice de confusion.

3.12. Conclusion

Ce chapitre a permis d'établir un cadre technique solide, fournissant ainsi les bases nécessaires à la conduite de notre étude. Nous avons mis en lumière l'importance de choisir judicieusement les outils et techniques appropriés pour garantir la fiabilité et la précision de nos analyses. Cette exploration technique a souligné la nécessité de s'appuyer sur des ressources et des méthodes robustes pour mener à bien des recherches de haute qualité dans le domaine complexe de l'apnée du sommeil. En jetant ainsi les bases nécessaires à la compréhension des résultats exposés dans le chapitre suivant.

Chapitre 4 : DÉVELOPPEMENT, DISCUSSION & ÉVALUATION

4.1. Introduction

Dans ce chapitre nous allons présenter le modèle proposé ainsi que son évolution. Nous avons proposé de créer un modèle de détection de l'apnée du sommeil basé sur le concept neuronal, plus précisément sur les réseaux de neurones convolutifs. Nous avons évalué cet algorithme et nous l'avons amélioré en faisant appel à l'algorithme des k plus proches voisins, qui est connu pour l'optimisation qu'il apporte.

4.2. Conception du système

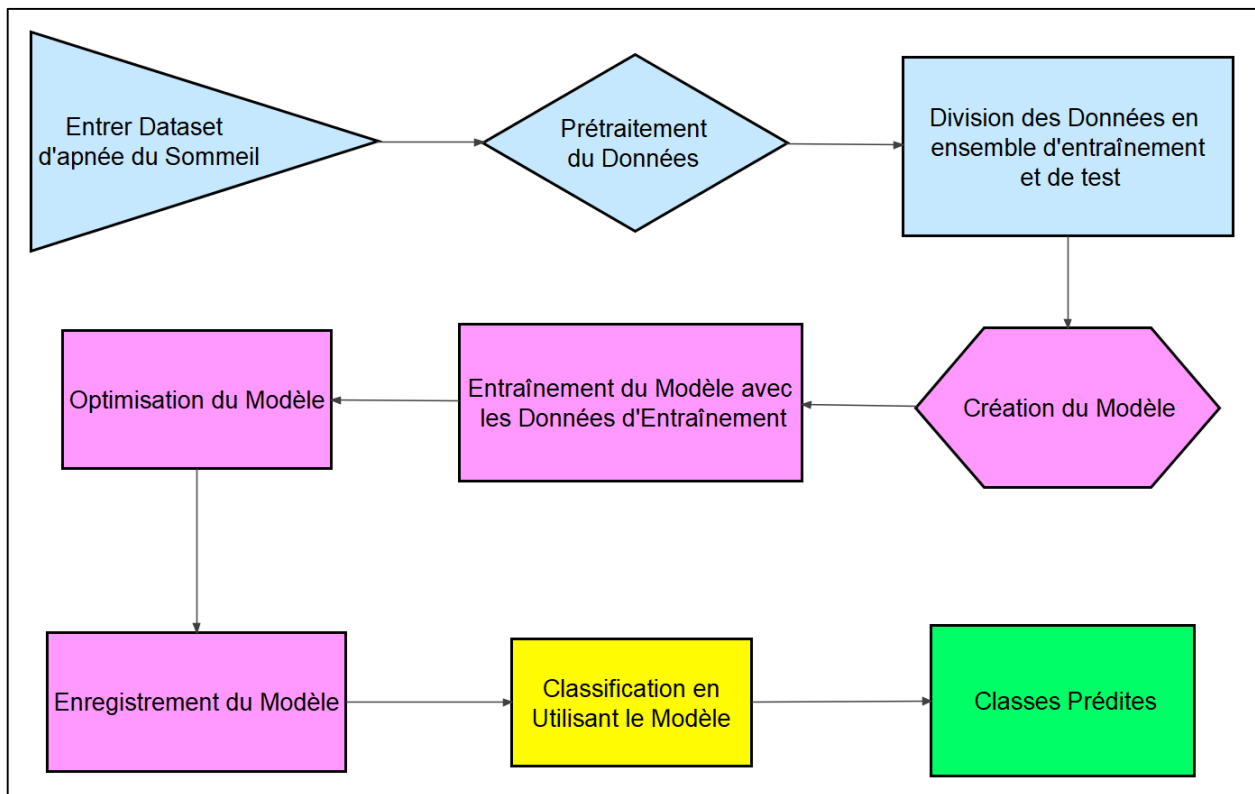


Figure 18. Conception du système.

La figure n°18 schématise les étapes de conception de notre système de Détection de l'Apnée du Sommeil, voici l'explication de ses étapes :

- **Acquisition du dataset d'Apnée du Sommeil** : càd se procurer ou télécharger le dataset d'apnée du sommeil contenant les enregistrements ECG et les annotations d'apnée provenant du PhysioNet Apnea-ECG dataset.
- **Prétraitement des données** : charger les enregistrements ECG et les annotations d'apnée, nettoyer et prétraiter les données pour éliminer les artefacts et les données incorrectes, nous allons mieux expliquer cela par la suite.
- **Division des données prétraitées en deux ensembles distincts** : un ensemble d'entraînements et un ensemble de tests, en s'assurant que les enregistrements de chaque participant sont présents dans les deux ensembles pour une validation croisée robuste.
- **Création du modèle** : définir l'architecture du modèle pour la détection de l'apnée du sommeil à partir des données ECG prétraitées, puis configurer les couches convolutionnelles, de pooling, de dropout et entièrement connectées du modèle.
- **Entraînement du modèle avec les données d'entraînement** : faire passer les données d'entraînement prétraitées à travers le modèle pour ajuster ses poids et ses biais, et utiliser un algorithme d'optimisation (comme Adam) pour minimiser la fonction de perte du modèle.
- **Optimisation du modèle** : ajuster les hyper-paramètres du modèle, tels que le taux d'apprentissage, la taille du lot et le nombre d'époques, pour améliorer les performances du modèle sur les données de validation.
- **Enregistrement du modèle** : sauvegarder le modèle entraîné afin qu'il puisse être utilisé ultérieurement sans avoir besoin de le ré-entraîner à chaque fois.
- **Classification en utilisant le modèle** : utiliser le modèle entraîné pour détecter l'apnée du sommeil dans de nouveaux ensembles de données.
- **Classes prédites** : obtenir la classe prédite pour chaque enregistrement.

En suivant ces étapes, nous avons pu concevoir et mettre en œuvre un modèle complet de détection de l'apnée du sommeil à partir de données ECG.

4.3. Préparation du dataset

Nous avons d'abord chargé les données du dataset d'apnée du sommeil. Ces données comprennent les enregistrements ECG ainsi que les annotations d'apnée. Pour chaque enregistrement ECG nous avons le prétraité par étapes suivantes :

- ❖ Premièrement nous avons lu les données de l'enregistrement ECG spécifié par Name, et puis extrait le signal de ce canal pour le stocker dans la variable signals.
- ❖ Deuxièmement parcourir les annotations « labels » et vérifier si chaque'une se trouve dans un intervalle spécifié par les paramètres
- ❖ Ensuite extrait un segment de signal ECG autour de chaque annotation et applique un filtre passe-bande FIR pour conserver les fréquences de coupure entre 3 et 45 Hz. Ceci est conçu pour atténuer les fréquences indésirables qui se situent en dehors de la bande passante d'intérêt, et permet de supprimer le bruit, améliorer la qualité du signal, et de conserver les composantes pertinentes du signal cardiaque.
- ❖ On a appliqué l'algorithme de segmentation de Hamilton pour détecter les pics R dans le signal ECG déjà filtré à une fréquence d'échantillonnage 100. Les pics R représentent les points où l'onde R apparaît dans un signal ECG, indiquant la contraction des ventricules du cœur ET.
- ❖ Et puis on a ajusté et corrigé les positions des pics R détectés.
- ❖ Après on a vérifié si le nombre de pics R dans le signal est dans une plage acceptable en fonction des intervalles spécifiés avant et après chaque période, pour éliminer les signaux de pics R anormaux qui ne sont pas représentatifs d'un ECG normal.
- ❖ Ensuite nous avons extrait les signaux RRI « Intervalles R-R » fournissent des informations sur la variabilité du rythme cardiaque et Ampl « Amplitude des signaux R » à partir des indices des pics R dans le signal ECG donné qui peuvent aider à détecter les épisodes d'apnée.

Voici l'intervalle R-R extrait de la distance entre deux pics R montré dans le haut de la figure n°19 suivante :

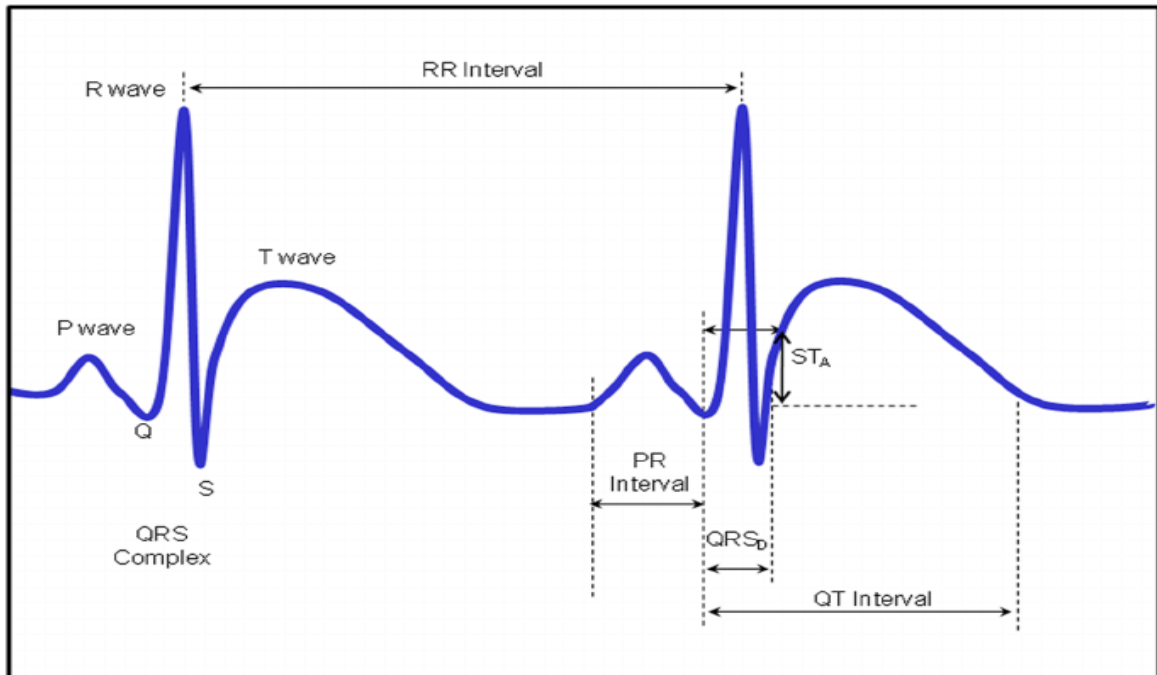


Figure 19. Représentation de l'intervalle R-R dans un signal ECG. [14]

- ❖ Puis nous avons étiqueté les données en fonction des annotations d'apnée pour distinguer les segments normaux (N) des segments apnéiques (A). Cela permettra d'entraîner un modèle de détection de l'apnée à partir de ces données.
- ❖ Et à la fin nous avons Devisé les données en ensemble d'apprentissage et de test et j'ai fait un traitement parallèle des enregistrements ECG pour l'entraînement et le test, en extrayant les signaux et en vérifiant les annotations pour identifier les périodes d'apnée.

Enfin, nous avons sauvegardé les données prétraitées dans un fichier de type pickle. Et ceci afin de nous permettre de charger rapidement les données lors de l'entraînement du modèle sans avoir à refaire le prétraitement à chaque fois.

4.4. Diviser les données en Train et Test

Pour entraîner et évaluer efficacement le modèle de détection d'apnée du sommeil, nous avons adopté une approche stratégique dans la division de l'ensemble de données. Nous avons choisi de constituer un ensemble d'entraînement en sélectionnant judicieusement les enregistrements des sujets a01 à a20, b01 à b05, et c01 à c10. Cette sélection a été faite avec soin pour garantir une représentation équilibrée des différents types de données et des conditions de sommeil. Ces enregistrements représentent environ 80 % du jeu de données total, offrant ainsi une base solide pour l'entraînement du modèle.

D'autre part, nous avons réservé un ensemble de tests composé des enregistrements des sujets x01 à x35 pour évaluer les performances du modèle. En choisissant ces enregistrements, nous nous sommes assuré que le modèle soit confronté à des données qu'il n'a pas vues pendant l'entraînement, ce qui garantit une évaluation impartiale de sa capacité à généraliser sur de nouvelles situations. Cet ensemble de test représente environ 20 % du jeu de données total, ce qui offre une ample variété de situations pour évaluer la robustesse du modèle.

Cette division stratégique en ensembles d'entraînement et de test assure une représentation équilibrée des données tout en fournissant un cadre fiable pour évaluer les performances du modèle de détection d'apnée du sommeil. En entraînant le modèle sur un large éventail de données représentatives et en les évaluant de manière impartiale sur des données inconnues, nous attendons de ce modèle qu'il puisse généraliser efficacement et détecter avec précision l'apnée du sommeil dans de nouvelles situations.

4.5. La méthodologie proposée

Dans notre modèle de détection d'apnée du sommeil, nous avons employé deux approches méthodologiques différentes : le classificateur K plus proches voisins (KNN) et un réseau de neurones convolutif (CNN), puis une combinaison CNN+KNN.

Pour notre approche basée sur l'algorithme KNN (K-Nearest Neighbors), nous avons suivi une méthodologie systématique. Tout d'abord, nous avons prétraité les données en normalisant les signaux RRI (intervalles RR) et les signaux d'amplitude. Ensuite, pour éviter tout déséquilibre entre les classes dans l'apprentissage du modèle, nous avons utilisé la technique de sur-échantillonnage aléatoire (Random Over Sampler) pour équilibrer les classes. Cette étape est cruciale pour garantir une performance robuste du modèle, en particulier lorsque les classes sont déséquilibrées.

Après avoir identifié les meilleurs paramètres, nous avons entraîné le modèle KNN sur l'ensemble d'entraînement en utilisant ces paramètres optimaux. Une fois le modèle entraîné, nous l'avons évalué sur l'ensemble de tests pour estimer sa performance en termes de classification entre les classes "Apnée" et "Non-apnée".

Enfin, pour une évaluation plus détaillée des performances du modèle, nous avons calculé la précision du modèle ainsi que la matrice de confusion. La précision mesure la proportion d'instances positives correctement prédites parmi toutes les instances prédites comme positives, tandis que la matrice de confusion fournit une répartition détaillée des prédictions du modèle, permettant une analyse approfondie de ses performances de classification.

La figure n° 20 ci-dessous illustre le flux de travail complet de notre approche KNN :

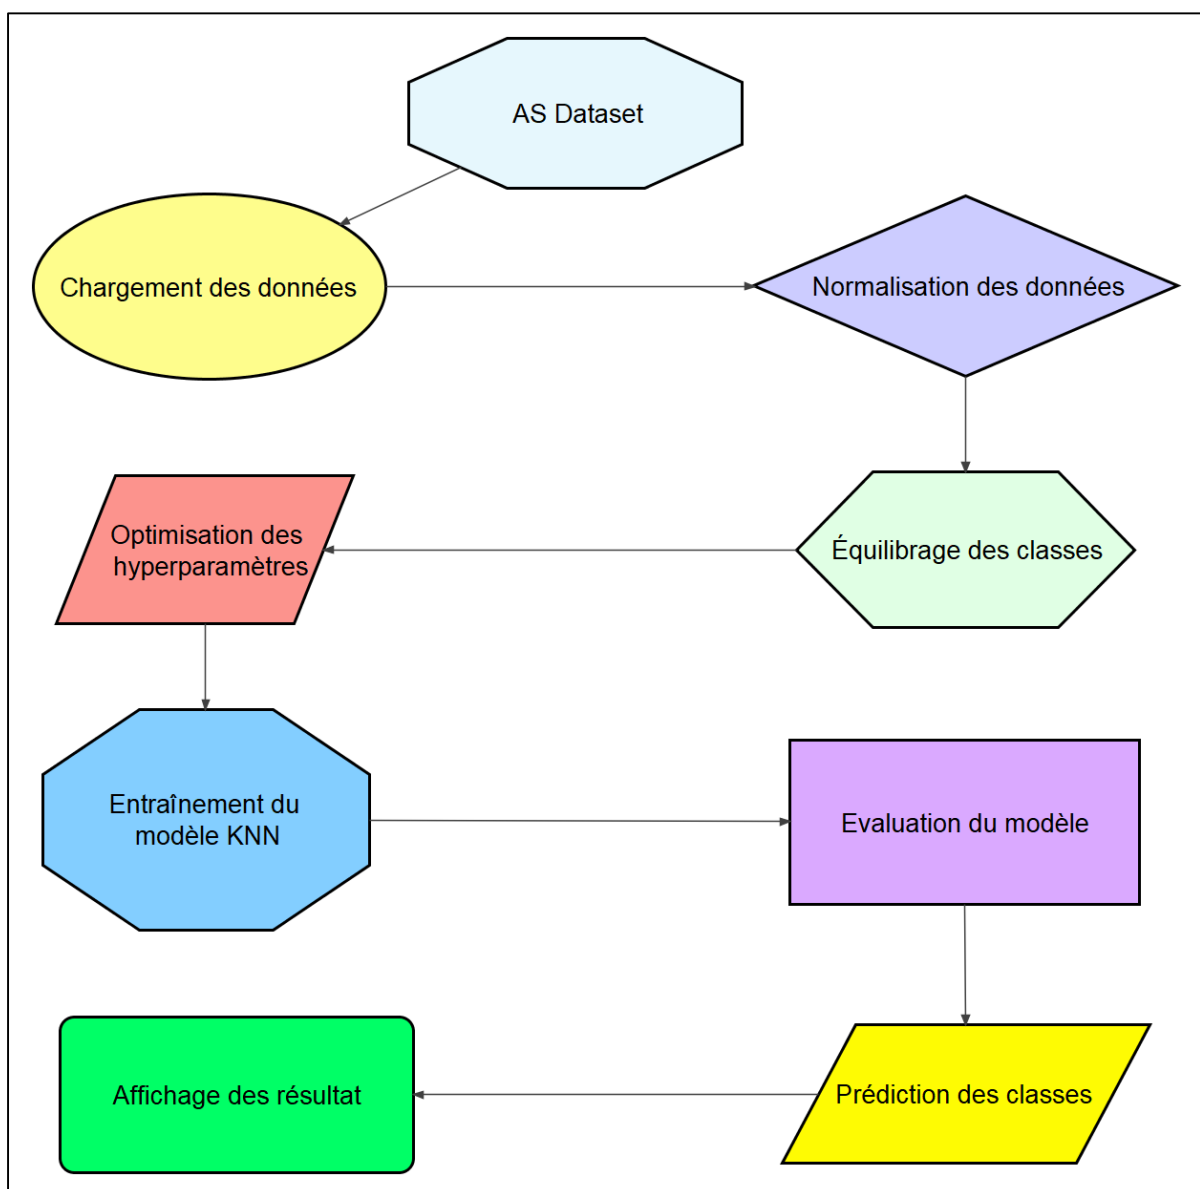


Figure 20. Le flux de travail avec le KNN.

Voici ainsi le paramétrage du nombre de voisins pour KNN dans la figure n°21 suivante :

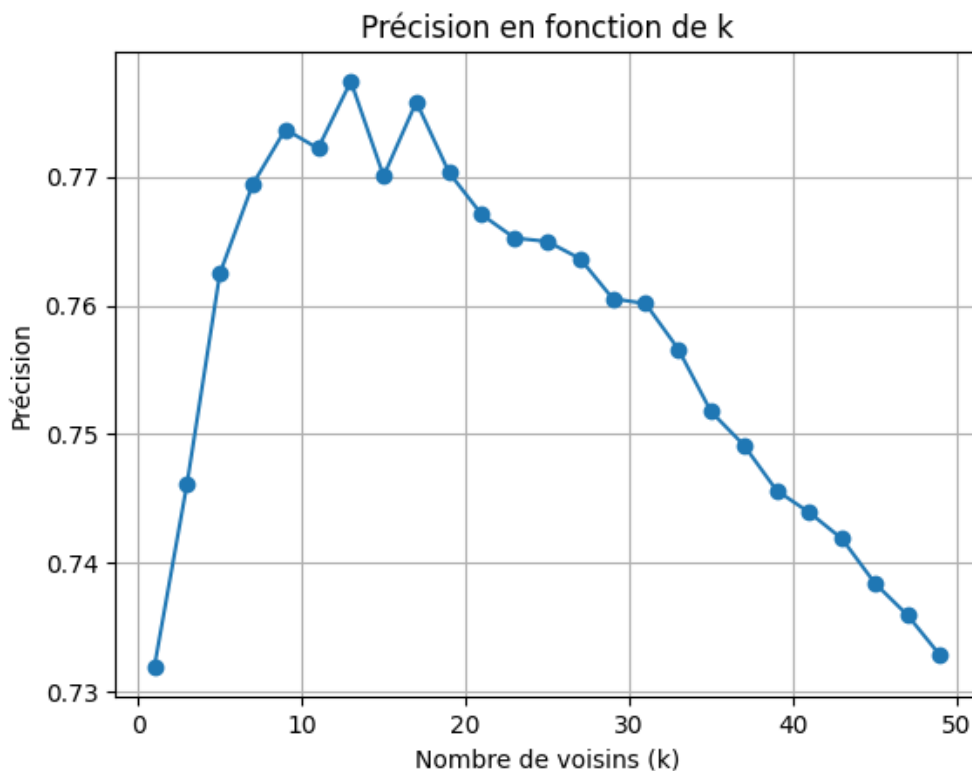


Figure 21. Le paramétrage du nombre des voisins pour KNN.

Cette figure illustre la précision du modèle KNN pour différentes valeurs jusqu'à $K=50$ sur le jeu de données de test. Chaque point sur la courbe représente la précision du modèle lorsque le nombre de voisins, k , est fixé à une valeur spécifique. L'axe des abscisses représente les valeurs de k testées, tandis que l'axe des ordonnées représente la précision correspondante.

En examinant la courbe, nous observons une tendance générale à l'augmentation de la précision lorsque le nombre de voisins augmente. Cependant, cette tendance n'est pas linéaire, et la précision atteint un maximum à un certain point avant de diminuer à nouveau. Dans ce cas particulier, la précision maximale est atteinte avec $k=13$, où elle s'élève à 77.76%.

Il est intéressant de noter que bien que la précision augmente généralement avec k , elle atteint son maximum à $k=13$ avant de commencer à diminuer légèrement. Cela suggère que, pour ce jeu de données spécifique, un compromis optimal entre biais et variance est atteint avec un k légèrement plus élevé.

Cette analyse détaillée de la précision du modèle en fonction de différentes valeurs de k fournit des informations essentielles pour choisir le meilleur paramètre k dans le modèle KNN, permettant ainsi une prise de décision plus éclairée pour le problème de classification des données respiratoires.

D'autre part, pour la méthodologie CNN, nous avons utilisé une architecture de réseau de neurones convolutif pour extraire automatiquement les caractéristiques discriminantes des signaux ECG. Cette approche implique l'utilisation de plusieurs couches de convolution suivies de couches de pooling pour capturer les motifs temporels dans les données. Après l'entraînement du modèle, nous avons également évalué sa performance de la même manière que pour le KNN, en calculant la précision et en générant la matrice de confusion, voici la figure n°22 suivante qui montre le flux de travail avec le CNN :

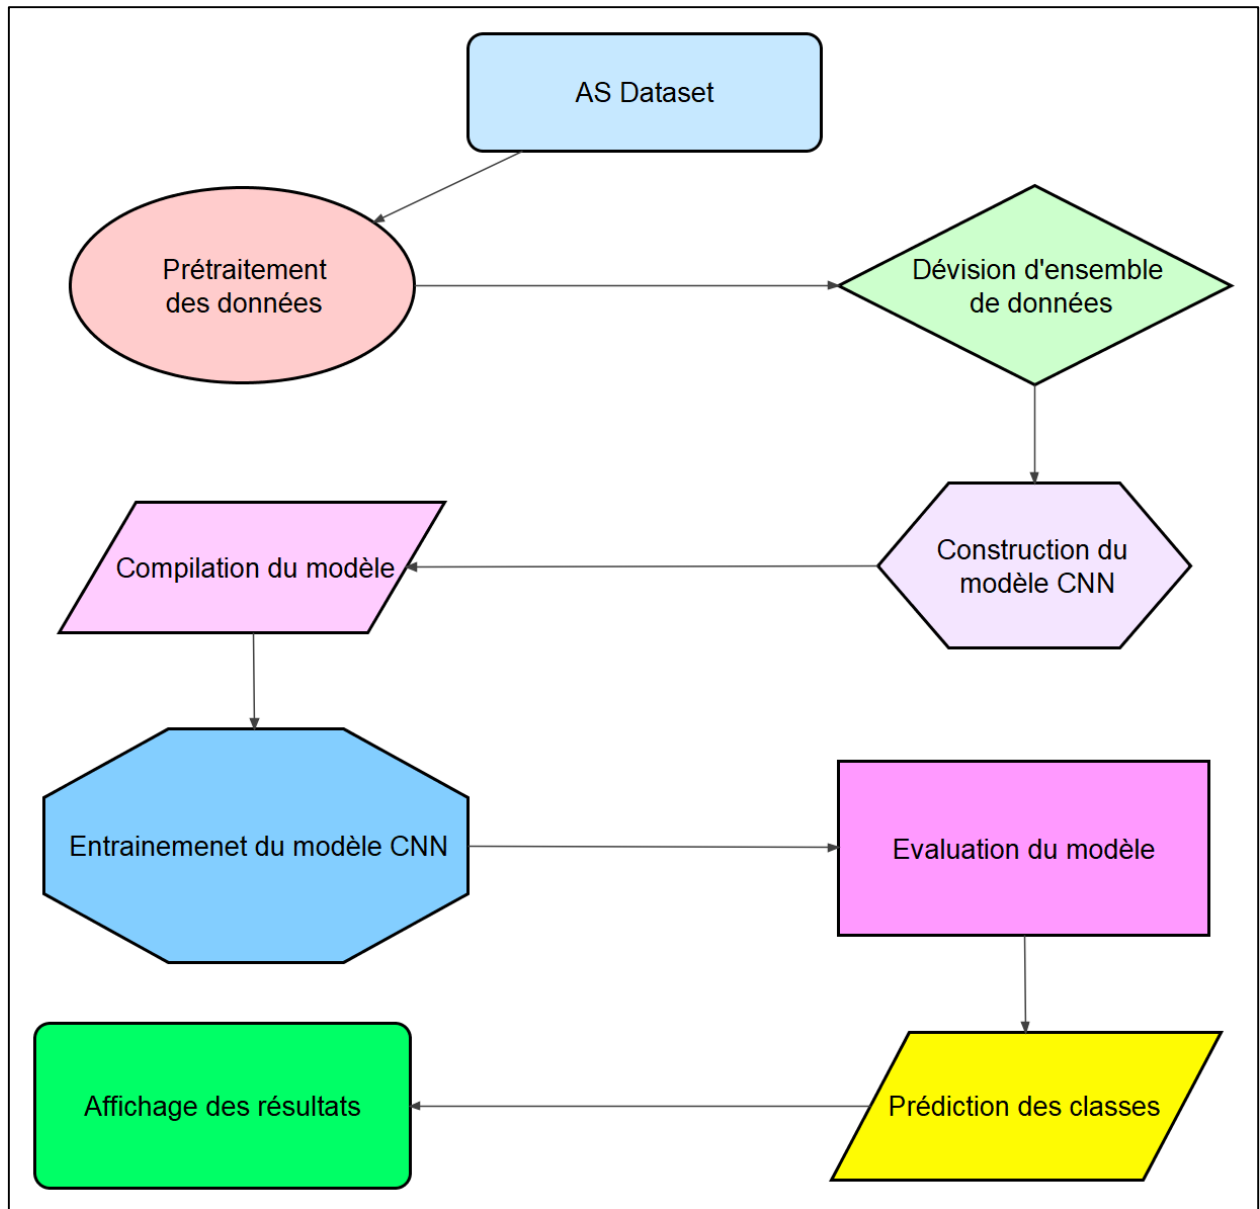


Figure 22. Le flux de travail avec le CNN.

Et voici ainsi le flux de travail qui combine intelligemment les deux algorithmes d'apprentissage automatique, le CNN et le KNN, pour améliorer la classification des données respiratoires. Tout d'abord, le CNN est entraîné à extraire des caractéristiques pertinentes des signaux respiratoires. Ensuite, les prédictions du CNN sont utilisées comme caractéristiques d'entrée pour le modèle KNN, qui exploite les relations de similarité entre les caractéristiques pour effectuer une classification plus précise. Cette approche hybride tire parti des avantages de chaque algorithme, exploitant la capacité du CNN à apprendre des représentations de haut niveau des données et la simplicité et la flexibilité du KNN dans la classification basée sur les caractéristiques. En combinant ces deux approches, le modèle résultant offre une performance améliorée, comme en témoigne la précision accrue dans la classification des données respiratoires, voici la figure n°23 suivante qui montre le flux de travail avec la combinaison CNN&KNN :

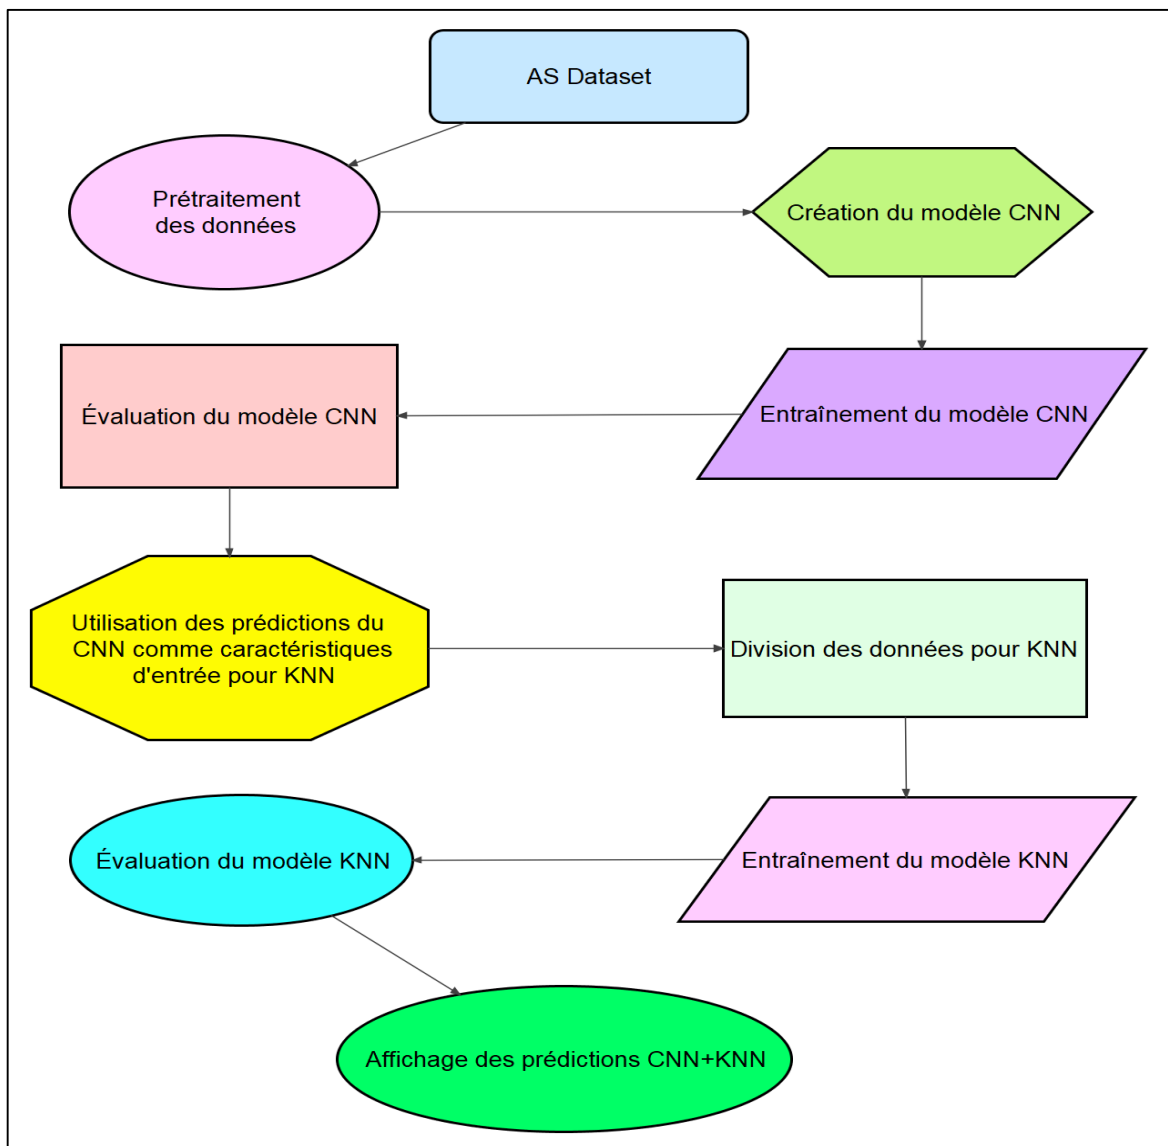


Figure 23. Le flux de travail du CNN+KNN.

En utilisant ces trois méthodologies, nous avons pu explorer différentes façons de modéliser les données et d'effectuer la classification des signaux ECG pour détecter l'apnée du sommeil. Cela nous a permis d'avoir une vision comparative des performances des trois approches et de choisir celle qui offre les meilleures performances pour notre tâche spécifique.

4.6. Choix du modèle CNN

Dans notre recherche du modèle optimal pour la classification des données, nous avons exploré plusieurs architectures de réseaux de neurones convolutionnels (CNN). Chaque modèle a été conçu avec des couches différentes, des hyperparamètres variés et des techniques de régularisation distinctes. Notre objectif était de trouver le modèle qui offre le meilleur compromis entre la capacité de généralisation et les performances sur les données de test. Pour ce faire, nous avons comparé les résultats obtenus à partir de divers indicateurs tels que la précision, la perte :

A. Modèle 1 : Conv1D-32-5-Relu-MaxPool1D-2-Flatten-Dense-32-Relu-Dense-2-Softmax

Ce modèle commence par une couche Conv1D avec 32 filtres, suivie d'une fonction d'activation ReLU et d'une couche de MaxPooling1D pour la réduction de dimension. Ensuite, les données sont aplaties avant de passer à une couche Dense de 32 neurones avec une activation ReLU. Enfin, il y a une couche Dense de sortie avec une activation softmax pour la classification.




Figure 24. La précision du modèle 1.




Figure 25. La perte du modèle 1.

La précision du modèle sur les données de test est d'environ 67. Cependant, la perte sur les données de test est d'environ 0.62, ce qui signifie que le modèle commet encore une certaine erreur dans ses prédictions. Malgré des performances qui montrent une certaine capacité d'apprentissage, le modèle semble ne pas être optimal. La précision sur les données de test n'est pas très élevée, et la perte pourrait être réduite davantage. Cela suggère que le modèle pourrait bénéficier d'ajustements supplémentaires pour améliorer ses performances.

B. Modèle 2 : Conv1D-32-5-Relu-MaxPool1D-3-Conv1D-64-5-Relu-MaxPool1D-3-Flatten-Dropout-0.8- Dense-32-Relu-Dense-2-Softmax

Le modèle 1 est un réseau de neurones convolutionnel (CNN) composé de deux couches de convolution en série. La première couche utilise 32 filtres de taille 5 avec une fonction d'activation ReLU, suivie d'une couche de max pooling de taille 3. Ensuite, une seconde couche de convolution est utilisée avec 64 filtres de taille 5 et une fonction d'activation ReLU, suivie d'une autre couche de max pooling de taille 3. Les sorties sont ensuite aplaties et soumises à un dropout de 80% pour la régularisation. Enfin, deux couches denses sont ajoutées, avec respectivement 32 neurones activés par ReLU pour la première et 2 neurones avec une activation softmax pour la classification binaire.




Figure 26. La précision du modèle 2.




Figure 27. La perte du modèle 2.

L'affichage des deux figures montre les résultats d'un modèle CNN sur un ensemble de données. Malheureusement, les performances ne sont pas optimales. Bien que la perte de test soit assez faible à 0.6580, la précision du test est seulement de 60.96%. Cela signifie que le modèle ne parvient à classer correctement que près de 61% des exemples du jeu de données de test, ce qui est en dessous des attentes pour de nombreuses applications. Il est donc clair que ce modèle nécessite des améliorations pour obtenir de meilleures performances.

C. Modèle 3 : Conv1D-64-5-Relu-MaxPool1D-2-Dropout-0.5-Conv1D-64-5-Relu-MaxPool1D-2-Dropout-0.5-Concat-Conv1D-128-3-Relu-MaxPool1D-2-Dropout-0.5-Flatten-Dense-64-Relu-Dense-2-Softmax

Ce modèle utilise trois couches de convolution 1D (Conv1D) avec 64 filtres chacune et des fenêtres de convolution de taille 5, suivies de couches de max-pooling 1D (MaxPool1D) avec une fenêtre de taille 2. Des couches Dropout avec un taux de 0.5 sont insérées après chaque max-pooling pour la régularisation. Les sorties des deux branches sont concaténées avant d'être envoyées à une couche supplémentaire de convolution (Conv1D) avec 128 filtres et une fenêtre de taille 3. Ensuite, il y a une couche de max-pooling 1D suivie d'une couche Dropout avant d'aplatir les caractéristiques pour les passer à travers deux couches denses pour la classification binaire.

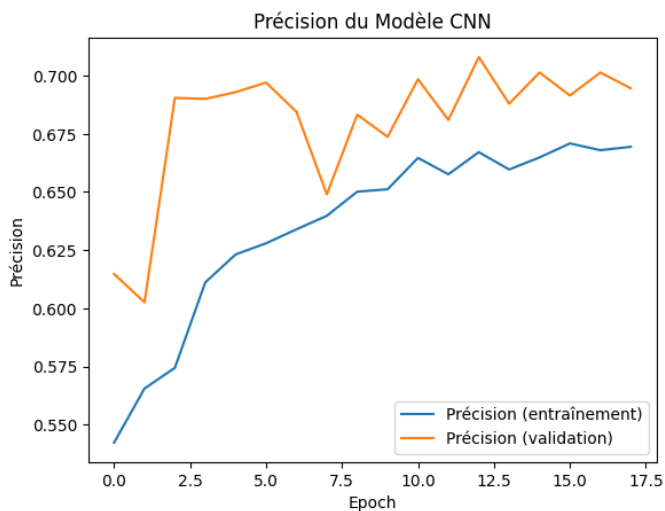


Figure 28. La précision du modèle 3.




Figure 29. La perte du modèle 3.

Ce modèle montre une amélioration par rapport au précédent, avec une précision de test d'environ 71% et une perte d'environ 0.60, mais il reste des possibilités d'amélioration pour atteindre des performances encore meilleures.

D. Modèle 4 : Conv1D-64-5-Relu-MaxPool1D-3-Conv1D-128-5-Relu-MaxPool1D-3-Flatten-Dropout-0.5-Dense-64-Relu-Dense-2-Softmax

Ce modèle utilise deux couches de convolution 1D avec respectivement 64 et 128 filtres de taille 5, suivies de fonctions d'activation ReLU et de couches de pooling MaxPool1D de taille 3 pour extraire les caractéristiques importantes. Ensuite, les données sont aplaties et passées par une couche de dropout à 50% pour prévenir le surapprentissage. Enfin, une couche dense de 64 neurones avec ReLU est utilisée avant une couche de sortie softmax avec deux neurones pour la classification binaire.

A. La courbe d'exactitude




Figure 30. La précision du modèle 4.

La figure de la courbe d'accuracy n°30 illustre l'évolution de la précision du modèle CNN au cours de l'entraînement sur les données d'entraînement et de validation. Au fur et à mesure que les epochs progressent, l'accuracy sur les données d'entraînement et de validation est tracée. Initialement, l'accuracy augmente rapidement, mais elle se stabilise par la suite, indiquant que le modèle a convergé vers une certaine performance. Dans ce cas, la précision du modèle sur les données d'entraînement augmente et atteint environ 89.79% ce qui indique que le modèle apprend à mieux ajuster ses poids pour mieux correspondre aux données d'entraînement, et l'accuracy atteint environ 89,16 % sur les données de test, ce qui suggère que le modèle parvient à classifier correctement plus de 89 % des échantillons.

A. La courbe de perte

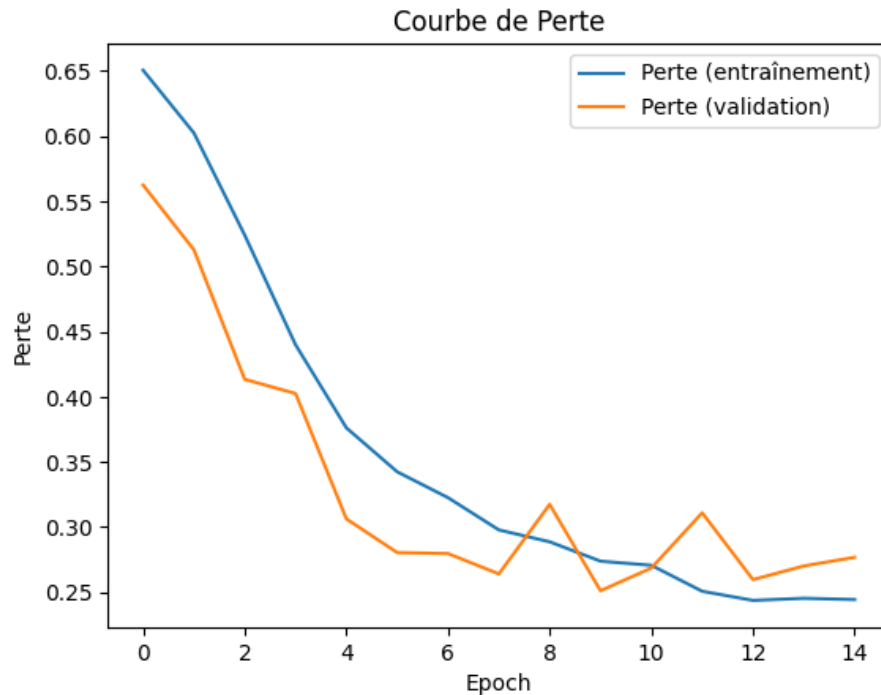


Figure 31. La perte du modèle 4.

La figure n°31 représente la courbe de perte (loss curve) du modèle. Elle montre comment la perte évolue au cours de l'entraînement. Initialement, la perte diminue rapidement, ce qui signifie que le modèle s'ajuste bien aux données et apprend efficacement. Par la suite, la diminution de la perte ralentit, mais elle continue de décroître, indiquant que le modèle continue d'apprendre. Une faible perte finale, comme dans ce cas où la perte de test est d'environ 0,25. Suggère que le modèle a réussi à généraliser ses connaissances sur de nouvelles données.

En conclut que le quatrième modèle se démarque comme le plus performant parmi les précédents, affichant une précision remarquable de 89% et une perte minimale de 0.25 lors de son évaluation. Son architecture utilise des couches de convolution 1D, suivies de couches de pooling pour extraire efficacement les caractéristiques clés des données. En incorporant une couche de dropout à 50%, il parvient à éviter le surapprentissage, tandis que ses couches denses permettent une classification précise avec une activation ReLU. Avec ses performances supérieures, ce modèle présente une robustesse et une capacité de généralisation qui en font un choix optimal pour des tâches de classification binaire.

4.7. Architecture du modèle CNN

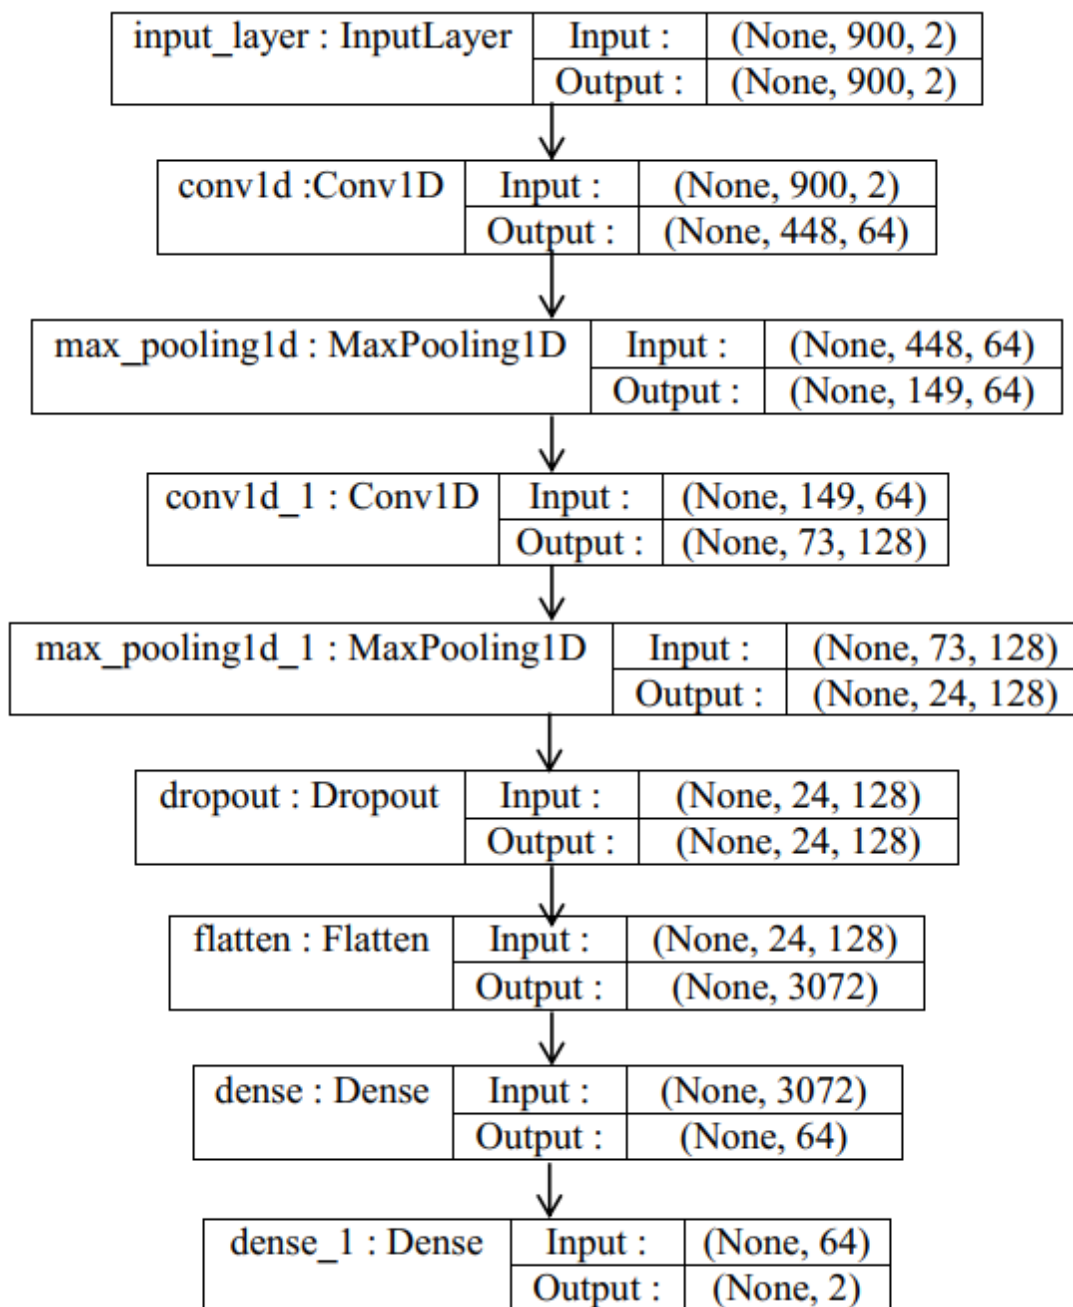


Figure 32. L'architecture du modèle AS (CNN).

Le modèle présenté dans la figure n°32 est l'architecture du réseau de neurones convolutifs (CNN) fonctionnelle, conçue pour la classification des données d'apnée du sommeil.

- En commence par La couche d'entrée accepte les données sous forme de tenseur (None, 900, 2), où None est la taille du batch, 900 est le nombre de pas de temps, et 2 est le nombre de caractéristiques (Apnée et Non apnée).
- Une couche Convolution 1D applique 64 filtres de taille 5 avec des strides de 2, réduisant la séquence de 900 à 448. Nombre total de paramètres : 704.
- Ensuite couche de pooling réduit la séquence de 448 à 149 en prenant le maximum sur une fenêtre de taille 3 avec des strides de 3.
- Puis une autre couche Convolution 1D applique 128 filtres de taille 5 avec des strides de 2, réduisant la séquence de 149 à 73.
- Et une autre couche de pooling réduit la séquence de 73 à 24 en prenant le maximum sur une fenêtre de taille 3 avec des strides de 3.
- Ainsi une couche de dropout met à zéro 50% des unités de la couche précédente pour chaque mise à jour afin de prévenir le sur-apprentissage.
- Et une couche flatten transforme les données d'une matrice multidimensionnelle en un vecteur 1D. La sortie a une forme de $(24 * 128 = 3072)$.
- Une couche dense applique une transformation linéaire suivie d'une activation ReLU, réduisant la dimension de 3072 à 64.
- Et à la fin la couche de sortie dense utilise une activation Softmax pour produire une distribution de probabilité sur les 2 classes (apnée et non-apnée).

Le modèle utilise l'optimiseur Adam pour minimiser la fonction de perte de la perte de catégorisation croisée et est évalué en utilisant la précision comme métrique de performance.

Voici la configuration et le paramétrage du modèle AS dans la figure n°33 suivante :

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 900, 2)	0
conv1d (Conv1D)	(None, 448, 64)	704
max_pooling1d (MaxPooling1D)	(None, 149, 64)	0
conv1d_1 (Conv1D)	(None, 73, 128)	41,088
max_pooling1d_1 (MaxPooling1D)	(None, 24, 128)	0
dropout (Dropout)	(None, 24, 128)	0
flatten (Flatten)	(None, 3072)	0
dense (Dense)	(None, 64)	196,672
dense_1 (Dense)	(None, 2)	130

Total params: 238,594 (932.01 KB)
Trainable params: 238,594 (932.01 KB)
Non-trainable params: 0 (0.00 B)

Figure 33. Configuration et paramétrage du modèle AS.

Le concept des paramètres du modèle présenté dans la figure n°33 est crucial pour comprendre comment un réseau neuronal apprend à partir des données et effectue des prédictions. Voici une explication plus détaillée de chaque partie :

- **Nombre total de paramètres (Total params) :**

Ce nombre représente la somme totale de tous les paramètres dans le modèle, qu'ils soient entraînaux ou non-entraînaux. Les paramètres incluent les poids des connexions entre les neurones, ainsi que d'autres paramètres tels que les biais des neurones et les paramètres de normalisation. Dans ce modèle, le nombre total de paramètres est de 238,594.

- **Nombre de paramètres entraînaux (Trainable params) :**

Ce chiffre indique le nombre de paramètres dans le modèle qui seront ajustés pendant l'entraînement pour apprendre à représenter les données et effectuer des prédictions précises. Ces paramètres comprennent généralement les poids des connexions entre les neurones ainsi que les biais des neurones dans les couches entièrement connectées. Dans ce modèle, tous les paramètres sont entraînaux, ce qui signifie qu'ils seront ajustés pendant l'entraînement.

- **Nombre de paramètres non entraînaux (Non-trainable params) :**

Ce nombre représente les paramètres du modèle qui ne seront pas ajustés pendant l'entraînement. Ils comprennent généralement les paramètres des couches telles que les couches de pooling et de normalisation, qui n'ont pas besoin d'être mis à jour pendant l'apprentissage. Dans notre modèle, il n'y a pas de paramètres non entraînaux, ce qui signifie que tous les paramètres sont ajustés pendant l'entraînement.

En combinant ces trois éléments, nous obtenons une vue d'ensemble complète de la complexité et de la capacité du modèle à apprendre à partir des données. Dans ce cas, le modèle a une capacité de 238,594 paramètres, tous ajustables pendant l'entraînement, ce qui lui permet de s'adapter efficacement aux données et d'effectuer des prédictions précises.

4.8. Discussion et évaluation des résultats obtenus

Dans cette section, nous allons examiner et évaluer nos résultats, obtenus en utilisant différentes architectures de modèles pour la détection et la classification des apnées du sommeil. Nous avons exploré trois approches distinctes : tout d'abord, notre architecture personnalisée développée précédemment, en utilisant exclusivement un réseau de neurones convolutifs (CNN), ensuite, l'emploi unique de l'algorithme de classification K plus proches voisins (KNN). Enfin, nous avons également évalué une combinaison de CNN et de KNN.

4.8.1. Résultats et évaluation du modèle AS (CNN)

Le modèle de classification binaire pour des signaux ECG à une seule dérivation, visant à détecter la présence ou l'absence d'apnée du sommeil. Tout d'abord, les données sont chargées à partir d'un fichier binaire (apnea-ecg.pkl) contenant les enregistrements d'ECG prétraités, les signaux sont interpolés et normalisés. Les étiquettes de classe sont ensuite converties en format one-hot pour être utilisées pendant l'entraînement, et compatibles avec le modèle CNN. Le modèle utilise des couches de convolution, de max pooling, de dropout, et une couche dense. Le modèle est compilé avec l'optimiseur Adam et la perte de catégorisation croisée catégorique. Le modèle est entraîné sur les données d'entraînement avec 14 époques et une taille de lot de 32. L'ensemble de validation est utilisé pour surveiller les performances pendant l'entraînement. Enfin, le modèle est évalué sur les ensembles d'entraînement et de test pour évaluer sa performance en termes de perte et d'exactitude, et utilisé pour prédire les classes des données de test (Apnée ou Non Apnée).

Après avoir entraîné le modèle de détection d'apnée du sommeil, plusieurs mesures de performance ont été évaluées pour évaluer son efficacité. Tout d'abord, la perte et l'exactitude ont été calculées sur l'ensemble de test pour évaluer la performance du modèle. La perte sur l'ensemble de test était de 25,10 %, tandis que l'exactitude était de 89,16%. Ces mesures fournissent des indications sur l'aptitude du modèle à généraliser à de nouvelles données. Ensuite, une matrice de confusion a été générée et visualisée sous forme d'image pour examiner les performances de classification du modèle. La matrice de confusion révèle le nombre de prédictions correctes et incorrectes, permettant une évaluation détaillée de la capacité du modèle à classifier les données. De plus, une courbe de précision-rappel a été tracée pour évaluer la capacité du modèle à maintenir un équilibre entre la précision et le rappel à différents seuils de classification. Cette courbe met en évidence la relation entre la sensibilité du modèle et sa capacité à éviter les faux positifs. Enfin, la courbe de la précision et de la perte a été tracée au fil des époques d'entraînement pour examiner la convergence du modèle et son apprentissage au fil du temps. Ces mesures et visualisations combinées offrent une vue holistique de la performance du modèle de détection d'apnée du sommeil et de sa capacité à généraliser à de nouvelles données.

- **Rapport**

	Apnée	Non Apnée	Macro-avg	weighted avg
Précision	0.94	0.80	0.87	0.89
Rappel	0.88	0.89	0.89	0.89
F1-Score	0.91	0.85	0.88	0.89

Tableau 4. Évaluation du modèle AS.

Le tableau n°4 représente l'évolution des performances du modèle de détection d'apnée du sommeil à l'aide de l'architecture CNN. Il évalue la capacité du modèle à classer correctement les échantillons en fonction de leur étiquette de classe, distinguant entre les échantillons d'apnée et de non-apnée.

- **Précision** : C'est la proportion d'échantillons correctement identifiés comme appartenant à la classe respective parmi tous les échantillons identifiés comme appartenant à cette classe. Par exemple, le modèle a une précision de 0.94 pour la classe "Apnée", ce qui signifie que 94,22 % des échantillons classés comme apnée le sont réellement. Pour la classe "Non Apnée", la précision est de 0.80, ce qui indique que 80,99 % des échantillons classés comme non apnée le sont réellement.
- **Rappel** : C'est la proportion d'échantillons de la classe respective qui ont été correctement identifiés parmi tous les échantillons réels de cette classe. Par exemple, le modèle a un rappel de 0.88 pour la classe "Apnée", ce qui signifie que 88,90% des échantillons d'apnée ont été correctement identifiés. Pour la classe "Non Apnée", le rappel est de 0.89, indiquant que 89,65 % des échantillons de non apnée ont été correctement identifiés.
- **F1-Score** : C'est une mesure combinée de la précision et du rappel, calculée comme la moyenne pondérée de ces deux mesures. Il fournit une évaluation globale de la capacité du modèle à classer correctement les échantillons pour chaque classe. Par exemple, le modèle a un F1-score de 0.91 pour la classe "Apnée" et de 0.85 pour la classe "Non Apnée".
- **Macro-avg** : C'est la moyenne non pondérée des mesures de précision, de rappel et de F1-score pour chaque classe. Ici, la moyenne macro-avg pour la précision, le rappel est de 0.89 et le F1-score est de 0.88, ce qui donne une indication globale des performances du modèle sans tenir compte du déséquilibre entre les classes.

- **Weighted avg** : C'est la moyenne pondérée des mesures de précision, de rappel et de F1-score pour chaque classe, où les poids sont les proportions d'échantillons dans chaque classe. Dans ce cas, la moyenne weighted avg pour la précision, le rappel et le F1-score est de 0.89, ce qui prend en compte le déséquilibre entre les classes.

A. La matrice de confusion




Figure 34. La matrice de confusion du Modèle CNN.

La figure de la matrice de confusion n°34 offre une vue détaillée des performances du modèle de classification binaire. Dans cette matrice, les TP (True Positives) représentent les cas où le modèle a correctement prédit la classe positive, dans ce cas, 2821 échantillons. Les TN (True Negatives) sont les cas où le modèle a correctement prédit la classe négative, totalisant 1500 échantillons. Les FP (False Positives) désignent les cas où le modèle a prédit à tort la classe positive alors qu'elle était négative, comptabilisant 352 échantillons. Enfin, les FN (False Negatives) sont les cas où le modèle a prédit à tort la classe négative alors qu'elle était positive, totalisant 173 échantillons. Une matrice de confusion idéale aurait des valeurs diagonales élevées

(TP et TN) et des valeurs hors-diagonales proches de zéro (FP et FN). Dans ce cas, bien que le nombre de FP et de FN ne soit pas négligeable, les valeurs de TP et TN indiquent que le modèle parvient à bien classifier la plupart des échantillons, avec une certaine marge d'erreur pour les faux positifs et les faux négatifs. Cette analyse de la matrice de confusion permet de mieux comprendre les forces et les faiblesses du modèle CNN dans sa tâche de détection de l'apnée du sommeil.

B. La courbe ROC

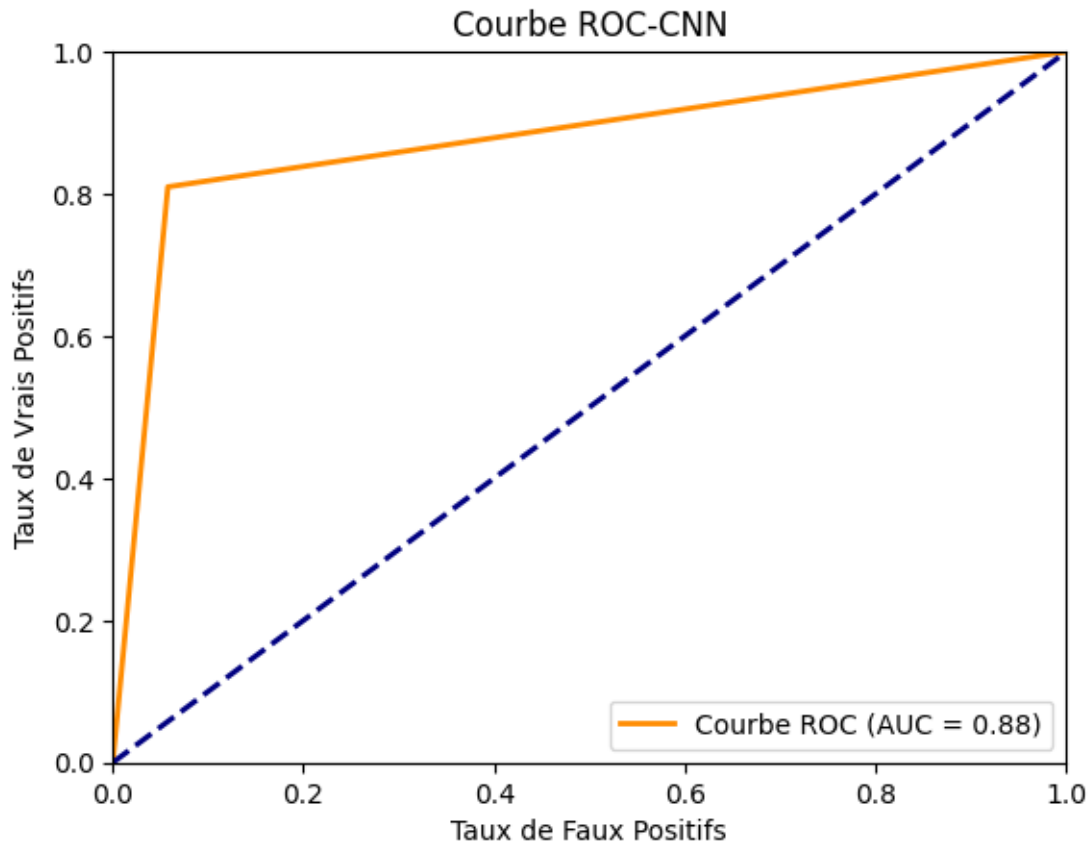


Figure 35. La courbe ROC CNN.

La figure n°35, illustrant la courbe ROC (Receiver Operating Characteristic), offre une analyse détaillée des performances du modèle de classification binaire à divers seuils de classification. L'AUC (Area Under Curve) associée à cette courbe, évaluée à 0,88, indique une capacité impressionnante du modèle à discriminer efficacement entre les classes positives et négatives. L'AUC est une mesure couramment utilisée pour quantifier la capacité prédictive d'un modèle de classification binaire. Plus l'AUC se rapproche de 1, meilleure est la capacité du modèle à classer correctement les exemples positifs et négatifs. Dans ce cas, une valeur élevée de 0,88 pour l'AUC suggère que le modèle présente une performance robuste et fiable dans sa capacité à faire la distinction entre les deux classes. Cela signifie que le modèle est capable de générer des

scores de probabilité plus élevés pour les exemples positifs par rapport aux exemples négatifs, ce qui est essentiel pour une classification précise.

C. La courbe Précision-Rappel

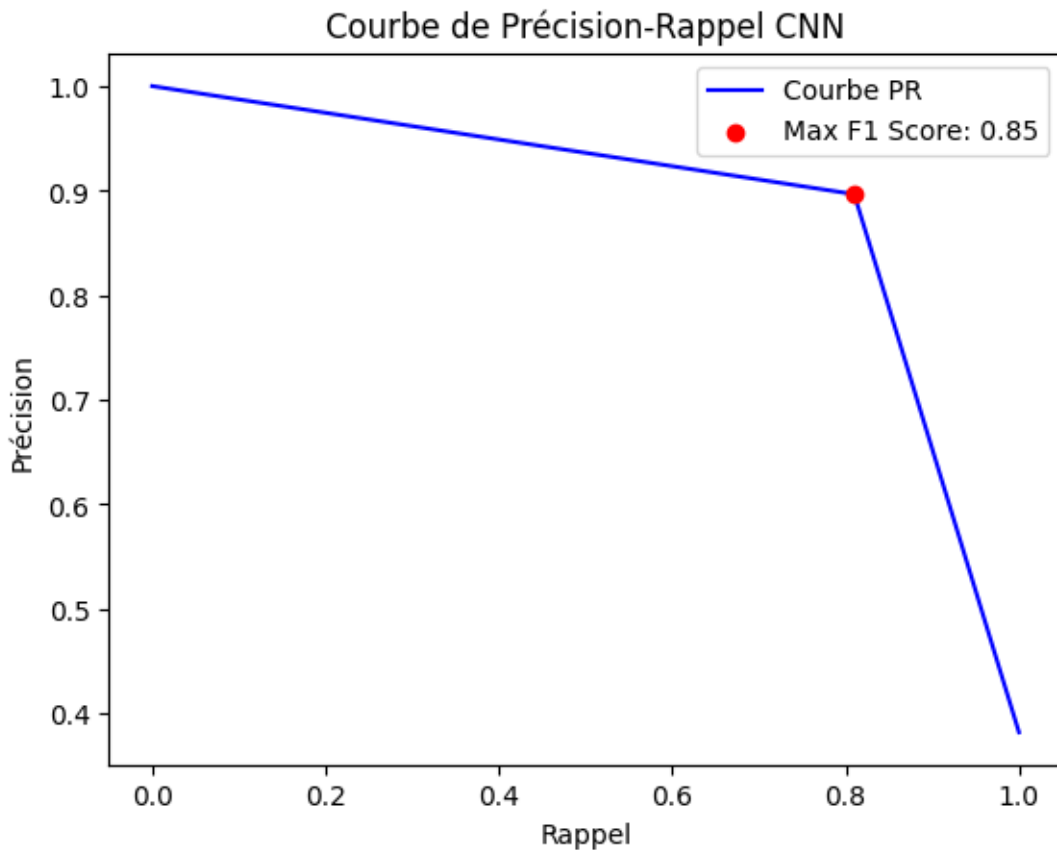


Figure 36. La courbe Précision-Rappel CNN.

La figure n°36 présente la courbe de précision-rappel, qui offre une perspective essentielle sur les performances du modèle, en mettant en lumière le point où le score F1 atteint son maximum, à 0,85. Cette courbe est particulièrement précieuse lorsque les classes de données sont déséquilibrées, car elle prend en compte à la fois la précision et le rappel du modèle. Le score F1 est une mesure composite de l'exactitude, représentant l'harmonique moyenne de la précision et du rappel. Ainsi, un score F1 élevé, tel que celui observé ici, suggère une performance globale solide du modèle en termes de sa capacité à identifier correctement les exemples positifs tout en minimisant les faux positifs et les faux négatifs. Dans ce contexte, une valeur de 0,85 pour le score F1 indique que le modèle parvient à atteindre un équilibre remarquable entre la précision et le rappel, ce qui témoigne de son efficacité dans la classification précise des échantillons, même dans des situations où les classes sont déséquilibrées.

4.8.2. Résultats et évaluation du modèle KNN

Le modèle des k plus proches voisins (KNN) est un algorithme d'apprentissage supervisé utilisé pour la classification et la régression. Dans le contexte de la détection de l'apnée du sommeil, le KNN est appliqué pour classer les données de signaux physiologiques en apnée ou non apnée.

Dans ce modèle, le paramètre k détermine le nombre de voisins les plus proches à considérer lors de la classification d'un point de données. Un k plus grand implique une frontière de décision plus lisse, tandis qu'un k plus petit peut conduire à une frontière de décision plus complexe. Dans notre cas, le modèle a été entraîné avec différentes valeurs de k.

Après l'entraînement du modèle KNN sur les données d'entraînement et l'évaluation sur les données de test, nous avons constaté que le meilleur k était de 13, avec une précision maximale obtenue de 0.7776. Cela signifie que le modèle a pu classer correctement environ 77,76% des données de test, ce qui est une mesure de la performance du modèle pour distinguer entre les périodes d'apnée du sommeil et les périodes de respiration normale.

La courbe de précision-rappel et la courbe ROC sont également des outils utilisés pour évaluer les performances du modèle. La courbe de précision-rappel montre la relation entre la précision et le rappel pour différentes valeurs de seuil de classification, tandis que la courbe ROC représente le taux de vrais positifs par rapport au taux de faux positifs pour différentes valeurs de seuil. Ces courbes nous permettent d'avoir une vue plus détaillée de la performance du modèle à différentes valeurs seuils.

A. La courbe ROC




Figure 37. La courbe Roc du modèle KNN.

Dans la figure 37, nous observons une courbe ROC avec une Aire sous la Courbe (AUC) de 0,84. L'AUC est une mesure de la capacité du modèle à classer correctement les échantillons positifs avant les échantillons négatifs. Plus l'AUC est proche de 1, meilleure est la performance du modèle, indiquant une capacité élevée à discriminer entre les deux classes. Dans notre cas, une AUC de 0,84 suggère que le modèle KNN a une bonne capacité de discrimination entre les périodes d'apnée du sommeil et les périodes de respiration normale, et mesure la performance binaire d'un test binaire et représente la sensibilité c'est-à-dire la probabilité d'être positifs sachant qu'on est malade en fonction de la probabilité d'être positifs sachant qu'on n'est pas malade, Cette valeur élevée suggère une performance robuste et fiable du modèle.

Une courbe ROC idéale se situerait dans le coin supérieur gauche du graphique, où le Taux de Vrais Positifs (TVP) est élevé et le Taux de Faux Positifs (TFP) est faible. Bien que notre courbe ROC puisse ne pas être parfaite, une AUC de 0,84 indique que le modèle KNN a une performance solide dans la classification des échantillons, ce qui suggère qu'il pourrait être un outil précieux dans la détection de l'apnée du sommeil à partir de signaux physiologiques.

B. La courbe précision-rappel




Figure 38. La courbe précision-rappel du modèle KNN.

Dans la figure 38, nous observons une courbe de précision-rappel avec un F1-score de 0,80. Un F1-score élevé indique à la fois une haute précision et un haut rappel, ce qui signifie que le modèle KNN parvient à bien classifier à la fois les vrais positifs et les vrais négatifs, tout en minimisant à la fois les faux positifs et les faux négatifs.

Cela suggère que le modèle KNN est capable de détecter efficacement les périodes d'apnée du sommeil tout en limitant les erreurs de classification. Un F1-score de 0,80 est considéré comme un résultat solide, indiquant que le modèle KNN est prometteur pour la détection de l'apnée du sommeil à partir des signaux physiologiques utilisés dans notre étude.

4.8.3. Résultats et évaluation du modèle CNN+KNN

Cette combinaison de deux modèles d'apprentissage automatique, un modèle CNN (Convolutional Neural Network) et un algorithme KNN (K-Nearest Neighbors), pour la classification de l'apnée du sommeil à partir de données d'électrocardiographie (ECG).

Les données sont chargées à partir d'un fichier prétraité au format pickle. Ces données sont ensuite prétraitées et divisées en ensembles d'entraînement et de test.

Ensuite, un modèle CNN est créé et entraîné sur les données d'apnée, avec une configuration d'optimisation et un callback Early-Stopping pour prévenir le sur-apprentissage. Le modèle est évalué sur les données de test pour calculer la perte et la précision du CNN seul. Ensuite, les prédictions du CNN sont utilisées comme caractéristiques d'entrée pour le modèle KNN.

Pour le KNN, différentes valeurs de k sont testées pour trouver la meilleure précision. Une fois la meilleure valeur de k trouvée, le modèle KNN est entraîné avec cette valeur et évalué. La matrice de confusion, la courbe ROC, la courbe de précision-rappel et la précision en fonction de k sont toutes calculées et affichées pour évaluer les performances du modèle combiné CNN+KNN. La matrice de confusion est affichée sous forme de heatmap, mettant en évidence les prédictions correctes et incorrectes pour les classes "Apnée" et "Non Apnée". Enfin, la meilleure précision obtenue en fonction de k est affichée graphiquement pour illustrer l'impact de la sélection de k sur les performances du modèle combiné.

La combinaison du CNN et du KNN a conduit à une amélioration significative des performances par rapport au CNN seul. En effet, le CNN a initialement produit une précision de 89,16%. Cependant, une fois combiné avec le KNN, la précision globale a augmenté à 90,30%. Cette amélioration démontre l'efficacité du KNN pour optimiser les résultats du CNN. En utilisant les prédictions du CNN comme caractéristiques d'entrée pour le KNN, nous avons pu exploiter davantage d'informations contenues dans les données, ce qui a conduit à une meilleure capacité de classification. Ainsi, le KNN a agi comme un complément puissant au CNN, permettant une amélioration notable des performances globales du modèle.

Cela montre comment les sorties d'un modèle peuvent être utilisées comme caractéristiques d'entrée pour un autre modèle, permettant ainsi de tirer parti des forces de chaque approche pour améliorer les performances globales de la classification.

- **Rapport**

	Apnée	Non Apnée	Macro-avg	weighted avg
Précision	0.95	0.82	0.88	0.90
Rappel	0.89	0.91	0.90	0.90
F1-Score	0.92	0.86	0.89	0.90

Tableau 5. Évaluation de la combinaison.

Le tableau n°5 représente l'évolution des performances de la combinaison du modèle de détection d'apnée du sommeil à l'aide de l'architecture CNN et l'algorithme KNN. Il évalue la capacité de ses deux modèles à classer correctement les échantillons en fonction de leur étiquette de classe, distinguant entre les échantillons d'apnée et de non-apnée.

- **Précision** : la combinaison des deux modèles a eu une précision de 0.95 pour la classe "Apnée", ce qui signifie que 95% des échantillons classés comme apnée le sont réellement. Pour la classe "Non Apnée", la précision est de 0.82, ce qui indique que 82,65 % des échantillons classés comme non apnée le sont réellement.
- **Rappel** : le rappel est de 0.89 pour la classe "Apnée", ce qui signifie que 89,20% des échantillons d'apnée ont été correctement identifiés. Pour la classe "Non Apnée", est de 0.91, indiquant que 91,04 % des échantillons de non apnée ont été correctement identifiés.
- **F1-Score** : le F1-score est de 0.92 pour la classe "Apnée" et de 0.86 pour la classe "Non Apnée".
- **Macro-avg** : Ici, la moyenne macro-avg pour la précision est 0.88, le rappel est de 0.90 et le F1-score est de 0.89, ce qui donne une indication globale des performances de la combinaison sans tenir compte du déséquilibre entre les classes.
- **Weighted avg** : la moyenne weighted avg pour la précision, le rappel et le F1-score est de 0.90, ce qui prend en compte la distribution des classes.

A. La précision du CNN-KNN en fonction de meilleur K

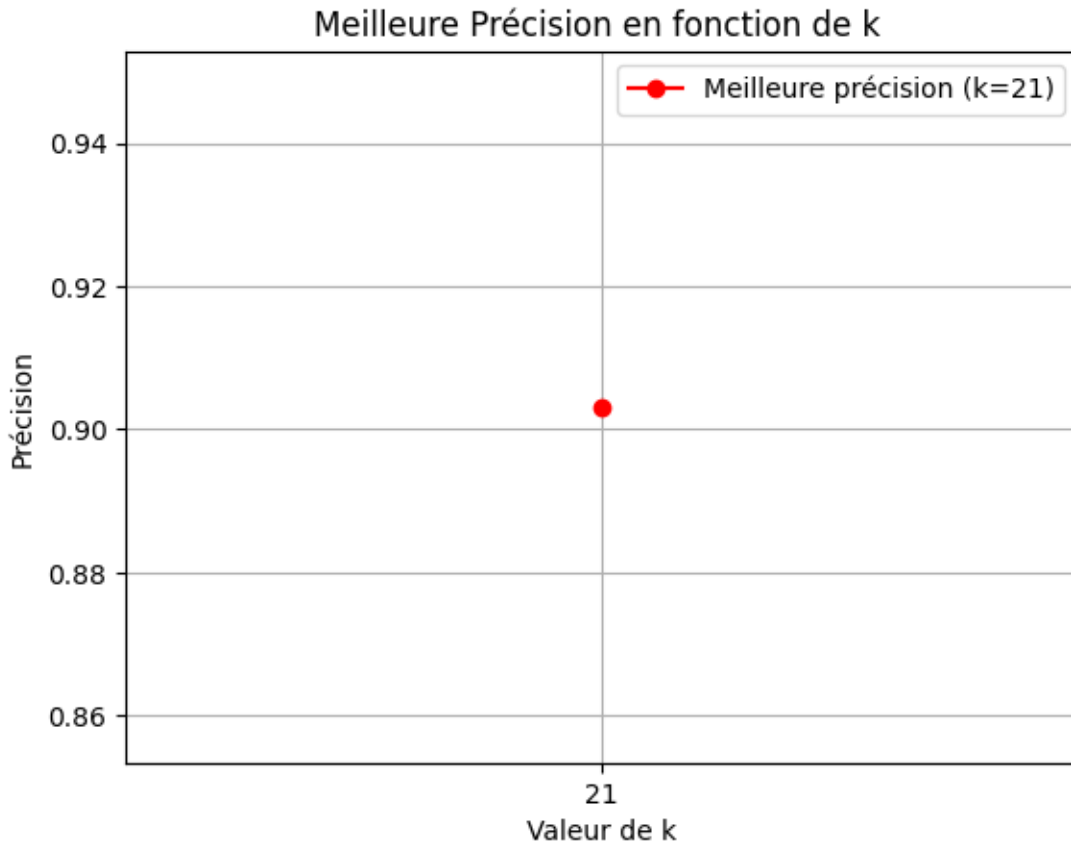


Figure 39. L'augmentation de précision avec 21-NN.

La figure n°39 montre que le modèle combiné CNN-KNN a atteint sa meilleure précision de 90.30% lorsque le paramètre k de KNN a été fixé à 21. Cette valeur de k a été déterminée après avoir évalué les performances du modèle KNN pour différentes valeurs impaires de k. Lorsque k a été fixé à 21, le modèle a réussi à améliorer la précision globale par rapport au CNN seul. Cela indique que le modèle combiné a mieux réussi à classer les données en utilisant une approche qui prend en compte à la fois les caractéristiques extraites par le CNN et les voisins les plus proches des données dans l'espace des caractéristiques. Ainsi, cette valeur optimale de k a permis d'optimiser les résultats du CNN, renforçant ainsi l'efficacité du modèle combiné dans la classification des périodes d'apnée.

B. La matrice de confusion




Figure 40. La matrice de confusion de la combinaison CNN+KNN.

La figure n°40 illustre le fait que lorsque le CNN est combiné avec le modèle KNN avec le meilleur k trouvé, la matrice de confusion montre une amélioration significative. Le nombre de faux positifs et de faux négatifs diminue, avec seulement 64 faux positifs et 30 faux négatifs. Cela indique une meilleure capacité du modèle combiné à classifier correctement les données. La précision globale augmente également à 90.30%.

En conclusion, l'ajout du modèle KNN à côté du CNN a amélioré les performances du modèle, réduisant les erreurs de classification et augmentant la précision globale. Cela suggère que le KNN a pu compenser certaines lacunes du CNN, améliorant ainsi la capacité globale du modèle combiné à identifier avec précision les périodes d'apnée.

C. La courbe ROC




Figure 41. La courbe Roc CNN-KNN.

La courbe ROC dans la figure n°41 illustre la performance du modèle combiné CNN-KNN dans la classification des périodes d'apnée, avec une AUC de 0.90. Cette valeur d'AUC représente la capacité du modèle à discriminer entre les périodes d'apnée et les périodes non apnée. Plus l'AUC est proche de 1, meilleure est la capacité de discrimination du modèle. Dans ce cas, une valeur d'AUC de 0.90 indique une performance très solide, suggérant que le modèle combiné est capable de classifier efficacement les périodes d'apnée avec peu de faux positifs et de faux négatifs. Cela confirme que l'approche combinée CNN-KNN a réussi à améliorer les performances du CNN seul dans la tâche de classification des périodes d'apnée.

D. La courbe Précision – Rappel

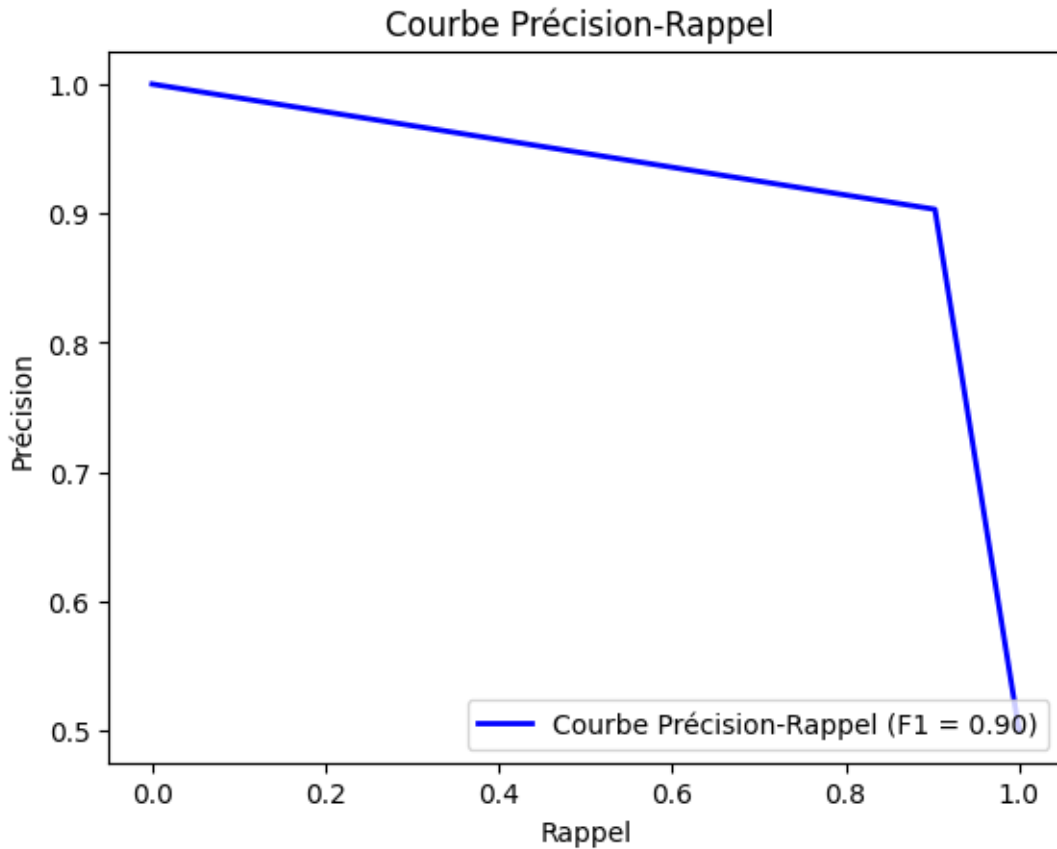


Figure 42. La courbe précision - Rappel CNN+KNN.

La courbe précision-rappel dans la figure n°42 démontre la performance du modèle combiné CNN-KNN dans la classification des périodes d'apnée, avec un point d'intersection situé à un score de 0,90. Ce point d'intersection représente le niveau de seuil où la précision et le rappel du modèle sont équilibrés, ce qui signifie que le modèle parvient à maintenir une précision de 90% tout en rappelant 90% des vraies périodes d'apnée présentes dans les données.

Le point d'intersection à 0,90 sur la courbe précision-rappel confirme que le modèle combiné CNN-KNN parvient à obtenir un équilibre optimal entre la précision et le rappel, ce qui témoigne de son efficacité dans la classification des périodes d'apnée.

4.9. Comparaison de nos résultats obtenus

La méthode	Précision	Rappel	AUC	F1-Score
KNN	0.77	0.77	0.84	0.80
CNN	0.89	0.89	0.88	0.85
CNN+KNN	0.90	0.90	0.90	0.90

Tableau 6. Comparaison de nos résultats obtenus.

Les résultats obtenus en utilisant différents modèles pour la classification des périodes d'apnée démontrent clairement l'impact significatif de l'approche combinée CNN-KNN. Lorsque le KNN est utilisé seul, la précision atteint 77,76%, ce qui indique une performance modérée dans la classification des périodes d'apnée. En revanche, l'utilisation du CNN seul améliore considérablement la précision à 89,16%, montrant la capacité du modèle CNN à extraire des caractéristiques pertinentes des données d'entrée.

Cependant, l'ajout de la méthode KNN pour tirer parti des prédictions du CNN entraîne une amélioration supplémentaire de la précision, qui atteint désormais 90,30%. Cela met en évidence le fait que le KNN peut jouer un rôle crucial dans l'optimisation des résultats du CNN en exploitant les caractéristiques extraites par ce dernier pour une meilleure classification. Cette approche hybride combine les forces des deux modèles, capitalisant sur la capacité du CNN à apprendre des représentations complexes et sur la simplicité et la flexibilité du KNN dans la classification.

En conclusion, l'approche combinée CNN-KNN se révèle être la plus performante, avec une précision de 90,30%, dépassant à la fois les performances du KNN seul et du CNN seul. Cela souligne l'importance de l'intégration de différentes techniques de modélisation pour obtenir des résultats optimaux dans des tâches de classification complexes telles que la détection des périodes d'apnée dans les données d'ECG.

4.10. Comparaison entre nos résultats et les résultats des travaux relatifs

En comparant nos résultats avec les travaux relatifs présentés dans le tableau suivant, il est évident que notre approche combine « CNN-KNN » se fait une place respectable parmi les méthodes précédemment étudiées en termes de précision de classification des périodes d'apnée. Cette combinaison de modèles permet d'exploiter efficacement les caractéristiques extraites par le CNN pour améliorer la capacité de classification du KNN. Ainsi, notre approche offre une solution prometteuse et compétitive dans le domaine de la détection des apnées dans les données d'ECG.

Etude & Méthode	Précision
Etude 1 : CNN	97,1%
Etude 2 : CNN	94%
Etude 5 : CNN 1D	97,1%
Notre étude : CNN	89,16%
Etude 1 : KNN	82,9%
Notre étude : KNN	77,76%
Etude 3 : TW-MLP	87,3%
Etude 4 : SE-ResNext 50	90,28%
Notre étude : CNN+KNN	90,30%

Tableau 7. Comparaison avec les travaux relatifs.

Le tableau n°7 montre que nos résultats de précision avec le CNN et le KNN se situent respectivement autour de 89,16% et 77,76%, ce qui est comparable à plusieurs études antérieures. Par exemple, l'étude 1 a obtenu une précision de 97,1% avec le CNN, tandis que l'étude 1 avec le KNN a atteint 82,9%. Notre étude se situe dans des plages de précision similaires à ces travaux antérieurs, ce qui confirme la qualité de nos résultats. Cependant, ce qui distingue notre approche, c'est l'utilisation de la combinaison CNN-KNN, où nous avons atteint une précision de 90,30%. À notre connaissance, c'est la première fois qu'une telle approche est appliquée à la classification des données ECG d'apnée du sommeil, ce qui témoigne de l'originalité et de l'efficacité de notre méthode. En conséquence, nos résultats démontrent la valeur de la combinaison des modèles CNN et KNN pour améliorer significativement les performances de classification dans ce domaine spécifique.

4.11. Conclusion

Dans ce chapitre, nous avons présenté notre approche utilisant les réseaux de neurones convolutifs (CNN) pour la détection de l'apnée du sommeil. Afin d'améliorer la précision de cette méthode, nous avons intégré l'algorithme des k plus proches voisins (KNN).

Les résultats obtenus avec le modèle CNN seul se sont révélés prometteurs. L'introduction de l'algorithme KNN, spécifiquement avec $k=21$, a conduit à une amélioration significative des performances du modèle, confirmant ainsi l'efficacité de notre approche hybride.

Conclusion et Perspectives

Ce mémoire de fin d'études s'est consacré au développement d'un modèle innovant de détection de l'apnée du sommeil basé sur l'analyse des signaux électrocardiographiques (ECG). L'apnée du sommeil, un trouble caractérisé par des interruptions répétées de la respiration pendant le sommeil, présente des risques sérieux pour la santé, incluant des complications cardiovasculaires, de l'hypertension et une diminution générale de la qualité de vie. La détection précoce et précise de cette condition est donc cruciale pour assurer une prise en charge efficace et prévenir ses conséquences néfastes.

Notre projet a débuté par une exploration approfondie de l'état de l'art, mettant en lumière les méthodes existantes de détection de l'apnée du sommeil et les limitations de celles-ci. Nous avons identifié le potentiel des techniques d'apprentissage automatique, en particulier les réseaux de neurones convolutifs (CNN) et l'algorithme des k plus proches voisins (KNN), pour surmonter ces défis.

La réalisation de ce travail n'a pas été sans difficultés. La collecte et le prétraitement des données ECG, l'optimisation des hyperparamètres des modèles CNN et KNN, ainsi que la mise en œuvre de la combinaison CNN-KNN ont représenté des défis techniques significatifs. Malgré ces obstacles, l'expérience acquise a été inestimable, nous permettant de développer des compétences avancées en traitement du signal et en apprentissage automatique. Nous avons également renforcé notre capacité à résoudre des problèmes complexes et à innover dans le domaine de la santé.

La solution proposée combine la puissance de traitement des CNN avec la simplicité et l'efficacité des KNN. Les résultats expérimentaux obtenus montrent que notre modèle combine CNN-KNN atteint une précision de 90,30%, surpassant les performances des modèles CNN seuls (89,16%) et KNN seuls (77,76%). Cette approche combine améliore significativement la précision de la classification des événements apnéiques, démontrant son potentiel pour une application clinique.

Les atouts de notre travail résident dans l'intégration réussie de techniques avancées d'apprentissage automatique pour offrir une solution non invasive et efficace à la détection de l'apnée du sommeil. Cependant, comme tout projet de recherche, notre travail comporte des limites. Par exemple, notre modèle pourrait bénéficier d'une plus grande diversité de données pour améliorer sa robustesse et sa généralisation à d'autres populations.

En termes de perspectives, plusieurs axes d'amélioration et d'extension peuvent être envisagés. L'un des principaux axes est l'intégration de données supplémentaires, telles que les signaux de respiration ou les mouvements corporels, pour enrichir l'analyse et améliorer la précision du modèle. De plus, l'application de techniques d'apprentissage profond plus avancées, comme les réseaux de neurones récurrents (RNN) ou les réseaux de neurones à attention, pourrait offrir des améliorations supplémentaires. L'exploration de l'apprentissage fédéré pourrait également permettre d'entraîner des modèles plus robustes tout en préservant la confidentialité des données des patients.

Enfin, notre travail ouvre de nouvelles voies de recherche dans l'application de l'apprentissage automatique pour le diagnostic et la gestion des troubles du sommeil. Ces recherches pourraient non seulement améliorer la détection de l'apnée du sommeil, mais aussi contribuer à la gestion d'autres troubles respiratoires et cardiovasculaires, offrant ainsi des solutions de santé plus complètes et personnalisées.

En conclusion, ce mémoire représente une petite avancée dans la détection de l'apnée du sommeil, démontrant le potentiel des techniques d'apprentissage automatique pour transformer la pratique clinique et améliorer la qualité de vie des patients. Les perspectives futures promettent des développements encore plus innovants et efficaces, soulignant l'importance continue de la recherche et de l'innovation dans le domaine de la santé.

Références Bibliographiques

- [1] Abeer A, Ibtesam M, Alaa Soliman, Samy S, Potato Classification Using Deep Learning, International Journal of Academic Pedagogical Research (IJAPR), Al-Azhar University, Gaza, Palestine, 2019.[Consulté le 16/02/2024]
- [2] Alexandre A, Rafael S, La prise en charge nutritionnelle peut-elle améliorer la qualité du sommeil chez les adultes souffrant d'apnée du sommeil ? Haute école de santé de Genève, Juillet 2023. [Consulté le 30/01/2024]
- [3] Anirudha Ghosh, Abu Sufian, Farhana Sultana, Amlan Chakrabarti, Debashis De, Fundamental Concepts of Convolutional Neural Network, 2020. [Consulté le 16/02/2024]
- [4] Goodfellow, I., Bengio, Y., and Courville, A. (2016). Deep learning. Chapter 8: Optimization for Training Deep Models. [Consulté le 06/05/2024].
- [5] HAO G, YU W, SHENG H, and GUAN G, (Senior Member, IEEE), Blind Channel Identification Aided Generalized Automatic Modulation Recognition based on Deep Learning, Nanjing University of Posts and Telecommunications, China, 2019. [Consulté le 16/02/2024].
- [6] Hugues G, Analyse de filtres numériques, Université de lorraine. [Consulté le 06/05/2024].
- [7] Hung-Yu Chang, Cheng-Yu Yeh, Chung-Te Lee and Chun-Cheng Lin, 2020 (A Sleep Apnea Detection System Based on a One-Dimensional Deep Convolution Neural Network Model Using Single-Lead Electrocardiogram), doi:10.3390, s20154157. [Consulté le 06/02/2024].
- [8] Iqbal H. Sarker, Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions, 2021. [Consulté le 17/02/2024]
- [9] Julie Vicat, Syndrome d'apnées du sommeil, médicaments du système nerveux central : rôle du pharmacien d'officine, Sciences pharmaceutiques, 2016. [Consulté le 09/02/2024].

- [10] Kamal Omari, Étude comparative des algorithmes d'apprentissage automatique pour la détection de sites Web de phishing, IJACSA, Université Hassan II. Casablanca, Marocco, 2023. [Consulté le 17/02/2024].
- [11] Kingman P. Strohl, Apnée obstructive du sommeil, Case Western Reserve University, 2022. [En ligne ; consulté le 11/02/2024].
- [12] Laurie Masse, Intérêt du dépistage du syndrome d'apnées du sommeil chez les malades rénaux chroniques, UNIVERSITE DE LA REUNION U.F.R Santé, 2019. [Consulté le 11/02/2024].
- [13] Lazhar Manai, Radhia Bouzid, Analyse et classification des signaux ECG sous MATLAB et implémentation d'une solution embarquée, université El Manat, Tunis. [Consulté le 22/04/2024]
- [14] Maria P Bonomini, Pedro D Arini, Germán E Gonzalez, Bruno Buchholz, Max E Valentinuzzi, The allometric model in chronic myocardial infarction, Université de Buenos Aires, Argentina. [Consulté le 02/02/2024].
- [15] Nguyen A, Nguyen T, Le H, Pham H et Do C. 2022 (A novel deep learning-based approach for sleep apnea detection using single-lead ECG signals), arXiv:2208.03408v2. [Consulté le 02/02/2024].
- [16] Pan, J., Tompkins, W. J. (1985). "A real-time QRS detection algorithm." IEEE Transactions on Biomedical Engineering. [Consulté le 06/05/2024].
- [17] Purwono, Alfian Ma'arif, Wahyu Rahmaniar, Haris Imam, Karim Fathurrahman, Aufaclav Zatu Kusuma Frisky, Qazi Mazhar ul Haq, Understanding of Convolutional Neural Network (CNN): A, International Journal of Robotics and Control Systems, 2022. [Consulté le 16/02/2024].
- [18] Raoua B, Sébastien B, Renaud T, Marie J, Jean-Louis P, Laboratoire hypoxie et physiopathologies cardiovasculaires et respiratoires (HP2), Inserm U1300, université Grenoble Alpes, Grenoble, France, 30 November 2023. [Consulté le 02/02/2024]
- [19] Shraya B, Subhanki S, Trishita D, Debrupa P, PYTHON PROGRAMMING LANGUAGE AND ITS SCOPE IN FUTURE, Narula Institute of Technology, India, 2022. [Consulté le 13/03/2024].
- [20] SOMMEIL UN CARNET POUR MIEUX COMPRENDRE, Institut National du Sommeil et de la Vigilance, France, 2010. [Consulté le 09/02/2024].

- [21] Tao Wang, Changhua Lu, Guohao Shen 2019 (Detection of Sleep Apnea from Single-Lead ECG Signal Using a Time Window Artificial Neural Network). [Consulté le 02/02/2024].
- [22] Tao W, Changhua L, Guohao S, Feng H, Sleep apnea detection from a single-lead ECG signal with automatic feature-extraction through a modified LeNet-5 convolutional neural network, Academic editor Dennis Lau, 2019. [Consulté le 17/03/2024].
- [23] Yannick GOTTWALLES, L'E.C.G. pour les nuls, Directeur Médical de Pôle, Hôpitaux Civils de Colmar, 2008. [Consulté le 16/03/2024].
- [24] Yunxiang Bai, Luqiao Zhang, Dechao Wan, Yu Xie, Hanghang Deng 2021, (Detection of sleep apnea syndrome by CNN based on ECG), Journal of Physics: Conference Series 1757: 012043. [Consulté le 02/02/2024].

Références Web

- [W1] Apnée du sommeil, <https://www.elsan.care/fr/pathologie-et-traitement/maladies-generale/apnee-du-sommeil-causes-traitements>. [En ligne ; consulté le 27/01/2024].
- [W2] Chollet, F. and Team, K. (2021). Keras documentation : Optimizers. <https://keras.io/api/>. [Consulté le 06/05/2024].
- [W3] COMPRENDRE L'APNÉE DU SOMMEIL, <https://www.mutuelle-entrain.fr/content/comprendre-l%E2%80%99apn%C3%A9e-du-sommeil> . [En ligne ; consulté le 27/01/2024]..
- [W4] Examens du sommeil, Plateforme d'analyse de données médicales Polygraphie & Polysomnographie, <https://www.evasommeil.com/24-la-polysomnographie-psg> . [En ligne ; consulté le 02/02/2024].
- [W5] Formation de réseaux de neurones profonds. <https://towardsdatascience.com/training-deep-neural-networks-9fdb1964b964>, 2018. [En ligne ; consulté le 03/02/2024].
- [W6] Georges M, Roger M. Détection et quantification de l'apnée sur la base de l'ECG : The PhysioNet/Computing in Cardiology Challenge 2000. <https://physionet.org/content/challenge-2000/1.0.0/>. [En ligne ; consulté le 22/04/2024].
- [W7] Institut de télécommunications, 2015-2018. <https://biosppy.readthedocs.io/en/stable/>. [Consulté le 21/04/2024].
- [W8] L'importance du sommeil : dormez une heure de plus !, Sorbonne université (siège), France, <https://www.sorbonne-universite.fr/dossiers/sommeil/limportance-du-sommeil-dormez-une-heure-de-plus>. [En ligne ; consulté le 09/02/2024].
- [W9] Optimisation Adam, https://datafranca.org/wiki/Optimisation_Adam#:~:text=D%C3%A9finition,moments%20des%20gradients%20sont%20utilisés. [Consulté le 06/05/2024].
- [W10] Raphael Kassel, Keras : tout savoir sur l'API de Deep Learning, 2021. <https://datascientest.com/keras>. [Consulté le 21/04/2024].
- [W11] Raphael Kassel, NumPy : la bibliothèque Python la plus utilisée en Data Science, 2021. <https://datascientest.com/numpy>. [Consulté le 21/04/2024].

- [W12] Raphael Kassel, SciPy : tout savoir sur la bibliothèque Python de Machine Learning, 2022. <https://datascientest.com/scipy>. [Consulté le 21/04/2024].
- [W13] Sommeil : qu'est-ce que c'est ?. <https://www.futura-sciences.com/sante/definitions/biologie-sommeil-13340/>. [Consulté le 09/02/2024].
- [W14] TensorFlow, <https://www.databricks.com/fr/glossary/tensorflow-guide>. [Consulté le 09 /05/2024].
- [W15] <https://www.cardiosecur.com/fr/magazine/articles-specialises/systemes-de-derivation-ecg>. [Consulté le 11/02/2024].
- [W16] https://www.researchgate.net/figure/Representation-dun-signal-ECG-type_fig1_313664183. [Consulté le 22/04/2024].
- [W17] <https://www.lesnumeriques.com/telecharger/visual-studio-code-vscode-53512> . [Consulté le 08/05/2024].
- [W18] <https://www.hwlibre.com/fr/colaboratoire-google/> . [Consulté le 08/05/2024].
- [W19] <https://www.python.org/community/logos/> . [Consulté le 02/02/2024].
- [W20] https://fr.m.wikibooks.org/wiki/Fichier:Bandform_template.svg. [Consulté le 02/02/2024].
- [W21] <https://code.visualstudio.com/docs>. [Consulté le 28/04/2024].
- [W22] <https://research.google.com/colaboratory/faq.html?hl=fr>. [Consulté le 09/05/2024].
- [W23] <https://docs.python.org/3/library/pickle.html>. [Consulté le 21/04/2024].
- [W24] <https://docs.python.org/fr/3/library/sys.html>. [Consulté le 21/04/2024].
- [W25] <https://docs.python.org/fr/3/library/os.html>. [Consulté le 21/04/2024].
- [W26] <https://docs.python.org/3/library/concurrent.futures.html>. [Consulté le 21/04/2024].
- [W27] <https://archive.physionet.org/physiotools/wfdb.shtml>. [Consulté le 21/04/2024].
- [W28] <https://pypi.org/project/tqdm/>. [Consulté le 21/04/2024].
- [W29] https://scikit-learn.org/stable/getting_started.html. [Consulté le 21/04/2024].
- [W30] <https://manual.dewesoft.com/fr/fr/x/setupmodule/modules/general/math/filters/math-firfilter#Window> . [Consulté le 06/05/2024].
- [W31] https://imbalanced-learn.org/stable/over_sampling.html#random-over-sampler . [Consulté le 06/05/2024].

- [W32] <https://pypi.org/project/imbalanced-learn/> . [Consulté le 23/05/2024].
- [W33] <https://datascientest.com/matplotlib-tout-savoir> . [Consulté le 23/05/2024].
- [W34] <https://datascientest.com/seaborn-tout-savoir> . [Consulté le 23/05/2024].

