



جامعة العربي التبسي - تبسة
Université Larbi Tébessi - Tébessa

République Algérienne Démocratique et
Populaire
Ministère de l'enseignement supérieur et de la
recherche scientifique



Université Echahid Cheikh Larbi Tébessi - Tébessa
Faculté des Sciences Exactes et des Sciences de la Nature et de la Vie
Département : Mathématiques et Informatique

Mémoire de fin d'étude
Pour l'obtention du diplôme de **MASTER**
Domaine : Mathématiques et Informatique
Filière : Informatique
Option : Systèmes d'information

Thème

Classification of Normal /Abnormal Heart Sound Recordings

Présenté Par
Aoun Fatima & Zerifi Razika

Devant le jury

Dr. Achouri Mounir	MCB	Université Echahid Cheikh Larbi Tébessi	Président
Dr. Abdelhakim Gharbi	MAA	Université Echahid Cheikh Larbi Tébessi	Examineur
Dr. Issam BENDIB	MCA	Université Echahid Cheikh Larbi Tébessi	Encadreur
Dr. Mohamed Yassine Haouam	MCA	Université Echahid Cheikh Larbi Tébessi	Co-encadreur

Date de soutenance : 09/06 /2024

REMERCIEMENT

Nous remercions **Allah** qui nous a donné la force, le courage et la patience pour élaborer ce travail. Nous tenons à exprimer notre profonde gratitude à :

Notre encadrant, **M. Bendib Issam**, pour sa présence morale et physique tout au long de notre travail. Ses précieux conseils et commentaires nous ont été d'une grande aide. Sa disponibilité et ses encouragements nous ont permis de mener à bien ce travail.

M. Mohamed Yassine Haouam, merci de nous avoir donné confiance et courage pour compléter notre mémoire. Merci également de nous avoir consacré de votre temps.

Nous exprimons aussi nos vifs remerciements aux membres du jury, **Dr. Abdelhakim Gharbi** et **Dr. Achouri Mounir**, d'avoir accepté d'évaluer ce travail.

Nos profonds remerciements à tous les enseignants qui ont participé à notre formation tout au long de notre cursus.

À tous nos collègues et au personnel qui nous ont aidés durant nos pratiques.
Enfin, à notre famille pour son soutien tout au long de cette formation.

MERCI

شكر وعرفان

(وآخر دعوانهم أن الحمد لله رب العالمين)

ما سلكننا البدايات إلا بتيسيره وما بلغنا النهايات إلا بتوفيقه وما حققنا الغايات إلا بفضلته فالحمد لله الذي وفقنا لتتميم

هذه الخطوة في مسيرتنا الدراسية

إلى من علمني ان الدنيا كفاح... سلاحها العلم والمعرفة إلى الذي لم يبخل عني بأي شيء إلى من سعى لأجل راحتي ونجاحي

إلى أعظم و أعمز رجل في الضون أبي العزيز **زيرفي الحسين**

إلى تلك الحبيبة ذات القلب النقي إلى من أوصاني الرحمن بما وإحسانا إلى من تعبني وعانني من أجلي إلى من كان دعائها سر

نجاحي أمي الحبيبة زيرفي مليكة

إلى من أشاركهم لحظاتي...إلى من يفرحون لنجاحي وكأنه نجاحهم إلى من كانوا سندا ثابتا لا يميل... إلى نور المحبة في حياتي

أخي محمد القادر و هو علاء وأختي أمال وهسيناز وهيماء وزوجة أخي شريفة

إلى سكر العائلة والذين ل خاطر عيونهم أصبحت خالدة وعمة امين الله وهما صاب الدين ونزيه ومدين

إلى أصدقاء الخطوات الأولى إلى من كانوا في السنوات العجاف سحابة ممطرة

ظلود و أسماء و فاطمة و اسراء

بكل حب واحترام أهديكم ثمرة نجاحي وتخريبي



Zerifi Razika

شكر وعرفان

الحمد لله حبا وشكرا وامتنانا على البدء والختام ، وآخر دعواهم أن الحمد لله رب العالمين

بكل حب أهدي ثمرة نجاحي وتنرجي

إلى الذي زين اسمي بأجمل الألقاب من دعمني بلا حدود وأعطاني بلا مقابل داعمي الأول في مسيرتي وسندي وقوتي وملاذي بعد الله فخري واعتزازي والدي "عموم م" رحمه الله واسكنه فسيح جناته

إلى من جعل الله الجنة تحفة أقدامها واحتضني قلبها قبل يديها وسهل لي الشدائد بدعائها إلى القلب الحنون والشمعة التي كانت لي الليالي المظلمة ، سر قواي ونجاي جنتي والعتي

إلى خلعي الثابت وأمان أيامي ، إلى من شددت عضدي بهم فكانوا لي يذابح أرتوي منها....إلى خيرة أيامي وصفوتها إلى

قرة عيني اخواتي عموم ليليا وعموم حنان وعموم أظلم الغالين

إلى أساتذتي الكرام ممن لم يتوانوا في مد العون لنا ...يا من صنعتم لنا المجد

إلى رفقاتي الاتي استعيد بجوارهم كل مسراتي ، اليد القوية عندما تنهاني بينا الأيام ، أصحاب الشدائد والأزمات ، محفوا ، نور

ورفيقة العلم ورفيقة

إلى كل من أحبهم وإلى كل من يعرفني

اهدبكم هذا الإنجاز وثمره نجاحي الذي لطالما تمنيت ، فالحمد لله على ما وهبني ، وأن يعينني ويجعلني مباركة أينما كنت وأخيرا من قال " أنا لها " نالها ، وأنا لها وإن أبصر ربحا عنها أتيت بها

تذكر دائما أن الحياة تتطلب منا الشجاعة لنكون أنفسنا ، الشجاعة لنحلم وأكثر من ذلك ، الشجاعة لنحول تلك الأحلام إلى واقع ، فكن فخورا بما وصلت إلي



Aoun Fatima

Résumé

Dans ce projet, nous abordons le domaine médical lié au système cardiovasculaire et aux maladies cardiaques. Notre objectif est de développer une solution basée sur les techniques de l'intelligence artificielle, en particulier celles du Machine Learning, sous forme d'un système intelligent d'aide au diagnostic pour détecter les anomalies des battements cardiaques. En utilisant l'ensemble de données du 2016 PhysioNet/CinC Challenge. Pour cela nous appliquons des techniques d'extraction des caractéristiques temporelles des signaux PCG, Afin de former le modèle à reconnaître les bruits cardiaques, nous avons utilisé divers algorithmes tels que Random Forest, KNN et SVM. Les résultats obtenus sont très satisfaisants avec un score d'accuracy de 92% et démontrent l'efficacité et la fiabilité de notre système intelligent, qui vise d'être un outil d'aide de diagnostic pour les praticiens de la santé.

Mot clé: CAD, AI ,Machine Learning ,SVM ,Random Forest ,KNN,PCG; battements cardiaques

ملخص

في هذا المشروع، نتعامل مع المجال الطبي المتعلق بجهاز القلب والأوعية الدموية وأمراض القلب. هدفنا هو تطوير حل يعتمد على تقنيات الذكاء الاصطناعي، ولا سيما تقنيات التعلم الآلي، في شكل نظام ذكي للمساعدة في التشخيص للكشف عن تشوهات ضربات القلب باستخدام مجموعة بيانات تحدي PhysioNet/Cin2016، وللقيام بذلك نطبق تقنيات استخراج الميزات الزمنية على إشارات مخطط القلب الصوتي PCG، ومن أجل تدريب النموذج على التعرف على أصوات القلب، استخدمنا خوارزميات مختلفة مثل SVM و KNN و Random Forest. وكانت النتائج التي تم الحصول عليها مرضية للغاية حيث بلغت درجة الدقة 92%، وأظهرت فعالية وموثوقية نظامنا الذكي، الذي يهدف إلى أن يكون أداة مساعدة تشخيصية للممارسين الصحيين.

الكلمات المفتاحية: الذكاء الاصطناعي، التعلم الآلي، نبضات القلب، إشارات مخطط القلب الصوتي، SVM, KNN, CAD, Random Forest .

Abstract

In this project, we address the medical field related to the cardiovascular system and heart diseases. Our objective is to develop a solution based on artificial intelligence techniques, in particular those of Machine Learning, in the form of an intelligent diagnostic support system to detect heartbeat anomalies using the dataset of the 2016 PhysioNet/CinC Challenge. For this we apply techniques for extracting temporal characteristics from PCG signals. In order to train the model to recognize heart sounds, we used various algorithms such as Random Forest, KNN and SVM. The results obtained are very satisfactory with an accuracy score of 92% and demonstrate the effectiveness and reliability of our intelligent system, which aims to be a diagnostic aid tool for health practitioners.

Keyword: CAD, AI, Machine Learning, SVM, Random Forest, KNN, PCG; heartbeat

Table des matières

<i>Résumé</i>	i
<i>Abstract</i>	ii
ملخص.....	iii
Remercîments.....	iv
Dédicace	v
Table des matières	vi
Liste des figures	ix
Liste des tableaux.....	xi
Introduction générale.....	1
<i>Chapitre I : Le rythme cardiaque : Contexte et enjeux</i>	
1. Introduction	3
2. Le cœur humain.....	3
2.1 . Anatomie du cœur	4
2.2 . Principe de fonctionnement du cœur	4
3. Les éléments du cœur humain.....	5
3.1 . Les valves cardiaques	5
3.2 Les battements cardiaques	6
4. Les modalités de diagnostic des battements cardiaque	7
4.1. La phonocardiographie	7
4.2. L'électrocardiographe	8
5. Les sons des battements cardiaques	9
5.1. Le premier son S1	9
5.2. Le deuxième son S2.....	10
5.3. Le troisième son S3	10
5.4. Le quatrième son S4	10
6. Les battements de cœur pathologiques.....	10
6.1. Les souffles cardiaques.....	10

6.2. Les problèmes du rythme cardiaque	11
7. Conclusion.....	11

Chapitre II : L'IA pour la classification des battements cardiaques

1. Introduction	12
2. Architecture general d'un model de prediction in ML.....	12
2.1. Prétraitement des données et filtrage du signal PCG	12
2.2. La segmentation des battements cardiaques	13
2.2.1. La segmentation à base des Modèle Semi-Markovien Caché -HSMM	14
2.2.2. La segmentation à base de l'énergie du Shannon	14
2.2.3. La segmentation avec K-Means et ondelettes	15
2.2.4. La segmentation avec les réseaux récurrents convolutionnels.....	15
2.3. Extraction de caractéristiques	16
2.3.1. Les caractéristiques temporelles.....	16
2.3.2. Les caractéristiques fréquentielles.....	17
2.4. Les algorithmes de classification.....	18
2.4.1. Le classifieur <i>Random Forest</i>	18
2.4.2. Le classifieur SVM (Les Machines à Vecteurs de Support)	19
2.4.3. Le classifieur kNN (le plus proche voisin).....	20
2.4.4. Les réseaux de neurones ANN	21
3. Les métriques d'évaluation des systèmes d'aide de diagnostic (CADe)	21
3.1. Les métriques de performances	21
3.2. La matrice de confusion	22
4. Etude bibliographique sur les data Set des signaux PCG.....	23
4.1. La Data Set CinC '2016.....	23
4.2. La Data Set PASCAL Heart Sound Challenge (HSC) dataset	24
4.3. La Data Set Heart sound and Murmur Library	24
4.4. La Data Set CirCor DigiScope Phonocardiogram'2022.....	24
4.5. Synthèse sur les data set des battements cardiaques.....	24
5. Les travaux connexes sur la classification des battements cardiaques.....	25
6. Tableaux récapitulatif des travaux connexes	29
7. Synthèse	32
8. conclusion.....	32

Chapitre III : CADe: Identification of Normal and Abnormal Heart Sounds system

1.	Introduction	33
2.	Architecture du système proposé	33
3.	Description du data set utilisée.....	33
3.1.	Vue global du dataset	34
3.2.	Description du dataset après la segmentation et validation manuelle	34
3.3.	Description du dataset après réduction des enregistrements vides.....	35
3.4.	Fichiers d’annotation des signaux PCG des patients.....	35
4.	L’étape de segmentation.....	36
4.1.	Fichiers de segmentation	36
4.2.	Résultat de la segmentation	37
5.	Extraction de caractéristiques.....	38
6.	Résultats et discussion.....	40
6.1.	Le protocole de test utilisé.....	40
6.2.	Les hyperparamètres des algorithmes de classification utilisés	41
6.3.	Résultats de classification obtenus de classifier	42
6.3.1.	Le classifieur Random Forest.....	42
6.3.2.	Le classifieur SVM.....	43
6.3.3.	Le classifieur Ensemble Classifier	43
6.3.4.	L’algorithme de KNN	43
7.	Discussions.....	44
7.1.	Le model de prédiction retenue	44
7.2.	Les performances du model retenu.....	44
7.3.	Comparaison avec les Travaux existants.....	45
8.	Conclusion.....	46

Liste des Figures

Figure.1.1 : Le cœur se situe dans le médiastin antérieur	3
Figure.1.2 : Anatomie du cœur humain	4
Figure.1.3: principe de fonctionnement du cœur.....	5
Figure.1.4 : Schéma illustratif des Valves cardiaques	6
Figure.1.5: un exemple de tracé d'un signal PCG.....	8
Figure.1.6: Les dérivations précordiales unipolaires	9
Figure.1.7: les activités cardiaques avec les différents signaux correspondants mesurés : ECG, PCG, Echo	9
Figure.2.1: Architecture d'un system de prédiction.....	12
Figure.2.2: Exemple de Filtrage des bruits cardiaques avec les filtres numériques Butterworth, Chebyshev et Elliptic.....	13
Figure.2.3 : Signal PCG et quatre états du cycle cardiaque	14
Figure.2.4: Les techniques de segmentation : HSMM, DRNN, durée-LSTM, et CLSTM....	15
Figure.2.5: Exemple de la façon d'analyser un signal PCG segmenté pour l'extraction de caractéristiques dans le domaine temporel.....	16
Figure.2.6: Exemple d'un spectrogramme d'un signal PCG.....	17
Figure.2.7: Exemple des caractéristiques MFCC d'un signal PCG normal, MFCC d'un signal PCG avec murmure.....	17
Figure.2.8 : Exemple des caractéristiques Mel-scaled power spectrogram d'un signal PCG normal, Mel-scaled power spectrogram d'un signal PCG avec murmures.....	18
Figure.2.9: Principe du classifieur Random Forest.....	19
Figure 2.10: Principe du classifieur SVM.....	20

Figure.2.11 :Principe du classifieur Knn.....	20
Figure 2.12 :Architecture des classifieurs ANN	21
Figure.2.13 : Les quatre valeurs essentielles de la matrice de confusion.....	22
Figure.3.1 : Architecture du système Proposé de signaux PCG pour la classification des battements cardiaques	33
Figure.3.2 : Exemple d’annotation d’un fichier qui contient des segments incertains.....	35
Figure.3.3 : Le fichiers CSV.....	35
Figure.3.4 :Exemple de stratégie d’annotation des segments.....	36
Figure.3.5 :Exemple d’un fichier d’annotation du signal PCG.....	36
Figure 3.6 :Les résultats de la segmentation du signal PCG par la méthode HSMM sur une partie de l'enregistrement « a0011 » existant dans la base de données du challenge Physio net 2016.....	37
Figure.3.7 : les différent type de Asymétrie.....	39
Figure.3.8 : les différent type de Aplatissement.....	40
Figure.3.9 : Répartissions des classes de la Dataset utilisée.....	41
Figure.3.10 : La matrice de confusion du CADe : Identification of Normal and Abnormal Heart Sounds System.....	45

Liste des Tableaux

Tableau 2.1: Un résumé des Data Set des battements cardiaques-PCG.....	24
Tableau 2.2: Tableaux récapitulatif des travaux réalisés pour la détection des anormalités des sons cardiaques.....	29
Tableau 3.1: PhysioNet/CinC Challenge dataset.....	34
Tableau 3.2: Dataset après segmentation et validation manuelle.....	34
Tableau 3.3: Description du dataset après réduction des enregistrements incertains (zéro battement).....	35
Tableau 3.4: Les résultats de la segmentation du signal PCG pour chaque répertoire	37
Tableau 3.5: le protocole de test utilisé	41
Tableau 3.6: Résultats obtenus par le classifieur Random Forest	42
Tableau 3.7: Résultats obtenus par le classifieur SVM.....	43
Tableau 3.8: Résultats obtenus par le classifieur Ensemble Classifier	43
Tableau 3.9: Résultats obtenus par le classifieur Ensemble KNN	43
Tableau 3.10: Un tableau comparaison entre les résultats obtenus et quelques travaux existants	45

Liste des Abréviations

Liste des Abréviations

ECG : Electrocardiogramme

CAD : *Computer Aided Diagnosis*

PCG : Le Phono cardiogramme

AI : Artificial Intelligence.

SVM : Support Vector Machine

KNN : k-Nearest Neighbors

ANN : Artificial Neural Network.

MFCC : Mel-Frequency Cepstral Coefficients

VG : Ventricule gauche

VD : Ventricule droit

HSMM : Hidden Semi-Markov Models

CLSTM : Convolutional long short-term memory

LSTM : Long Short-Term Memory

INTRODUCTION GÉNÉRALE

Introduction générale

Les maladies cardiovasculaires sont les principales causes de décès dans le monde et font environ 17,9 millions de morts chaque année¹. En effet, le cœur est l'organe vital du corps humain, il est responsable de la circulation sanguine et de l'acheminement de l'oxygène et des nutriments vers les autres organes. Selon l'Organisation mondiale de la santé, les maladies cardiovasculaires sont parmi les principales causes de décès mondiales. De point de vue pratique, phonocardiogramme (PCG) et l'électrocardiogramme (ECG) sont les modalités les plus utilisées pour le diagnostic de ces pathologies. Ils sont faciles à utiliser et moins coûteux et permettant d'analyser les signaux cardiaques pour une bonne interprétation du fonctionnement du cœur.

En effet, l'interprétation des signaux cardiaques est complexe, nécessitant une compréhension approfondie de l'anatomie cardiovasculaire et les pathologies associées. L'interprétation précise des enregistrements PCG et l'analyse des bruits cardiaques requiert une bonne expertise significative des praticiens. Dans ce contexte, les techniques de l'intelligence artificielle (IA) offrent une solution prometteuse pour ces défis par le biais des systèmes d'aide de diagnostic (CAD : *Computer Aided Diagnosis*) intelligent. Actuellement, l'utilisation des stéthoscopes numériques, combinés avec les systèmes d'IA, présente une opportunité prometteuse pour offrir une assistance fiable pour les médecins dans le diagnostic des pathologies cardiovasculaires. En plus, les stéthoscopes numériques peuvent enregistrer et numériser les sons cardiaques, offrant une qualité sonore supérieure et la possibilité de stocker et de partager les enregistrements pour une analyse ultérieure.

Cependant, afin de réduire les risques associés aux diagnostics de maladies cardiovasculaires, des méthodes innovantes ont été développées pour créer des systèmes CAD capables de distinguer les bruits cardiaques normaux et anormaux avec des taux de précisions fiables. Dans ce contexte, notre problématique est de développer une solution à base des techniques de l'intelligence artificielle et précisément celles de *Machine Learning* sous forme d'un système intelligent d'aide de diagnostic pour détecter les anomalies cardiaques à partir des signaux PCG. Notre projet de fin d'études est développé sur les problématiques suivantes :

¹ https://www.who.int/fr/health-topics/cardiovascular-diseases#tab=tab_1

- ✓ Quelles caractéristiques seront utilisées pour représenter mieux le signal PCG.
- ✓ Comment repérer les différentes sections critiques d'un abatement cardiaque dans un signal PCG.
- ✓ Quels sont les algorithmes de classification les plus adaptés pour ce type de signaux.

Afin de répondre aux différents enjeux de cette problématique, nous avons organisé ce manuscrit comme suit :

Dans le premier chapitre, nous abordons les fondements de bases du système cardiaque en incluant l'anatomie du cœur, ainsi que certains examens et modalités utilisées pour le diagnostic des pathologies cardiaques comme l'ECG et de la phonocardiographie – PCG.

Pour le deuxième chapitre nous introduisons une introduction sur les techniques d'intelligence artificielle qui peuvent être utilisées dans notre contexte. Il présente également une étude sur les Data set du PCG existantes ainsi que les métriques d'évaluation utilisées pour les tâches de classification. Aussi, nous dressons une étude bibliographique sur les travaux réalisés dans la détection des anomalies dans les signaux PCG. Nous terminons ce chapitre par un tableau de synthèse.

Tandis que, dans le troisième chapitre, nous présentons notre solution en précisant la conception et la mise en œuvre de notre système intelligent de détection des anomalies cardiaques. Nous présentons la méthodologie utilisée, le Data Set et le protocole de test utilisé, ainsi que les résultats obtenus. Nous discutons également les résultats obtenus des différents algorithmes de Machine Learning utilisés. Nous terminons ce manuscrit par une conclusion générale et les perspectives futures.

CHAPITRE I

Le rythme cardiaque : Contexte et enjeux

1. Introduction

La cardiologie est l'étude des affections du cœur et de certaines parties du système circulatoire dans le domaine médical. Ce domaine couvre le diagnostic médical et le traitement de certaines pathologies comme les maladies coronariennes, insuffisance cardiaque, cardiopathies valvulaires et cardiopathies congénitales. Dans ce contexte, l'examen de l'ECG (ElectroCardioGramme) est l'un des outils les plus importants dans ce domaine. Les cardiologues doivent étudier les électrocardiogrammes pour prendre des décisions vitales concernant les patients. Les bruits cardiaques sont représentés par des signaux Phono Cardiogrammes (PCG). L'analyse de ces signaux est basée sur la segmentation, qui constitue le premier et le plus important processus de diagnostic automatique des bruits cardiaques. Le PCG est synchronisé avec l'ECG et peut-être ausculté avec un stéthoscope. L'analyse automatisée des ECG et des PCG est un excellent outil pour la cardiologie en raison de sa plus grande efficacité, précision et rapidité.

2. Le cœur humain

Le cœur, organe musculaire d'environ 250 grammes, situé dans la partie médiane de la cage thoracique (le médiastin) délimité latéralement par les deux poumons, en avant le sternum et en arrière par la colonne vertébrale [1]. La figure 1.1 présente la position du cœur dans le corps humain.

De point de vue morphologique, le cœur mesure entre 14 et 16 cm pour un diamètre de 12 à 14 cm chez l'adulte et d'un volume de 50 à 60 cm³, un peu plus gros chez l'homme que chez la femme . [1]

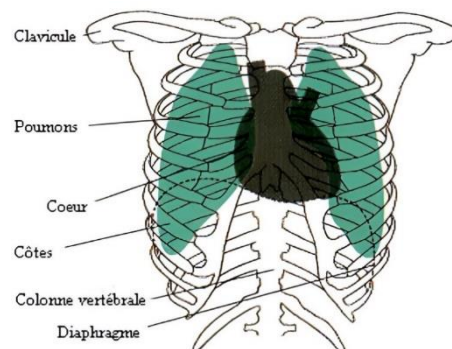


Figure.1.1: Le cœur se situe dans le médiastin antérieur [1]

2.1. Anatomie du cœur

Le cœur est situé dans la cage thoracique, derrière le sternum, est entouré d'une enveloppe, le péricarde. Il se compose de deux couches : une qui s'attache au muscle cardiaque, au myocarde, et une autre qui attache de manière stable le cœur aux poumons et au diaphragme. Le cœur divisé en quatre cavités : deux oreillettes (ou atriums) et deux ventricules. Les oreillettes se situent dans la partie supérieure du cœur, ce sont des cavités de réception du sang veineux [2]. Les ventricules sont le point de départ de la circulation sanguine dans la partie inférieure du cœur.

Au sein du cœur, quatre valves cardiaques permettent au sang de circuler dans un seul sens. Chaque oreillette communique avec le ventricule correspondant par l'intermédiaire d'une valve, la valve tricuspide à droite ; la valve mitrale à gauche comme la montre la figure 1.2. Entre les ventricules et l'artère correspondante se trouvent les deux autres valves : la valve aortique et la valve pulmonaire. [2]




Figure.1.2 : Anatomie du cœur humain [3]

2.2. Principe de fonctionnement du cœur

Le cœur est un organe merveilleux, il se contracte et se dilate afin de faire circuler le sang dans le corps. À chaque fois que le cœur bat, il évacue du sang dans les artères. Dans un premier temps, l'oreillette droite se regorge de sang à faible oxygène issu du certain organe du corps comme les muscles, le cerveau et même le cœur lui-même. Lorsque l'oreillette est pleine, elle se contracte. La valvule tricuspide qui relie l'oreillette droite au ventricule droit s'ouvre lors de la contraction.

Ainsi, le sang pénètre dans le ventricule droit. Quand le ventricule droit est rempli, il se contracte lui aussi pour faire pénétrer le sang dans les poumons par la valvule pulmonaire.

Ensuite, lorsque l'oreillette gauche se contracte, la valvule mitrale reliant cette dernière au ventricule gauche s'ouvre. Ainsi, le sang pénètre dans ce ventricule.

En fin, le ventricule gauche refoule le sang oxygéné par la valvule aortique vers l'aorte, qui alimente le reste du corps cœur. Cette magie de fonctionnement permet au sang rempli d'oxygène se circule dans tout le corps [4]. Ce processus est illustre par la figure 1.3.




Figure .1.3 :principe de fonctionnement du cœur [4]

3. Les éléments du cœur humain

Le cœur humain est composé de plusieurs parties, nous intéressons dans cette section sur les parties concernées par le processus du battement du cœur et son éventuel dysfonctionnement.

3.1. Les valves cardiaques

- ✓ Les valves cardiaques séparent les oreillettes des ventricules, et les ventricules des gros vaisseaux. Ces valves comprennent deux ou trois feuillets ou cuspidés autour des orifices atrioventriculaires et racines des gros vaisseaux [5]. En effet, il existe deux catégories de valves : atrioventriculaire et semilunaire.
- ✓ **La valve atrioventriculaire droite** se trouve entre l'oreillette droite et le ventricule droit. Elle est composée de trois feuillets antérieur/antérosupérieur, septal et postérieur/inférieur.
- ✓ **La valve atrioventriculaire gauche** est aussi appelée la valve mitrale, puisqu'elle ne possède que deux cuspidés et ressemble ainsi à une mitre. Elle est située entre l'oreillette gauche et le ventricule gauche et est formée de deux feuillets antérieur/aortique et postérieur/murale. [5]
- ✓ **La valve semilunaire pulmonaire** se trouve entre le ventricule droit et l'orifice du tronc pulmonaire. Trois feuillets sont présents : antérieur/non-adjacent, gauche/gauche adjacent et droit/droit adjacent.
- ✓ **La valve semilunaire aortique** se trouve entre le ventricule gauche et l'orifice de l'aorte. Elle contient trois feuillets semilunaires : gauche/gauche coronaire, droit/droit coronaire et postérieur/non coronaire. [5]

En effet, dans la pratique clinique, il est possible d'ausculter les valves du cœur, généralement à l'aide d'un stéthoscope. La figure 1.4 illustre ces valves, leurs positions et leurs principe de fonctionnement.




Figure.1.4:Schéma illustratif des Valves cardiaques [6]

3.2 Les battements cardiaques

Les battements cardiaques, ou contractions cardiaques, sont les mouvements rythmiques du cœur qui assurent la circulation du sang dans tout le corps. Chaque battement cardiaque est composé de deux phases principales : la systole et la diastole.

- ✓ **La systole** est la phase du cycle cardiaque où le cœur se contracte et pompe le sang. Au cours de la systole, les valves auriculo-ventriculaires se ferment, tandis que les valves aortique et pulmonaire s'ouvrent. Cela permet au sang d'être pompé des ventricules vers les artères pulmonaires et aorte. [7]
- ✓ **La diastole** est la phase du cycle cardiaque où le cœur se relâche et se remplit de sang. Au cours de la diastole, les valves auriculo-ventriculaires (mitrale et tricuspide) sont ouvertes, tandis que les valves aortique et pulmonaire sont fermées. Cela permet au sang de s'écouler des oreillettes vers les ventricules. [7]

Cependant, le rythme cardiaque normal, aussi appelé rythme sinusal, est d'environ 60 à 100 battements par minute au repos pour un adulte en bonne santé. Cependant, divers facteurs tels que l'activité physique, le stress, la maladie cardiaque ou d'autres conditions médicales peuvent affecter le rythme cardiaque. [8]

Les anomalies des battements cardiaques, telles que les arythmies, peuvent se manifester par des battements trop rapides (tachycardie), trop lents (bradycardie) ou irréguliers. Ces conditions peuvent être détectées et évaluées à l'aide de divers outils diagnostiques, tels que l'électrocardiogramme (ECG) et le Phonocardiogramme (PCG).

4. Les modalités de diagnostic des battements cardiaque

Il existe plusieurs standards d'examen utilisés pour le diagnostic des pathologies cardiaques. En effet, le stéthoscope est l'outil indispensable pour les médecins, il est utilisé pour la première phase de consultations mais ils font recours souvent aux autres examens comme l'ECG et l'échographie. Dans notre mémoire, nous intéressons seulement aux modalités liées étroitement pour la détection des anomalies dans les battements cardiaques.

4.1. La phonocardiographie

En effet, le stéthoscope est un outil essentiel en médecine. Inventé par René Laennec en 1816, il a révolutionné la pratique de l'auscultation, permettant aux médecins d'écouter directement les sons internes du corps, en particulier ceux du cœur et des poumons [9]. Au fil du temps, il a été amélioré avec l'ajout de membranes et de guides pour faciliter l'écoute de sons spécifiques. Ces améliorations ont permis une meilleure distinction des différents sons et une meilleure compréhension de ce qu'ils signifient en matière de santé du patient.

Avec l'avènement de la technologie des équipements médicaux, les stéthoscopes électroniques sont devenus de plus en plus courants. Ces appareils peuvent amplifier les sons, ce qui peut aider à détecter des anomalies qui pourraient être difficiles à entendre avec un stéthoscope acoustique traditionnel. De plus, certains stéthoscopes électroniques peuvent enregistrer et stocker les sons, ce qui permet aux médecins de les réécouter plus tard ou de les partager avec des collègues pour obtenir une deuxième opinion.

Le signal obtenu par le stéthoscope électronique est appelé le Phono cardiogramme (PCG). C'est un examen non invasif très précieux, souvent couplé à l'auscultation, permettant d'enregistrer les vibrations produites par les bruits cardiaques. Il se réalise en plaçant des électrodes sur la face antérieure du thorax pour capter les sons du cœur, y compris les sons normaux (S1, S2), les sons surajoutés et les souffles. Ce signal est composé de deux types de sons acoustiques : les sons du cœur et les murmures cardiaques. [10]

Le PCG est une technique de traçage des bruits cardiaques, il se concentre sur les bruits générés par la fermeture des valves cardiaques. Le signal sonore capté est converti en impulsions électriques pour être enregistré sur un tracé. Cet examen permet de préciser ce que le cardiologue détecte à l'oreille avec son stéthoscope. Les enregistrements de sons peuvent être évalués soit sur l'écran de papier (PCG) soit sur un ordinateur [11]. La figure 1.5 présente un exemple de tracé d'un signal PCG.

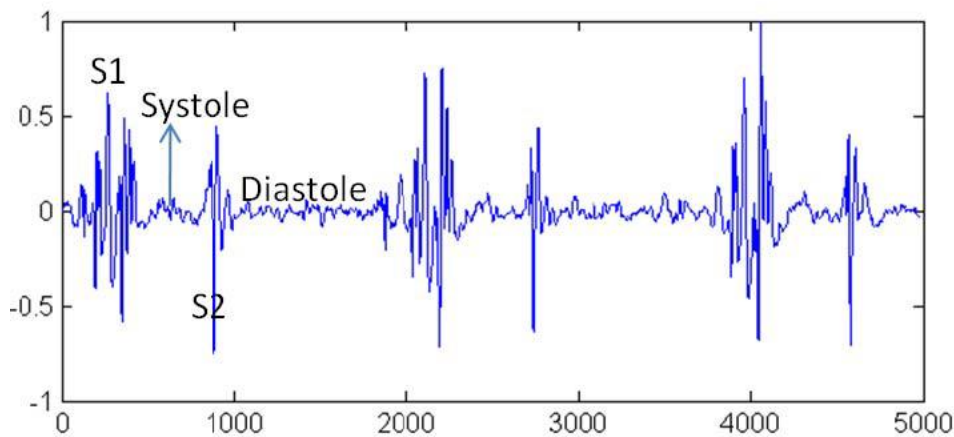


Figure.1.5: un exemple de tracé d'un signal PCG. [9]

4.2. L'électrocardiographie

L'ECG est en effet un outil précieux qui permet d'étudier le fonctionnement du cœur en enregistrant son activité électrique. Chaque battement cardiaque est déclenché par une impulsion électrique qui traverse le cœur, provoquant la contraction du muscle cardiaque et l'expulsion du sang. En effet, l'ECG est une représentation graphique de l'activité électrique du cœur sous la forme des tracés des signaux électriques. [12]

L'ECG peut aider à identifier diverses anomalies cardiaques, telles que les arythmies, l'ischémie myocardique (manque de sang vers le cœur) et les infarctus du myocarde (crises cardiaques). Il peut également aider à évaluer la fonction cardiaque chez les patients atteints de maladies cardiaques. L'ECG est un examen essentiel en cardiologie [13]. Il peut être recommandé dans de nombreux cas comme :

- ✓ Problèmes de battement cardiaque.
- ✓ Bilan médical avant une intervention chirurgicale .
- ✓ Palpitations ou douleurs à la poitrine.
- ✓ Urgences cardiaques.
- ✓ Suivi de l'activité cardiaque en cas de patients des maladies cardiopathies .

Entre temps, afin de réaliser cet examen, les praticiens de la santé utilisent des unipolaires précordiales. Elles sont placées près du cœur, en des points précis sur le thorax. Ces emplacements permettent d'obtenir les dérivations V1 à V6. Ces dérivations permettent de mesurer l'activité électrique du cœur sur le plan horizontal et donner une image complète de l'activité électrique du cœur et aider à diagnostiquer diverses conditions cardiaques. [14]

Ces emplacements des électrodes exploratrices schématisée dans la figure 1.6 sont les suivants :

- ✓ V1-V2 : situées près des oreillettes, du septum, du ventricule droit (VD) et de la paroi basale du ventricule gauche (VG).
- ✓ V3-V4 : situées à l'apex du cœur.

✓ V5-V6 : situées sur la paroi latérale du ventricule gauche (VG).




Figure.1.6: Les dérives précordiales unipolaires [14]

Nous pouvons schématiser les différents examens effectués par les praticiens et les spécialistes de la santé pour la détection des pathologies cardiaques par la figure 1.7

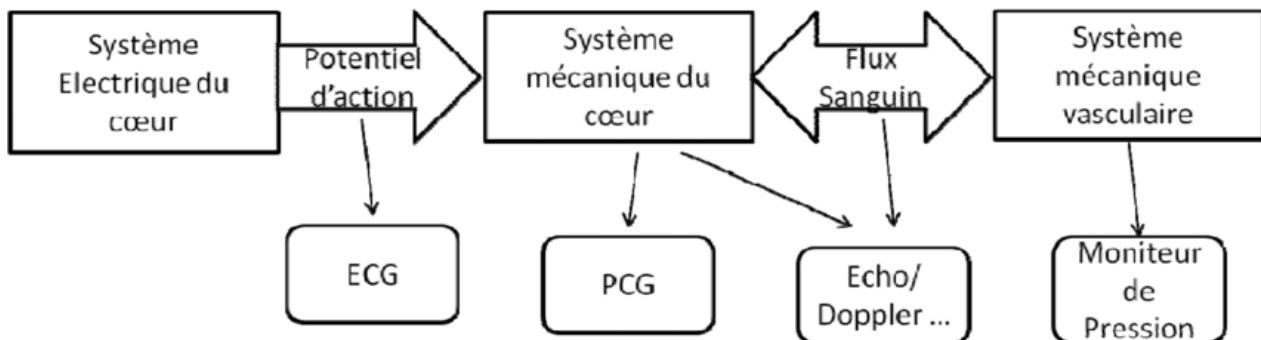


Figure.1.7: Les activités cardiaques avec les différents signaux correspondants mesurés : ECG, PCG, Echo [9]

5. Les sons des battements cardiaques

Les sons du cœur sont les sons habituels générés par l'activité du cœur et perçus à l'aide d'un stéthoscope placé sur la paroi thoracique lié au rythme cardiaque (contraction et relaxation) ainsi qu'au flux sanguin à travers le cœur et les vaisseaux sanguins importants. Quatre sons cardiaques se produisent durant les parties du cycle cardiaque. Contrairement à ce que l'on croit généralement, les sons cardiaques ne sont pas le résultat de la contraction et de la relaxation du muscle cardiaque, mais des effets liés au fonctionnement du cœur. [15]

5.1. Le premier son S1

Il se produit lorsque le cœur se contracte et que les valves situées entre les oreillettes et les ventricules (valves AV – valves mitrale et tricuspide) se ferment hermétiquement pour

empêcher le reflux du sang. C'est le début de la systole. Le premier bruit cardiaque est sourd et grave, il est plus fort à l'apex du cœur. [15]

5.2. Le deuxième son S2

Il correspond à la fermeture des valves sigmoïdes (valve aortique et valve pulmonaire) à la fin de la systole. Le S2 est plus fort à la base du cœur (au niveau du point d'auscultation aortique et pulmonaire) et il marque la fin de la contraction ventriculaire. [15]

5.3. Le troisième son S3

Il correspond à la fin du remplissage rapide du ventricule et se produit environ 0.15 seconde après la composante aortique du deuxième son. C'est un signal de faible fréquence et faible intensité qui peut être entendu au début de la phase diastolique (juste après S2). Il est associé à une dilatation ventriculaire et peut être entendu chez les patients atteints d'insuffisance cardiaque congestive. [1]

5.4. Le quatrième son S4

Il correspond à la systole auriculaire ou phase de remplissage actif du ventricule. Normalement inaudible, de faible fréquence et faible intensité, il se produit à la fin du régime diastolique (juste avant S1). S3 et S4 accompagnent souvent d'autres maladies cardiaques congénitales. S4 peut être entendu chez les personnes âgées. Il se produit pendant la diastole et est associé à une résistance à la remplissage ventriculaire. Il ne peut pas être entendu avec un stéthoscope et nécessite l'aide d'un phonocardiogramme. [1]

6. Les battements de cœur pathologiques

Les sons cardiaques pathologiques sont des sons anormaux qui sont entendus pendant le cycle cardiaque. Nous citons parmi eux :

6.1. Les souffles cardiaques

Sont des phénomènes sonores d'une durée plus longue et plus douce que celle d'un bruit. Ils sont produits par l'écoulement du sang d'une zone de haute pression vers une zone de basse pression à travers un orifice rétréci.

- ✓ **Les souffles systoliques** se produisent entre S1 et S2 et sont classés comme début, milieu ou fin systolique ou holosystolique. Parmi les différents souffles systoliques, on peut citer le souffle du rétrécissement valvulaire aortique, le souffle de rétrécissement valvulaire pulmonaire, le souffle d'insuffisance mitrale, le souffle d'insuffisance tricuspidiennne, le souffle de la communication interventriculaire, etc. [1]
- ✓ **Les souffles diastoliques** se produisent entre S2 et S1 et sont classés comme début, milieu ou fin de diastole. Parmi les différents souffles diastoliques, on peut citer le souffle d'insuffisance valvulaire aortique, le souffle de rétrécissement mitral, le souffle de rétrécissement tricuspidienn, etc. [1]

6.2. Les problèmes du rythme cardiaque

Il existe plusieurs anomalies du rythme cardiaque détectées par les sons cardiaques et le signal PCG, nous citons :

- ✓ **Valvulopathies** : Les problèmes au niveau des valves cardiaques, tels que des sténoses (rétrécissements) ou des insuffisances, peuvent générer des bruits spécifiques qui peuvent être identifiés par le PCG.
- ✓ **Cardiopathie congénitale** : Les défauts cardiaques présents dès la naissance peuvent être détectés par des anomalies sonores enregistrées par le PCG.
- ✓ **Troubles du rythme cardiaque** : Certains troubles du rythme cardiaque, tels que les souffles ou les palpitations, peuvent être évalués par le PCG.
- ✓ **Péricardite** : L'inflammation du péricarde, la membrane entourant le cœur, peut provoquer des bruits cardiaques spécifiques détectables par le PCG.
- ✓ **Anomalies du flux sanguin** : Les turbulences dans le flux sanguin, souvent associées à des sténoses ou des fuites valvulaires, peuvent générer des bruits anormaux enregistrés par le PCG.
- ✓ **Cardiomyopathie** : Les anomalies du muscle cardiaque peuvent également être évaluées par le PCG en écoutant les bruits produits pendant le cycle cardiaque.

7. Conclusion

Ce chapitre offre une vue d'ensemble sur l'anatomie du système cardiovasculaire, les maladies qui le touchent, la phonocardiographie et les sons cardiaques. Une compréhension approfondie de ces aspects est cruciale pour interpréter les enregistrements phonocardiographiques (PCG) et analyser les bruits cardiaques de manière précise.

La phonocardiographie est une méthode importante en pratique clinique pour évaluer la santé cardiaque. Elle complète l'électrocardiographie (ECG) en permettant une évaluation plus complète de l'état cardiaque des patients.

Dans le chapitre suivant, nous aborderons les différentes techniques d'intelligence artificielle utilisées pour détecter les anomalies des battements cardiaques. Ces techniques, combinées à une bonne compréhension de l'anatomie et de la physiologie cardiaque, offrent des moyens innovants et précis pour diagnostiquer et gérer les maladies cardiovasculaires.

CHAPITRE II

L'IA pour la classification des battements cardiaques

1. Introduction

Les maladies cardiovasculaires restent la première cause de mortalité dans le monde. L'une des premières étapes du diagnostic sur les pathologies liées au système cardiovasculaire dans la pratique clinique est l'examen physique. L'audition des bruits cardiaques est une partie essentielle de l'examen physique et peut révéler de nombreuses maladies cardiaques.

Dans ce chapitre, nous concentrerons sur les principales étapes des systèmes d'aide de diagnostic (CADe : Computer-aided détection) pour la détection des anomalies des battements cardiaques. En effet, ces systèmes sont basés sur les techniques de l'intelligence artificielle et plus précisément pour notre problématique celles de Machine Learning. Dans ce contexte, nous décrivons chaque partie de l'architecture générale de ces systèmes, ainsi nous citons les Data Set utilisées et nous présentons un état de l'art sur les travaux de recherches réalisées pour la classification des battements cardiaques normaux ou anormaux.

2. Architecture general d'un model de prediction in ML

Un modèle de prédiction en apprentissage automatique (Machine Learning) suit généralement une architecture de base qui comprend les composants suivants : Collecte de données, prétraitements et sélection des caractéristiques pertinentes. Cependant, pour les signaux PCG nous recourons aux techniques de segmentation pour l'extraction des battements cardiaques. Enfin, nous recourons aux algorithmes de classification pour la détection des anomalies des battements cardiaques via un protocole de test bien défini. La figure 2.1 présente un schéma illustratif de ces modèles de prédiction.



Figure.2.1: Architecture d'un system de prédiction

2.1. Prétraitement des données et filtrage du signal PCG

En effet, les sons cardiaques dans l'ensemble de données sont généralement enregistrés dans des environnements bruyants avec un grand nombre de patients et de personnel médical. Il convient de noter que le cœur fonctionne à proximité du poumon humain et est naturellement accompagné du son des poumons ou de la respiration humaine, ce qui provoque des bruits adjacents de haute fréquence engendré dans l'enregistrement des signaux PCG. Ceci nécessite le recours de certaines techniques pour traiter ces signaux.

Pour éliminer les bruits existant dans les signaux de phonocardiogramme (PCG), différents filtres de signal sont utilisés, pour améliorer la qualité du signal et faciliter l'analyse [16]. Parmi eux nous citons :

- ✓ **Filtre passe-bas** : Il est utilisé pour éliminer le bruit de haute fréquence dans le signal PCG. Il réduit les composants de haute fréquence du signal audio en ne laissant passer que les fréquences inférieures à sa fréquence de coupure.
- ✓ **Filtre passe-haut** : Il est utilisé pour éliminer le bruit de basse fréquence dans le signal PCG. Il atténue les composantes basses fréquences (graves) du signal audio en ne faisant passer que les fréquences supérieures à une fréquence spécifique (la fréquence de coupure).
- ✓ **Filtre passe-bande** : Il est utilisé pour isoler une certaine bande de fréquences dans le signal PCG. En ne laissant passer qu'une certaine bande de fréquences (et en atténuant tout ce qui est au-dessus ou en dessous).

Les filtres numériques peuvent être implémentés à l'aide de différents algorithmes tels que le filtre de *Butterworth*, le filtre de *Chebyshev*, et *Elliptic*. La figure 2.2 présente quelques exemples de filtres utilisés dans le domaine du traitement du signal.

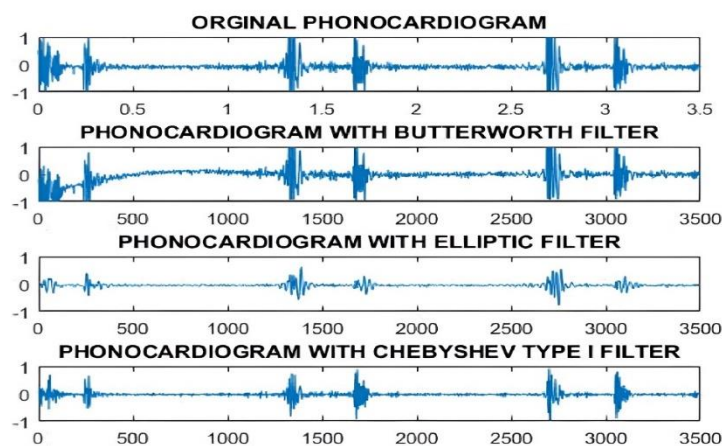


Figure.2.2: Exemple de Filtrage des bruits cardiaques avec les filtres numériques Butterworth, Chebyshev et Elliptic [17]

2.2. La segmentation des battements cardiaques

Dans le domaine biomédical, il est essentiel d'analyser simultanément les signaux de plusieurs patients pour détecter les interruptions causées par des artefacts indésirables. Étant donné que chaque patient présente des variations spécifiques, nous utilisons la segmentation pour séparer le signal de chaque battement cardiaque. Ce processus permet ainsi une évaluation précise de leur durée en vue d'une analyse ultérieure.

L'objectif de la segmentation est de diviser les données de phono-cardiogramme (PCG) en segments distincts correspondant à différentes parties du cycle cardiaque : les sons S1, les intervalles de systole, les sons S2 et les intervalles de diastole. Chaque segment représente une partie spécifique du cycle cardiaque et contient des informations qui peuvent être utiles

pour distinguer les sons cardiaques normaux des sons anormaux. La figure 2.3 présente un exemple de la segmentation des différents éléments d'un battement cardiaque.

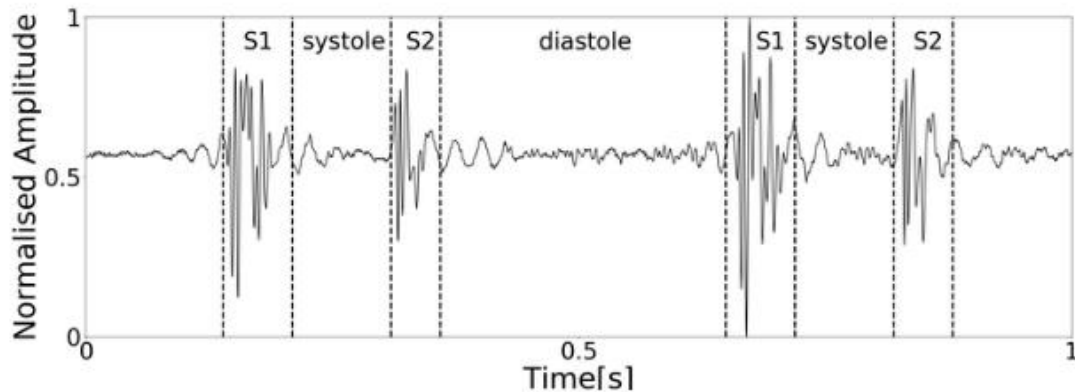


Figure.2.3: Signal PCG et quatre états du cycle cardiaque (S1, systole, S2, diastole)[18]

Dans les littératures, nous trouvons plusieurs travaux qui proposent des algorithmes efficaces pour la segmentation des battements cardiaques dans les signaux PCG. Parmi eux, nous citons :

2.2.1. La segmentation à base des Modèle Semi-Markovien Caché -HSMM

Cette technique est basée sur les modèles Markoviennes Cachés- HMM, elle utilise une machine à états finis probabiliste pour modéliser la durée des intervalles systoliques et diastoliques (Gamero et Watrous, 2003) [19]. La détection de S1 et S2 a été réalisée à l'aide d'un réseau de deux HMM avec des contraintes grammaticales pour analyser la séquence des intervalles systoliques et diastoliques. Les auteurs de cette technique ont utilisé la méthode HSMM et l'ont étendue avec l'utilisation de la régression logistique pour l'estimation de la probabilité d'émission, afin de résoudre le problème de la segmentation précise des enregistrements bruyants de bruits cardiaques réels [19].

2.2.2. La segmentation à base de l'énergie du Shannon

La technique de l'enveloppe énergétique de Shannon est la plus utilisée pour l'extraction des segments PCG. Cette technique utilise l'enveloppe énergétique moyenne normalisée de Shannon qui met l'accent sur les sons d'intensité moyenne tout en atténuant les composantes de faible intensité. Les performances de cette méthode ont été évaluées à l'aide de 515 cycles PCG à partir de 37 enregistrements acquis auprès d'enfants souffrant de souffles et ont atteint une précision de 93 % pour la segmentation PCG [19].

2.2.3. La segmentation avec K-Means et ondelettes

Cette technique de segmentation utilise la méthode d'intégrale de Viola et l'algorithme basé sur l'énergie de Shannon pour extraire la fonction de l'enveloppe de l'énergie du son cardiaque. Ensuite, il extrait les caractéristiques du domaine temps-fréquence de l'enveloppe acquise à partir de différentes dimensions et recherche le pic optimal de manière adaptative en fonction d'un seuil de segmentation dynamique. Enfin, le clustering K-means et la transformée en ondelettes de Haar sont mis en œuvre pour localiser S1 et S2 des sons cardiaques dans le domaine temporel [20].

2.2.4. La segmentation avec les réseaux récurrents convolutionnels

Cette technique utilise le signal PCG comme entrée directe, ce qui signifie qu'il n'a pas besoin d'une étape de prétraitement ou d'extraction de caractéristiques manuelle. Les couches convolutionnelles sont utilisées pour extraire automatiquement les caractéristiques pertinentes du signal audio et pour effectuer le sous-échantillonnage, ce qui réduit la dimensionnalité des données. Ensuite, les couches LSTM (Long Short-Term Memory) sont utilisées pour analyser les séquences de données dans le temps et effectuer la reconnaissance de séquence. Cela permet à l'algorithme de comprendre les dépendances temporelles dans les données, ce qui est crucial pour la segmentation des sons cardiaques. [21]

La figure 2.4 suivante décrit les différentes étapes des techniques de segmentation utilisées pour l'extraction des battements cardiaques à partir d'un signal PCG.

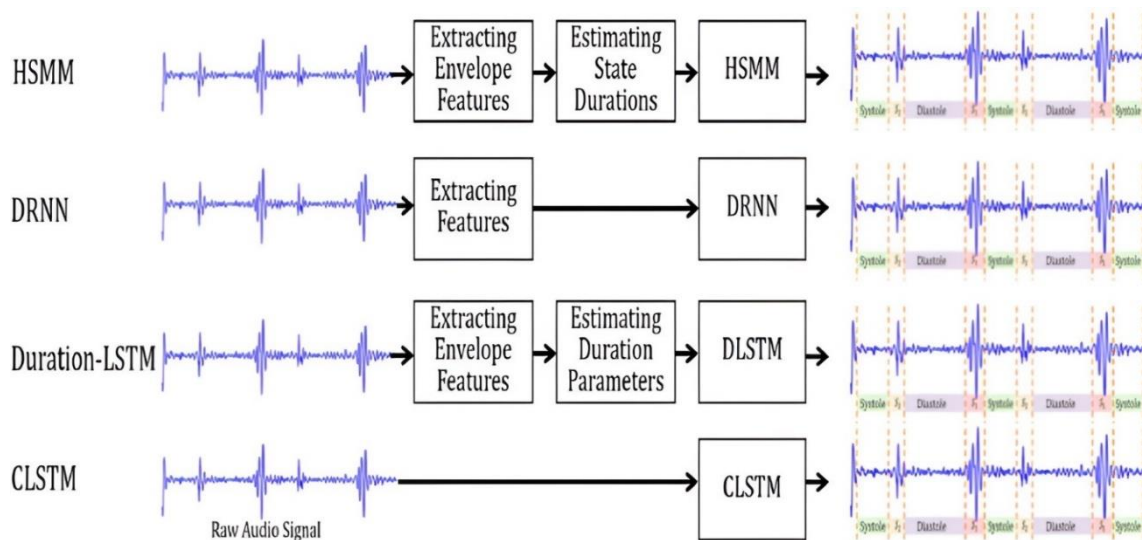


Figure.2.4: Les techniques de segmentation : HSMM, DRNN, durée-LSTM, et CLSTM [21]

2.3. Extraction de caractéristiques

L'extraction de caractéristiques est une étape cruciale dans le traitement des signaux de phono-cardiogramme (PCG) puisqu'elle permet de transformer les données brutes en informations exploitables pour l'analyse et la classification des battements cardiaques. Ces caractéristiques extraites servent de base pour différencier les sons cardiaques normaux des sons pathologiques. Il existe différentes techniques qui peuvent être utilisées pour extraire ces caractéristiques. Parmi ces techniques, nous citons :

2.3.1. Les caractéristiques temporelles

L'extraction de caractéristiques temporelles est une technique spécifique d'extraction de caractéristiques destinée aux données temporelles, comme des séries chronologiques. Elle vise à extraire des informations pertinentes sur la façon dont les données évoluent au fil du temps.

Les caractéristiques temporelles, tels que l'amplitude, la durée du cycle cardiaque, la zone de pic et l'intensité du signal. Ces caractéristiques peuvent contenir des informations différentes dans les sons cardiaques normaux et anormaux. Par exemple, le son S1 est généralement plus fort que le son S2 dans un cœur sain, donc le niveau d'intensité du son S1 est généralement plus grand. La figure 2.5 présente un exemple de certaines caractéristiques temporelles.

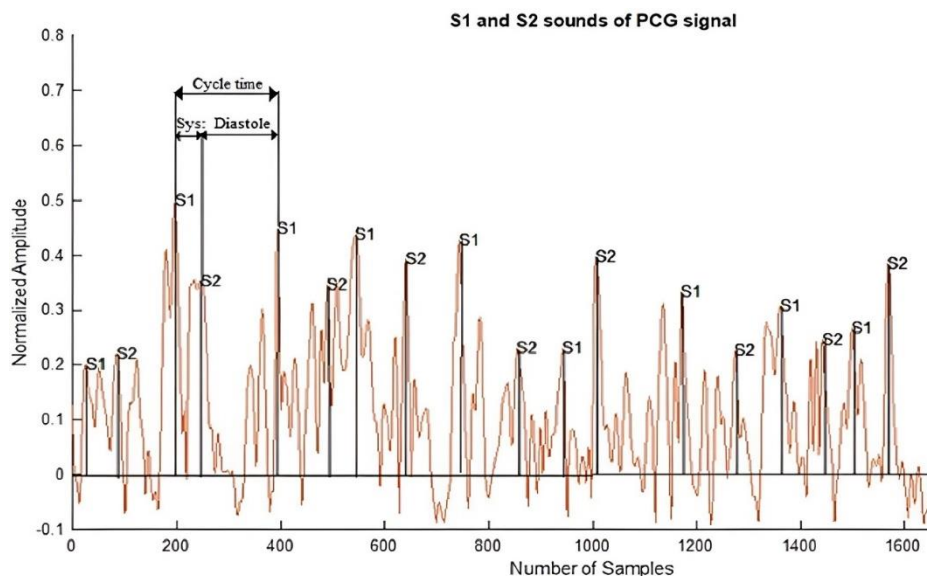


Figure.2.5: Exemple de la façon d'analyser un signal PCG segmenté pour l'extraction de caractéristiques dans le domaine temporel [22]

2.3.2. Les caractéristiques fréquentielles

L'extraction de caractéristiques fréquentielles est particulièrement utile pour les données de nature temporelle, telles que les signaux audio, les signaux biomédicaux et les vibrations mécaniques. Elle permet de quantifier et de résumer les aspects fréquentiels de ces signaux, fournissant des informations essentielles pour des tâches telles que la classification, la reconnaissance de formes et la détection d'anomalies. Les techniques comme les MFCC (*Mel-Frequency Cepstral Coefficients*), le spectrogramme et le Mel-scaled power spectrogram peuvent être appliquées dans le traitement du signal audio pour l'analyse des PCG. La figure 2.6 présente un exemple d'un spectrogramme et d'un signal PCG tandis que les figures 2.7 et 2.8 présentent les caractéristiques MFCC et Mel-scaled power spectrogram extraites à partir d'un signal PCG.

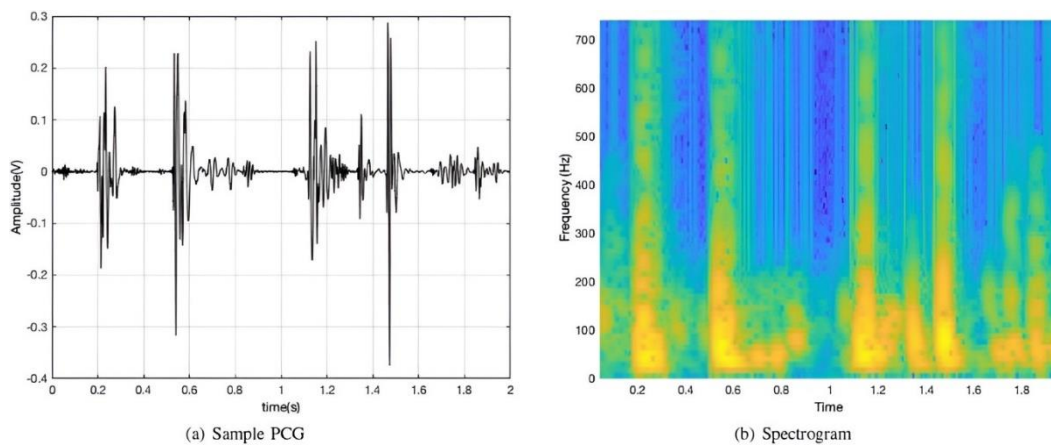


Figure.2.6: Exemple d'un spectrogramme d'un signal PCG [23]

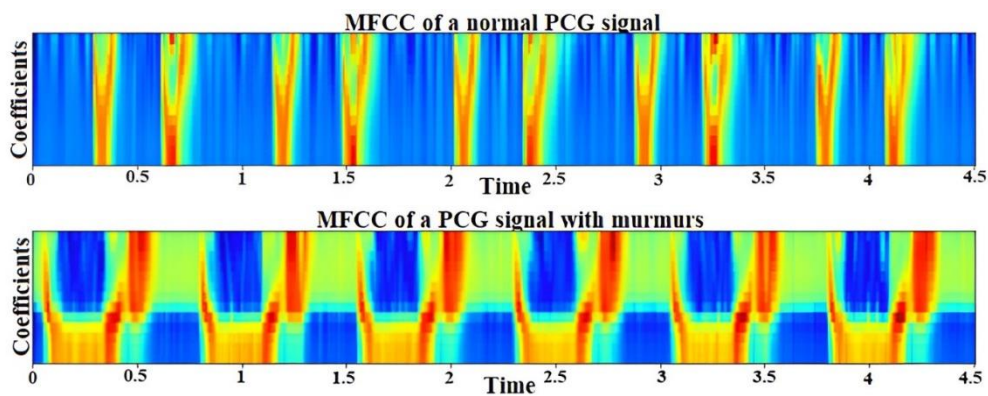


Figure.2.7: Exemple des caractéristiques MFCC d'un signal PCG normal, MFCC d'un signal PCG avec murmure [24]

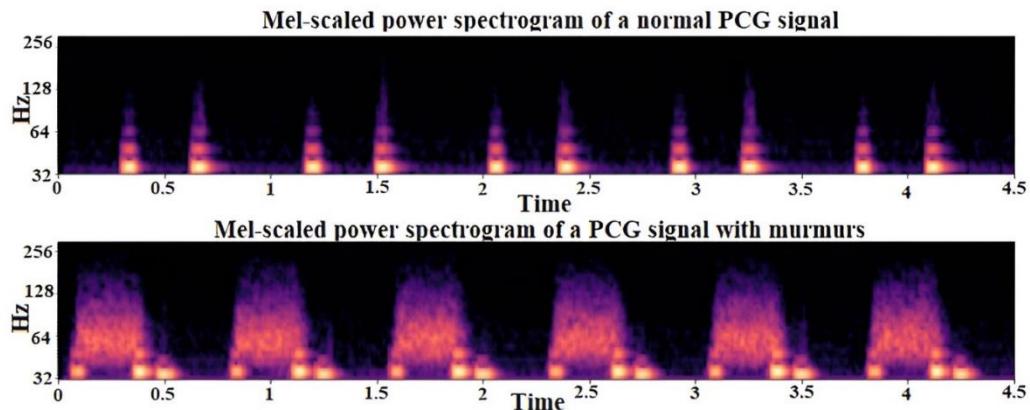


Figure.2.8: Exemple des caractéristiques Mel-scaled power spectrogram d'un signal PCG normal, Mel-scaled power spectrogram d'un signal PCG avec murmures [24]

2.4. Les algorithmes de classification

Les algorithmes de classification jouent un rôle central dans les systèmes intelligents de détection des anomalies ou des pathologies cardiaques. Dans le cas de la phonocardiographie (PCG), ces algorithmes peuvent également être utilisés pour classifier les signaux en différentes catégories, telles que les sons cardiaques normaux et anormaux.

Pour cette tâche de classification des sons cardiaques, une gamme d'algorithmes peut être employée, incluant notamment les machines à vecteurs de support (SVM), Les forêts aléatoires (Random Forest), l'algorithme des KNN et les réseaux de neurones.

Le choix de l'algorithme dépendra de la nature des données PCG et des objectifs spécifiques de la classification. Une fois que la classification a été effectuée, le modèle peut être évalué pour déterminer sa précision, sa sensibilité et sa spécificité, ce qui permet d'évaluer son efficacité dans la détection des anomalies cardiaques à partir des signaux PCG.

2.4.1. Le classifieur *Random Forest*

Random forest est un algorithme d'apprentissage supervisé. Il peut être utilisé à la fois pour la classification et la régression. C'est également l'algorithme le plus flexible et le plus facile à utiliser. Une forêt comme la présente la figure 2.9 est composée d'arbres. On dit que plus il y a d'arbres, plus la forêt est robuste.

Les forêts aléatoires génèrent des arbres de décision à partir d'échantillons de données choisis au hasard, réalisent des prédictions à partir de chaque arbre et choisissent la solution la plus optimale par vote. Il fournit également un assez bon indicateur de l'importance des fonctionnalités. Ce classifieur possède une variété d'applications, telles que les moteurs de recommandation, la classification d'images et la sélection de caractéristiques. Il peut être utilisé pour les systèmes d'aide de diagnostic (CADe) des pathologies [25].

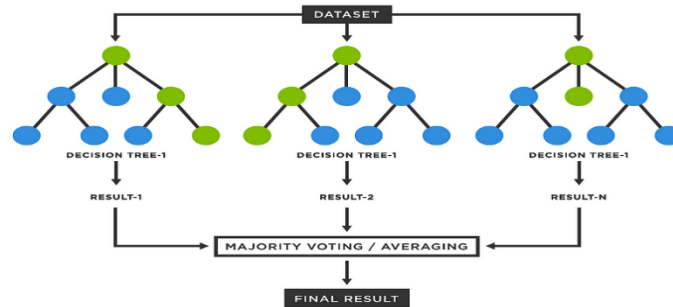


Figure.2.9: Principe du classifieur Random Forest [26]

2.4.2. Le classifieur SVM (Les Machines à Vecteurs de Support)

Les SVM sont des algorithmes d'apprentissage automatique supervisé puissants qui sont utilisés à la fois en classification et en régression, mais ils sont généralement utilisés dans les problèmes de classification. Son principe de classification basé sur la séparation de classes par des hyperplans comme la montre la figure 2.10. Dernièrement, il connaît un très grand succès, pour de multiples avantages comme :

- ✓ Il ne nécessite pas plusieurs hyperparamètres.
- ✓ Il garantit de bons résultats théoriques.
- ✓ Il peut égaler ou dépasser en performance les réseaux de neurones ou modèles gaussiens. [25]

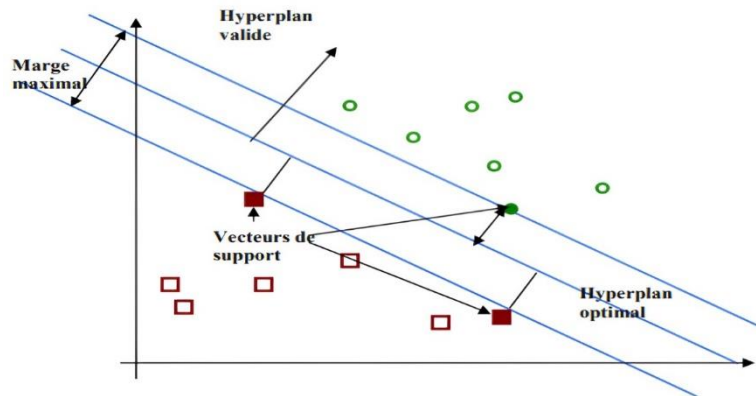


Figure.2.10: Principe du classifieur SVM [25]

2.4.3. Le classifieur kNN (le plus proche voisin)

Le KNN est un discriminant d'apprentissage supervisé non paramétrique qui utilise la proximité pour réaliser des classifications ou des prédictions sur le regroupement d'un point de données individuel. Bien qu'il puisse être utilisé pour des problèmes de régression ou de classification, il est souvent utilisé comme algorithme de classification basé sur l'hypothèse que des points similaires peuvent être trouvés les uns à côté des autres comme la montre la figure 2.11. [9]




Figure.2.11: Principe du classifieur kNN [30]

2.4.4. Les réseaux de neurones ANN

Un réseau de neurones artificiels (ANN) est un modèle de calcul inspiré par le fonctionnement du cerveau humain. Il est composé d'unités de calcul, appelées neurones artificiels, qui sont organisées en couches. Chaque neurone reçoit des entrées, effectue un calcul simple sur ces entrées, puis transmet le résultat à d'autres neurones. La figure 2.12 présente un exemple d'architecture d'un classifieur ANN.

Les poids dans les réseaux ANN représentent la force des connexions entre les neurones et sont utilisés pour calculer les sorties des neurones. Ces poids sont ajustés au cours de l'apprentissage pour améliorer la performance du réseau. Les classifieurs ANN sont capables d'apprendre et de s'adapter aux données d'entrée, ce qui les rend utiles pour une variété de tâches, y compris la reconnaissance d'images, la prédiction de séries temporelles, la classification, et bien d'autres. Ils sont un élément clé de l'apprentissage profond et de l'intelligence artificielle. [29]




Figure.2.12 : Architecture des classifieurs ANN [29]

3. Les métriques d'évaluation des systèmes d'aide de diagnostic (CADE)

3.1. Les métriques de performances

Il existe plusieurs métriques permettent d'évaluer la performance des systèmes d'aide de diagnostic pour les tâches de détection ou de classification. Les plus utilisées sont :

- ✓ **Rappel** : Le rappel mesure la proportion d'échantillons réellement positifs qui sont correctement prédits comme positifs. Il est calculé par la formule suivante :

$$\text{Rappel} = \frac{TP}{TP + FN}$$

- ✓ **Précision** : La précision mesure la proportion d'échantillons prédits comme positifs qui sont réellement positifs. Elle est calculée par la formule suivante :

$$\text{Précision} = \frac{TP}{TP + FP}$$

- ✓ **F1-Score** : le F1 Score est une mesure pondérée de la précision et du rappel. Il prend en compte à la fois les faux positifs et les faux négatifs. Il est calculé par la formule suivante :

$$\text{F1 Score} = 2 * \frac{(\text{Précision} * \text{Rappel})}{(\text{Précision} + \text{Rappel})}$$

3.2. La matrice de confusion

Cette matrice est essentielle pour évaluer les performances d'un modèle de classification. Elle permet de visualiser et de quantifier les différents types d'erreurs commises par le modèle. La matrice est composée de N x N cases, où N représente le nombre de classes cibles. Chaque case représente le nombre d'échantillons appartenant à une classe réelle et prédits par le modèle comme appartenant à une autre classe. Les quatre valeurs essentielles de la matrice de confusion sont :

- ✓ **Vrais positifs (TP)** : Nombre d'échantillons réellement positifs et correctement prédits comme positifs.
- ✓ **Vrais négatifs (TN)** : Nombre d'échantillons réellement négatifs et correctement prédits comme négatifs.
- ✓ **Faux positifs (FP)** : Nombre d'échantillons réellement négatifs mais prédits comme positifs.
- ✓ **Faux négatifs (FN)** : Nombre d'échantillons réellement positifs mais prédits comme négatifs

Cette matrice est présente une vue globale et détaillée à la fois sur les performances des systèmes d'aide de diagnostic (CADE). Elle intègre aussi les métriques de la section précédente. La figure 2.13 présente un exemple d'une matrice de confusion.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Figure.2.13 :Les quatre valeurs essentielles de la matrice de confusion [30]

4. Etude bibliographique sur les data Set des signaux PCG

Les data set en cardiologie font référence à des ensembles de données cliniques et/ou de signaux cardiaques collectés à partir de patients atteints de différentes pathologies cardiaques. Ces bases de données ont été créées dans le but de faciliter la recherche en cardiologie, en fournissant aux chercheurs des données précieuses pour la compréhension des maladies cardiaques et la création de nouvelles approches pour le diagnostic et le traitement. Plusieurs data set en cardiologie sont disponibles publiquement, nous citons :

4.1. La Data Set CinC ‘2016

PhysioNet est une plateforme en ligne qui facilite la diffusion et l'échange de signaux biomédicaux enregistrés et de logiciels open-source pour leur analyse. Elle fournit des installations pour l'analyse coopérative des données et l'évaluation de nouveaux algorithmes proposés.

La compétition *PhysioNet/CinC 2016* est une initiative importante qui vise à promouvoir le développement d'algorithmes capables de classifier les enregistrements de battements et les bruits cardiaques. Ces enregistrements peuvent provenir d'environnements cliniques ou non cliniques. L'objectif est d'identifier, à partir d'un court enregistrement provenant d'un seul endroit sur la poitrine, le diagnostic adéquat sans le recours aux avis des experts.

La compétition fournit des enregistrements audios étiquetés de 'A' à 'E', utilisés pour entraîner les algorithmes à distinguer les sons cardiaques normaux des sons anormaux. L'ensemble d'entraînement comprend un total de 3126 fichiers, tandis que l'ensemble de validation comprend 300 enregistrements. Les durées des fichiers varient de 5 à 120 secondes.

L'ensemble de test n'a pas été rendu public et a été utilisé uniquement pour évaluer les participants à la compétition [31].

4.2. La Data Set PASCAL Heart Sound Challenge (HSC) dataset

Elle est publiée dans le cadre de la compétition ‘*Heart Sound Challenge (HSC)*’ et a été mise à disposition pour la première fois en 2011 pour deux défis, la segmentation des battements cardiaques et la classification des bruits cardiaques.

Cette Data Set est divisée en deux sous-ensembles, l'ensemble de données « A » et l'ensemble de données « B ». L'ensemble de données « A » a été collecté à l'aide de l'application iPhone *iStethoscope Pro*, tandis que l'ensemble de données « B » a été collecté dans un environnement clinique à l'aide du stéthoscope numérique *DigiScope*. Les deux jeux de données contiennent respectivement 176 et 656 auscultations totales. Les fichiers des deux ensembles de données contiennent des battements cardiaques normaux, des souffles et des systoles supplémentaires. En plus de cela, l'ensemble de données « B » contient également des fichiers avec des artefacts et des sons supplémentaires et elle a plus de challenge. [32]

4.3. La Data Set Heart sound and Murmur Library

Elle était publiée par l'*Université de Michigan*, elle contient un ensemble de données publiques qui comprend les bruits cardiaques normaux, le fractionnement normal S1, le clic systolique, le galop S4, le galop S3, le simple S2, le fractionnement S2 persistant, le fractionnement S2 et certains bruits transitoires et divers types de souffles. Les données contiennent respectivement 23 auscultations totales. [33]

4.4. La Data Set CirCor DigiScope Phonocardiogram'2022

Cette data set contient un ensemble de données disponibles sur physionet.org, comprenant 5282 enregistrements de battements de cœur provenant de 1568 patients. Les enregistrements sont divisés en deux catégories : normaux/anormaux et présence/absence de murmures. La durée des enregistrements varie de 4,8 à 80,4 secondes. Les données comprennent des informations détaillées sur les patients telles que l'identification, la taille, le poids, l'âge, le sexe, ainsi que des caractéristiques importantes. Les enregistrements sont issus de quatre régions d'auscultation centrales : la valve pulmonaire (PV), la valve tricuspide (TV), la valve aortique (AV) et la valve mitrale (MV), annotées respectivement comme 1, 2, 3 et 4 pour les périodes S1, systolique, S2 et diastolique. [34]

4.5. Synthèse sur les data set des battements cardiaques

Dans le tableau 2.1, nous présentons les caractéristiques des Data Set les plus utilisées pour avoir une idée globale sur ces données.

Dataset	Auscultations totales	Catégories de sons
PhysioNet CinC challenge dataset 2016[31]	3126	Normal, incertain, et anormal
PASCAL heart sound challenge dataset 2011[32]	Dataset 'A', iStethoscope, samples: 176 dataset 'B', Digiscope, samples :656	Dataset A: Normal, Murmur, Extra Heart Sound, Artifact. Dataset B: Normal, murmur, Extrasystole.
Heart sound and Murmur Library, University of Michigan Health Systems. [33]	23	Normale et des sons anormaux
The CirCor DigiScope Phonocardiogram Dataset 2022 [34]	5282	Normaux/anormaux et présence/absence de murmures

Tableau 2.1 :Un résumé des Data Set des battements cardiaques-PCG

5. Les travaux connexes sur la classification des battements cardiaques

Dans cette nous présentons les travaux récents dans le contexte de notre solution proposée pour la détection des anomalies des battements cardiaques

Nous citons en premier lieu le travail de Milani et al (2021) [22], dans cette étude les auteurs ont extrait 30 caractéristiques du domaine temporel et 100 caractéristiques du domaine fréquentiel via les filtres *MFCC* qui incluent leurs valeurs statistiques telles que ; moyenne, écart-type, médiane, maximum et minimum. Ensuite, l'Analyse Discriminante Linéaire (*LDA*) est utilisée pour réduire la dimensionnalité de toutes les caractéristiques extraites avant de les envoyer à travers un modèle ANN à une seule couche pour effectuer la classification des signaux PCG normaux et anormaux. Il a été démontré que Le modèle proposé de classification des bruits cardiaques LDA/ANN a obtenu une classification de 90 %, 83,33 % et 93,33 % précisions utilisant le domaine temporel, le domaine fréquentiel et la combinaison temps-fréquence fonctionnalités du domaine, respectivement sur l'ensemble de données PhysioNet/CinC Challenge 2016.

Aussi, nous citons le travail de Fan Li et al (2020) [35], cette étude a intégré des méthodes conventionnelles d'extraction des caractéristiques et des algorithmes d'apprentissage en profondeur pour classer les bruits cardiaques normaux et anormaux. Un total de 497 caractéristiques ont été extraites de huit domaines différents, qui sont : Temps, Amplitude, Énergie, Statistiques d'ordre supérieur, Cepstre, Fréquence, Cyclostationnaire, Entropie. Ces caractéristiques ont ensuite été utilisées pour effectuer les tâches de classification nécessaires via un classificateur CNN (*Convolutional Neural Network*). Cette approche combine les avantages de techniques d'extraction des caractéristiques traditionnelles avec les capacités puissantes de l'extraction automatique des caractéristiques via l'apprentissage en profondeur,

offrant une méthode complète pour la classification des bruits cardiaques. La précision moyenne, la sensibilité, la spécificité et le coefficient de corrélation de Matthews observés sur l'ensemble de données PhysioNet/CinC Challenge 2016 étaient respectivement de 86,8%, 87%, 86,6% et 72,1%.

D'autres travaux sont menés par Potes, Parvaneh et al (2016) [36]. Dans cette étude, la moyenne et l'écart type des caractéristiques du domaine temporel des intervalles de temps PCG et des amplitudes PCG sont extraites. De plus, la puissance médiane passant par neuf (9) bandes de fréquences des spectres de puissance des signaux PCG est extraite en tant que caractéristiques du domaine fréquentiel. Ensuite, la classification des signaux PCG normaux et anormaux est effectuée via un classificateur combiné *AdaBoost* et un réseau neuronal convolutif *CNN*. Le modèle *AdaBoost* + *CNN* a obtenu les scores de précision, de sensibilité, et spécificité globales obtenus sont : 0,9424, 0,7781 et 0,8602, respectivement, sur l'ensemble de données PhysioNet/CinC Challenge 2016.

Aussi, dans l'étude de Jan, H., & Tang, C. (2023) [37], les auteurs utilisent une approche d'apprentissage profond pour l'extraction des caractéristiques. Les quatre premières entrées utilisent des couches *BiLSTM* pour extraire indépendamment les caractéristiques temporelles des quatre emplacements d'auscultation. La cinquième entrée analyse le sexe du patient à travers d'une couche entièrement connectée (Dense). L'étude propose un modèle d'apprentissage profond hybride multi-entrées-multi-sorties pour l'analyse des battements cardiaques. Ce modèle intègre l'architecture des réseaux récurrents à mémoire à long terme bidirectionnelle *BiLSTM* avec une couche Dense comme entrées, et ajoute une architecture de segmentation *UNet* suivi de blocs résiduels comme colonne vertébrale pour trouver simultanément des battements cardiaques anormaux et des murmures à travers une architecture multi-sorties. Le modèle proposé est testé par le principe de validation croisée K-Fold, Ils ont obtenu un score de précision de 95% sur la Data Set CirCor DigiScope. Cependant, comme ce jeu de données avait des caractéristiques manquantes, ils ont modifié en excluant les échantillons qui manquaient d'audio des sites d'auscultation essentiels.

Un autre travail de Fuad Noman et al [38], qui ont présentés, un ensemble de réseaux neuronaux convolutionnels *CNN* profonds a été développé pour classer les bruits cardiaques normaux et anormaux. Cette architecture *CNN* a été basée sur des enregistrements de courts segments de battements de cœur individuels. La nouvelle architecture de réseau combine un *CNN-1D* et un *CNN-2D* conçus respectivement pour apprendre plusieurs niveaux de représentations à partir des signaux bruts du domaine temporel et des caractéristiques de la fréquence temporelle. L'évaluation a été effectuée sur la Data Set du PhysioNet CinC 2016 et elle a démontré les avantages des modèles *CNN* proposés, avec une amélioration considérable des performances de classification. Les meilleurs scores de classification avec une précision de 89,22% et une sensibilité de 89,94% ont été obtenus par le *CNN-1D*, et une spécificité de 91,55% et une précision modifiée de 88,82% par le *CNN-2D* seul sur l'ensemble de test.

D'autres travaux sont menés par Lu, H et al 2022 [39], cette étude vise à détecter les murmures cardiaques et les résultats cliniques à partir d'enregistrements de sons cardiaques

provenant de plusieurs sites d'auscultation. Pour cela, l'équipe *HearHeart* a proposé un réseau neuronal convolutif *CNN* léger pour détecter les murmures et un modèle de *Random-Forest* pour classifier les résultats cliniques. L'étude extrait 128 Mel-spectrogrammes ainsi que des caractéristiques larges telles que les données socio-démographiques et les caractéristiques statistiques des patients. La data set utilisé c'était *CirCor DigiScope* et les résultats montrent un score de détection des murmures de 0.791 avec une stratégie de validation $Kfold=5$. Tandis que, sur les données de test cachées, un score de détection des murmures de 0.751 a été obtenu.

Dans cette étude du Kaleem Nawaz Khan et al 2023[40], les auteurs ont utilisé des réseaux neuronaux convolutionnels *CNN* pour effectuer une détection préliminaire des anomalies du rythme cardiaque. Ils ont utilisé des spectrogrammes basés sur la transformée de fourrier à court terme (*STFT*) pour apprendre les caractéristiques représentatives des signaux PCG normaux et anormaux. Ces spectrogrammes ont été générés à partir de deux ensembles de données largement utilisés et disponibles publiquement, à savoir *PhysioNet* et *PASCAL*. Le modèle *CNN* personnalisé proposé pour la classification des ensembles de données *PhysioNet*, combinés et *PASCAL* a obtenu une précision, une sensibilité, une spécificité, une précision et un score F1 respectivement de 95,4%, 96,3%, 92,4%, 97,6% et 96,98% pour la première étude, et de 94,2%, 95,5%, 90,3%, 96,8% et 96,1% pour la deuxième étude. Enfin, la troisième étude montre une précision de 98,29% sur l'ensemble de données bruyant *PASCAL* avec l'approche de *Transfert Learning*.

D'autres travaux sont menés par Yasser Zeinal et al 2021 [41], le Data Set utilisé dans cette étude fait partie des données des compétitions du *PhysioNet* et *PASCAL*, collectées soigneusement par un médecin. Il contient 650 échantillons, dont 104 patients avec des sons cardiaques anormaux et 52 patients avec des sons cardiaques normaux ont été sélectionnés pour créer un ensemble de données composé de 156 échantillons de sons cardiaques. Pour extraire les caractéristiques des sons cardiaques, chaque son cardiaque est divisé en cinq plages séparées, chacune ayant une durée moyenne de 0,16 s. Par conséquent, l'ensemble de données créé se compose de caractéristiques obtenues dans des plages différentes : caractéristiques statistiques, caractéristiques du signal, caractéristiques de l'ondelette et la théorie de l'information. L'étude a utilisé des algorithmes d'apprentissage automatique pour analyser et classer les sons cardiaques. Les algorithmes utilisés sont : *SVM*, le *Gradient Boosting algorithm* et *Random Forest*. Les résultats de l'étude donnent d'excellentes performances de classification avec une précision de 87,5% et 95% pour les données multi classe (3 classes) et de 98% pour la classification binaire (normal vs anormal).

Aussi, nous citons les travaux présentés par Sachin Vernekar et al 2016[42], ils ont présenté une nouvelle approche utilisée pour la classification d'extraits de phono cardiogrammes (PCG) en classes normales et anormales dans le cadre de la compétition *Physionet 2016*. Les auteurs ont proposé une technique qui tire parti des recherches précédentes sur l'extraction de caractéristiques avec une nouvelle approche pour modéliser la dynamique temporelle du signal en utilisant l'analyse des chaînes de Markov. Ces nouvelles caractéristiques de Markov, ainsi que d'autres caractéristiques statistiques et de domaine de fréquence, ont été formées sur un ensemble de réseaux neuronaux artificiels et d'arbres de renforcement du gradient, avec

bagging. Ils ont utilisé la durée générée par l'algorithme de segmentation pour les quatre états du son cardiaque pour obtenir quelques caractéristiques statistiques typiques. De l'analyse du domaine fréquentiel, des statistiques *FFT*, des caractéristiques *MFCC*, de l'entropie d'échantillonnage, des caractéristiques musicales, des caractéristiques de bande d'octave, etc. Ils ont obtenu une précision de 82% sur l'ensemble de données de validation fourni dans le concours et cela était cohérent avec les données de test avec le meilleur résultat de 78%.

Une autre étude menée par Jinghui Li et al 2019[43], les auteurs ont proposé une méthode de classification basée sur la Fractale de Wavelet et la machine à vecteurs de support jumelée *TWSVM* pour le diagnostic des maladies cardiaques. L'ensemble de données utilisé sont celles de la compétition PhysioNet/CinC Challenge 2016. Les résultats expérimentaux montrent que cet algorithme proposé basé sur la machine à vecteurs de support jumelée (*TWSVM*) est supérieur à l'algorithme basé sur la machine à vecteurs de support (*SVM*) en termes de précision et de vitesse de classification. L'algorithme proposé atteint les meilleurs résultats avec une précision de classification de 90,4%, une sensibilité de 94,6%, une spécificité de 85,5% et un score F1 de 95,2%.

Aussi, Abduh, Z et al 2020 [44], ils ont présenté un système d'apprentissage automatique pour la classification des sons cardiaques. Les classifieurs utilisés sont *SVM*, *KNN*, et un classificateur d'ensemble (*Random Forest*, *KNN* de sous-espace, et arbre *RUSBoosted*). L'évaluation a été testée à l'aide du Data Set de la compétition du PhysioNet Challenge 2016. Les résultats étaient prometteurs, avec un score de 0.9200, une sensibilité de 0.8735, et une spécificité de 0.9666 en utilisant un classificateur de machine à vecteurs de support avec un noyau cubique. La méthode d'extraction de caractéristiques utilisée est les coefficients spectraux de fréquence Mel basés sur la transformée de Fourier fractionnaire (*FrFT-MFSC*).

D'autres travaux sont menés par Mohammad Nassralla et al 2017[45], cette étude présente un algorithme de classification automatique pour les anomalies (état cardiaque normal vs anormal). L'approche proposée est testée sur l'ensemble de données PhysioNet '2016 pour produire une précision, une spécificité, et une sensibilité de 92%, 98%, et 78% respectivement. Des caractéristiques distinctives de temps et de fréquence sont extraites des signaux sonores cardiaques pour construire un modèle d'apprentissage en utilisant l'algorithme de *Random Forest*. Les caractéristiques de temps sont estimées à partir du modèle autorégressif (*AR*) pour chaque segment. Les caractéristiques de fréquence sont extraites en utilisant les Coefficients Cepstraux de Fréquence Mel (*MFCC*), l'entropie d'ondelette, et le spectre de puissance de chaque état sonore cardiaque.

Le dernier travail que nous citons dans cette section est le travail de Michael al Homsy, et al 2016 [46]. Les signaux du *PCG* sont d'abord sous-échantillonnés à 1 kHz à l'aide d'un filtre anticrénelage polyphasé. Ensuite, chaque bruit cardiaque est segmenté pour identifier quatre états : S1, S2, systole et diastole. À partir de ces états, 131 caractéristiques dans les domaines du temps, de la fréquence, des ondelettes et des statistiques sont extraites. Un méta-classificateur comprenant *Random Forest*, *LogitBoost* et il est utilisé avec une approche de

validation croisée k-Fold sur la Data Set de la compétition Physionet Challenge 2016 et ils ont obtenus un score global de 84,48%.

6. Tableaux récapitulatif des travaux connexes

Ce Tableau 2.2 présente notre synthèse sur l'étude bibliographique que nous avons menés pour la détection des anomalies dans les battements cardiaques.

Auteur	Les méthodes d'extraction de caractéristiques	Technique de classification	Data Set utilisée	Résultats
Milani, M.G.M et al (2021) [22]	Time domain and frequency domain features	ANN	2016 PhysioNet	Accuracy :93.33%
Fan Li et al (2020) [35]	(8) domains -in the Time Domain -in the State Amplitude Domain -in the Energy Domain -in the Higher-Order Statistics Domain -in the Cepstrum Domain -in Frequency Domain -in the Cyclostationarity Domain -in the Entropy Domain	CNN	2016 PhysioNet	Sensitivity: 87% Specificity : 86.6% Accuracy: 86.8%
Potes, Parvaneh, Rahman, and Conroy (2016) [36]	Time-domain Features Frequency-domain Features (MFCC)	CNN + AdaBoost	2016 PhysioNet	Sensitivity: 0.9424 Specificity: 0.7781 score: 0.8602

Jan, H., & Tang, C 2023 [37]	BiLSTM+ UNet	Hybrid Deep Learning Model	The CirCor DigiScope	Accuracy: 95%
Fuad Noman et al [38]	Raw heart sound signals and Mel-frequency cepstral coefficients (MFCC)	ensemble de CNN temps-fréquence (TF-ECNN)+ CNN 1D CNN 2D	2016 PhysioNet	Accuracy: 89.22% sensitivity: 89.94% + accuracy: 88.82% specificity: 91.55%
2022 Lu, H et al [39]	128 Mel-spectrogram+ Données socio-démographiques et caractéristiques statistiques	convolutional neural network (CNN)+ Random Forest	The CirCor DigiScope	accuracy :0.791%
Kaleem Nawaz Khan et al 2023 [40]	Spectrograms	CNN	PhysioNet 2016+ PASCAL Q	étude 1 (Accuracy95.4,Sensitivity96.3,Specificity92.4,Precision97.6) étude 2(Accuracy 94.2,Sensitivity 95.5,Specificity,90 .3,Precision96.8)

<p>Yasser Zeinali et al 2021 [41]</p>	<p>Caractéristiques statistiques ; Caractéristiques du signal , Caractéristiques de l'ondelette ;Théorie de l'information</p>	<p>SVM+ le Gradient boosting algorithm (GBA) + Random forests algorithm (RFA)</p>	<p>PhysioNet et PASCAL</p>	<p>accuracy :98%</p>
<p>Sachin Vernekar et al 2016 [42]</p>	<p>l'analyse du domaine fréquentiel, des statistiques FFT, des caractéristiques de l'ARMA, des caractéristiques MFCC, de l'entropie d'échantillonnage, des caractéristiques musicales, des caractéristiques de bande d'octave, etc. et de nouvelles caractéristiques de Markov</p>	<p>Un ensemble de réseaux neuronaux artificiels et d'arbres de renforcement du gradient</p>	<p>Physionet 2016</p>	<p>accuracy :82%</p>
<p>Jinghui Li et al 2019 [43]</p>	<p>Wavelets, entropy, fractal dimension.</p>	<p>twin support vector machine (TWSVM)</p>	<p>Physionet 2016</p>	<p>accuracy 90.4%, sensitivity 94.6%, specificity 85.5%,</p>
<p>Abduh, Z et al 2020 [44]</p>	<p>FrFT- MFSC features</p>	<p>SVM, KNN, and an ensemble classifier (bagged Trees, subspace KNN, and RUSBoosted tree)</p>	<p>Physionet 2016</p>	<p>Specificity : 0.9666 Sensitivity: 0.8735 score 0.9200</p>

Mohammad Nassralla et al 2017 [45]	Time features+ Frequency features5(MFCC)+ Wavelet entropy+ power spectrum	Random Forest	Physionet 2016	Accuracy 92% Specificity 98% Sensitivity 78%
Homs, M et al 2016 [46]	131 caractéristiques dans les domaines du temps, de la fréquence, de l'ondelette et statistiques	Random Forest+ LogitBoost + Cost-Sensitive	Physionet 2016	accuracy :84.48%

Tableau 2.2 : Tableaux récapitulatif des travaux réalisés pour la détection des anomalies des sons cardiaques

7. Synthèse

L'analyse des travaux met en lumière l'importance cruciale des techniques d'apprentissage automatique et de l'apprentissage profond dans la prédiction et la détection des maladies cardiaques. Plusieurs approches sont discutées, y compris l'utilisation d'algorithmes tels que les SVM (Support Vector Machines), les réseaux de neurones artificiels (ANN), KNN, CNN, et les modèles de forêts aléatoires. L'accent est mis sur l'importance de la précision dans la détection des maladies cardiaques, soulignant la nécessité d'évaluer les performances des modèles à l'aide de différentes méthodes d'extraction de caractéristiques pour garantir leur fiabilité et leur efficacité, telles que les spectrogrammes, les ondelettes, ainsi que les caractéristiques temporelles et fréquentielles. En résumé, ces études montrent comment les avancées en apprentissage automatique et apprentissage profond peuvent être appliquées efficacement pour améliorer la détection et la prédiction des maladies cardiaques, ayant ainsi un impact significatif sur les soins de santé préventifs et l'intervention médicale précoce. Les divers algorithmes utilisés et les résultats obtenus soulignent l'importance de la sélection des techniques appropriées d'extraction de caractéristiques et de classification pour atteindre des performances optimales.

8. conclusion

En conclusion, ce deuxième chapitre a traité de la structure du système de détection des anomalies du battement cardiaque à partir des données des examens PCG. Nous avons décrit et expliqué les travaux qui ont utilisé Machine Learning et ceux qui ont utilisé Deep Learning, en mentionnant et en expliquant toutes les data sets utilisées.

Dans le prochain chapitre, nous présenterons notre solution pour un système intelligent de détection des anomalies du battement cardiaque grâce à l'utilisation des algorithmes du *Machine Learning* avec la Data Set de la compétition PhysioNet/CinC Challenge 2016.

CHAPITRE III

*CADe: Identification of Normal and Abnormal Heart Sounds
system*

1. Introduction

Ce chapitre représente l’apogée de notre mémoire, mettant en lumière les résultats de nos efforts de recherche. Notre objectif principal est de mettre en avant les progrès significatifs que nous avons accomplis dans l’élaboration d’une méthode basée sur les outils de l’intelligence artificielle et les techniques de traitement de signal pour la détection des anomalies et la classification des battements cardiaques. Notre solution proposée qu’on a appelée : **CADe : Identification of Normal and Abnormal Heart Sounds System**. Cette solution est sous la forme d’un système d’aide de diagnostic qui permet la classification des battements cardiaques sur deux classes : battement normal ou anormal. En effet, notre système peut être utilisé sur deux aspects : soit au niveau des battements elle-même ou =au niveau du signal global d’un patient. Notre contribution dans cette solution est la recherche des caractéristiques les plus discriminante pour la classification des battements cardiaques. Dans ce contexte, en premier lieu nous avons focalisé sur les caractéristiques temporelles et en second lieu dans nos futures perspectives nous ajoutons les caractéristiques fréquentielles. Aussi, nous avons travaillé dans notre solution sur la recherche de classifieur adéquat pour la tâche de classification.

2. Architecture du système proposé

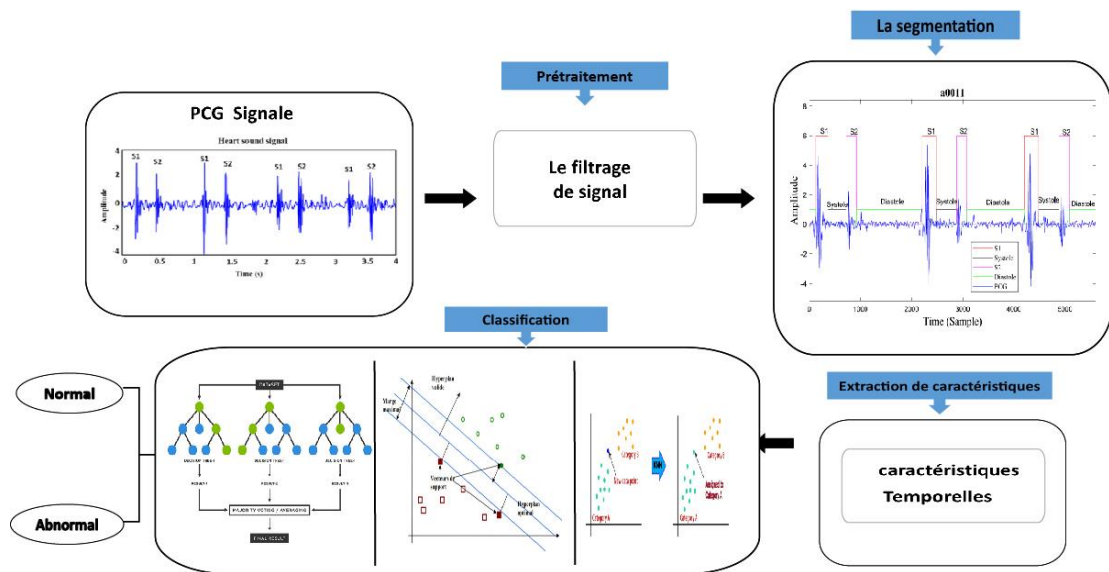


Figure.3.1: Architecture du système Proposé de signaux PCG pour la classification des battements cardiaques

3. Description du data set utilisée

Nous avons utilisé des enregistrements CinC Challenge 2016 de PhysioNet, accessible au public sur le site Internet de PhysioNet. L’ensemble d’entraînement du Challenge est composé de 6 bases de données (de A à F) contenant un total de 3240 enregistrements de sons cardiaques, d’une durée allant de 5 secondes à un peu plus de 120 secondes. En effet, nous avons effectuées certains traitements sur cette dataset qui seront détaillée dans les sections suivantes :

3.1. Vue global du dataset

Ce dataset comprend six ensembles de données d'entraînement (Training-a à Training-f). Chaque ensemble contient un nombre spécifique d'enregistrements normaux et anormaux. Le total des enregistrements est de 3240. Les 6 bases de données (a à f) collectées indépendamment par six équipes de recherche différentes de sept pays et trois continents.

De plus, les données ont été enregistrées à la fois sur des personnes normales et sur des patients pathologiques, ainsi que sur des enfants et des adultes, ce qui signifie que chaque répertoire a ses propres conditions d'enregistrement.

Data set	Normal	Abnormal	Total
Training-a	292	117	409
Training-b	104	386	490
Training-c	24	7	31
Training-d	28	27	55
Training-e	183	1958	2141
Training-f	34	80	114
Total	665	2575	3240

Tableau 3.1: PhysioNet/CinC Challenge dataset

3.2. Description du dataset après la segmentation et validation manuelle

Après le processus de segmentation, les fichiers qui ne contiennent aucun segment valide, autrement dit, les fichiers PCG qui ne contiennent aucun battement sont supprimés. On note que la segmentation est réalisée à l'aide de l'algorithme proposé par Spring [47] et les résultats de cette segmentation sont validés manuellement par des experts du domaine ; c.-à-d. : '*Hand corrected*'. Cette étape touche essentiellement le jeu de données du '*Training-e*' a été réduit de 2141 à 2054, le total des enregistrements est de 3153.

Data set	Normal	Abnormal	Total
Training-a	292	117	409
Training-b	104	386	490
Training-c	24	7	31
Training-d	28	27	55
Training-e	96	1958	2054
Training-f	34	80	114
Total	578	2575	3153

Tableau 3.2: Dataset après segmentation et validation manuelle

3.3. Description du dataset après réduction des enregistrements vides

Lorsque nous avons étudié les fichiers d'annotation, nous avons trouvé des valeurs vides ou dont la validité était incertaine, c'est pourquoi nous avons supprimé ces fichiers, le nombre total est donc passé à 2873. Voici un exemple pour un annotation vide a0008 :

1	1	'N'
2	71611	'N'
3		

Figure.3.2: Exemple d'annotation d'un fichier qui contient des segments incertains

Data set	Normal	Anormal	Total
Training-a	291	101	392
Training-b	13	355	368
Training-c	24	3	27
Training-d	27	25	52
Training-e	5	1921	1926
Training-f	31	77	108
Total	391	2482	2873

Tableau 3.3: Description du dataset après réduction des enregistrements incertains (zéro battement)

3.4. Fichiers d'annotation des signaux PCG des patients

Après la validation manuelle par les experts des résultats de la segmentation, nous trouvons des fichiers d'annotation en format '.csv' pour chaque ensemble de données (A à f). Ce fichier d'annotation contient les noms des fichiers PCG sous forme '.wav' correspondant à l'enregistrement. En effet, les annotations du dataset PhysioNet2016 sont fait pour chaque patient c'est-à-dire par fichier et non pas par battement, cela indique que l'annotation est propagée sur tout le signal PCG. De point de vue codage : la valeur : -1 décrit "Normal" et la :1 signifie "Anormal", la figure suivante représente un exemple d'annotation

6	a0006,1
7	a0007,-1
8	a0008,1
9	a0009,-1
10	a0010,1

Figure.3.3: Le fichiers CSV

4. L'étape de segmentation

4.1. Fichiers de segmentation

Nous avons mentionné dans la section précédente que la dataset *CinC PhysioNet2016* est annoté par patient ; c.-à-d par enregistrement PCG. Dans ce contexte, nous avons opté pour l'annotation de tous les segments par l'annotation du fichier du patient PCG. La figure 3.4 représente un exemple de cette stratégie d'annotation des segments.




Figure.3.4: Exemple de stratégie d'annotation des segments

Le Figure 3.5 représente la séquence des événements cardiaques, enregistrée à l'aide d'un stéthoscope, indiquant le type d'événement cardiaque détecté. Le cycle cardiaque comporte quatre parties (S1, diastole, S2, systole), chacune avec le temps de début et de fin.

2	679	'S1'
3	959	'systole'
4	1479	'S2'
5	1679	'diastole'
6	2719	'S1'

Figure.3.5: Exemple d'un fichier d'annotation du signal PCG

Par exemple, à partir de ce tableau on trouve que la partie du pic S1 se commence à 0.3395 (s) et se termine à 0.473 (s). Entretemps, la figure 3.6 schématise la segmentation des différentes sections d'un signal PCG.




Figure.3.6: Les résultats de la segmentation du signal PCG par la méthode HSMM sur une partie de l'enregistrement « a0011 » existant dans la base de données du challenge Physio net 2016. [47]

4.2. Résultat de la segmentation

Après les différentes étapes de segmentation, nous obtenons le nombre de segment pour chaque ensemble du dataset *CinC PhysioNet2016* mentionné dans le tableau 3.4.

Data set	Normal	Anormal	Total
Training-a	4364	10023	14387
Training-b	2552	636	3188
Training-c	361	1441	1802
Training-d	325	505	830
Training-e	55733	2924	58657
Training-f	3050	1157	4207
Total	66385	16686	83071

Tableau 3.4: Les résultats de la segmentation du signal PCG pour chaque répertoire

5. Extraction de caractéristiques

Dans cette phase nous avons opté pour l'extraction de quatorze caractéristiques dans le domaine temporel pour chaque battement cardiaque. Ces caractéristiques sont :

- ✓ **Moyenne de S1** : Il s'agit de la moyenne des amplitudes du signal dans le segment correspondant au battement S1. Cette caractéristique fournit des informations sur la moyenne des amplitudes du premier battement cardiaque. Il est calculé par la formule suivante :

$$\text{Means}_1 = \sum(\text{Début S1} + \text{Fin S1}) / \text{Taille}$$

- ✓ **Moyenne de Systole** : Il s'agit de la moyenne des amplitudes du signal dans le segment correspondant à la période systolique (entre S1 et S2). Cette caractéristique fournit des informations sur la moyenne des amplitudes pendant la période systolique. Il est calculé par la formule suivante :

$$\text{MeanSys} = \sum(\text{Début Systole} + \text{Fin Systole}) / \text{Taille}$$

- ✓ **Moyenne de S2** : Il s'agit de la moyenne des amplitudes du signal dans le segment correspondant au battement S2. Cette caractéristique fournit des informations sur la moyenne des amplitudes du deuxième battement cardiaque. Il est calculé par la formule suivante :

$$\text{Means}_2 = \sum(\text{Début S2} + \text{Fin S2}) / \text{Taille}$$

- ✓ **Moyenne de Diastole** : Il s'agit de la moyenne des amplitudes du signal dans le segment correspondant à la période diastolique (après S2). Cette caractéristique fournit des informations sur la moyenne des amplitudes pendant la période diastolique. Il est calculé par la formule suivante :

$$\text{MeanDias} = \sum(\text{Début Diastole} + \text{Fin Diastole}) / \text{Taille}$$

- ✓ **Durée de S1** : Il s'agit de la durée du segment correspondant au battement S1, en secondes. Cette caractéristique fournit des informations sur la durée du premier battement cardiaque. Il est calculé par la formule suivante :

$$\text{Lens}_1 = \frac{FS1 - DS1}{s * FS}$$

- ✓ **Durée de Systole** : Il s'agit de la durée du segment correspondant à la période systolique, en secondes (entre S1 et S2). Cette caractéristique fournit des informations sur la durée de la période systolique. Il est calculé par la formule suivante :

$$\text{Lens}_{\text{sys}} = \frac{FS_{\text{systole}} - DS_{\text{systole}}}{s * FS}$$

- ✓ **Durée de S2** : Il s'agit de la durée du segment correspondant au battement S2, en secondes. Cette caractéristique fournit des informations sur la durée du deuxième battement cardiaque. Il est calculé par la formule suivante :

$$\mathbf{Lens}_2 = \frac{FS2 - DS2}{s * FS}$$

- ✓ **Durée de Diastole** : Il s'agit de la durée du segment correspondant à la période diastolique, en secondes (après S2). Cette caractéristique fournit des informations sur la durée de la période diastolique. Il est calculé par la formule suivante :

$$\mathbf{Lend}_{Dias} = \frac{FS_{Diastole} - D_{Diastole}}{s * FS}$$

- ✓ **Amplitude de S1** : Il s'agit de la valeur maximale de l'amplitude du signal dans le segment correspondant au battement S1. Cette caractéristique fournit des informations sur l'amplitude maximale du premier battement cardiaque. Il est calculé par la formule suivante :

$$\mathbf{Amplitudes}_{S1} = \max (DS1 - FS1)$$

- ✓ **Amplitude de S2** : Il s'agit de la valeur maximale de l'amplitude du signal dans le segment correspondant au battement S2. Cette caractéristique fournit des informations sur l'amplitude maximale du deuxième battement cardiaque. Il est calculé par la formule suivante :

$$\mathbf{Amplitudes}_{S2} = \max (DS2 - FS2)$$

- ✓ **Asymétrie de S1** : Il s'agit de la mesure de l'asymétrie du signal dans le segment correspondant au battement S1. Cette caractéristique fournit des informations sur la distribution des amplitudes du premier battement cardiaque.




Figure.3.7: Les différents types de Asymétrie

Elle est calculée par la formule suivante :

$$\mathbf{Skews}_{S1} = \frac{\frac{1}{n} \sum_{i=1}^n (S1_i - \bar{S1})^4}{(\frac{1}{n} \sum_{i=1}^n (S1_i - \bar{S1})^2)^{3/2}}$$

- ✓ **Asymétrie de S2** : Il s'agit de la mesure de l'asymétrie du signal dans le segment correspondant au battement S2. Cette caractéristique fournit des informations sur la distribution des amplitudes du deuxième battement cardiaque. Elle est calculée par la formule suivante :

$$\mathbf{Skews}_{S2} = \frac{\frac{1}{n} \sum_{i=1}^n (S2_i - \bar{S2})^4}{(\frac{1}{n} \sum_{i=1}^n (S2_i - \bar{S2})^2)^{3/2}}$$

- ✓ **Aplatissement de S1** : Il s'agit de la mesure de l'aplatissement du signal dans le segment correspondant au battement S1. Cette caractéristique fournit des informations sur la distribution des amplitudes du premier battement cardiaque.




Figure.3.8: Les différents types de Aplatissement

Elle est calculée par la formule suivante :

$$kurtS1 = \frac{\frac{1}{n} \sum_{i=1}^n (S1_i - \bar{S1})^4}{\left(\frac{1}{n} \sum_{i=1}^n (S1_i - \bar{S1})^2\right)^2} - 3$$

- ✓ **Aplatissement de S2** : Il s'agit de la mesure de l'aplatissement du signal dans le segment correspondant au battement S2. Cette caractéristique fournit des informations sur la distribution des amplitudes du deuxième battement cardiaque. Elle est calculée par la formule suivante :

$$kurtS2 = \frac{\frac{1}{n} \sum_{i=1}^n (S2_i - \bar{S2})^4}{\left(\frac{1}{n} \sum_{i=1}^n (S2_i - \bar{S2})^2\right)^2} - 3$$

6. Résultats et discussion

6.1. Le protocole de test utilisé

Nous avons divisé notre ensemble de données en un échantillon d'entraînement de 80% qui permet à l'algorithme de s'entraîner dessus et un échantillon de test de 20% qui est inconnu pour l'algorithme, qui consiste à tester l'algorithme pour sa capacité de prédiction sur des nouvelles données. Pour faire cela, on utilise la fonction *train_test_split* de la bibliothèque *Sklearn* du langage *Python*.

Data set	Train =80%		Test = 20%	
	Normal	Abnormal	Normal	Abnormal
Training-a	3506	8003	858	2020
Training-b	2019	531	533	105
Training-c	284	1157	77	284
Training-d	269	395	56	110
Training-e	44558	2367	11175	557
Training-f	2444	921	606	236

Tableau 3.5: Le protocole de test utilisé

Entre temps, nous utilisons les histogrammes pour visualiser la repartitions des classes dans cette dataset. En effet, l'histogramme est très utile pour comprendre les caractéristiques des données. On rappelle que, les étiquettes de classe sont soit 0 (pour « Normal ») soit 1 (pour « Abnormal »).




Figure.3.9: Répartitions des classes de la Dataset utilisée

6.2. Les hyperparamètres des algorithmes de classification utilisés

Dans le cadre de notre recherche, nous avons mis en œuvre quatre algorithmes de classification distincts. Chaque algorithme a été configuré avec des hyperparamètres les plus utilisés, qui sont cruciaux pour leur fonctionnement et peuvent avoir un impact significatif sur la performance et les résultats obtenus du modèle.

- ✓ **Forêt aléatoire (Random Forest)** : Nous avons employé l'implémentation *RandomForestClassifier* avec $n_estimators=100$, ce qui signifie que nous avons généré une forêt composée de 100 arbres. Un nombre plus grand d'arbres peut améliorer la performance

du modèle, mais cela augmente également le temps de calcul. Pour garantir la reproductibilité des résultats, nous avons fixé `random_state=42`.

- ✓ **Les k plus proches voisins (K-Nearest Neighbors, KNN)** : Nous avons utilisé l'implémentation `KNeighborsClassifier` avec `n_neighbors=5`, ce qui signifie que nous avons pris en compte les 5 voisins les plus proches pour le vote majoritaire lors de la classification. Un nombre plus grand de voisins peut rendre le modèle plus robuste, mais moins sensible aux petites variations.
- ✓ **Machine à vecteurs de support (Support Vector Machine, SVM)** : Nous avons employé l'implémentation `SVC` avec un noyau RBF (`kernel='rbf'`), un paramètre de régularisation `C=1.0` et un coefficient pour le noyau RBF `gamma='scale'`. Pour garantir la reproductibilité des résultats, nous avons fixé `random_state=42`.
- ✓ **Ensemble de Classifieur** : Nous avons utilisé l'implémentation d'ensemble de classifieur avec une liste d'estimateurs qui comprend le classifieur KNN et le classifieur SVM. Le type de vote a été défini sur 'hard', ce qui signifie que chaque classifieur donne un vote et la classe avec le plus de votes est choisie.

6.3. Résultats de classification obtenus de classifieur

Nous avons entraîné nos modèles de classification avec le protocole de test défini précédemment et nous avons évalué ces modèles avec les métriques suivantes : Accuracy, precision, recall et f1-score.

6.3.1. Le classifieur Random Forest

Data set	Train	Test	Accuracy	precision	recall	f1-score
Training-a	11509	2878	82.70 %	83 %	83 %	81%
Training-b	2550	638	86.52 %	86%	87%	83%
Training-c	1441	361	93.07 %	93 %	93 %	93 %
Training-d	664	166	88.55 %	89%	89 %	88 %
Training-e	46925	11732	99.45 %	99%	99%	99%
Training-f	3365	842	85.63%	86 %	86 %	85%

Tableau 3.6 : Résultats obtenus par le classifieur Random Forest

6.3.2. Le classifieur SVM

Data set	Train	Test	Accuracy	precision	recall	f1-score
Training-a	11509	2878	72.86%	71%	73%	68 %
Training-b	2550	638	83.54%	70 %	84 %	76%
Training-c	1441	361	86.70%	86%	87%	85%
Training-d	664	166	75.30 %	80%	75 %	71%
Training-e	46925	11732	97.70%	98%	98%	97%
Training-f	3365	842	71.97%	52%	72 %	60 %

Tableau 3.7 : Résultats obtenus par le classifieur SVM

6.3.3. Le classifieur Ensemble Classifier

Data set	Train	Test	Accuracy	precision	recall	f1-score
Training-a	11509	2878	71.54%	70%	72%	71%
Training-b	2550	638	83.54%	70 %	84%	76 %
Training-c	1441	361	86.98%	87 %	87 %	87%
Training-d	664	166	72.29%	72 %	72 %	72 %
Training-e	46925	11732	97.47%	97%	97%	97%
Training-f	3365	842	71.97 %	52%	72 %	60 %

Tableau 3.8 : Résultats obtenus par le classifieur Ensemble Classifier

6.3.4. L'algorithme de KNN

Data set	Train	Test	Accuracy	precision	recall	f1-score
Training-a	11509	2878	71.82%	70%	72%	70%
Training-b	2550	638	81.50 %	77%	82 %	78 %
Training-c	1441	361	86.43%	86 %	86 %	86 %
Training-d	664	166	71.08%	71 %	71 %	71 %
Training-e	46925	11732	98.23%	98 %	98 %	98 %

Training-f	3365	842	68.53 %	63 %	69 %	65 %
------------	------	-----	---------	------	------	------

Tableau 3.9 : Résultats obtenus par le classifieur KNN

7. Discussions

La matrice de confusion est un outil précieux pour évaluer la performance de notre modèle, car elle illustre les métriques du Vrai Positif (TP), Vrai Négatif (TN), Faux Positif (FP) et Faux Négatif (FN). Nous avons utilisé quatre algorithmes de classification pour déterminer si une personne est malade ou non : Random Forest, SVM, KNN et un classifieur d'ensemble.

Voici les scores d'accuracy obtenus pour chaque algorithme :

- ✓ Le SVM a obtenu un score d'accuracy de 81%. Bien que ce score soit inférieur à celui du Random Forest, il reste significatif. Ce résultat indique que 81% des prédictions étaient correctes.
- ✓ Le KNN a obtenu un score d'accuracy de 83%. Cela montre une légère amélioration par rapport au SVM et indique que cet algorithme est également performant pour cette tâche.
- ✓ Le classifieur d'ensemble (Voting Classifier) a également obtenu un score d'accuracy de 81%. Ce résultat est identique à celui du SVM, ce qui suggère que la combinaison de KNN et SVM n'a pas apporté d'amélioration notable par rapport à l'utilisation du SVM seul.
- ✓ Le Random Forest a obtenu le meilleur score d'accuracy avec 92%. Cela signifie que 92% des prédictions faites par le modèle étaient correctes. Les résultats détaillés sont les

7.1. Le model de prédiction retenue

Selon les résultats obtenus, nous avons un score très compétitif par rapport à l'état de l'art des travaux réalisés pour ce contexte. On note aussi, qu'on a utilisé uniquement les caractéristiques temporelles et nous visons dans le futur d'améliorer les performances de notre système : *CADE : Identification of Normal and Abnormal Heart Sounds System* par l'intégration de certaines caractéristiques de l'espace fréquentiel. Pour cela, le modèle choisi pour notre système est : *Random Forest* qui enregistre un score d'accuracy de 92% sur l'ensemble de test utilisé.

7.2. Les performances du model retenu

Généralement dans le domaine de l'Intelligence Artificielle et *Machine Learning*, la matrice de confusion présentée dans la figure 3.10 illustre de façon claire les performances des systèmes de classification. Pour dresser cette matrice, nous calculons les paramètres suivants :

- ✓ **Vrai positif (TP)** = 12964, ce qui signifie que 12964 segments de classe positive ont été correctement classés par le modèle.
- ✓ **Vrai négatif (TN)** = 2314, ce qui signifie que 2314 segments de classe négative ont été correctement classés par le modèle.
- ✓ **Faux positif (FP)** = 936, ce qui signifie que 936 segments de classe négative ont été incorrectement classés comme appartenant à la classe positive par le modèle.

- ✓ **Faux négatif (FN) = 401**, ce qui signifie que 401 segments de classe positive ont été incorrectement classés comme appartenant à la classe négative par le modèle.

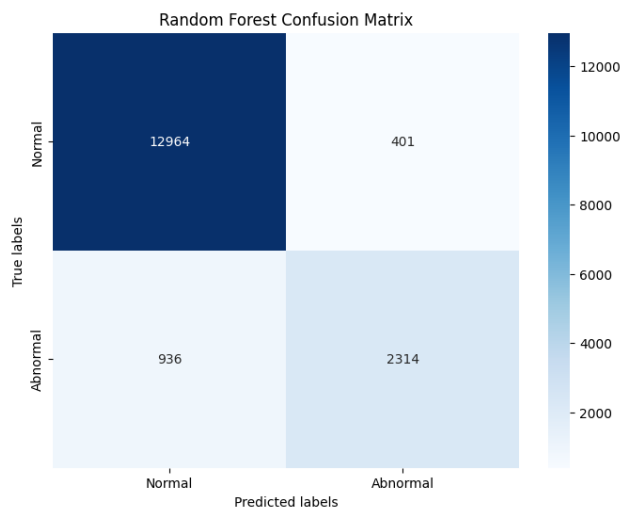


Figure. 3.10: La matrice de confusion du CADe : Identification of Normal and Abnormal Heart Sounds System

7.3. Comparaison avec les Travaux existants

Auteur	Les méthodes d'extraction de caractéristiques	Technique de classification	Data Set utilisée	Résultats
Jinghui Li et al 2019 [43]	Wavelets, entropy, fractal dimension.	twin support vector machine (TWSVM)	Physionet 2016	Accuracy 90.4%, sensitivity 94.6%, specificity 85.5%,
Potes, Parvaneh, Rahman, and Conroy (2016) [36]	Time-domain Features Frequency-domain Features (MFCC)	CNN + AdaBoost	2016 PhysioNet	score:0.8602 Sensitivity: 0.9424 Specificity: 0.7781

Homsy, M et al 2016 [46]	131 caractéristiques dans les domaines du temps, de la fréquence, de l'ondelette et statistiques	Random Forest+ LogitBoost + Cost-Sensitive	Physionet 2016	accuracy :84.48%
Mohammad Nassralla et al 2017 [45]	Time features+ Frequency features5(MFCC)+ Wavelet entropy+ power spectrum	Random Forest	Physionet 2016	Accuracy 92% Specificity 98% Sensitivity 78%
Notre système	Time-domain Features	SVM, KNN,Random Forest , et ensemble classifier	Physionet 2016	Accuracy 91.95% Precision: 0.92% recall : 0.92 %

Tableau 3.10: Un tableau comparaison entre les résultats obtenus et quelques travaux existants

8. Conclusion

En conclusion, ce chapitre a présenté la description de notre système : **CADe : Identification of Normal and Abnormal Heart Sounds System** que nous avons proposé pour la détection des anomalies du rythme cardiaque à partir de signaux PCG, le data set utilisé, les composantes intégrées, ainsi que les logiciels utilisés. Nous avons menés un ensemble d'expérimentations sur les algorithmes de Machine Learning qui sont Random Forest, KNN et SVM et ensemble de classifier et on a afficher et analyser les différents résultats pour chaque algorithme.

Les résultats obtenus lors de nos expérimentations ont montré des performances acceptables, soulignant le potentiel de notre méthode pour améliorer la prise en charge des patients atteints de certaines pathologies cardiaques.

CONCLUSION GÉNÉRALE

Conclusion Générale

Dans cette étude a mis en lumière l'importance cruciale de l'analyse des signaux phonocardiogrammes (PCG) dans le diagnostic des maladies cardiaques normaux et anormaux via l'analyse des battements cardiaques. L'analyse des signaux PCG et la détermination de leur état sont des tâches difficiles qui nécessitent des ressources informatiques puissantes, des techniques de segmentation et de prédiction et une expertise humaine. Nous avons présenté une revue approfondie des techniques d'intelligence artificielle utilisées pour détecter ces anomalies, en mettant en évidence les avancées réalisées dans ce domaine.

À travers notre solution proposée *CADe : Identification of Normal and Abnormal Heart Sounds system*, nous avons démontré comment l'intégration de l'intelligence artificielle, notamment des méthodes de machine Learning, peut améliorer la précision et l'efficacité du diagnostic des battements cardiaques. En utilisant l'ensemble de données 2016 PhysioNet/CinC Challenge, nous avons pu mettre en œuvre une approche encourageante pour la détection des anomalies du battement cardiaque.

Ces avancées sont essentielles dans la pratique clinique, car elles offrent aux professionnels de la santé des outils supplémentaires pour évaluer la santé cardiaque des patients de manière plus précise et plus rapide. En combinant une bonne compréhension de l'anatomie et de la physiologie cardiaque avec des techniques d'intelligence artificielle, nous sommes en mesure d'offrir des solutions diagnostiques plus fiables, ce qui peut avoir un impact significatif sur la prise en charge des maladies cardiovasculaires.

Les résultats obtenus avec un score d'*accuracy* de l'ordre 92% est très prometteur et il est très compétitif par rapport aux méthodes proposées dans la littérature et à la stratégie de choix de caractéristiques retenu lors de cette réalisation de ce projet de fin d'études. De notre point de vue, nous souhaitons principalement améliorer les performances de la solution proposée. Pour ce faire, nous envisageons plusieurs axes d'amélioration.

Il sera nécessaire de modifier l'équilibre des données pour garantir que chaque classe est suffisamment représentée, ce qui devrait améliorer la robustesse et la précision du modèle. Ensuite, l'utilisation de techniques d'extraction de caractéristiques en fréquence permettra de mieux capturer les nuances des signaux cardiaques. L'extraction de caractéristiques telles que les composantes fréquentielles aidera à mieux comprendre et analyser les propriétés inhérentes aux différentes phases des battements cardiaques.

Conclusion Générale

Nous espérons également promouvoir et développer des systèmes plus sophistiqués et plus précis pour détecter les anomalies cardiaques, classer certains types de maladies. Ces améliorations pavent la voie à une meilleure prévention, un diagnostic précoce, et une gestion plus efficace des maladies cardiaques. Notre objectif ultime est d'améliorer la santé du cœur et du patient en général, en fournissant des outils de diagnostic avancés et fiables.

Bibliographies

- [1] Lamraoui, H. (2015/2016). Caractérisation du signal phono cardiogramme. Mémoire pour l'obtention du diplôme de Magister en Électronique, Option Traitement du signal. Université Hadj Lakhdar Batna 2, Faculté de Technologie, Département d'Électronique.
- [2] Cœur : Anatomie, pathologies et traitements <https://www.passeportsante.net/fr/parties-corps/Fiche.aspx?doc=coeur> consulter le 6 /03/2024
- [3] Généralités sur le cœur <https://www.sante-sur-le-net.com/maladies/cardiologie/generalites-coeur/> consulter le 6 /03/2024
- [4] Fonction du cœur <https://www.coeuretavc.ca/maladies-du-coeur/qu-est-ce-que-les-maladies-du-coeur/comment-fonctionne-le-coeur> consulter le 7 /03/2024
- [5] <https://www.kenhub.com/fr/library/anatomie/coeur> consulter le 7 /03/2024
- [6] <https://medizzy.com/feed/11791351> consulter le 11 /03/2024
- [7] Cardiac Cycle <https://courses.lumenlearning.com/suny-ap2/chapter/cardiac-cycle/> consulter le 14 /03/2024
- [8] Présentation des troubles du rythme cardiaque <https://www.msdmanuals.com/fr/accueil/troubles-cardiaques-et-vasculaires/troubles-du-rythme-cardiaque/vue-d-ensemble-des-troubles-du-rythme-cardiaque> consulter le 26/04/2024
- [9] (Moukadem, A. (2011). Segmentation et classification des signaux nonstationnaires. Application au traitement des sons cardiaques et à l'aide au diagnostic. Thèse de doctorat, Université de Haute-Alsace, Mulhouse, France.)
- [10] GUERMOUI, Mouloud. "Analyse spectrale du signal Phonocardiogramme (PCG)." Mémoire de magister en électronique, Université de Batna, Faculté de Technologie, 2011/2012.
- [11] <https://www.docteurcliv.com/examen/phonocardiogramme.aspx> consulter le 27/03/2024
- [12] Electrocardiogramme (ECG) <https://www.sante-sur-le-net.com/maladies/examens-medicaux/electrocardiogramme-ecg/> consulter le 16 /03/2024
- [13] <https://www.passeportsante.net/fr/Maux/examens-medicaux-operations/Fiche.aspx?doc=examen-electrocardiogramme> consulter le 22 /03/2024

[14] MEDDAH, K. (2021). Implémentation sur FPGA d'un système intelligent pour la surveillance de l'état de santé des patients souffrant d'arythmie cardiaque (Thèse de doctorat, Université des Sciences et de la Technologie Houari Boumediène, Faculté d'électronique et Informatique).

[15] Raisons et emplacements des sons cardiaques <https://gesundmd.com/sante/raisons-et-emplacements-des-sons-cardiaques/> consulter le 27/03/2024

[16] <https://www.easyzic.com/dossiers/le-filtrage,h32.html> consulter le 18/04/2024

[17] Deperlioglu, O. (2018). Segmentation of Heart Sounds by Re-Sampled Signal Energy Method. BRAIN – Broad Research in Artificial Intelligence and Neuroscience, 9(1), 18-23. ISSN 2067-8957.

[18] "Temporal-Framing Adaptive Network for Heart Sound Segmentation without Prior Knowledge of State Duration" by Xingyao Wang, Chengyu Liu, Yuwen Li, Xianghong Cheng, Jianqing Li, and Gari D. <https://ieeexplore.ieee.org/abstract/document/9144413>

[19] <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7199391/> consulter le 24 /04 /2024

[20] Xu, X., Geng, X., Gao, Z., Yang, H., Dai, Z., & Zhang, H. (2023). Optimal Heart Sound Segmentation Algorithm Based on K-Mean Clustering and Wavelet Transform. Applied Sciences, 13(2), 1170. <https://doi.org/10.3390/app13021170>

[21] Chen, Y., Sun, Y., Lv, J., Jia, B., & Huang, X. (2021). End-to-end heart sound segmentation using deep convolutional recurrent network. Complex & Intelligent Systems, 7, 2103–2117. <https://doi.org/10.1007/s40747-021-00325-w>

[22] Milani, M.G.M., Abas, P.E., De Silva, L.C., & Nanayakkara, N.D. (2021). Abnormal heart sound classification using phonocardiography signals. Smart Health, 21, 100194.

[23] Kazemnejad, A., Gordany, P., & Sameni, R. (2021, May 18). An Open–Access Simultaneous Electrocardiogram and Phonocardiogram Database. bioRxiv. <https://doi.org/10.1101/2021.05.17.444563>

[24] Chowdhury, M. T. H., Poudel, K. N., & Hu, Y. (2020). Time-Frequency Analysis, Denoising, Compression, Segmentation, and Classification of PCG Signals. IEEE Access, 8, 160882-160892. DOI: 10.1109/ACCESS.2020.3020806

[25] DEKKICHE, Lydia. "Classification des arythmies ECG avec des méthodes de Machine Learning et de Deep Learning. Mémoire de Master, Université Mouloud Mammeri de Tizi Ouzou, Faculté de Génie Électrique et d'Informatique, Département Informatique, 2019-2020.

[26] Random Forest <https://medium.com/@denizgunay/random-forest-af5bde5d7e1e> consulter le 24 /04 /2024

[27] <https://www.ibm.com/fr-fr/topics/knn>

[28] K-Nearest Neighbors (KNN) in Depth <https://ai.plainenglish.io/k-nearest-neighbors-knn-769bd39514c6> consulter le 24 /04 /2024

[29] <https://techvidvan.com/tutorials/artificial-neural-network/> consulter le 24 /04 /2024

[30] <https://towardsdatascience.com/taking-the-confusion-out-of-confusion-matrices-c1ce054b3d3e>

[31] Classification of Heart Sound Recordings: The PhysioNet/Computing in Cardiology Challenge 2016 <https://physionet.org/content/challenge-2016/1.0.0/> consulter le 19 /04 /2024

[32] P Bentley, et al, PASCAL Classifying heart sounds challenge (2011). <https://istethoscope.peterjbentley.com/heartchallenge/index.html> consulter le 19 /04 /2024

[33] Michigan Medicine. Heart Sound & Murmur Library University of Michigan Health System. Ann Arbor. MI.

https://www.med.umich.edu/lrc/psb_open/html/repo/primer_heartsound/primer_heartsound.html consulter le 19 /04 /2024

[34] The CirCor DigiScope Phonocardiogramme Dataset <https://physionet.org/content/circor-heart-sound/1.0.0/> consulter le 24 /04 /2024

[35] Li, F., Tang, H., Shang, S., Mathiak, K., & Cong, F. (2020). Classification of Heart Sounds Using Convolutional Neural Network

[36] Potes, C., Parvaneh, S., Rahman, A., & Conroy, B. (2016). Ensemble of Feature-based and Deep learning-based Classifiers for Detection of Abnormal Heart Sounds. PhysioNet/CinC Challenge, Cambridge, MA, USA

[37] Jan, H., & Tang, C. (2023). An Enhanced Cardiac Auscultation Approach for the detection of abnormal Heartbeat and murmur based on Multimodal Deep Learning. Tianjin University <https://doi.org/10.21203/rs.3.rs-3708860/v1>

- [38] Noman, F., Ting, C. M., Salleh, S. H., & Ombao, H. (2019). Short-segment Heart Sound Classification Using an Ensemble of Deep Convolutional Neural Networks. Dans ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) (pp. 1318-1322). IEEE.
- [39] Lu, H., Yip, J. B., Steigleder, T., Griebhammer, S., Jami, N. V. S., Eskofier, B., Ostgathe, C., & Koelpin, A. (2022). Lightweight Robust Approach for Automatic Heart Murmurs and Clinical Outcomes Classification from Phonocardiogram Recordings.
- [40] Khan, K. N., Khan, F. A., Abid, A., Olmez, T., Dokur, Z., Khandakar, A., Chowdhury, M. E. H., & Khan, M. S. (2023). Deep Learning Based Classification of Unsegmented Phonocardiogram Spectrograms Leveraging Transfer Learning.
- [41] zeinali, Y., & Niaki, S. T. A. (2021). Heart sound classification using signal processing and machine learning algorithms. *Machine Learning with Applications*, 7, 100206. <https://doi.org/10.1016/j.mlwa.2021.100206>
- [42] Vernekar, S., Nair, S., Vijaysenan, D., & Ranjan, R. (2016). A Novel Approach for Classification of Normal/Abnormal Phonocardiogram Recordings using Temporal Signal Analysis and Machine Learning. *Physionet Challenge*.
- [43] Li, J., Ke, L., & Du, Q. (2019). Classification of Heart Sounds Based on the Wavelet Fractal and Twin Support Vector Machine. *Entropy*, 21(5), 472. <https://doi.org/10.3390/e21050472>
- [44] Abduh, Z., Nehary, E. A., Wahed, M. A., & Kadah, Y. M. (2020). Classification of heart sounds using fractional fourier transform based mel-frequency spectral coefficients and traditional classifiers. *Biomedical Signal Processing and Control*, 57, 101788. <https://doi.org/10.1016/j.bspc.2019.101788>
- [45] Nassralla, M., El Zein, Z., & Hajj, H. (2017). Classification of normal and abnormal heart sounds. Conference Paper, Fourth International Conference on Advances in Biomedical Engineering (ICABME). DOI: 10.1109/ICABME.2017.8167538
- [46] Homsy, M. N., Medina, N., Hernandez, M., Quintero, N., Perpiñan, G., Quintana, A., & Warrick, P. (2016). Automatic Heart Sound Recording Classification using a Nested Set of Ensemble Algorithms. *Computing in Cardiology 2016*, 43, ISSN: 2325-887X. DOI:10.22489/CinC.2016.237-325.
- [47] Sadeghi Nia, P., & Danandeh Hesar, H. (2024). Abnormal Heart Sound Detection using Time-Frequency Analysis and Machine Learning Techniques. *Biomedical Signal Processing and Control*, 90, 105899. <https://doi.org/10.1016/j.bspc.2023.105899>