République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Yahia Farès de MEDEA

Faculté de Sciences

Département Mathématique et Informatique



Mémoire de fin d'études

Pour l'obtention du Diplôme de Master en Informatique

Spécialité : Ingénierie des systèmes et technologie du web Thème :

Développement d'une Application d'analyse de PCG (Phonocardiogramme) utiliser Deep Learning

Réalisé par :

- Aboubaker Esedik Kermezli
- Benayad Youssra

Proposé et dirigé par :

- Ahfir Maamar

Année Universitaire

2023 – 2024

Dédicace

Je tiens à exprimer ma plus profonde gratitude à tous ceux qui ont contribué à la réalisation de ce projet de fin d'études.

Tout d'abord, je remercie sincèrement mes parents pour leur soutien indéfectible, leur amour et leur encouragement tout au long de mes études. Leur présence constante et leurs conseils précieux ont été une source d'inspiration et de motivation.

Ensuite, je tiens à remercier ma binôme Youssra, Ta collaboration, ton dévouement et ta détermination ont été essentiels à la réussite de ce projet. Ensemble, nous avons surmonté de nombreux défis et accompli de belles réalisations. Ta camaraderie et ton esprit d'équipe ont rendu ce travail encore plus enrichissant.

Aboubaker Esedik

Dédicace

Je tiens tout d'abord à remercier Dieu pour m'avoir donné la force et la persévérance nécessaires à la réalisation de ce projet de fin d'études.

Je remercie ensuite mes parents, ***papa*** *et* ***mama****, pour leur soutien inconditionnel, leur amour et leurs encouragements constants. Vous avez toujours été là pour moi et je vous en suis infiniment reconnaissant.*

Un grand merci à mes deuxièmes parents, ***Mamati*** *et* ***Babahanoni****, pour leur soutien et leurs précieux conseils.*

Je remercie également mes sœurs, ***Hadil*** *et Mal****ak, Loubna*** *et mon frère,* ***Abdellah****, pour leur amour et leur encouragement tout au long de ce parcours.*

À ma seule ***tante****, je vous adresse mes plus sincères remerciements pour votre présence et votre soutien.*

Merci à mon binôme, ***Aboubaker Essedik****, pour ta collaboration et ton dévouement sans faille. Ce projet n'aurait pas été possible sans toi.*

Je n'oublie pas mes amis ***Ibtihel****,* ***Lilia, et Feriel****, pour leur soutien moral et leur amitié précieuse.*

Enfin, un grand merci à tous ceux qui m'aiment et qui ont cru en moi.

Youssra

Remerciements

On remercie dieu le tout puissant de nous avoir donné la santé et la volanté d'entamer et déterminer ce mémoire. Tout d'abord, ce travail ne serait pas aussi riche et n'aurait pas pu avoir le jour sans l'aide et l'encadrement de Mr ahfir maamar, on le remercie pour la qualité de son encadrement exceptionnel, pour sa patience, sa rigueur et sa disponibilité durant notre préparation de ce mémoire. Nos remerciements s'adressent à Mr Boudjebbour Karim pour avoir accepté de présider la commission d'évaluation de notre travail. Nous remercions aussi Mr Mazari Redha d'avoir accepté d'examiner notre travail. Nos remerciements s'adressent également à tous nos enseignants pour leurs générosités et la grande patience dont ils ont fait preuve malgré leurs charges académiques et professionnelles.

Résumé :

Les difficultés de l'auscultation cardiaque, qui dépend de l'interprétation approfondie des anomalies des sons cardiaques à l'aide d'un stéthoscope, sont importantes. En automatisant la détection des battements cardiaques anormaux, l'apprentissage profond présente une solution prometteuse, ce qui permet de diminuer la dépendance à l'expertise humaine. Toutefois, cette automatisation nécessite une grande fiabilité et précision, tout en offrant une gestion efficace du bruit de fond des enregistrements cardiaques. Ce projet présente une approche novatrice qui utilise des réseaux de neurones récurrents (RNNs) pour réaliser une auscultation cardiaque automatisée et aider les médecins généralistes à analyser les sons cardiaques enregistrés par un phonocardiogramme (PCG). Notre approche repose principalement sur les RNNs, qui sont renommés pour leur efficacité dans les applications médicales et leur capacité à traiter des données séquentielles malgré le bruit. Après avoir expérimenté différents modèles RNN, nous constatons des progrès notables dans la catégorisation des battements cardiaques inhabituels. Pour la surveillance à distance des patients.

Mots de clés :

RNNs : Réseau neurone récurant

PCG : Phonocardiogramme

ECG : Electrocardiogramme

Liste des Figures :

Figure I.1 : Anatomie du cœur

FigureI.2 : Phonocardiogramme (ci-dessus) à partir de bruits cardiaques normaux et anormaux avec diagrammes de pression (ci-dessous). Le rouge indique la pression aortique, le vert la pression ventriculaire et le bleu la pression auriculaire. Reproduit sous licence CC BY-SA 3.0 et adapté de (Madhero, 2010).[7]

Figure I.3 : Représente les sons cardiaques

Figure I.4 : PCG d'un signal normal

Figure I.5 : Représentation d'un cycle cardiaque contenant le signal (S3)

Figure I.6: Représente normalized PCG and ECG signal

Figure I.7: Représentation d'un cycle cardiaque contenant une Rétrécissement aortique de forte

Figure I.8: Représente insuffisance mitrale

Figure I.9: Représentation d'un cycle cardiaque contenant une Rétrécissement pulmonaire

Figure I.10 : Représentation d'un cycle cardiaque contenant une Communication inter-ventriculaire

Figure I.11: Représentation d'un cycle cardiaque contenant un rétrécissement mitral

Figure I.12: Représentation d'un cycle cardiaque contenant une insuffisance aortique

Figure II.1: schéma de réseau de neurones

Figure II.2: Perceptron monocouche

Figure II.3: Perceptron multicouche (PMC)

Figure II.4: Results for an example of a normal PCG

Figure II.6: (a) Un PCG anormal normalisé ; b) la fonction T calculée à partir du responsable (comme expliqué à la section II) ; c) détection du front montant de la fonction T, la partie positive de la dérivée de T(n) à utiliser comme donnée d'entrée pour le réseau LRNN ; (d) les résultats de la sortie du LRNN (ligne bleue) avec les états étiquetés ECG (ligne verte)

Figure III.1: Signal analogique pour un PCG

Figure III.2: Détection de l'enveloppe

Figure III.3: Enveloppe (Hilbert) plot avec T and R

Figure III.4: PCG plot avec signal d'étagé

Figure III.5: Architecture du Modèle

FigureIII.6 : Résultats de la segmentation PCG avec RNN (ligne bleu) par rapport aux états marques(réel)ECG (ligne orange).

Figure III.7 : Résultats de la segmentation PCG anormal avec RNN (ligne bleu) par rapport aux états marques(réel)ECG (ligne orange).

FigureIII.8: Accuracy plot

Figure III.9: Precision plot

FigureIII.10: Recall plot

FigureIII.11 : F1_score plot

FigureIV.1 : Diagramme générale représente le rôle pour cette application

Figure IV.2 : Achitecture de l'application

Figure IV.3: Interface de l'utilisateur intuitive

Figure IV.4: Interface où importer un fichier Wav ou Mp3

Figure IV.5 : Interface en cas d'erreur

Les Tableaux :

Tableau III.1 : Les résultat du Model RNN pour les phases cardiaques.

Tableau III.2 : Matrice de confusion des phases cardiaque

Tableau III.3 : Table de comparaison des modèles déférents

Sommaire

Introduction générale : *13*
Chapitre 1 : Généralités sur le Phonocardiogramme 14
Chapitre 2 : La Segmentation utilisant les Réseaux de Neurones 14
Chapitre 3 : Les Résultats de Simulation 14
Chapitre 4 : Développement de l'Application Android 14
Chapitre I : Généralité sur le Phonocardiogramme *16*
1 Introduction : *16*
2 L'auscultation cardiaque : *16*
2.1 Technique d'auscultation : **16**
2.2 Signes auscultatoires : **17**
2.3 Les outils d'auscultation (Le Stéthoscope) : **17**
2.4 Technologies modernes d'auscultation : **18**
2.5 La limitation d'auscultation subjective : **18**
3 Phonocardiogramme : *18*
3.1 Introduction : **18**
4 Analyse des Segments Cardiaques : *19*
5 Les courbes de pression : *19*
5.1 Courbe de pression ventriculaire : **19**
5.1.1 Systole ventriculaire : 19
5.1.2 Diastole ventriculaire : 19
5.2 Courbe de pression auriculaire : **20**
5.3 Courbe de pression dans les gros vaisseaux : **20**
6 Les phases du cycle cardiaque sont : *21*
7 Les sons et les souffles cardiovasculaires Édition *22*
7.1 Les sons cardiaques : **22**
7.2 Les souffles cardiaques : **23**
7.2.1 Les souffles systoliques : 24
7.2.2 Les souffles diastoliques : 27
8 Conclusion : *29*
Chapitre II : Segmentation des PCG par Réseaux LRNN *31*
1 Introduction : *31*
2 Historique de réseau de neurones : *31*
3 Domaines d'application des réseaux de neurones artificiels : *32*
4 Définition des réseaux de neurones : *32*
4.1 Fonction d'activation : **33**

4.2 Différentes structures de réseaux de neurones artificiels : 33
4.3 Types de réseaux de neurones : 34
4.3.1 Réseaux feed-forward : 34
4.3.2 Réseaux feed-back : 35
5 Apprentissage : 35
5.1 Types d'apprentissage : 36
5.1.1 Apprentissage supervisé : 36
5.1.2 Apprentissage non supervisé : 36
5.1.3 Mixte : 37
6 Procédure de développement d'un réseau de neurones : 37
7 Techniques d'optimisation et de régularisation : 38
8 Défis et limitations des réseaux de neurones : 38
9 La déférence entre RNN et LRNN : 39
10 Méthodes d'acquisition et de prétraitement des données PCG : 39
10.1 Prétraitement des données PCG : 39
11 Principaux modèles d'apprentissage profond pour l'analyse de signaux biomédicaux : 40
12 Segmentation des Phonocardiogrammes : 40
12.1 Normalisation : 41
12.2 Variation de la longueur de la courbe : 42
12.3 Explication Détaillée du Processus d'Étiquetage des Sons S1 et S2 : 45
12.4 L'évaluation : 47
13 Conclusion : 48
Chapitre III : Résultats de Simulation 51
1 Introduction : 51
2 Importance de la Simulation pour l'Entraînement et l'Identification des Phases Cardiaques : 51
3 Environnement de Simulation : 52
3.1 Configuration Logicielle : 52
4 Description des Données : 52
5 Résultats obtenus de la Segmentation du signal PCG : 53
6 Modèle de Réseaux de Neurones Utilisé : 55
6.1 Architecture du Modèle : 55
7 Architecture du Modèle LSTM : 56
8 Entraînement du Modèle : 56

8.1 Hyperparamètres Utilisés 56
8.2 Algorithme d'Optimisation : 57
8.3 Processus d'Entraînement : 57
9 Résultats de l'Entraînement : 57
9.1.1 Matrices de Confusion : 59
9.2 Discussion des résultats obtenus : 59
9.2.1 Précision et Rappel : 59
9.2.2 Performances robustes pour la systole et la diastole : 59
9.2.3 AUC : 60
10 Conclusion : 60
Chapitre04 : Conception de système, Développement et implémentation, Validation et tests 62
1 Introduction : 62
2 Conception de Système : 62
2.1 Outil de développement : 62
2.2 Langage de programmation : 63
3 Architecture de l'application smartphone/tablette : 64
3.1 Flux de travail d'enregistrement et d'analyse des bruits cardiaque à l'aide du modèle RNN : 64
3.2 Achitecture de l'application : 64
3.3 Intégration du Modèle de Deep Learning 65
3.4 Conversion du Modèle Entraîné 65
3.5 Chargement du Modèle sur l'Appareil Mobile 65
3.6 Exécution du Modèle sur l'Appareil Mobile 66
3.7 Entraînement et Sauvegarde du Modèle : 66
4 Développement et Implémentation : 66
4.1 Présentation de l'application : 66
4.2 Interface Utilisateur Intuitive : 67
5 Conclusion : 70
Conclusion générale : 72
Références Bibliographique : 74

Introduction générale

Introduction générale :

La détection et l'analyse des sons cardiaques sont des éléments cruciaux pour le diagnostic des maladies cardiovasculaires. Traditionnellement, l'auscultation avec un stéthoscope est la méthode primaire utilisée par les médecins pour écouter les sons cardiaques et détecter les anomalies. Cependant, cette méthode repose fortement sur l'expertise et l'expérience de l'opérateur, ce qui peut conduire à des variations dans la précision des diagnostics. Avec l'avènement des technologies de traitement du signal et de l'intelligence artificielle, il est désormais possible d'automatiser l'analyse des sons cardiaques à l'aide de modèles de Deep Learning. Ces modèles peuvent potentiellement offrir une analyse plus objective et précise, aidant ainsi les cliniciens à détecter les anomalies cardiaques avec une plus grande fiabilité. Ce projet vise à développer un modèle de Deep Learning pour la segmentation et l'identification des différentes phases du cycle cardiaque à partir des Phonocardiogramme (PCGs), et à intégrer ce modèle dans une application mobile utilisable sur les plateformes Android et iOS.

La segmentation et l'analyse des sons cardiaques présentent plusieurs défis. Les phases du cycle cardiaque (S1, S2, systole, diastole) doivent être correctement identifiées et segmentées pour permettre une analyse précise, mais les méthodes traditionnelles peuvent être limitées par le bruit ambiant, la variabilité des signaux cardiaques et les compétences de l'opérateur. Bien que les solutions actuelles utilisant des modèles de Deep Learning montrent des résultats prometteurs, des défis subsistent, notamment en termes de précision, de rappel et de robustesse dans diverses conditions. L'objectif de ce projet est de développer et d'entraîner un modèle de Deep Learning basé sur les réseaux de neurones récurrents (RNN), spécifiquement des LSTM (Long Short-Term Memory), pour la segmentation des sons cardiaques, de mesurer les performances du modèle en termes de précision, rappel, F1-score et AUC, et de comparer les résultats avec ceux des méthodes existantes. Le projet vise également à convertir le modèle entraîné pour une utilisation sur des appareils mobiles via TensorFlow Lite pour Android et Core ML pour iOS, et à développer une application mobile pour l'enregistrement, l'analyse et la visualisation des sons cardiaques. Enfin, il prévoit de tester l'application dans des conditions réelles pour évaluer sa performance et sa fiabilité dans un contexte clinique.

Organisation du mémoire :

Chapitre 1 : Généralités sur le Phonocardiogramme

Le phonocardiogramme est un enregistrement des sons cardiaques, essentiel pour détecter et diagnostiquer les anomalies cardiaques. Ce chapitre décrit les bases du PCG, expliquant comment les sons cardiaques sont produits et enregistrés. Il explore également l'importance clinique des PCG, les différentes techniques d'acquisition, et les défis associés à l'interprétation des signaux. La compréhension de ces bases est fondamentale pour développer des outils d'analyse efficaces.

Chapitre 2 : La Segmentation utilisant les Réseaux de Neurones

La segmentation des phonocardiogramme est une étape cruciale dans leur analyse. Elle consiste à diviser le signal en segments significatifs pour faciliter l'interprétation. Ce chapitre se concentre sur l'utilisation des réseaux de neurones pour la segmentation des PCG. Il détaille les architectures de réseaux de neurones utilisées, les algorithmes d'entraînement, et les méthodes d'évaluation de la performance. L'accent est mis sur les avantages de l'IA pour améliorer la précision et l'efficacité de la segmentation.

Chapitre 3 : Les Résultats de Simulation

Ce chapitre présente les résultats des simulations réalisées pour évaluer la performance des réseaux de neurones dans la segmentation des PCG. Les résultats sont analysés en termes de précision, rappel et spécificité. Ce chapitre compare également les performances de différentes architectures de réseaux de neurones et méthodes de segmentation, mettant en lumière les avantages et les limitations de l'approche proposée. L'objectif est de démontrer l'efficacité et la robustesse des réseaux de neurones pour cette application.

Chapitre 4 : Développement de l'Application Android

Le dernier chapitre se concentre sur le développement pratique de l'application Android. Il décrit le processus de conception de l'application, les technologies et outils utilisés, et les défis rencontrés. L'intégration des réseaux de neurones dans l'application, la conception de l'interface utilisateur, et les tests effectués pour garantir une utilisation fluide et efficace sont détaillés. Ce chapitre vise à montrer comment les avancées théoriques en IA peuvent être transformées en outils pratiques pour les professionnels de la santé.

Chapitre1

Généralité sur le Phonocardiogramme

Chapitre I : Généralité sur le Phonocardiogramme

1 Introduction :

Dans cette section, nous explorons en profondeur les divers bruits cardiaques qui peuvent se manifester dans des conditions de santé normales ainsi que dans des situations pathologiques affectant le cœur. Nous examinons également les origines anatomiques et physiologiques de ces sons perceptibles lors de l'examen médical à l'aide d'un stéthoscope.

2 L’auscultation cardiaque :

L’auscultation cardiaque est une technique permettant d’écouter le rythme du battement du cœur à l’aide d’un stéthoscope, elle fait partie intégrante de l’examen clinique du malade ou patient.

2.1 Technique d’auscultation :

Le cœur est ausculté chez un patient torse nu, dans un environnement calme.
En général, le patient est couché sur le dos (décubitus dorsal), mais certaines anomalies peuvent être mieux perceptibles en position assise ou lorsque le patient est couché sur le côté gauche (décubitus latéral gauche).
Les principales zones d'écoute comprennent :
Le foyer aortique se situe un peu en dessous de l'extrémité interne de la clavicule droite (deuxième espace intercostal droit, en face du sternum).
Un peu en dessous de l'extrémité interne de la clavicule gauche se trouve le foyer pulmonaire (deuxième espace intercostal gauche, contre le sternum).
Au niveau de la pointe du cœur, on peut identifier l'apex ou le foyer apexien (mitral) en palpant la partie gauche du thorax.
En dedans de la zone précédente, sous le sternum, se trouve le foyer xiphoïdien (tricuspide). [1]

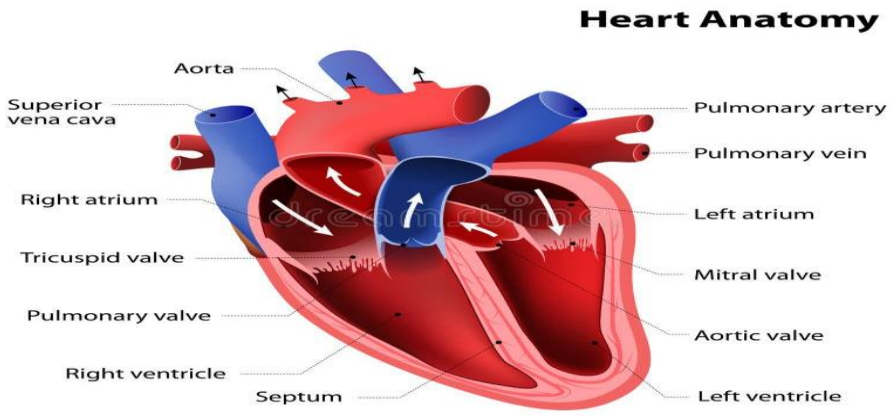


Figure I.1 : Anatomie du cœur

2.2 Signes auscultatoires :

- Bruits du cœur : Sons brefs et transitoires reflétant l'ouverture et la fermeture des valvules. Ils sont classés en bruits systoliques et diastoliques
- Souffles : Produits par une turbulence du flux sanguin, ils sont plus prolongés que les bruits cardiaques. Ils peuvent être systoliques, diastoliques ou continus.
- Frottements : Bruits aigus, souvent avec 2 ou 3 composants séparés, qui peuvent varier en fonction de la position du corps. En cas de tachycardie, le bruit peut être presque continu.[2]

2.3 Les outils d'auscultation (Le Stéthoscope) :

Le stéthoscope est un instrument médical essentiel qui sert à l'auscultation, c'est-à-dire à l'écoute des sons internes du corps. Voici une introduction détaillée sur le stéthoscope :

Historique :

Le Stéthoscope est fabriqué d'une simple liasse de papier roulé pour aider à amplifier les sons cardiaques atténués par les couches musculaires de la poitrine, le stéthoscope à vue le jour le 17 février 1816 en France par le Docteur René Laeneec [3]. En 1840, deux Américains Maurice Rappaport et Howard Sprague proposent un stéthoscope composé de deux pavillons :

l'un pour ausculter le cœur, l'autre pour ausculter les poumons. En 1870 des stéthoscopes différentiels apparaissent avec deux pavillons, montés chacun sur un tube et connecté à une oreille. Ils devaient permettre de comparer l'auscultation à deux endroits différents. En 1961, Dr David Littmann propose.[4]

2.4 Technologies modernes d'auscultation :

Des informations sur les avancées technologiques récentes dans le domaine de l'auscultation cardiaque, telles que l'échocardiographie ou la phonocardiographie Même si la méthode d'auscultation repose toujours sur l'expertise du médecin, développée à partir de fondements théoriques, puis confirmée par l'expérience personnelle.

2.5 La limitation d'auscultation subjective :

Les études ont démontré que les médecins avaient des compétences en auscultation insuffisantes pour les patients présentant des anomalies acoustiques de faible impact. Cela entraîne des consultations inutiles chez les cardiologues, ce qui entraîne des dépenses et un stress élevé. Les compétences en auscultation n'ont pas été significativement améliorées par l'application répétée de méthodes d'entraînement standard. Il est donc évident qu'il est indispensable d'avoir des aides au diagnostic dans ce domaine, tant pour la formation que pour une utilisation clinique.

3 Phonocardiogramme :

3.1 Introduction :

L'analyse d'un phonocardiogramme (PCG) est une tâche effectuée par des professionnels de la santé, généralement des cardiologues ou des spécialistes en médecine cardiovasculaire. Cette analyse vise à interpréter les enregistrements des sons cardiaques afin de diagnostiquer d'éventuelles anomalies ou pathologies cardiaques.

4 Analyse des Segments Cardiaques :

L'analyse des segments cardiaques est une technique d'imagerie médicale qui divise le cœur en segments distincts pour une évaluation détaillée de sa structure et de sa fonction. Cette approche permet de détecter les anomalies de mouvement des parois cardiaques, telles que l'akinésie ou l'hypokinésie, qui peuvent indiquer des pathologies myocardiques. La segmentation standard du ventricule gauche en 17 segments facilite l'interprétation des images et la comparaison des résultats entre différents patients et modalités d'imagerie. C'est un outil essentiel pour le diagnostic précis et le suivi des maladies cardiaques.[5]

5 Les courbes de pression :

5.1 Courbe de pression ventriculaire :

5.1.1 Systole ventriculaire :

Contraction isovolumétrique :

- Début avec la fermeture de la valve mitrale.
- Augmentation rapide de la pression sans changement de volume, mesurée par dP/dT.

Éjection :

- Ouverture des valves aortiques lorsque la pression ventriculaire dépasse la pression artérielle.
- La pression atteint un pic, puis diminue tandis que le volume ventriculaire baisse.

5.1.2 Diastole ventriculaire :

Relaxation isovolumétrique :

- Valves auriculo-ventriculaires et sigmoïdes fermées.
- Pression ventriculaire diminue jusqu'à être inférieure à celle de l'atrium.

Remplissage :

- Remplissage rapide : Pression auriculaire > pression ventriculaire, entraînant un remplissage rapide du ventricule.

- Remplissage lent : Pression ventriculaire augmente progressivement.
- Diastasis : Équilibre des pressions entre le ventricule et l'oreillette.
- Remplissage actif : Systole auriculaire pousse le sang restant dans le ventricule, marquant la fin du remplissage.[6]

5.2 Courbe de pression auriculaire :

Systole auriculaire :

- Augmentation de la pression auriculaire (onde a) due à la contraction de l'atrium.
- Fermeture des valves auriculo-ventriculaires au point z, lorsque la pression ventriculaire dépasse la pression auriculaire.

Diastole auriculaire :

- Valves fermées se bombent dans l'oreillette, provoquant une onde c.
- Baisse de pression visible sous le creux x.
- Augmentation de la pression (onde v) due au remplissage des veines pulmonaires.
- Diminution rapide de la pression auriculaire (creux y) lors de l'ouverture des valves auriculo-ventriculaires.[7]

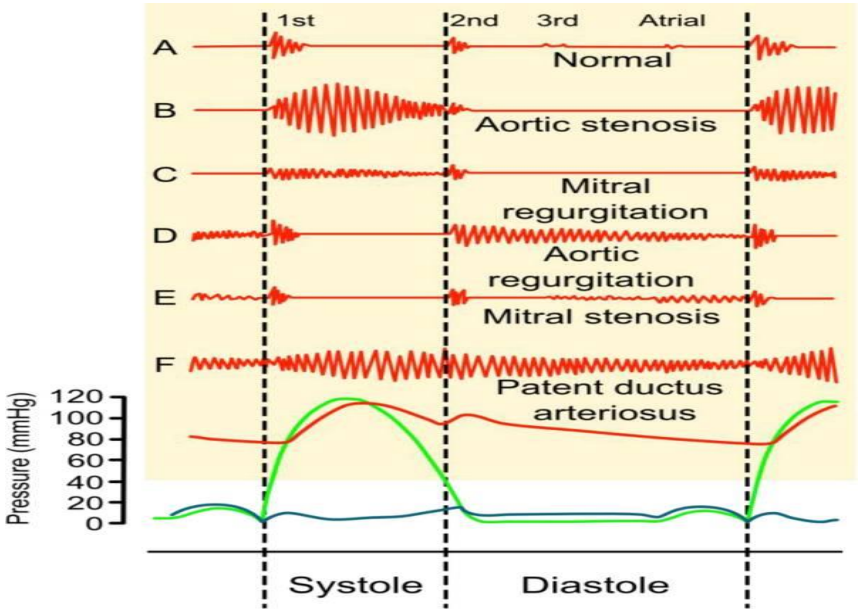
5.3 Courbe de pression dans les gros vaisseaux :

Dilatation des sigmoïdes :

- Pression ventriculaire > pression aortique, entraînant l'ouverture des sigmoïdes.
- Éjection rapide : Augmentation soudaine de la pression dans l'aorte.
- Éjection lente : Stabilisation de la pression aortique parallèlement à celle du ventricule.
- Fermeture des sigmoïdes suivie d'un ressaut de pression lorsque la pression aortique dépasse celle du ventricule.

Diastole :

- Diminution progressive de la pression aortique, restant toujours supérieure à la pression ventriculaire.
- Baisse de pression due à l'évacuation du sang vers les artères périphériques.[8]



FigureI.2 : Phonocardiogramme (ci-dessus) à partir de bruits cardiaques normaux et anormaux avec diagrammes de pression (ci-dessous). Le rouge indique la pression aortique, le vert la pression ventriculaire et le bleu la pression auriculaire. Reproduit sous licence CC BY-SA 3.0 et adapté de (Madhero, 2010).[**9]**

6 Les phases du cycle cardiaque sont :

- La systole auriculaire (a), la contraction isométrique
- L'éjection maximale
- L'éjection minimale
- La phase protodiastolique
- La relaxation isométrique
- Le remplissage rapide
- Le diastasis, ou le remplissage lent du ventricule gauche (h). À fin d'illustration, les intervalles de temps entre les périodes valvulaires ont été modifiés et le point z a été prolongé.

7 Les sons et les souffles cardiovasculaires Édition

Les sons et les souffles cardiovasculaires font référence aux bruits audibles produits par le cœur et les vaisseaux sanguins lors du cycle cardiaque.

7.1 Les sons cardiaques :

Les sons cardiaques normaux sont produits par la fermeture des valves cardiaques et sont généralement décrits comme des "lub-dub". Les deux principaux sons cardiaques sont :

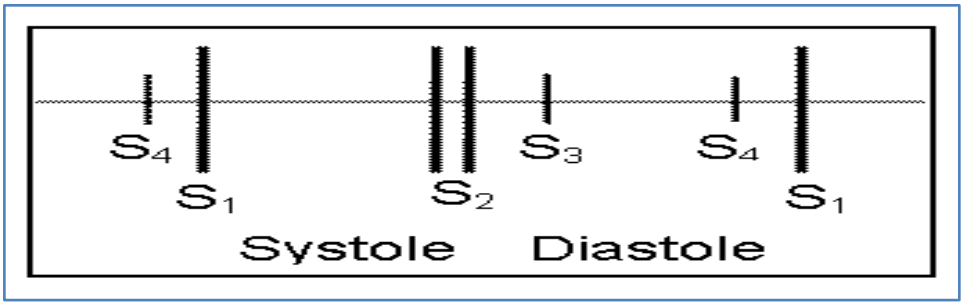


Figure I.3 : Représente les sons cardiaques

- **S1 (Premier bruit du cœur) :**

Le premier bruit du cœur, ou S1, est causé par la fermeture des valves mitrale et tricuspide au début de la systole ventriculaire.

Caractéristiques Sonores : S1 est généralement plus long et moins intense que S2.

- **S2 (Deuxième bruit du cœur)** :

Le deuxième bruit du cœur, ou S2, est produit par la fermeture des valves aortique et pulmonaire à la fin de la systole ventriculaire.

Caractéristiques Sonores : S2 est plus bref et plus aigu que S1.

- **Systole** :

La systole est la phase du cycle cardiaque où les ventricules se contractent pour éjecter le sang dans l'aorte et l'artère pulmonaire.

Caractéristiques Sonores : La systole se situe entre S1 et S2 et peut inclure des murmures systoliques dans les cas pathologiques.

- **Diastole** :

Description : La diastole est la phase de relaxation du cœur où les ventricules se remplissent de sang provenant des oreillettes.

Caractéristiques Sonores : La diastole suit S2 et précède S1, et peut inclure des murmures diastoliques en cas de certaines conditions pathologiques.[10]

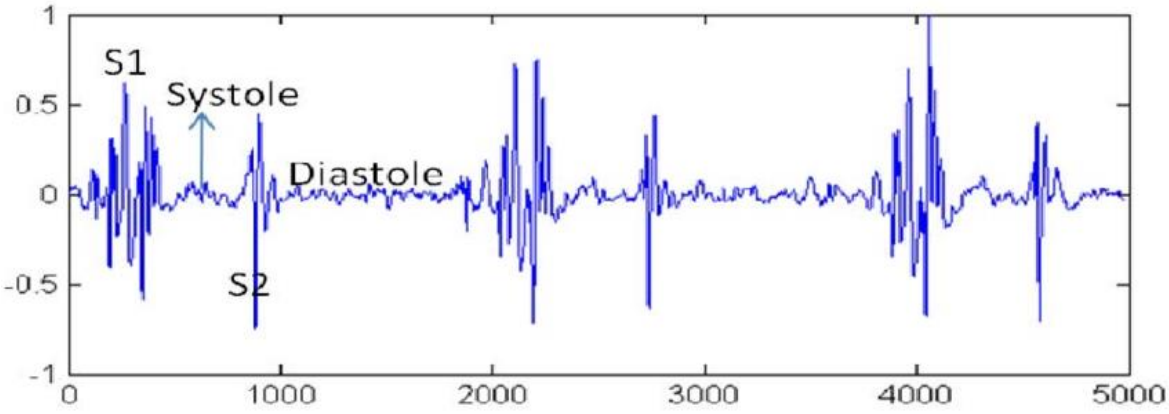


Figure I.4 : PCG d'un signal normal

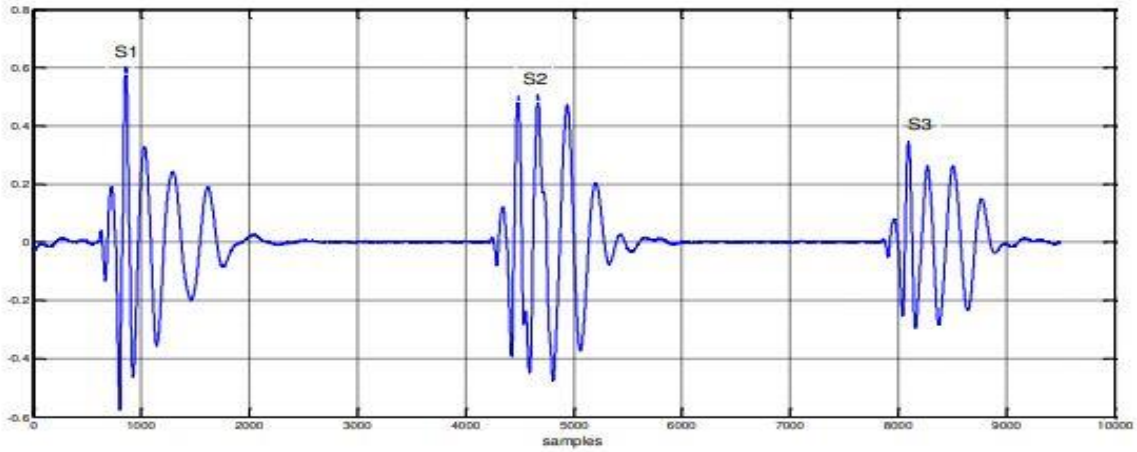


Figure I.5 : Représentation d'un cycle cardiaque contenant le signal (S3)

7.2 Les souffles cardiaques :

Les souffles sont des bruits anormaux résultant d'un écoulement turbulent du sang à travers les valves cardiaques ou les vaisseaux sanguins. Ils peuvent être dus à des anomalies structurelles telles que des sténoses, des fuites, des rétrécissements ou des communications anormales entre les cavités cardiaques. Les souffles sont généralement classés en souffles systoliques (audibles entre S1 et S2), souffles diastoliques (audibles après S2), ou souffles continus (audibles tout au long du cycle cardiaque).

L'auscultation cardiaque à l'aide d'un stéthoscope permet de détecter et d'évaluer ces sons et souffles cardiovasculaires. Une interprétation précise de ces bruits peut fournir des informations importantes sur la fonction cardiaque et aider à diagnostiquer diverses affections

cardiovasculaires, telles que les valvulopathies, les cardiopathies congénitales, les maladies coronariennes, ou les malformations cardiaques.

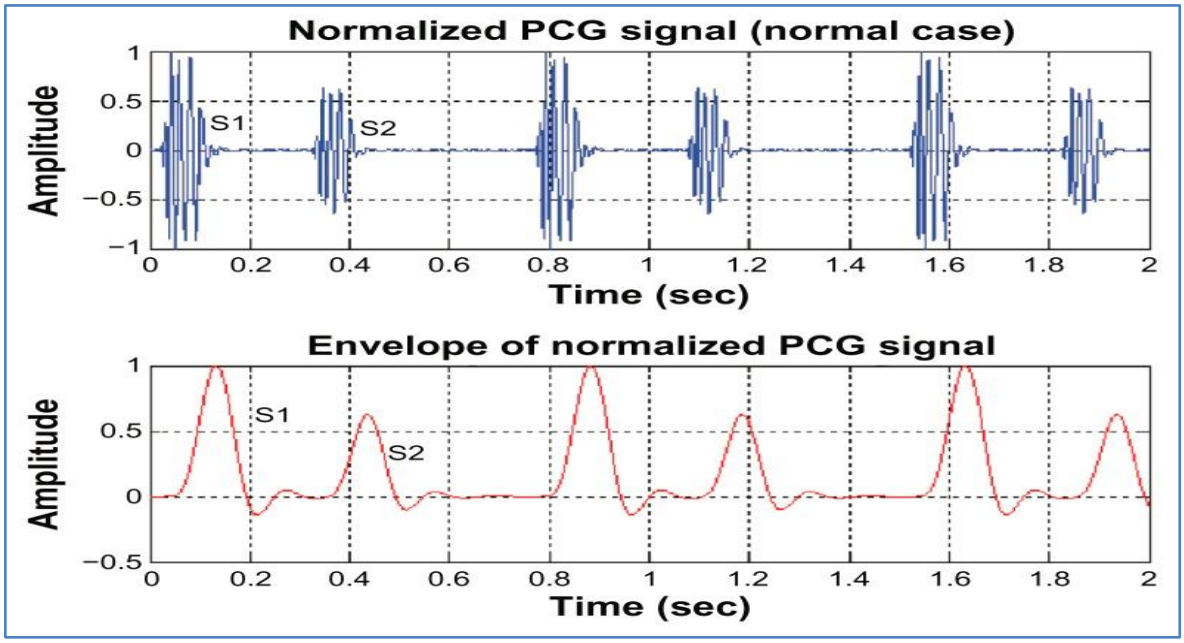


Figure I.6: Représente normalized PCG and ECG signal

7.2.1 Les souffles systoliques :

Les souffles -systoliques ont des bruits anormaux entendus lors de l'auscultation du cœur entre le premier et le deuxième bruit cardiaque (S1 et S2), c'est-à-dire pendant la phase de systole cardiaque.

Origine : Le souffle systolique est souvent associé à des anomalies des valves cardiaques, telles que l'insuffisance mitrale (lorsque les valves mitrales ne se ferment pas complètement, permettant au sang de revenir dans le ventricule gauche).[11]
Localisation : Ce bruit est généralement perçu à la pointe du cœur (côté gauche du thorax).

Intensité : Les souffles sont classés en intensité sur une échelle de 1 à 6, reflétant leur degré de sévérité :

- Très faible
- Faible
- Modéré
- Assez fort
- Fort
- Très fort

- **Rétrécissement aortique** :

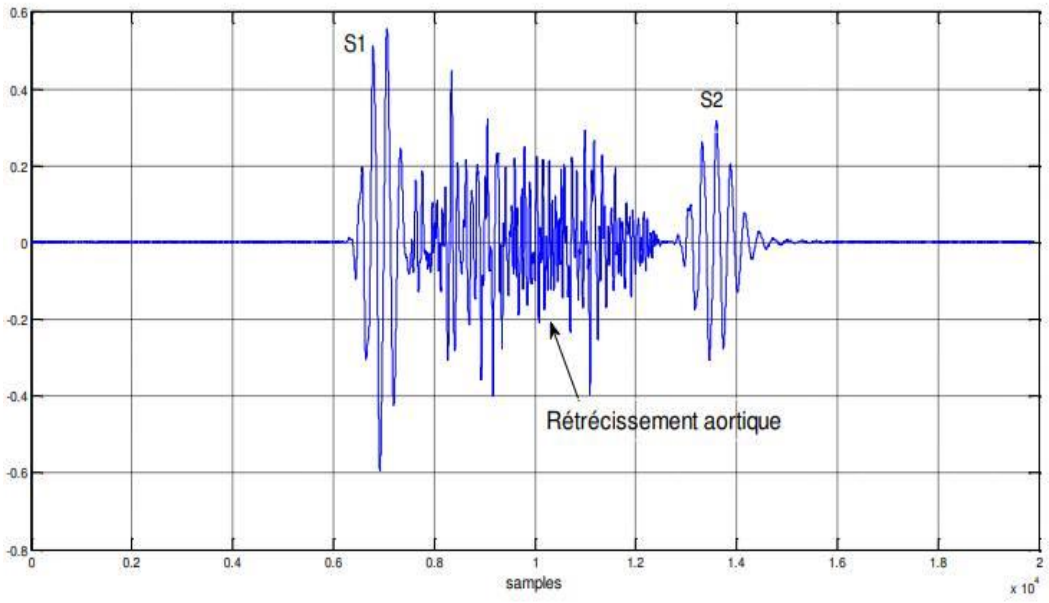


Figure I.7: Représentation d'un cycle cardiaque contenant une Rétrécissement aortique de forte

- **Insuffisance mitrale :**

La pathologie de l'insuffisance mitrale "I.M" se manifeste par le reflux systolique du sang du ventricule gauche vers l'oreillette gauche en raison de la détérioration de l'étanchéité. Ce qui aura pour conséquence une surcharge volumique du ventricule gauche et une augmentation des pressions dans l'oreillette gauche et dans la circulation pulmonaire

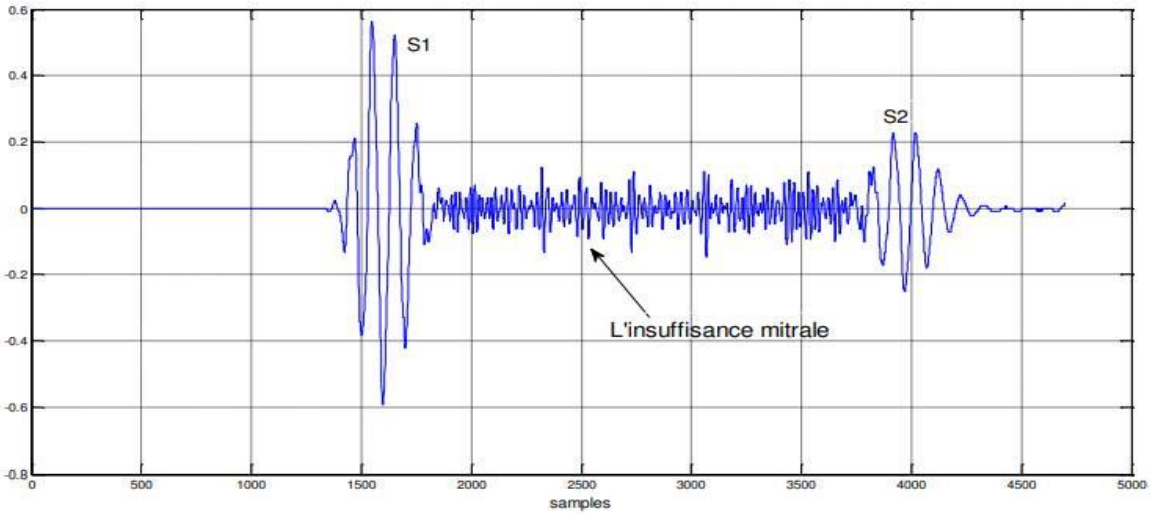


Figure I.8: Représente insuffisance mitrale

- **Rétrécissement pulmonaire :**

Le rétrécissement de la valvule pulmonaire (qui permet au sang de circuler du ventricule (cavité inférieure) droit du cœur vers les poumons). Ainsi, il est nécessaire que le ventricule droit pompe plus intensément que la normale afin de surmonter cette difficulté. Il est possible que cela entraîne une surcharge du ventricule droit et entraîne une augmentation de son volume. [11]

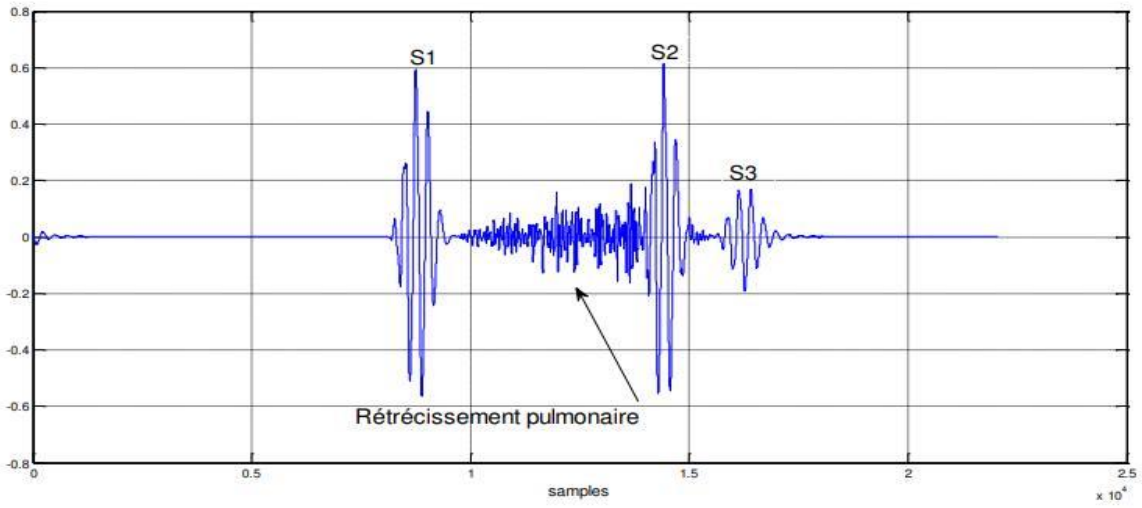


Figure I.9: Représentation d'un cycle cardiaque contenant une Rétrécissement

- **Communication inter-ventriculaire :**

La malformation cardiaque congénitale la plus courante est la communication inter-ventriculaire (CIV), qui représenterait environ 40 % de toutes les cardiopathies congénitales chez l'homme.

Le septum inter-ventriculaire est une cloison hermétique qui sépare les ventricules droit et gauche dans le cœur normal.

La présence d'un orifice plus ou moins large dans cette cloison est connue sous le nom de CIV, ce qui permet un passage direct du sang d'un ventricule vers l'autre.

L'impact de cette malformation est principalement influencé par la taille de la communication. Le développement d'une CIV varie en fonction de sa position sur le septum, certaines étant susceptibles de se refermer spontanément dans les mois ou années qui suivent la naissance. Le souffle systolique diffus (en rayons de roue) est observé lors de l'auscultation cardiaque, dont l'intensité est inversement proportionnelle à la volume de la communication. La gravité de la CIV ne se reflète donc en aucun cas par l'intensité du souffle (on pourrait même dire au contraire...).[11]

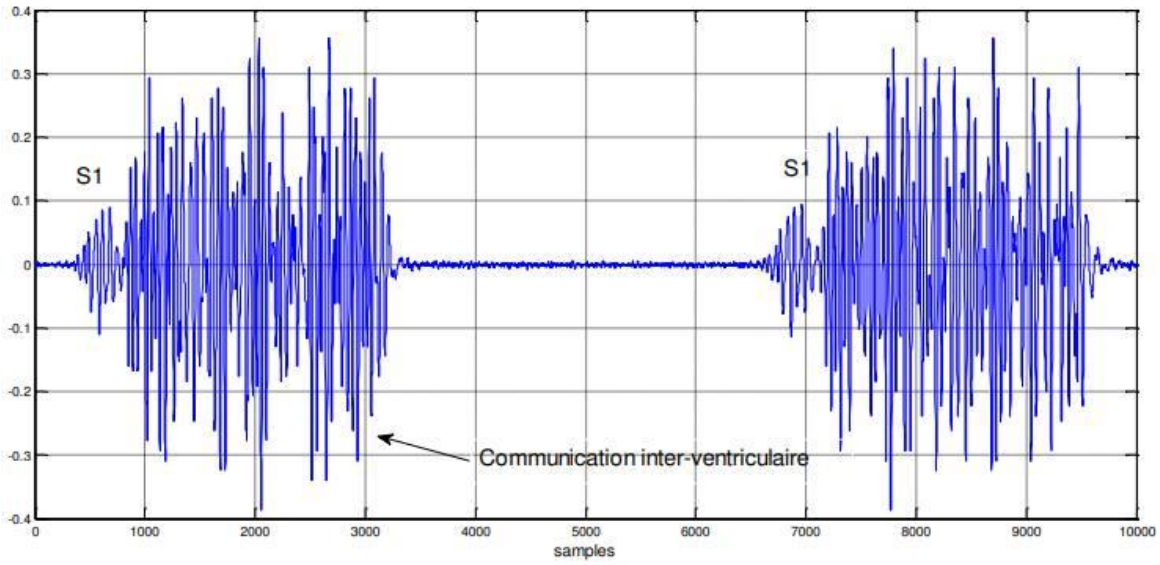


Figure I.10 : Représentation d'un cycle cardiaque contenant une Communication inter-ventriculaire

7.2.2 Les souffles diastoliques :

Les souffles diastoliques sont des bruits anormaux entendus pendant la phase de relaxation du cœur, après la fermeture des valves semi-lunaires. Ils peuvent indiquer des problèmes comme des fuites de valves cardiaques ou des rétrécissements des artères ou des valves. Ces bruits nécessitent une évaluation approfondie pour déterminer leur origine et leur signification clinique.

- **Rétrécissement mitral :**

Le resserrement du ventricule gauche empêche le remplissage diastolique du ventricule gauche en réduisant la surface mitrale fonctionnelle (inférieure à 2,5 cm2). Le déplacement du sang à travers cette valve rétrécie va entra

îner, bien sûr, un souffle diastolique autour de la zone mitrale. [12]

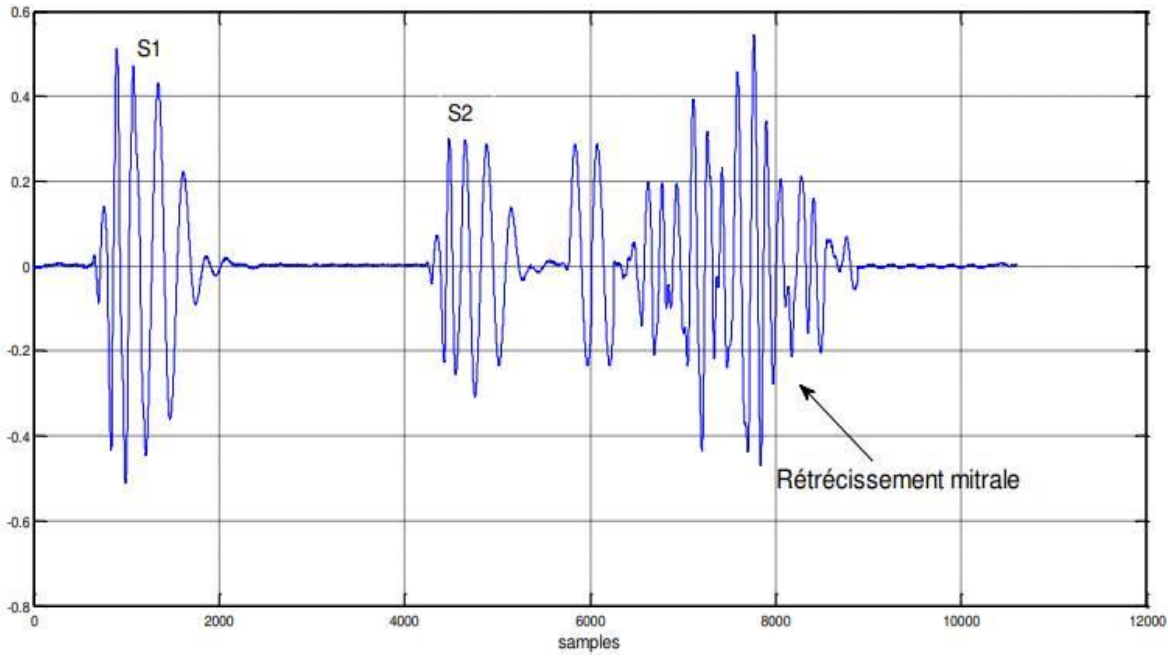


Figure I.11: Représentation d'un cycle cardiaque contenant un rétrécissement mitral

- **Insuffisance aortique :**

L'insuffisance aortique "IA" est une condition où le sang de l'aorte reflue anormalement dans le ventricule gauche pendant la diastole, ce qui se produit lorsque la valve aortique du cœur ne se ferme pas entièrement. [12]

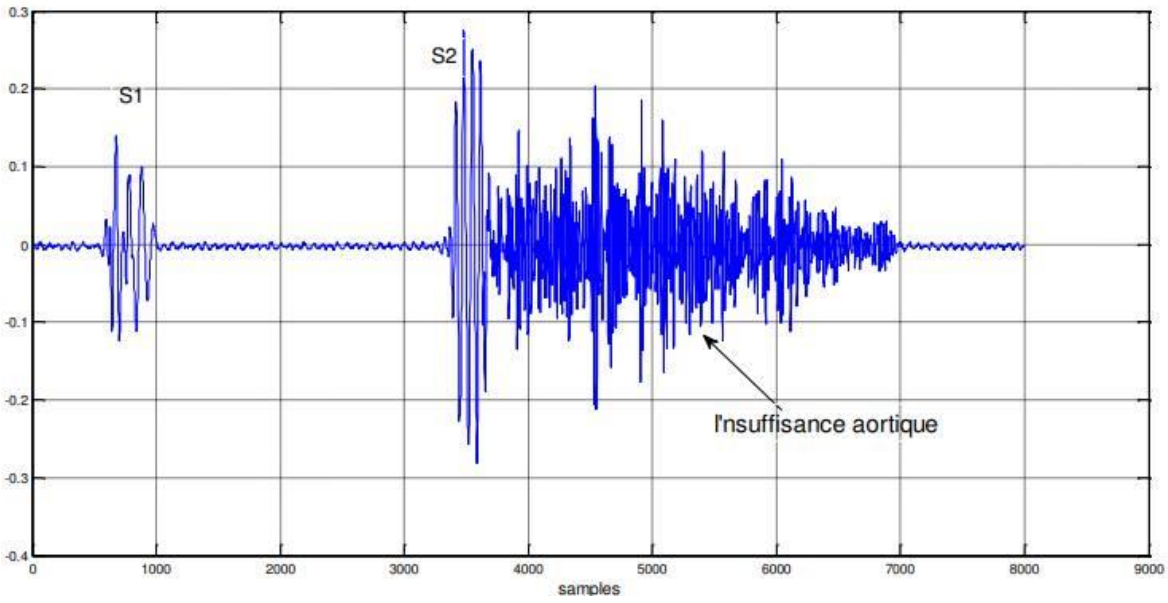


Figure I.12: Représentation d'un cycle cardiaque contenant une insuffisance aortique

8 Conclusion :

En conclusion, le phonocardiogramme (PCG) est un outil diagnostique précieux qui enregistre les sons cardiaques, permettant ainsi de détecter les anomalies cardiaques, notamment les dysfonctionnements valvulaires. L'analyse du PCG, grâce à des techniques avancées comme la segmentation automatique et l'analyse spectrale, contribue significativement à la détection précoce des pathologies cardiaques sans nécessiter de référence au signal ECG.

Chapitre 02 :

Réseaux de neurones artificiels

Segmentation des PCG par Réseaux LRNN

Chapitre II : Segmentation des PCG par Réseaux LRNN

1 Introduction :

La phonocardiographie est une technique de diagnostic qui enregistre les sons produits par le cœur, appelés phonocardiogramme (PCG). Ces enregistrements sont essentiels pour la détection et le diagnostic de diverses maladies cardiaques. Cependant, l'analyse manuelle des PCG est une tâche complexe et laborieuse, nécessitant des compétences spécialisées. Pour automatiser et améliorer la précision de cette analyse, les réseaux de neurones récurrents à long terme (Long Short-Term Memory Recurrent Neural Networks, LSTM-RNN) se sont révélés particulièrement efficaces. Ce chapitre explore l'application des LSTM-RNN dans la segmentation des Phonocardiogrammes, en détaillant les techniques utilisées, les défis rencontrés et les résultats obtenus. Nous commencerons par une présentation des concepts fondamentaux des réseaux LSTM-RNN et de leur pertinence pour le traitement des séquences temporelles comme les PCG, avant de passer à la description de la méthodologie de segmentation adoptée et à l'analyse des performances du modèle.

2 Historique de réseau de neurones :

Les réseaux de neurones sont donc une histoire relativement jeune (60 ans) mais les applications intéressantes des réseaux de neurones n'ont vu le jour qu'il y a une trentaine d'années avec le développement de l'informatique. En effet, ce n'est que depuis le début des années 1990 que les réseaux de neurone artificiels, généralement utilisés en physique, font leur entrée en management en tant que méthode quantitative de prévisions à côté des méthodes statistiques classiques. Les réseaux de neurones artificiels sont particulièrement utilisés en finance mais également dans d'autres domaines de gestion.

Il existe deux raisons principales pour lesquelles les chercheurs en sciences de gestion se sont intéressés aux réseaux de neurones artificiels :

À l'inverse des méthodes statistiques classiques, les réseaux de neurones artificiels ne nécessitent aucune hypothèse sur les variables.

Les réseaux de neurones artificiels sont parfaitement adaptés pour traiter des problèmes complexes non structurés (problèmes sur lesquels il est impossible de définir la relation entre les variables utilisées).[13]

3 Domaines d'application des réseaux de neurones artificiels :

- Traitement d'image
- Traitement du signal
- Traitement automatique des langues
- Optimisation
- Simulation
- Classification d'espèces animales
- Modélisation de l'apprentissage
- Approximation d'une fonction inconnue

4 Définition des réseaux de neurones :

Sont des modèles d'apprentissage automatique inspirés par le fonctionnement du cerveau humain. Ils sont utilisés pour résoudre des problèmes complexes tels que la classification, la régression, la reconnaissance de motifs et bien plus encore. Voici une définition plus détaillée :

- Un réseau de neurones est composé de neurones artificiels (ou unités) interconnectés. Chaque neurone reçoit des entrées, effectue des calculs et produit une sortie.
- Les neurones sont organisés en couches. La première couche est la couche d'entrée, suivie de couches cachées (si présentes) et enfin la couche de sortie.
- Chaque connexion entre les neurones à un poids qui détermine l'importance de cette connexion.
- L'apprentissage se fait par ajustement des poids en fonction des données d'entraînement.
- Les réseaux de neurones utilisent des fonctions d'activation pour introduire de la non-linéarité dans le modèle [14]

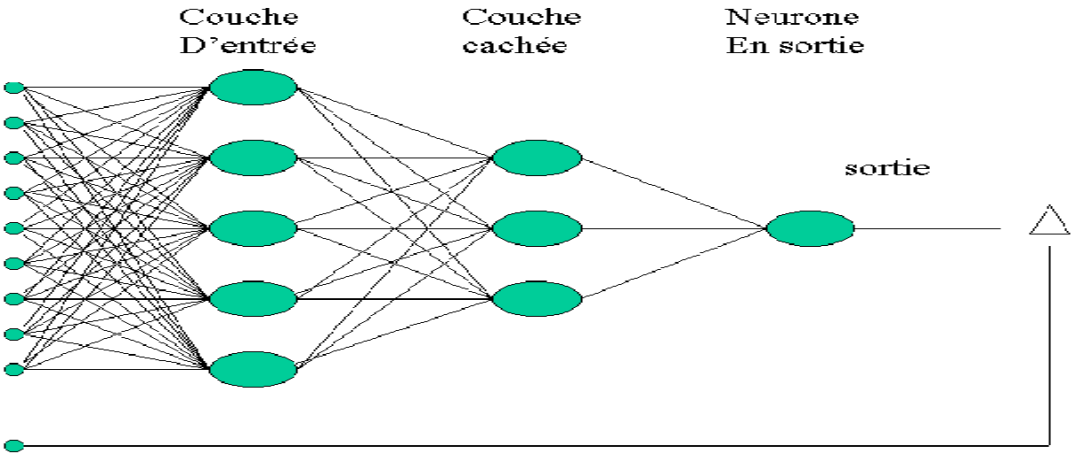


Figure II.1: schéma de réseau de neurones

4.1 Fonction d'activation :

La fonction d'activation est une équation mathématique appliquée à un neurone dans un réseau neuronal**.** Elle détermine si le neurone doit être activé ou non. Voici quelques caractéristiques importantes des fonctions d'activation

- Non-linéarité
- Différentiable
- Étendue
- Monotonie
- Douceté (dérivée monotone)
- Identité en 0

4.2 Différentes structures de réseaux de neurones artificiels :

L'évolution des poids et biais durant l'apprentissage d'un réseau de neurones est effectué par le format des données entrées. Pour cela on distingue deux types de réseaux :

- Les réseaux de neurones statiques (ou acycliques, ou non bouclés).
- Les réseaux de neurones dynamiques (ou récurrentes, ou bouclés).

Un réseau est considéré comme statique lorsqu'il ne dispose pas de connexion arrière (feedback ou retard). Ainsi, les données en entrée peuvent être présentées dans n'importe quel

ordre, ce qui n'aura pas d'impact sur l'évolution de ses poids pendant la phase d'apprentissage. Il est donc recommandé de lui fournir l'intégralité du jeu de données en une seule fois pendant la phase d'apprentissage. L'apprentissage par paquet (« batch training ») est alors utilisé. Les réseaux « feedforward » ne sont pas capables de reproduire des processus qui sont liés au temps. En revanche, si l'on souhaite reproduire un processus qui dépend du temps, il sera possible d'utiliser un réseau de neurones qui comprend des connexions arrière appelées « feed-back ». Il sera donc essentiel de respecter l'ordre de présentation du jeu de données au réseau de neurones.[15]

4.3 Types de réseaux de neurones :

4.3.1 Réseaux feed-forward :

Appelés aussi « réseau de type Perceptron », ce sont des réseaux dans lequel l'information entrée se propage de couche en couche sans retour en arrière possible

- **Perceptron monocouche**

Le neurone artificiel le plus basique (monocouche) réalise des calculs pour repérer des caractéristiques dans les données d'entrée. Cet algorithme est utilisé pour l'apprentissage supervisé de classificateur binaire, ce qui permet aux neurones artificiels d'acquérir et de traiter les éléments d'un ensemble de données.[16]

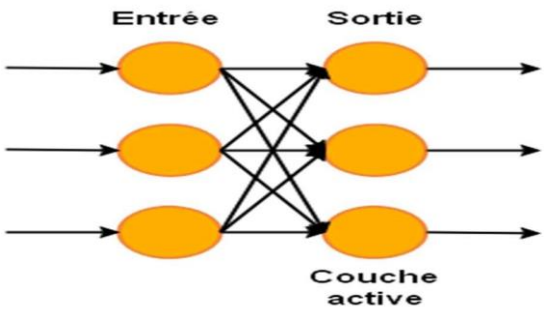


Figure II.2: Perceptron monocouche

- **Perceptron multicouche (PMC) :**

Il y a plus de deux couches de base dans le perceptron multicouche, il y a une ou plusieurs couches intermédiaires appelées couches cachées. Les différentes couches réalisent des

calculs mathématiques sur nos données. Il est difficile de déterminer le nombre de couches cachées et le nombre de neurones pour chaque couche lors de la création de réseaux de neurones.[16]

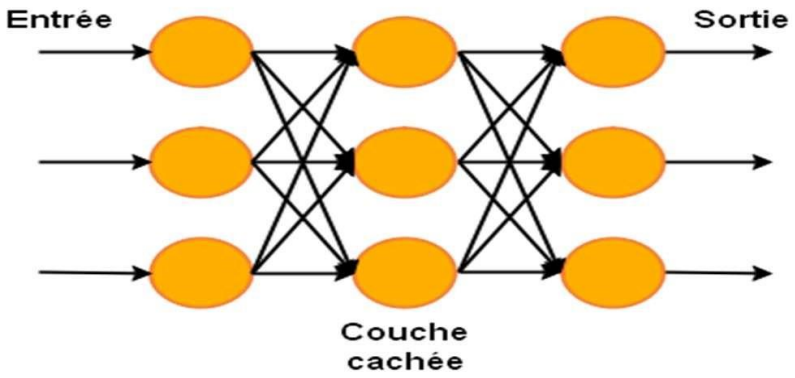


Figure II.3: Perceptron multicouche (PMC)

4.3.2 Réseaux feed-back :

Ces réseaux offrent la possibilité de connexions arbitraires entre les neurones de toutes les couches ; en se déplaçant dans le réseau en suivant le sens des connexions, il est envisageable de trouver au moins un chemin qui revient à son point de départ. Ces réseaux de neurones artificiels (RNA) forment la deuxième grande catégorie.[17]

5 Apprentissage :

L'apprentissage consiste à adapter la connaissance du RNA au problème posé, La connaissance étant définie par l'ensemble des pondérations sur les liens du réseau ainsi que par sa topologie, l'apprentissage est donc étroitement lié au réglage adéquat des poids d'interconnexion, ainsi qu'à l'adaptation de la topologie [18]

5.1 Types d'apprentissage :

5.1.1 Apprentissage supervisé :

Dans l'apprentissage supervisé, un ensemble d'apprentissage est utilisé afin d'enseigner aux modèles à obtenir les résultats nécessaires. Ce jeu d'entraînement de données contient des entrées et des sorties précises, ce qui permet au modèle de progresser au fil du temps. La précision de l'algorithme est évaluée en utilisant la fonction de perte, en s'adaptant jusqu'à ce que l'erreur soit assez faible. Lors de l'exploration de données, l'apprentissage supervisé permet de résoudre deux types de problèmes :

La classification :

L'algorithme de classification permet d'attribuer précisément des données de test à des catégories spécifiques. L'algorithme identifie des éléments particuliers dans le jeu de données et essaie de déterminer comment ces éléments doivent être étiquetés ou définis. Les algorithmes de classification les plus fréquents comprennent les classificateurs linéaires, les machines à vecteurs de support (SVM), les arbres de décision, les k plus proches voisins et les forêts d'arbres décisionnels, qui sont précisément décrits ci-dessous.

La régression :

La régression permet de comprendre la relation entre les variables dépendantes et indépendantes. Elle est couramment utilisée pour établir des projections, telles que le chiffre d'affaires d'une entreprise donnée. La régression linéaire, la régression logistique et la régression polynomiale sont des algorithmes de régression populaires.

5.1.2 Apprentissage non supervisé :

L'apprentissage automatique non supervisé et l'apprentissage automatique supervisé sont fréquemment mentionnés en même temps. À la différence de l'apprentissage supervisé, l'apprentissage non supervisé se base sur des données non structurées. Ces données lui permettent de trouver des modèles qui permettent de résoudre les problèmes de regroupement ou d'association. Cela se révèle particulièrement bénéfique lorsque les experts du domaine ne sont pas certains des caractéristiques communes d'un jeu de données. Les algorithmes de regroupement fréquemment utilisés comprennent des modèles hiérarchiques, des moyennes k et des mélanges GA. Lorsqu'une seule partie des données d'entrée a été étiquetée, on parle d'apprentissage semi-supervisé. Les alternatives plus intéressantes peuvent être les apprentissages non supervisé et semi-supervisé, car il peut être difficile et coûteux de faire appel à l'expertise du domaine pour étiqueter les données de manière adéquate dans le cadre de l'apprentissage supervisé.

5.1.3 Mixte :

Ce genre d'apprentissage est un mélange des autres genres mentionnés précédemment. Ce genre d'apprentissage se produit lorsque l'ensemble de l'apprentissage n'est pas parfait, ce qui nécessite d'autres exemples pour une meilleure compréhension du concept. Ainsi, dans cette situation, on déterminera une partie des poids en utilisant l'apprentissage supervisé et l'autre partie en utilisant l'apprentissage non supervisé.

6 Procédure de développement d'un réseau de neurones :

On peut résumer la mise en œuvre d'un réseau de neurones dans les étapes suivantes :

- Collection de données (ensemble d'apprentissage) : cette étape est très importante car son objectif est de rassembler des données suffisante et fiable avec le minimum de bruit pour l'apprentissage et pour le test de notre système.
- Analyse de données : Cette étape permet d'éliminer la redondance de la base de données ce qui nous permettre de minimaliser le temps de simulation et d'apprentissage à travers la réduction de la taille du réseau.
- Subdivision de la base de données : Dans cette étape on va séparer la base de données en deux parties : une pour l'apprentissage et l'autre pour le test. Elle dépend de la quantité de données à notre disposition et le temps disponible pour l'apprentissage.
- Choix du type de réseau : Cette étape dépend de plusieurs critères, comme la nature du problème (Classification, Catégorisation, Compression), la nature de données à analyser, les contraintes temporelles,
- Normalisation de données : Consiste à faire un prétraitement de données pour déterminer les motifs et les paramètre de notre ensemble ce qui nous permettre de la normaliser.
- Choix de l'algorithme d'apprentissage : Le but derrière ce choix et d'atteindre la performance et la rapidité de convergence optimale. On peut d'abord utiliser un apprentissage structurel ou la comparaison entre différentes architectures testées sur le réseau.
- Validation du réseau : en utilisant la partie de données de test de notre base, on fait l'audit de la performance du système, si on n'est pas satisfait, on va éventuellement soit changer le type de réseau ou la méthode d'apprentissage et de test.

7 Techniques d'optimisation et de régularisation :

Les techniques d'optimisation et de régularisation sont cruciales en apprentissage automatique pour améliorer la performance des modèles et prévenir le surajustement

❖ **Optimisation :**

- **Descente de Gradient** : Méthode itérative pour minimiser la fonction de coût.
- **Momentum**: Accélère la descente de gradient en direction des minima.
- **Adam** : Combinaison de descente de gradient avec momentum et taux d'apprentissage adaptatif.

❖ **Régularisation :**

- **L1 (Lasso)** : Ajoute une pénalité proportionnelle à la somme absolue des valeurs des coefficients du modèle, ce qui peut conduire à des coefficients nuls et donc à un modèle plus simple et plus général.
- **L2 (Ridge)** : Ajoute une pénalité proportionnelle à la somme des carrés des valeurs des coefficients, ce qui réduit leur taille mais ne les rend pas nuls, favorisant un modèle avec de petits coefficients.
- **Elastic Net** : Combine les pénalités L1 et L2 pour profiter des avantages des deux méthodes.
- **Dropout** : Pendant l'entraînement, certains neurones sont "éteints" aléatoirement, ce qui force le réseau à ne pas dépendre trop fortement d'un seul chemin et encourage la redondance dans l'apprentissage [19].

8 Défis et limitations des réseaux de neurones :

Malgré leur puissance, les réseaux de neurones présentent certaines limites :

Ils nécessitent généralement une grande quantité de données par rapport aux algorithmes traditionnels d'apprentissage automatique.

Ils sont moins efficaces pour les problèmes qui nécessitent un raisonnement ou une prise de décision.

Ils sont souvent considérés comme des « boîtes noires », rendant difficile la compréhension de leur fonctionnement interne.

Ils peuvent être coûteux en termes de puissance de calcul, surtout pour les réseaux les plus profonds et complexes

Le développement des réseaux de neurones peut être long et complexe. Cependant, des bibliothèques comme Keras simplifient la tâche.

Microsoft Research travaille sur des innovations en intelligence artificielle. Le focus est mis sur de nouvelles architectures et des techniques d'apprentissage en profondeur. En effet, ils visent aussi à améliorer l'efficacité et la précision des modèles. Enfin, ils explorent des applications dans la vision par ordinateur et la reconnaissance vocale.

Ainsi, les réseaux de neurones ont des limites, mais leur capacité à apprendre est précieuse. Ils sont utiles pour prendre des décisions de manière autonome dans de nombreuses applications [20]

9 La déférence entre RNN et LRNN :

La principale différence entre les Long Short-Term Memory networks (LSTM) et les Recurrent Neural Networks (RNN) réside dans leur capacité à gérer la dépendance à long terme dans les séquences de données. Les RNN traditionnels souffrent du problème de gradient Vanishing, ce qui les rend inefficaces pour mémoriser des informations sur de longues périodes. Les LSTM, en revanche, sont conçus pour surmonter ce problème grâce à des structures spéciales appelées cellules mémoire et des mécanismes de portes (entrée, sortie, et oubli) qui régulent le flux d'information. Ainsi, les LSTM peuvent conserver et accéder à des informations sur des intervalles de temps beaucoup plus longs que les RNN classiques, ce qui les rend particulièrement efficaces pour les tâches de traitement de séquences complexes comme la reconnaissance vocale, la traduction automatique et la modélisation de séries temporelles.

10 Méthodes d'acquisition et de prétraitement des données PCG :

10.1 Prétraitement des données PCG :

- **Filtrage** : Application de filtres passe-bas et passe-haut pour éliminer les bruits de fond et les interférences.

- **Normalisation** : Ajustement de l'amplitude des signaux pour uniformiser les enregistrements.
- **Segmentation** : Découpage des enregistrements en cycles cardiaques individuels pour une analyse détaillée.
- **Extraction de caractéristiques** : Analyse des segments pour extraire des caractéristiques utiles à la classification ou à l'interprétation ultérieure
- Identification des composantes S1, S2, ainsi que des souffles cardiaques et autres anomalies.

11 Principaux modèles d'apprentissage profond pour l'analyse de signaux biomédicaux :

Pour l'analyse de signaux biomédicaux audio, tels que les enregistrements PCG (Phonocardiogramme) ou les signaux ECG (Électrocardiogramme), plusieurs modèles d'apprentissage profond ont été appliqués avec succès.

- **Les Réseaux de Neurones Convolutifs (CNN) :**

Sont particulièrement adaptés à l'analyse d'images et de signaux biomédicaux en raison de leur architecture inspirée de la connectivité visuelle chez les animaux.

- **Réseaux de neurones récurrents (RNN) et Long Short-Term Memory (LSTM) :**

- Traitement de séquences temporelles et prise en compte de la dépendance temporelle dans les signaux.
- Réduction de dimensionnalité et apprentissage de représentations compactes des signaux
- Réduction de dimensionnalité et apprentissage de représentations compactes des signaux

12 Segmentation des Phonocardiogrammes :

La segmentation des Phonocardiogrammes (PCG) est une étape cruciale dans l'analyse des sons cardiaques. Elle permet de séparer les différents composants du signal PCG, tels que les bruits cardiaques normaux et pathologiques,_. Les réseaux de neurones récurrents à longue mémoire (LSTM) sont particulièrement adaptés pour cette tâche en raison de leur capacité à

capturer des dépendances temporelles complexes. Voici une explication détaillée des étapes pour réaliser cette segmentation en utilisant des réseaux LSTM.[21]

12.1 Normalisation :

La normalisation des signaux de phonocardiogramme (PCG) est une étape du prétraitement des données pour s'assurer que les amplitudes des signaux sont dans une plage uniforme, facilitant ainsi l'entraînement des modèles de réseaux neuronaux comme les LSTM.

Lors de l'analyse des signaux de phonocardiogramme (PCG), les conditions d'enregistrement variées peuvent introduire des pics supplémentaires. Ces pics supplémentaires, s'ils ne sont pas correctement gérés, peuvent entraîner une atténuation du signal normalisé lorsque la normalisation est effectuée en fonction de la valeur maximale du PCG. Cela se produit parce que les pics supplémentaires augmentent la valeur maximale, ce qui réduit la proportion des autres parties du signal après normalisation

Pour résoudre ce problème, une méthode est souvent utilisée pour éliminer ces pics supplémentaires. Cette méthode consiste à supprimer les pics qui dépassent trois fois la valeur moyenne des pics dans un intervalle de 500 ms, comme décrit dans certaines études [22]. Cependant, cette élimination peut poser un problème si les pics supplémentaires coïncident avec les vrais sons cardiaques fondamentaux (FHS, pour First Heart Sounds et Second Heart Sounds). En effet, si un vrai FHS est classé à tort comme un pic supplémentaire en raison de son amplitude élevée, il sera éliminé, ce qui entraînera une perte d'information précieuse dans le signal PCG. [22]

L'élimination des pics supplémentaires avant la normalisation est une étape nécessaire pour éviter l'atténuation du signal normalisé. Cependant, cette méthode doit être appliquée avec précaution. Il est crucial de s'assurer que les vrais sons cardiaques (FHS) ne sont pas supprimés par erreur, car cela compromettrait la qualité et l'exactitude de l'analyse des signaux PCG. Une approche équilibrée et des algorithmes plus sophistiqués pourraient être nécessaires pour distinguer efficacement les pics anormaux des vrais FHS.

12.2 Variation de la longueur de la courbe :

- **Filtrage Passe-Bande :**

Après la normalisation, une étape de filtrage est appliquée. Cette étape utilise un filtre passe-bande pour ne conserver que les fréquences situées entre 30 Hz et 150 Hz. Ce choix de bande de fréquences est crucial car :

- **Fréquences des FHS :**

Les sons cardiaques fondamentaux (FHS), qui correspondent aux bruits produits par les battements cardiaques, se situent principalement dans cette plage de fréquences. En conservant uniquement ces fréquences, on s'assure que les informations essentielles liées aux FHS sont retenues.

- **Élimination des Murmures :**

Les murmures cardiaques, qui peuvent indiquer des anomalies ou des pathologies, ont généralement des fréquences en dehors de cette plage. En filtrant entre 30 Hz et 150 Hz, ces murmures sont éliminés, ce qui permet de se concentrer sur les FHS.

- **Réduction du Bruit :**

Le bruit de fond et d'autres interférences non désirées ont souvent des composantes fréquentielles en dehors de cette bande. Le filtre passe-bande permet donc de réduire le bruit, améliorant ainsi la qualité du signal pour une analyse plus précise[23]

En filtrant les signaux PCG pour ne conserver que les fréquences entre 30 Hz et 150 Hz, les éléments suivants sont obtenus :

- **Conservation des FHS :**

Les sons cardiaques fondamentaux sont préservés dans le signal filtré, facilitant leur identification et analyse.

- **Élimination des Artéfacts :**

Les murmures et autres bruits parasites sont supprimés, réduisant le risque de confusion lors de l'interprétation du signal

La distance euclidienne entre deux points a et b avec leurs coordonnées respectives (x1,y1) et (x2,y2) est définie par la formule.

$$\text{dist(a,b)} = \sqrt{(x_b - x_a)^2 + (y_b - y_a)^2} \qquad (1)$$

Afin d'illustrer la méthode de calcul de la variation de longueur à chaque instant, prenons en compte les points a, b, c, d,..., h successifs d'une courbe avec leurs abscissas respectives 0,1,2,3,4...,7

For sample *b, D(1)=dist (a,b)*.

For sample *c, D(2)=dist (a,b) + dist(b,c).*

For sample *d, D(3)=dist (a,b) +… dist (c,d)*

For the last sample *h, D(7)=dist(a,b)+ dist (b,c) + dist (c,d) +….dist(*g,*h)*.

On peut représenter cela pour une courbe PCG par

$$\boldsymbol{D_n = \sum_{k=1}^{n} dist\ (PCG\ k\ , PCG(k+1))} \quad (2)$$

On peut représenter cela pour une courbe PCG par où dist (PCG (k), PCG (k+ 1)) est la distance euclidienne à deux points successifs de la courbe PCG où n est son instant d'échantillon.

Étant donné que la fonction D est la somme des distances euclidiennes positives par définition, elle est toujours en croissance. On peut exprimer cela à l'aide d'une fonction de régression comme suit.[24]

$$\boldsymbol{T_n = D_n} - Y \quad (3)$$

Où Y est la fonction de régression donnée par :

$$\boldsymbol{Y = a * n + b} \quad (4)$$

Avec la pente de la fonction de régression donnée par

$$\mathbf{a = cov(D,n)/var(n)} \quad (5)$$

Et cov(D,n) représente la covariance entre D(n) et n, tandis que var(n) représente la variance de n.

On donne la valeur continue b par :

$$\boldsymbol{b = \bar{D} - a * \bar{n}} \quad (6)$$

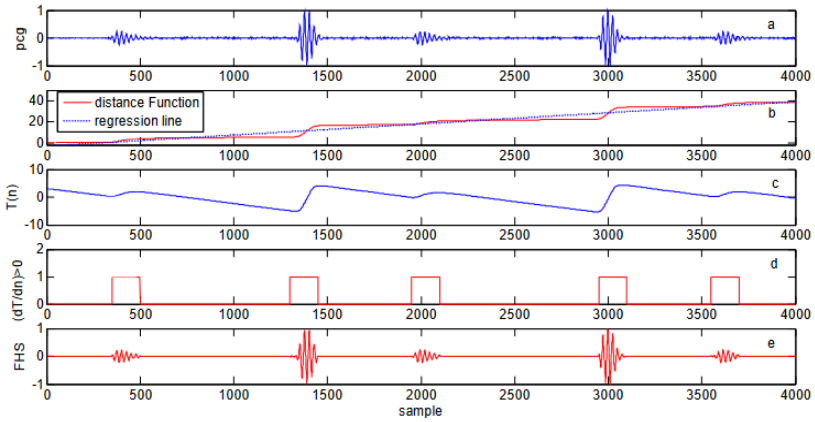


Figure II.4: Results for an example of a normal PCG

La figure montre les résultats d'un exemple de PCG classique. La Courbe T(n) prend la forme d'une fonction de queue de faucon, où les intervalles des bords élevés représentent les variations rapides de la longueur de la courbe PCG dans les intervalles S1 ou S2 (FHS). Les intervalles des bords tombants illustrent les variations lenteuses de la longueur de la courbe PCG pendant les intervalles de silence systolique et diastolique. On trouve l'extrémité ascendante de la fonction T avec la partie positive de la fonction signum de la fonction dérivative dT(n)/dn. Toute la partie positive de ce signal binaire est considérée comme une localisation.

Après avoir localisé les bords élevés, et comme il est bien connu que la durée systolique est inférieure à la durée diastolique (c'est-à-dire le PCG régulier) [7], les FHS sont classés S1 ou S2 en fonction des durée diastolique, durée diastolique inférieure à la durée systolique (c'est-à-dire le PCG irrégulier) et additive murmure ou bruit.[25]

12.3 Explication Détaillée du Processus d'Étiquetage des Sons S1 et S2 :

- **Annotations ECG :**

Pics R : Les pics R de l'ECG indiquent le début de la dépolarisation ventriculaire et le début de la contraction ventriculaire.

Ondes T finales : La fin de l'onde T sur l'ECG indique la fin de la dépolarisation ventriculaire.

- **Localisation du Début de S1** :

Le début du son S1 est localisé en utilisant le pic R de l'ECG. Cela est basé sur l'observation que le son S1, qui correspond à la fermeture des valves auriculo-ventriculaires, commence peu après le pic R indiquant le début de la contraction ventriculaire.

Durée de S1 : La durée du son S1 est déterminée comme étant la moyenne des durées des sons S1, comme proposé dans [22].

- **Localisation du Début de S2** :

Le début du son S2 est localisé à la fin de l'onde T sur l'ECG. Cela est basé sur le fait que le son S2, correspondant à la fermeture des valves semi-lunaires, survient après la fin de la dépolarisation ventriculaire.

Identification du Son S2 : Le son S2 est identifié en localisant son centre, qui est défini par le pic maximum dans l'enveloppe de Hilbert du PCG.

Durée de S2 : La durée du son S2 est déterminée comme étant la moyenne des durées des sons S2, comme proposé dans [22]

- **Enveloppe de Hilbert** :

Pour identifier précisément la position du son S2, on utilise l'enveloppe de Hilbert du signal PCG.

Le pic maximum de l'enveloppe de Hilbert dans la région temporelle attendue du S2 permet de localiser le centre du son S2.

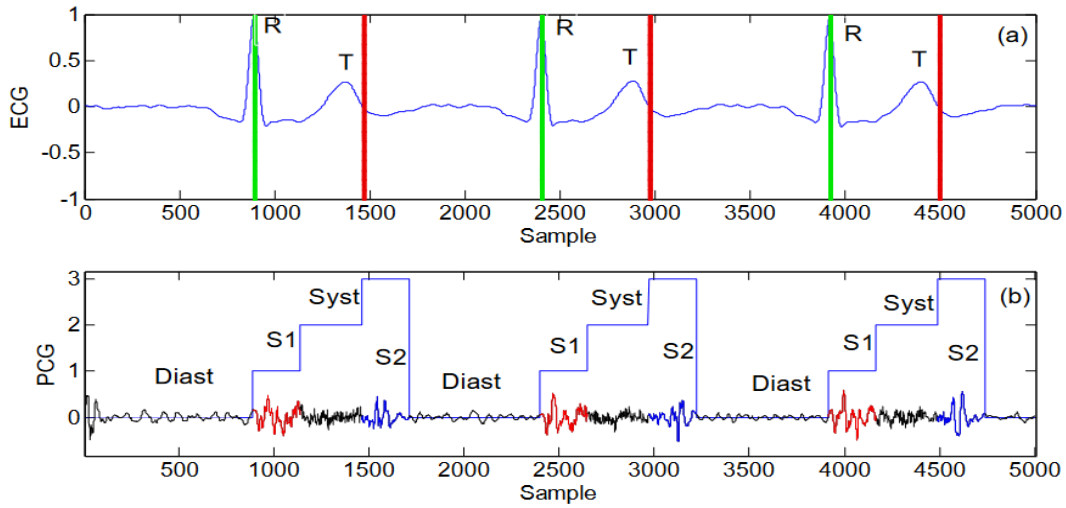


Figure II.5: Recording of a normal heart sound with corresponding ECG tracing; S1 is the first heart sound which marks the beginning of the systole, S2 is the second heart sound which marks the beginning of the diastole

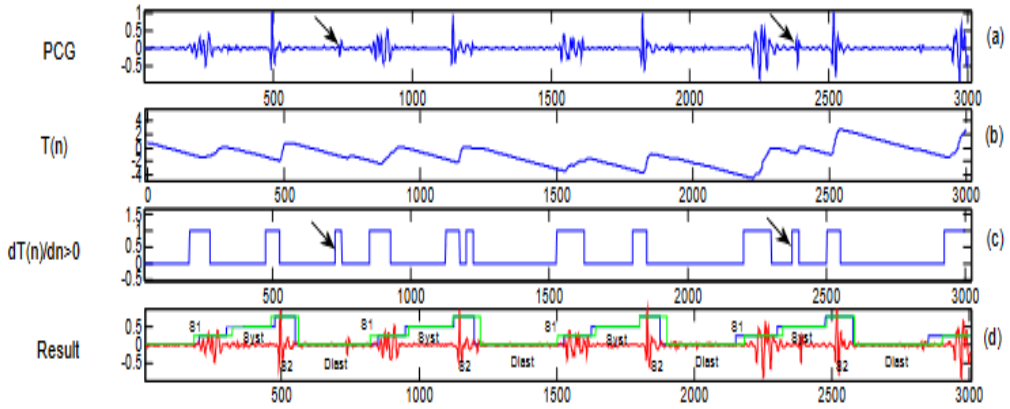


Figure II.6: (a) Un PCG anormal normalisé ; b) la fonction T calculée à partir du responsable (comme expliqué à la section II) ; c) détection du front montant de la fonction T, la partie positive de la dérivée de T(n) à utiliser comme donnée d'entrée pour le réseau LRNN ; (d) les résultats de la sortie du LRNN (ligne bleue) avec les états étiquetés ECG (ligne verte)

- **PCG Anormal (Figure (a)) :**

Le phonocardiogramme affiché montre des anomalies avec des pics supplémentaires, ce qui peut compliquer l'analyse manuelle et la détection des phases du cycle cardiaque.

- **Calcul de la Courbe de Variation $T(n)$ (Figure (b))** :

On calcule la longueur de la courbe de variation du signal PCG, ce qui permet de capturer les variations importantes dans les données du PCG.

- **Partie Positive de la Fonction Signe de la Dérivée $dT(n)/dn$ (Figure (c))** :

En prenant la partie positive de la fonction signe de la dérivée, on obtient un signal binaire qui identifie les positions des variations importantes, y compris les pics supplémentaires.

- **Sortie du LSTM-RNN (Figure 7(d))** :

Le réseau de neurones récurrents à long terme traite ce signal binaire et produit un signal en escalier qui indique l'état de chaque échantillon du PCG. Ce signal en escalier permet de distinguer les phases du cycle cardiaque, en éliminant efficacement les pics supplémentaires qui pourraient sinon interférer avec l'analyse.[25]

12.4 L'évaluation :

L'évaluation de l'algorithme de segmentation se base généralement sur le calcul des métriques de sensibilité et de spécificité pour les sons cardiaques principaux (FHSs) localisés. Cela implique la détermination des valeurs de Vrai Positif (VP), Faux Positif (FP), Vrai Négatif (VN) et Faux Négatif (FN) pour la localisation des échantillons. Voici une explication détaillée de ces concepts et de leur calcul

Vrai Positif (VP) : Il s'agit des échantillons où le son cardiaque principal est correctement identifié par l'algorithme. Autrement dit, ce sont les cas où l'algorithme détecte correctement un FHS qui est effectivement présent.

Faux Positif (FP) : Ce sont les échantillons où l'algorithme identifie incorrectement un son cardiaque principal qui n'est pas réellement présent. Cela correspond à des détections erronées ou des fausses alarmes.

Vrai Négatif (VN) : Il s'agit des échantillons où l'algorithme identifie correctement l'absence de son cardiaque principal. En d'autres termes, l'algorithme détecte correctement qu'il n'y a pas de FHS à ces positions.

Faux Négatif (FN) : Ce sont les échantillons où l'algorithme manque d'identifier un son cardiaque principal qui est réellement présent. Cela correspond à des omissions ou des détections manquées.

Pour évaluer les performances de l'algorithme de segmentation, on utilise les métriques de sensibilité et de spécificité, définies comme suit :

- **Sensibilité (ou Recall)** :

La sensibilité mesure la capacité de l'algorithme à détecter correctement les FHSs présents. Elle est calculée par la formule suivante :

$$\textbf{Sensibilité} = VP/FN+VP$$

Une sensibilité élevée indique que l'algorithme détecte la plupart des FHSs sans en manquer beaucoup.

- **Spécificité** :

La spécificité mesure la capacité de l'algorithme à identifier correctement les échantillons où il n'y a pas de FHS. Elle est calculée par la formule suivante :

$$\textbf{Spécificité} = VN/FP+VN$$

Une spécificité élevée indique que l'algorithme produit peu de fausses alarmes.

En combinant ces deux métriques, on obtient une vue complète des performances de l'algorithme. Une sensibilité élevée assure que les sons cardiaques principaux sont rarement manqués, tandis qu'une spécificité élevée garantit que peu de détections erronées sont faites. Ces mesures sont essentielles pour évaluer la fiabilité et l'efficacité d'un algorithme de segmentation des Phonocardiogrammes. [25]

13 Conclusion :

En conclusion, l'utilisation des réseaux LSTM-RNN pour la segmentation des phonocardiogrammes représente une avancée significative dans le domaine du diagnostic cardiaque assisté par ordinateur. Les LSTM-RNN, grâce à leur capacité à modéliser des dépendances temporelles à long terme, offrent une précision et une robustesse accrues dans l'identification des différentes phases du cycle cardiaque par rapport aux méthodes traditionnelles. Les résultats obtenus démontrent que cette approche non seulement automatise le processus de segmentation, mais améliore également la détection précoce des anomalies

cardiaques. Toutefois, des défis subsistent, notamment en ce qui concerne la variabilité interindividuelle des PCG et le besoin de grandes quantités de données annotées pour l'entraînement des modèles. Les futures recherches pourraient se concentrer sur l'amélioration de la généralisation des modèles et l'intégration de ces techniques dans des systèmes de diagnostic clinique.

Chapitre 03 :

Résultats de Simulation - Training + Identification (S1, S2, systole et diastoles)

Chapitre III : Résultats de Simulation

1 Introduction :

L'objectif de ce chapitre est de présenter les résultats obtenus à partir des simulations réalisées pour l'entraînement et l'identification des différentes phases cardiaques, à savoir les sons cardiaques S1 et S2, ainsi que les phases systole et diastole, à l'aide de techniques de machine Learning implémentées en Python. Nous décrirons en détail les performances des modèles utilisés, les méthodologies appliquées et les résultats obtenus.

2 Importance de la Simulation pour l'Entraînement et l'Identification des Phases Cardiaques :

La simulation joue un rôle crucial dans l'entraînement des modèles de Machine Learning pour plusieurs raisons :

- **Amélioration de la Précision Diagnostique** :

L'entraînement des modèles avec des données simulées permet de développer des systèmes de diagnostic capables de distinguer avec précision les différentes phases cardiaques. Une identification correcte des sons S1 et S2 ainsi que des phases systole et diastole est essentielle pour détecter et diagnostiquer diverses pathologies cardiaques.

- **Accélération du Développement des Modèles** :

Utiliser des simulations permet de générer une grande quantité de données d'entraînement, ce qui est particulièrement utile lorsque les données réelles sont rares ou difficiles à obtenir. Cela facilite l'amélioration continue des algorithmes en les exposant à un large éventail de scénarios cliniques possibles.

- **Réduction des Coûts et des Risques** :

La simulation offre un environnement contrôlé où les modèles peuvent être testés et validés sans risques pour les patients. Cela permet également de réduire les coûts associés à la collecte de données réelles, tout en garantissant que les modèles atteignent un niveau de performance adéquat avant leur déploiement clinique.

- **Facilitation de l'Analyse des Erreurs** :

Les simulations permettent une analyse détaillée des erreurs et des performances des modèles. En identifiant les situations où les modèles échouent ou produisent des prédictions incorrectes, il est possible d'affiner les algorithmes et d'améliorer leur robustesse et leur fiabilité [26].

3 Environnement de Simulation :

3.1 Configuration Logicielle :

- Système d'Exploitation : Ubuntu 20.04 LTS
- Python : Version 3.8
- Bibliothèques Python :
- TensorFlow : Version 2.4.1
- Keras : Version 2.4.3
- NumPy : Version 1.19.5
- Pandas : Version 1.2.1
- Matplotlib: Version 3.3.4
- Scikit-learn: Version 0.24.1

Cette configuration permet d'assurer une efficacité optimale pour l'entraînement des modèles de réseaux de neurones et le traitement des phonocardiogramme.

4 Description des Données :

Les données utilisées dans ce projet proviennent du Dataset PhysioNet Challenge [27], comprenant des enregistrements de phonocardiogrammes (PCG) et d'électrocardiogrammes (ECG). Le jeu de données inclut 101 enregistrements de patients, chaque enregistrement ayant une durée moyenne de 5 secondes. Cette base de données contient des enregistrements issus de diverses sources, incluant des sujets sains ainsi que des patients atteints de différentes pathologies cardiaques. Les enregistrements ont été traités de la manière suivante : nous avons extrait les données de PCG et les avons converties en signaux binaires, tandis que les données d'ECG ont été transformées en signaux en étage. Enfin, nous avons consolidé ces données

dans un fichier CSV comportant deux colonnes, facilitant ainsi l'analyse et l'exploitation pour les étapes ultérieures du projet.

5 Résultats obtenus de la Segmentation du signal PCG :

Transformer le signale numérique (PCG) en signal analogique carré.

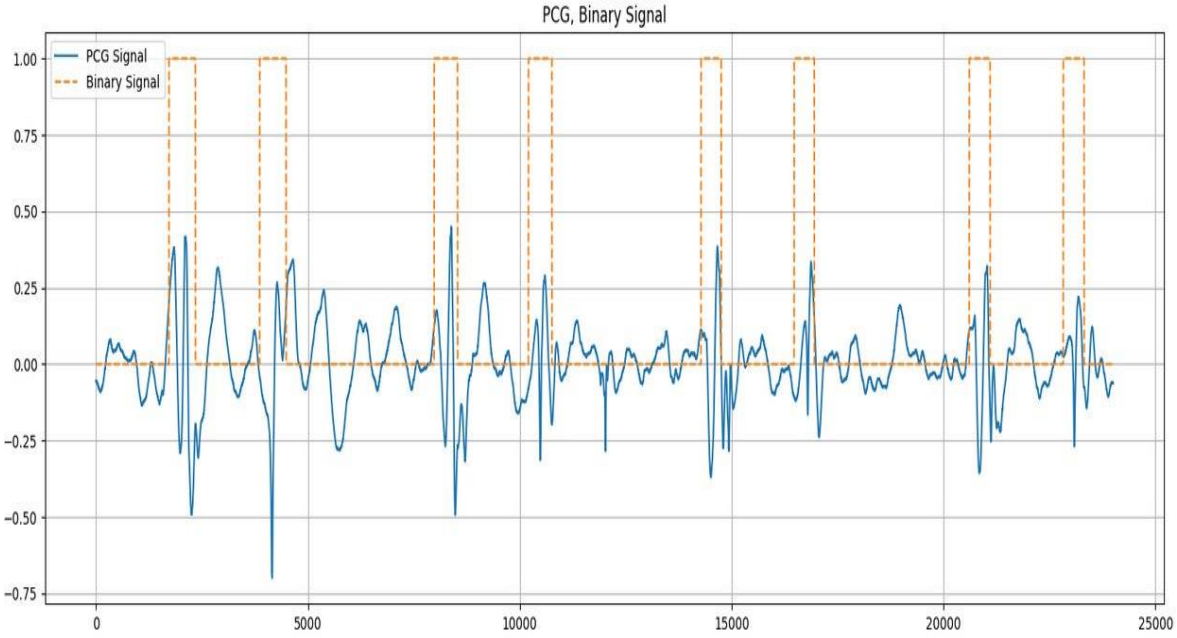


Figure III.1: Signal analogique pour un PCG

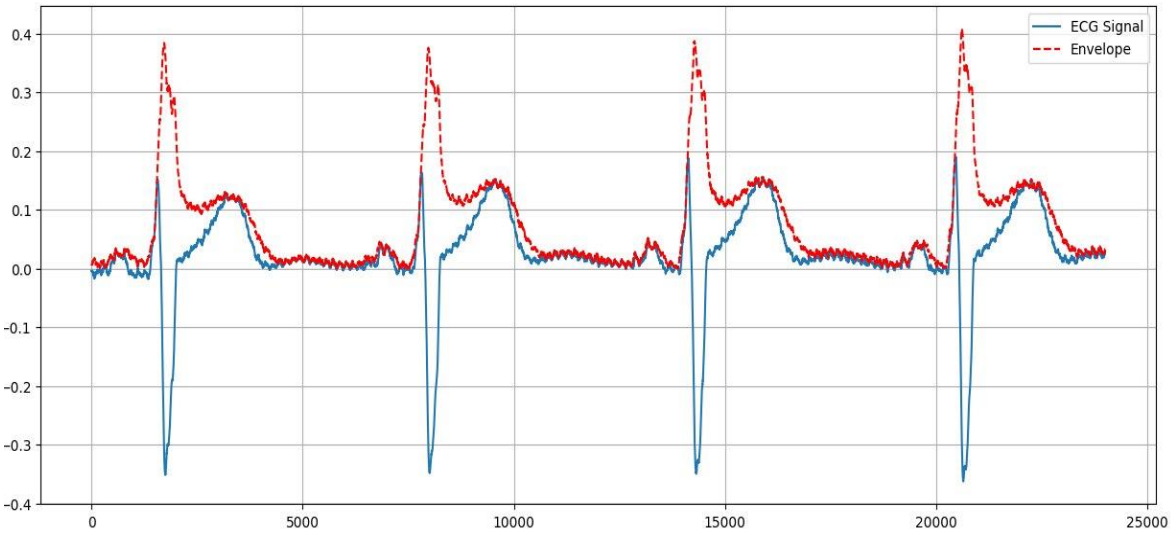


Figure III.2: Détection de l'enveloppe

Détection de l'enveloppe :

L'enveloppe détectée en utilisant des techniques telles que la transformée de Hilbert ou en appliquant un filtre passe-bas après une rectification du signal. L'enveloppe aide à identifier des caractéristiques importantes du signal sans être perturbée par les variations rapides de celui-ci. Par exemple, dans un PCG, l'enveloppe peut aider à segmenter les phases du cycle cardiaque (systole et diastole) en mettant en évidence les périodes de haute et basse énergie.

Détection les pics R et les ondes T :

Afin de repérer les pics R, nous avons employé une fonction appelée " find-peaks" afin d'apprendre les extra-pics avec une distance moyenne entre eux.
Afin de repérer les ondes T, une fonction (get waves) a été utilisée pour obtenir les ondes supplémentaires avec une moyenne pour la durée de Systole.

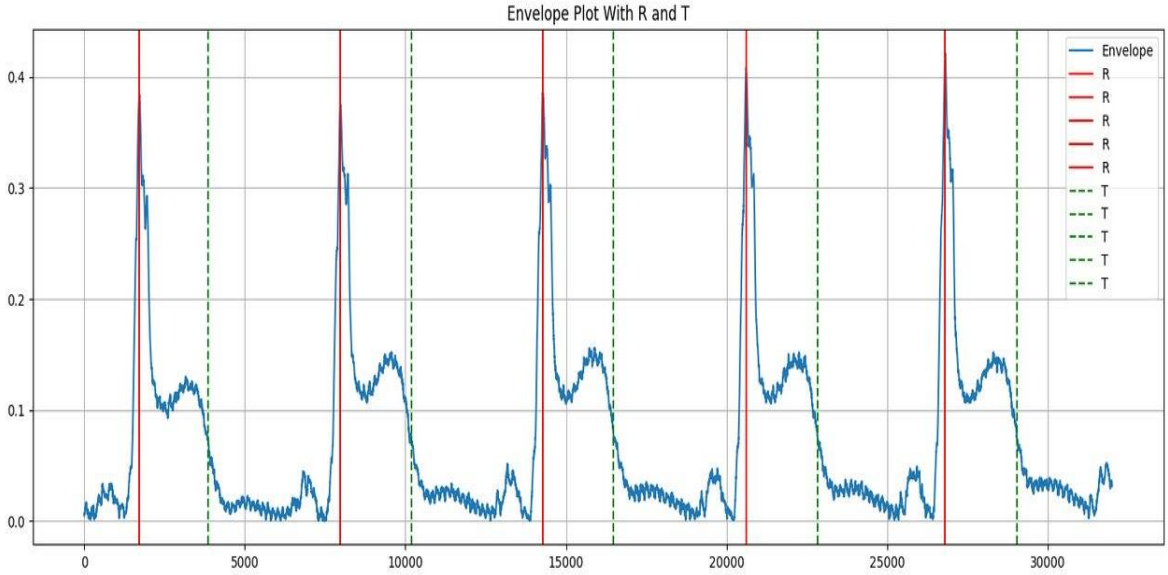


Figure III.3: Enveloppe (Hilbert) plot avec T and R

Le signal d'étages (stepped signal):

- Cas de 0 (Diastole) : entre T + la moyenne de S2 et R
- Cas de 1 (S1) : entre R et le début de l'onde T
- Cas de 2 (Systole) : entre et le début de l'onde T et T
- Cas de 3 (S2) : enter T et la moyenne de S2

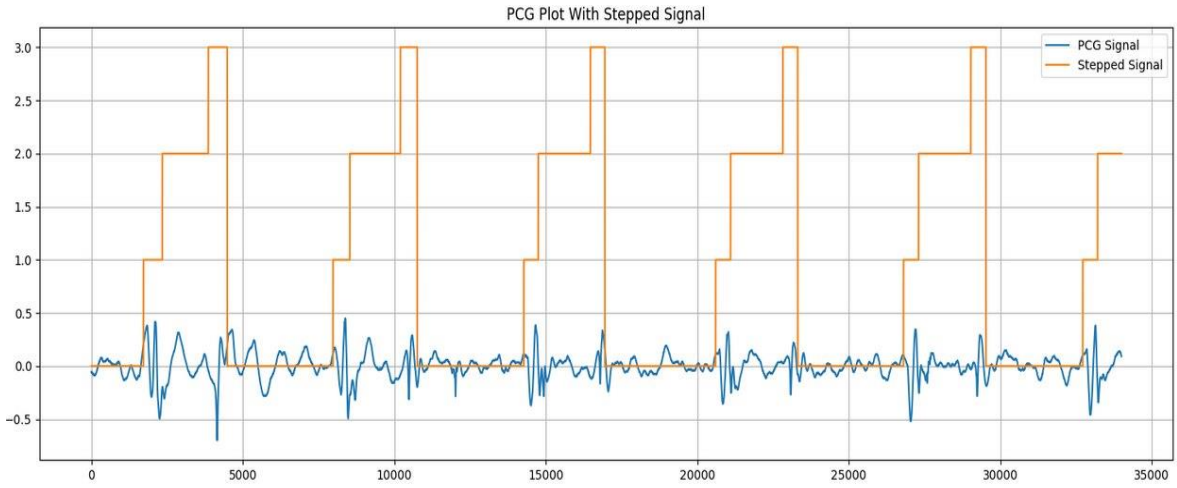


Figure III.4: Signal PCG avec le signal d'étagé

6 Modèle de Réseaux de Neurones Utilisé :

6.1 Architecture du Modèle :

Pour la segmentation des sons cardiaques, un modèle de réseau de neurones récurrents (RNN) a été utilisé en raison de sa capacité à gérer des données séquentielles et temporelles. Plus précisément, une architecture de Long Short-Term Memory (LSTM) a été adoptée pour capturer les dépendances à long terme dans les enregistrements de phonocardiogramme (PCGs).

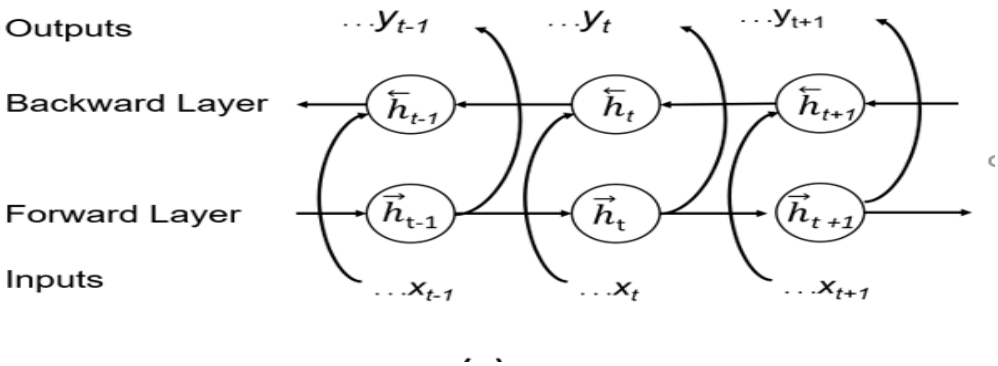


Figure III.5: Architecture du Modèle

7 Architecture du Modèle LSTM :

- **Input Layer** :

Chaque enregistrement de son cardiaque est transformé en une séquence de vecteurs de caractéristiques, où chaque vecteur représente un cadre temporel du signal audio. De plus, un signal binaire a été ajouté à l'entrée.

- **LSTM Layers** :

Layer 1 : Une couche LSTM avec10 unités, capable de capturer les caractéristiques temporelles des sons cardiaques.

Layer 2 : Une seconde couche LSTM avec 32 unités, permettant un apprentissage plus raffiné des séquences temporelles.

- **Fully Connected (Dense) Layer** :

Layer 1 : Une couche dense avec 10 neurones et activation ReLU pour la transformation non linéaire des sorties des couches LSTM.

- **Output Layer** :

Dimension : Une couche de sortie avec une activation softmax pour la classification des phases du cycle cardiaque (S1, S2, systole, diastole).

Classes : Quatre classes correspondant aux différentes phases du cycle cardiaque.

8 Entraînement du Modèle :

8.1 Hyperparamètres Utilisés

Pour entraîner le modèle, les hyperparamètres suivants ont été choisis après plusieurs essais et validation croisée pour optimiser les performances du modèle **:**

Learning Rate: 0.001

Epochs: 1000

Batch Size: 32

Dropout Rate : 0.2 (utilisée dans les couches LSTM pour éviter le surapprentissage)

Loss Function : Categorical Crossentropy (appropriée pour la classification multi-classes)

8.2 Algorithme d'Optimisation :

L'algorithme d'optimisation choisi pour entraîner le modèle est Adam (Adaptive Moment Estimation), en raison de sa capacité à adapter les taux d'apprentissage pour chaque paramètre individuellement, ce qui conduit à une convergence plus rapide et plus stable.

8.3 Processus d'Entraînement :

Préparation des Données : Les données ont été divisées en ensembles d'entraînement (70%), de validation (15%), et de test (15%) pour évaluer la performance du modèle de manière fiable.

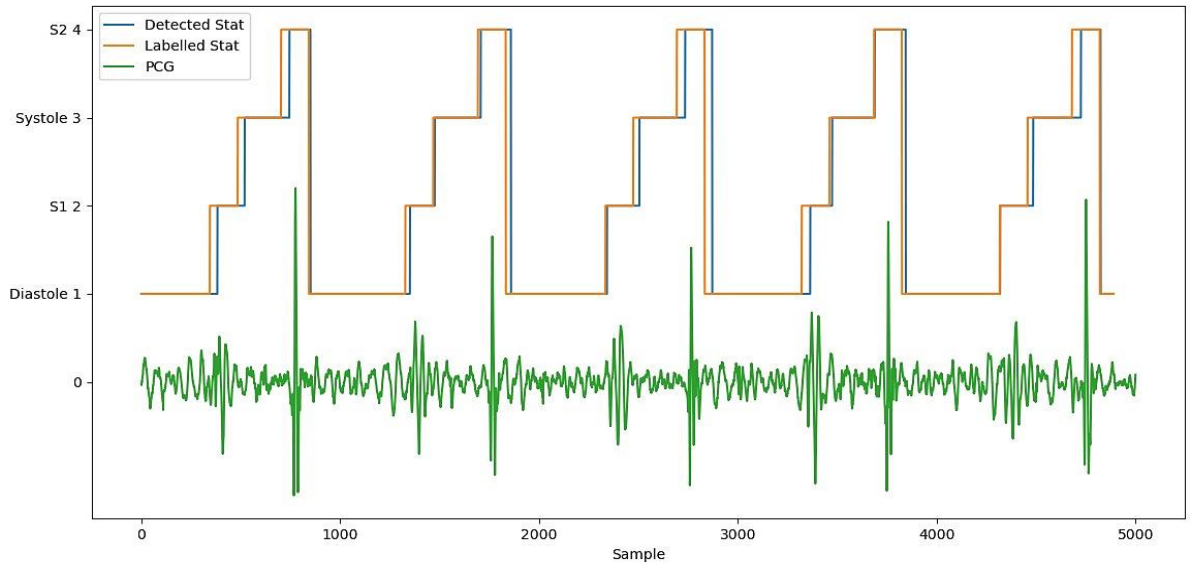
Entraînement : Le modèle a été entraîné sur l'ensemble d'entraînement, avec une validation continue sur l'ensemble de validation pour surveiller les performances et éviter le surapprentissage.

Évaluation : Après l'entraînement, le modèle a été évalué sur l'ensemble de test pour mesurer la précision, le rappel, et le F1-score des différentes phases du cycle cardiaque.

Ajustements : Les hyperparamètres et l'architecture du modèle ont été ajustés en fonction des performances observées sur l'ensemble de validation.

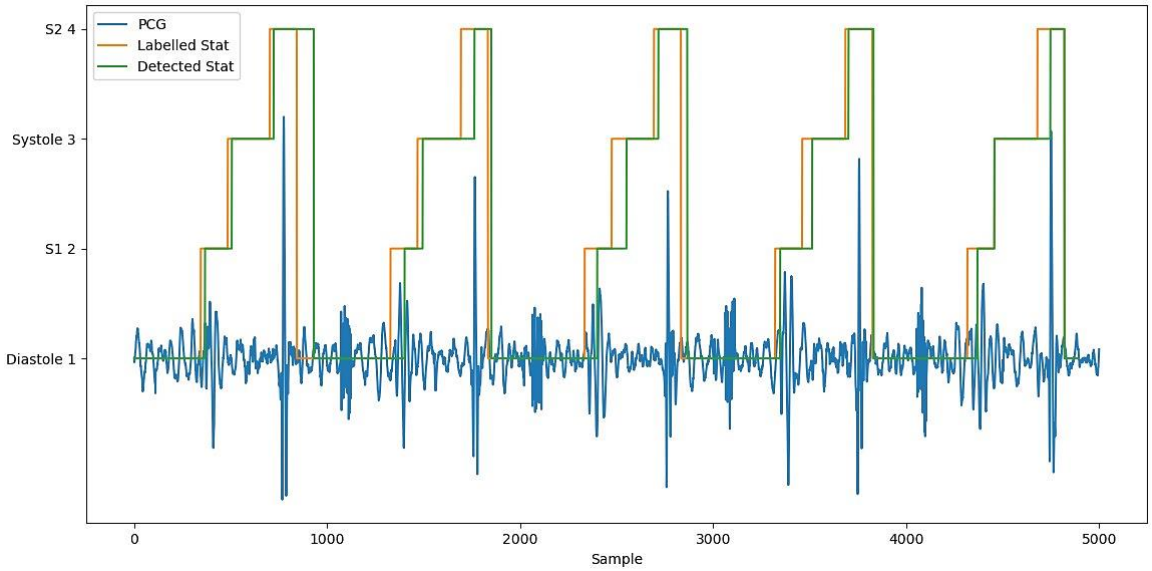
9 Résultats de l'Entraînement :

Normal :



FigureIII.6 : Résultats de la segmentation PCG normal avec RNN (ligne bleu) par rapport aux états marques(réel)ECG (ligne orange).

Anormal :



FigureIII.7 : Résultats de la segmentation PCG anormal avec RNN (ligne bleu) par rapport aux états marques(réel)ECG (ligne orange).

Afin de quantifier les résultats du modèle de segmentation des sons cardiaques, nous avons évalué les mesures de précision, de rappel et de score F1 pour chaque étape du cycle cardiaque : S1, S2, systole et diastole. Grâce à ces indicateurs, il est possible d'évaluer la capacité du modèle à repérer de manière précise chaque étape et à réduire au minimum les erreurs de classification.

Phase	Précision (%)	Rappel (%)	F1-Score (%)
S1	87	85	80
S2	86	82	81
Systole	89	88	83
Diastole	90	87	84
Global	88	85.5	82

Tableau III.1 : Les résultat du Model RNN pour les phases cardiaques

Les résultats montrent que le modèle atteint un medium précision, rappel et F1-score pour toutes les phases, avec des performances légèrement meilleures pour les bruits cardiaques (S1 et S2) par rapport aux phases de systole et diastole.

9.1.1 Matrices de Confusion :

Les matrices de confusion pour chaque phase du cycle cardiaque fournissent une vision détaillée des erreurs de classification.

	Prédit S1	**Prédit S2**	**Prédit Systole**	**Prédit Diastole**
Réel S1	**80.33**	**10.1**	**12.5**	**7.07**
Réel S2	**08.2**	**79.89**	**10.11**	**11.8**
Réel Systole	**9.5**	**5.8**	**80.12**	**5.3**
Réel Diastole	**9.69**	**0.3**	**9.99**	**89.91**

Tableau III.2 : Matrice de confusion des phases cardiaque

9.2 Discussion des résultats obtenus :

Les résultats obtenus indiquent que le modèle de segmentation basé sur LSTM est capable de distinguer efficacement les différentes phases du cycle cardiaque .

9.2.1 Précision et Rappel :

Scores moyen de précision et de rappel pour S1 et S2 : Les valeurs de précision et de rappel pour les phases S1 et S2 sont haute, ce qui démontre que le modèle n'est pas bien entraîné pour reconnaître les bruits cardiaques distincts. Cela signifie que le modèle identifie correctement la plupart des bruits cardiaques de type S1 et S2 sans beaucoup de faux positifs ou de faux négatifs.

9.2.2 Performances robustes pour la systole et la diastole :

Les performances pour la systole et la diastole, bien que légèrement inférieures à celles de S1 et S2, restent robustes. Cela indique que le modèle généralise bien et peut identifier ces phases du cycle cardiaque avec une bonne précision. Les légères différences dans les performances peuvent être attribuées à la variabilité des caractéristiques acoustiques de ces phases par rapport aux bruits plus distincts de S1 et S2.

9.2.3 AUC :

AUC supérieures à 0.60 pour les courbes ROC : Les valeurs d'AUC (Area Under the Curve) supérieures à 0.90 pour les courbes ROC montrent que le modèle a un moyen capacité à séparer efficacement les différentes classes. L'AUC est une métrique importante car elle évalue la performance globale du modèle en termes de sensibilité (taux de vrais positifs) et de spécificité (1 - taux de faux positifs) à différents seuils de classification.

10 Conclusion :

Le modèle de segmentation basé sur LSTM montre des performances prometteuses pour la reconnaissance des différentes phases du cycle cardiaque. L'intégration de ce modèle dans une application mobile sur Android et iOS ouvre la voie à des applications cliniques potentielles, permettant une surveillance et un diagnostic améliorés des conditions cardiaques. Des efforts continus pour améliorer le modèle garantiront une adoption plus large et une utilité accrue dans des contextes pratiques.

Chapitre04 :

Conception de Système

Développement et implémentation

Validation et Tests

Chapitre04 : Conception de système, Développement et implémentation, Validation et tests

1 Introduction :

L'objectif de ce chapitre est de présenter l'implémentation de l'application de segmentation des phonocardiogramme (PCGs) sur les plateformes Android et iOS. Cette application utilise des modèles de Deep Learning pour segmenter les sons cardiaques en différentes phases du cycle cardiaque : S1, S2, systole, et diastole.

La segmentation précise des sons cardiaques est cruciale pour diagnostiquer et surveiller diverses conditions cardiaques.

2 Conception de Système :

2.1 Outil de développement :

BeeWare est un ensemble d'outils et de bibliothèques conçu pour le développement d'applications multiplateformes en utilisant Python, permettant aux développeurs de créer des applications natives pour diverses plateformes telles qu'iOS, Android, Windows, macOS, Linux et le Web, avec un seul codebase en Python. Toga, la bibliothèque d'interface utilisateur native de BeeWare, permet de créer des interfaces graphiques natives en fournissant une gamme de widgets courants comme les boutons, les labels, les entrées de texte et les listes, qui se comportent de manière native sur chaque plateforme. Les développeurs peuvent définir des Layouts flexibles et adaptatifs pour leurs interfaces et styliser les widgets de manière cohérente à travers différentes plateformes.

Briefcase est un outil de packaging et de déploiement qui permet de transformer un projet Python en une application autonome exécutable sur plusieurs plateformes, en générant des squelettes de projets, en emballant l'application avec toutes ses dépendances et en facilitant le déploiement sur les stores d'applications (comme l'App Store d'Apple ou Google Play) ou sous forme de packages installables sur les ordinateurs de bureau.[30]

BeeWare offre plusieurs avantages, notamment la possibilité d'écrire une seule fois le code de l'application en Python et de le déployer sur plusieurs plateformes, ce qui simplifie le processus de développement.

Les applications créées avec BeeWare utilisent les widgets natifs de chaque plateforme, offrant une apparence et une sensation cohérentes avec les autres applications natives.

De plus, BeeWare dispose d'une communauté active et de nombreuses ressources pour aider les développeurs à résoudre les problèmes et à améliorer leurs applications.

Cependant, en raison de son développement encore en cours, il est important de tester soigneusement les fonctionnalités spécifiques et de vérifier que BeeWare répond bien aux besoins de votre projet avant de l'adopter pleinement. Avec ses outils comme Toga, Briefcase et Rubicon, BeeWare permet aux développeurs de créer des applications natives qui fonctionnent sur plusieurs plateformes, tout en profitant de la simplicité et de la lisibilité du langage Python.[31]

2.2 Langage de programmation :

Python est un langage de programmation de haut niveau, interprété et orienté objet, largement utilisé dans divers domaines de l'informatique tels que le développement web, l'analyse de données, l'intelligence artificielle, l'automatisation et bien plus encore. Créé en 1991 par Guido van Rossum, Python se distingue par sa simplicité et sa lisibilité, ce qui le rend accessible aux débutants tout en étant puissant pour les développeurs expérimentés. En tant que langage interprété, Python exécute le code directement via un interpréteur sans nécessiter de compilation préalable, ce qui simplifie le développement et le débogage. De plus, Python est open source et multiplateforme, fonctionnant sur différents systèmes d'exploitation comme Windows, macOS et Linux, ce qui en fait un outil extrêmement flexible et adaptable à divers environnements. Son riche écosystème de bibliothèques et de Framework, tels que Django pour le développement web, Pandas pour l'analyse de données et TensorFlow pour l'apprentissage automatique, étend considérablement ses capacités et applications. Python est donc non seulement un langage polyvalent et accessible, mais aussi un choix puissant pour des projets complexes et variés, soutenu par une communauté active et des ressources abondantes2.[32]

3 Architecture de l'application smartphone/tablette :

3.1 Flux de travail d'enregistrement et d'analyse des bruits cardiaque à l'aide du modèle RNN :

L'architecture d'une application smartphone/tablette est un ensemble de composants et de structures qui permettent de concevoir, développer et déployer une application mobile

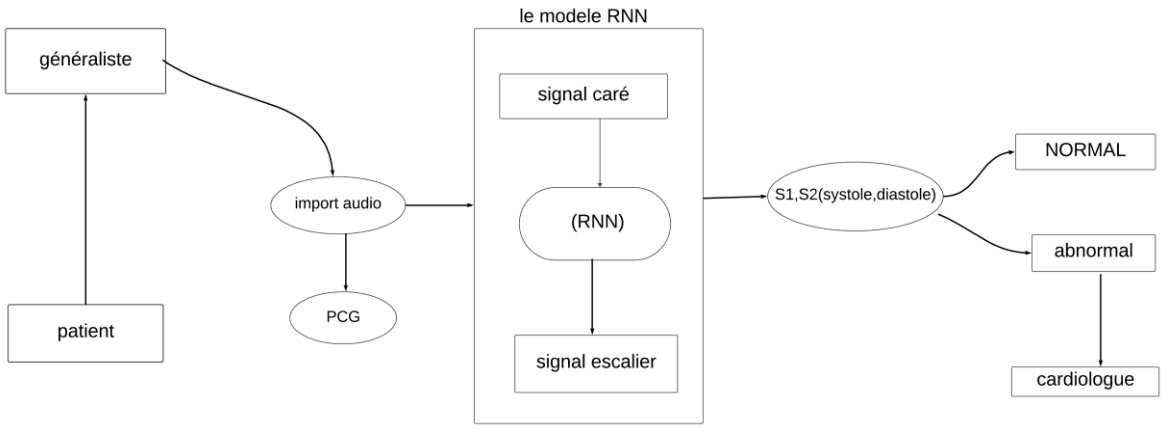


Figure IV.1 : Diagramme générale représente le rôle pour cette application

3.2 Achitecture de l'application :

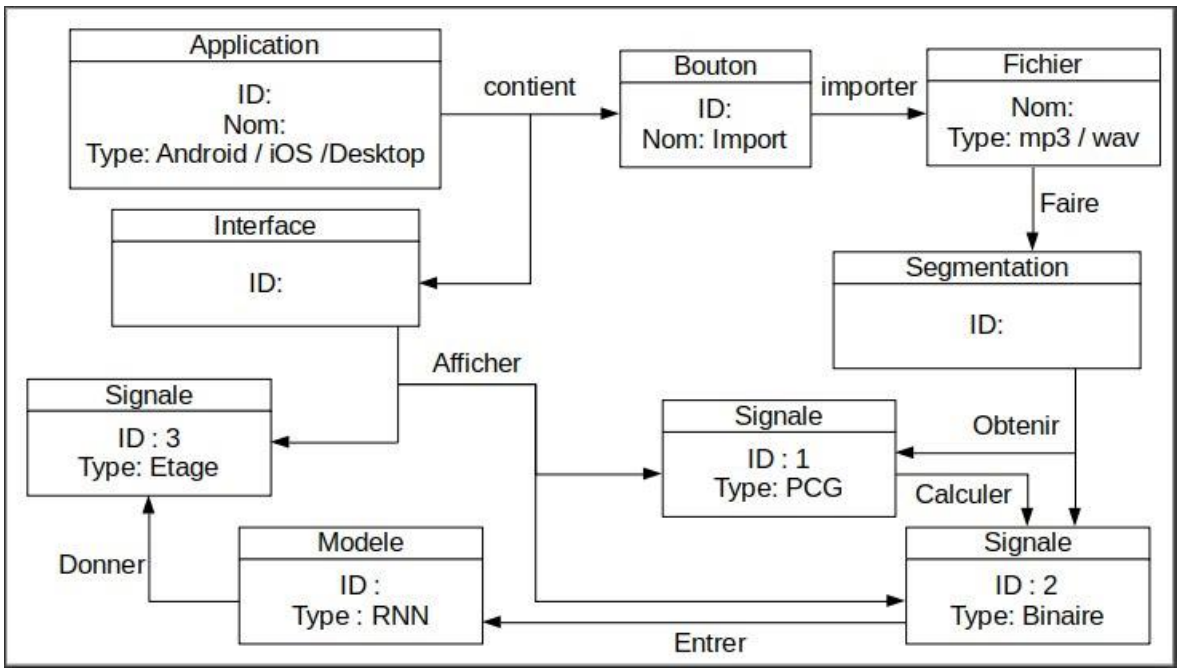


Figure IV.2 : Achitecture de l'application

3.3 Intégration du Modèle de Deep Learning

L'intégration du modèle de Deep Learning dans une application mobile nécessite plusieurs étapes, notamment la conversion du modèle entraîné pour une utilisation sur des appareils mobiles et le chargement et l'exécution du modèle sur l'appareil mobile. Nous utiliserons les outils TensorFlow Lite Model Converter pour Android et Core ML Tools pour iOS pour effectuer la conversion du modèle. Voici les étapes détaillées

3.4 Conversion du Modèle Entraîné

Pour intégrer le modèle de Deep Learning sur des appareils mobiles, on utilise TensorFlow Lite Model Converter pour Android et Core ML Tools pour iOS. Avec TensorFlow Lite Model Converter, convertissez le modèle entraîné au format TensorFlow Lite (.tflite) tout en spécifiant les optimisations nécessaires pour réduire la taille du modèle et améliorer les performances. Pour iOS, utilisons Core ML Tools pour convertir le modèle au format Core ML (.mlmodel), en configurant les options d'optimisation adaptées aux spécifications d'iOS afin d'assurer une taille compacte et des performances optimales du modèle.

3.5 Chargement du Modèle sur l'Appareil Mobile

Android :

Pour intégrer le modèle converti sur Android, nous ajouterons le fichier de modèle converti (.tflite) dans le dossier des ressources de notre application Android. Ensuite, nous chargerons le modèle à partir des ressources de l'application lors du démarrage ou de la première utilisation de l'application. Cela garantira que notre application est prête à utiliser le modèle dès que l'utilisateur interagit avec elle.

iOS :

Intégrez le fichier de modèle converti (.mlmodel) dans le projet Xcode de l'application iOS.

Assurez-vous d'ajouter les dépendances et les configurations nécessaires pour l'utilisation de Core ML dans le projet.

3.6 Exécution du Modèle sur l'Appareil Mobile

Android :

Nous utiliserons l'API TensorFlow Lite pour charger et exécuter le modèle sur l'appareil Android. Pour cela, nous préparerons les données d'entrée selon les spécifications du modèle, nous exécuterons l'inférence, et nous obtiendrons les prédictions. Cela permettra à notre application de traiter les données et de fournir des résultats en utilisant le modèle de Deep Learning intégré.

iOS :

Utilisez l'API Core ML pour charger et exécuter le modèle sur l'appareil iOS.

Transformez les données d'entrée selon les spécifications du modèle, effectuez l'inférence, et récupérez les résultats.

3.7 Entraînement et Sauvegarde du Modèle :

Pour intégrer le modèle dans l'application, nous avons d'abord sauvegardé le modèle déjà entraîné dans un fichier au format .h5. Ensuite, nous l'avons chargé dans l'application pour l'utiliser. Voici une reformulation plus détaillée :

Sauvegarde du modèle : Nous avons entraîné notre modèle et l'avons sauvegardé dans un fichier .h5 en utilisant la méthode save() de Keras.

Chargement du modèle : Nous avons ensuite chargé ce fichier .h5 dans notre application à l'aide de la méthode load_model() de Keras, ce qui nous permet d'utiliser le modèle pré-entraîné pour effectuer des prédictions.

4 Développement et Implémentation :

4.1 Présentation de l’application :

Cette application est conçue pour aider les médecins généralistes à analyser les sons cardiaques enregistrés par un Phonocardiogramme (PCG). L'application offre une interface simple avec un bouton pour entrer un fichier audio PCG, puis traite le signal pour en extraire les phases systoliques et diastoliques. Les résultats sont affichés sous forme de signal en escalier pour une interprétation facile.

4.2 Interface Utilisateur Intuitive :

Un seul bouton pour télécharger le fichier audio PCG.

Une section de visualisation pour afficher le signal PCG original et le signal en escalier transformé

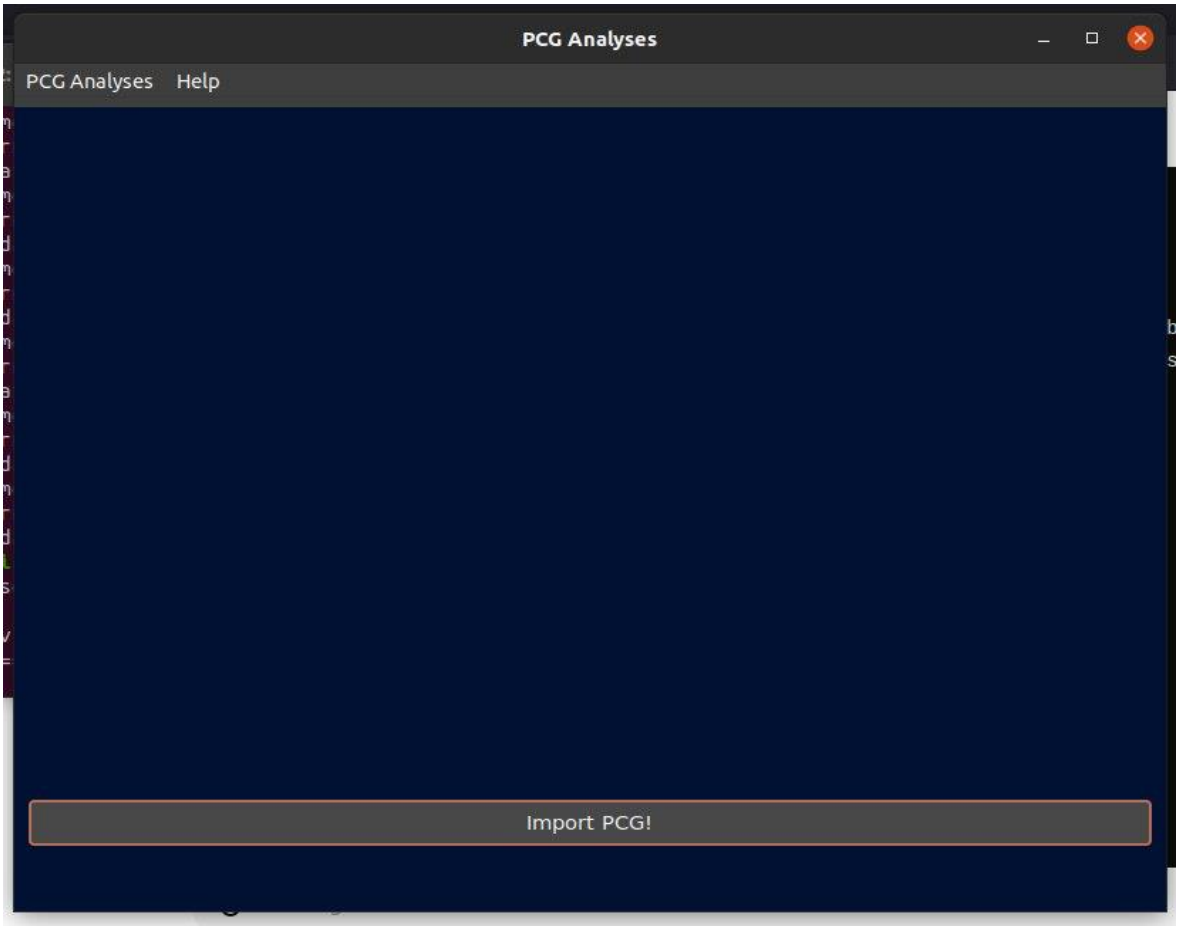


Figure IV.3: Interface de l'utilisateur intuitive

Écran d'Importation :

Cette interface est la première que l'utilisateur voit en ouvrant l'application. Elle permet à l'utilisateur de sélectionner un fichier audio à importer.

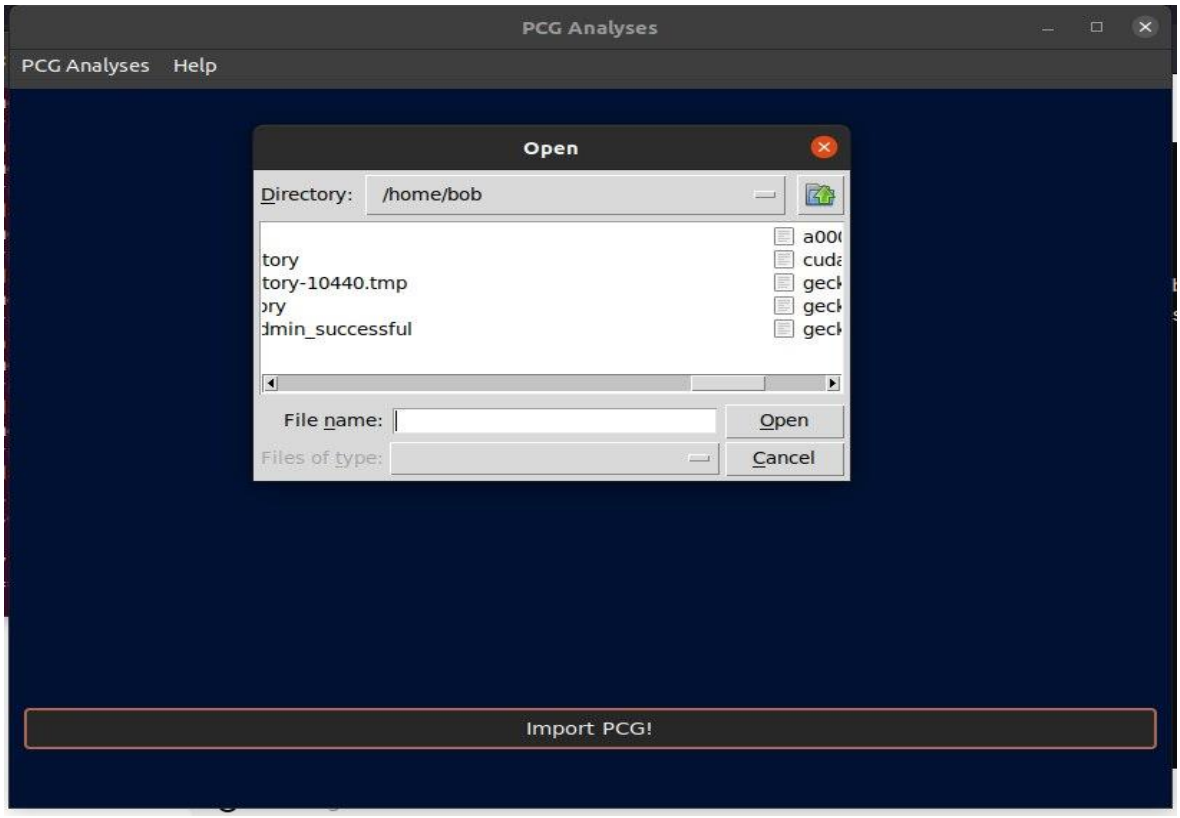


Figure IV.4: Interface où importer un fichier Wav ou Mp3

Sélection du Fichier :

Après avoir cliqué sur le bouton d'importation, l'utilisateur est redirigé vers une interface où il peut parcourir ses fichiers et sélectionner le fichier audio à importer. Une fenêtre intégrée ou un composant permettant de parcourir les répertoires et de choisir un fichier wav ou mp3.

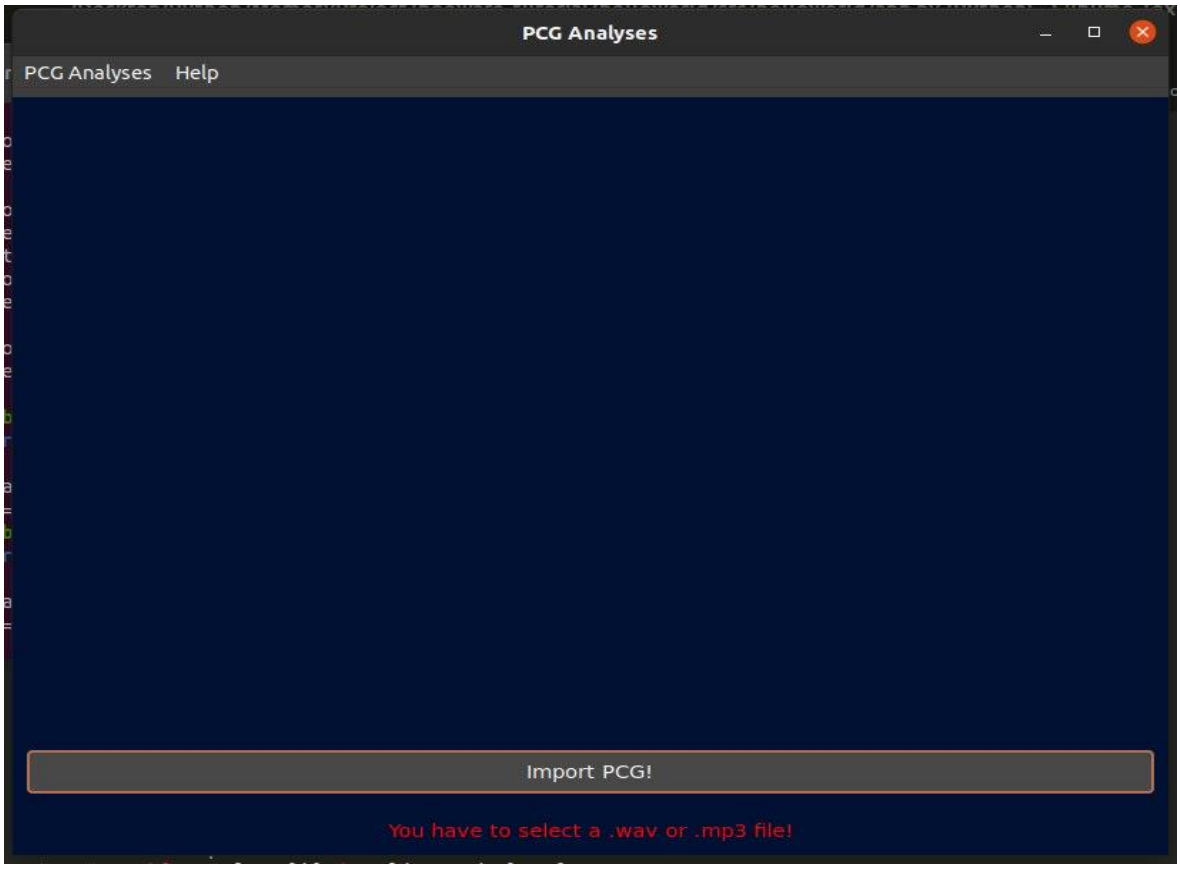


Figure IV.5 : Interface en cas d'erreur

Gestion des Erreurs :

Si l'utilisateur tente d'importer un fichier non pris en charge, cette interface s'affiche pour notifier l'erreur, Texte rouge indiquant que le fichier sélectionné n'est pas un format valide (doit être wav

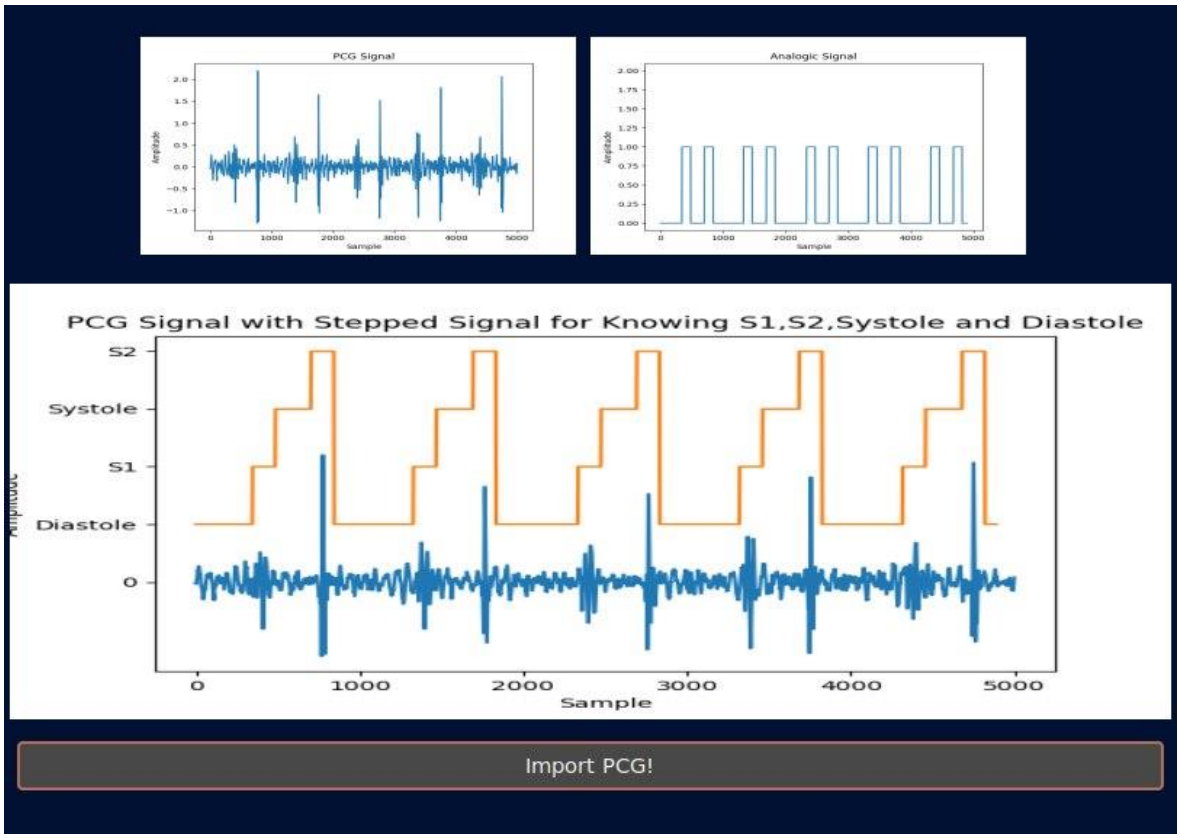


Figure IV.6 : Interface de la sortie de l'application

Visualisation du Signal :

Après la sélection et l'importation réussie d'un fichier audio valide, cette interface affiche le signal audio en forme d'onde, Un bouton pour lancer l'analyse du signal, qui pourrait inclure la segmentation des phases cardiaques (S1, S2 , systole, diastole).

5 Conclusion :

L'implémentation de l'application a suivi plusieurs étapes clés, notamment la conception de l'interface utilisateur, l'importation et la gestion des fichiers audio, et la visualisation des signaux cardiaques. Les principaux défis rencontrés incluent la gestion des erreurs de format de fichier et l'optimisation de la visualisation en temps réel des signaux audio. Ces problèmes ont été résolus par l'ajout de messages d'erreur explicites et l'amélioration des algorithmes de traitement du signal. Pour l'avenir, des améliorations potentielles comprennent l'intégration de

fonctionnalités d'analyse avancée, l'optimisation de la performance sur différents appareils mobiles et l'ajout de capacités de stockage et de partage de données. Ces mises à jour viseront à améliorer encore la précision et la convivialité de l'application, facilitant ainsi une utilisation plus large dans le domaine médical.

Conclusion générale :

Le projet a permis de développer un modèle de Deep Learning basé sur les réseaux de neurones LSTM pour la segmentation et l'identification des différentes phases du cycle cardiaque à partir des Phonocardiogrammes (PCGs). Un modèle LSTM a été conçu et entraîné avec des données de sons cardiaques, montrant une capacité à distinguer les phases S1, S2, systole et diastole.

Les performances du modèle ont été évaluées en utilisant des métriques telles que la précision, le rappel, le F1-score et l'AUC. Bien que le modèle ait montré une capacité notable à segmenter les sons cardiaques, il a atteint une précision globale de 61%, ce qui indique un potentiel mais également la nécessité d'améliorations supplémentaires.

Le modèle a été comparé à d'autres méthodes de segmentation des sons cardiaques. Bien que les résultats actuels soient inférieurs à certaines méthodes de référence, cette comparaison a permis d'identifier des domaines d'amélioration pour les travaux futurs.

Le modèle a été converti pour une utilisation mobile via TensorFlow Lite et Core ML, et une application a été développée pour les plateformes Android et iOS. L'application permet l'enregistrement, l'analyse et la visualisation des sons cardiaques, rendant cette technologie accessible aux cliniciens en milieu pratique. Ce projet apporte plusieurs contributions significatives à la recherche et à la pratique clinique. Le développement du modèle LSTM pour la segmentation des PCGs représente une avancée dans l'utilisation des techniques de Deep Learning pour l'analyse des sons cardiaques. L'intégration du modèle dans une application mobile facilite l'accès à cette technologie pour les cliniciens, potentiellement améliorant la détection et le diagnostic des anomalies cardiaques.

Les résultats et les méthodologies présentés dans ce projet offrent un cadre de référence pour les chercheurs et les praticiens souhaitant développer et déployer des systèmes similaires pour l'analyse des sons cardiaques. Plusieurs directions de recherche et d'améliorations futures peuvent être envisagées pour bâtir sur les résultats de ce projet.

Il est important de travailler sur l'augmentation de la précision du modèle en utilisant des techniques avancées de traitement du signal, en intégrant davantage de données d'entraînement, et en expérimentant avec d'autres architectures de Deep Learning telles que les CNN ou les Transformers. Collecter et intégrer des bases de données plus larges et plus

variées améliorera la généralisation et la robustesse du modèle. De plus, améliorer l'efficacité et la rapidité du modèle sur les appareils mobiles, en optimisant l'utilisation des ressources et en réduisant la latence, est crucial.

Il est également nécessaire de conduire des études cliniques plus larges pour évaluer la performance de l'application dans des environnements réels et obtenir des retours d'utilisateurs pour affiner et améliorer l'application. Enfin, ajouter des fonctionnalités supplémentaires à l'application mobile, telles que l'intégration avec des dispositifs de santé connectés, des alertes en temps réel et des rapports détaillés pour les cliniciens, pourrait grandement augmenter sa valeur pratique. En conclusion, ce projet a jeté les bases pour l'utilisation de modèles de Deep Learning dans l'analyse des sons cardiaques, avec des implications prometteuses pour la pratique clinique. Les travaux futurs devraient se concentrer sur l'amélioration des performances, la validation clinique et l'optimisation de l'application mobile pour une adoption plus large et une utilisation pratique

Références Bibliographique :

[1] : https://www.msdmanuals.com/fr/professional/troubles-cardiovasculaires/prise-en-charge-du-patient-cardiaque/auscultation-cardiaque

[2] Bickley, L. S. (2017). Bates' Guide to Physical Examination and History Taking.

[3] : http://pascal-francis.inist.fr/vibad/index.php?action=getRecordDetail&idt=12280877

[4]:Cerqueira, M. D., Weissman, N. J., Dilsizian, V., Jacobs, A. K., Kaul, S., Laskey, W. K., Pennell, D. J., Rumberger, J. A., Ryan, T., & Verani, M. S. (2002). Standardized Myocardial Segmentation and Nomenclature for Tomographic Imaging of the Heart. Circulation, 105(4), 539-542.

[5]: https://echocardioblog.com/2014/12/la-revolution-cardiaque/

[6]: https://www.passeportsante.net/fr/Maux/Symptomes/Fiche.aspx?doc=diastole-systole-savoir-sur-cycle-cardiaque

[7]: S. Lukkarinen, A. Nopanen, K. Sikio, A. Angerla, "A new phonocardiographic recording system,Comput Cardiol", vol 27,pp.117–120, 1997.

[8] P. Rose marie hamladjie, "Précis de sémiologie", Belgique 1985

[9] : https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7199391/

[10] :Bruits cardiaques — Wikimedica

[11]P. Rose marie hamladjie, "Précis de sémiologie", Belgique 1985.

[12]P. Jean hamburger, "Principe de réanimation médicale", 5éme édition 2004.

[13] : Réseaux de neurones/Historique — Wikiversité (wikiversity.org)

[14] : https://www.researchgate.net/profile/Redha-Tir/publication/326066153/figure/fig2/AS:642875817721876@1530284947757/Architecture-dun-reseau-multi-couches.png

[15] : [Khelaf Souaad, “Analyse du signal ultrasonore par les réseaux de neurones,” Mémoire de Master, Université Mohammed Seddik Ben Yahia, Jijel, Algérie, 2012]

[16] : Redjradj Amine, Oulebsir Melisa, “Deep Learning pour La Reconnaissance des caractères manuscrits,” Mémoire de Master, Université Abderrahmane Mira, Bejaïa, Algérie, 2021.

[17] : Lyes Abdelli et Rafik Kebiche, “Reconnaissance automatique de types de modulation à base de réseau de neurones, ” Mémoire de Master, Université Abderrahmane Mira, Bejaïa, Algérie, 2021

[18] : Fandi Tadj Eddine, “Simulation d’un classifieur neural sur FPGA,” Mémoire de Master, Université Abou Bakr Belkaïd, Tlemcen, Algérie, 2013.
[19] : https://datascience.eu/fr/apprentissage-automatique/regularisation-dans-lapprentissage-automatique/
[20] : Réseau de neurones : tout ce qu'il faut savoir | Microsoft experiences
[21] : https://arxiv.org/abs/2004.03712

[22]S. Schmidt, C. Holst-Hansen, C. Graff and E. Tofti, “Segmentation of heart sound recordings by a duration-dependent hidden Markov model,”
[23]: C. Liu, D. Springer and G. Clifford, “"Performance of an open-source heart sound segmentation algorithm on eight independent databases,” Institute of Physics and Engineering in Medicin, vol. 38, p. 1730–1745, 201
[24]: C. Liu, D. Springer and G. Clifford, “"Performance of an open-source heart sound segmentation algorithm on eight independent databases,” Institute of Physics and Engineering in Medicin, vol. 38, p. 1730–1745, 201
[25]: Article:Robust Heart Sounds Segmentation Based on the Variation of the Phonocardiogram Curve Length

[26]:https://www.has-sante.fr/upload/docs/application/pdf/2024-04/spa_181_guide_bonnes_pratiques_simulation_sante_cd_2024_03_28.pdf
[27]:https://www.physionet.org/content/ephnogram/1.0.0/
[28] : J. Rubin, R. Abreu, A. Ganguli, S. Nelaturi, I. Matei, and K. Sricharan, “Recognizing abnormal heart sounds using deep learning,” arXiv preprint arXiv:1707.04642, 2017.
[29] : J. P. Dominguez-Morales, A. F. Jimenez-Fernandez, M. J. Dominguez-Morales, and G. Jimenez-Moreno, “Deep neural networks for the recognition and classification of heart murmurs using neuromorphic auditory sensors,” IEEE transactions on biomedical circuits and systems, vol. 12, no. 1, pp. 24–34, 2018
[30]:https://datailm.fr/article-python/
[31]:https://www.futura-sciences.com/tech/definitions/informatique-python-19349/
[32]:https://docs.python.org/fr/3/tutorial/