

UNIVERSITÉ DU QUÉBEC À MONTRÉAL

ÉTUDE DES TECHNIQUES DE CONVERSION PPG-ECG ET CRÉATION D'UN RÉSEAU NEURONAL EFFICACE
POUR LA PRÉDICTION CARDIO-VASCULAIRE

MÉMOIRE

PRÉSENTÉ

COMME EXIGENCE PARTIELLE

DE LA MAÎTRISE EN INFORMATIQUE CONCENTRATION ÉLECTRONIQUE

PAR

DIANI MAMOUDOU SEKOU

MARS 2024

UNIVERSITÉ DU QUÉBEC À MONTRÉAL
Service des bibliothèques

Avertissement

La diffusion de ce mémoire se fait dans le respect des droits de son auteur, qui a signé le formulaire *Autorisation de reproduire et de diffuser un travail de recherche de cycles supérieurs* (SDU-522 – Rév.12-2023). Cette autorisation stipule que «conformément à l'article 11 du Règlement no 8 des études de cycles supérieurs, [l'auteur] concède à l'Université du Québec à Montréal une licence non exclusive d'utilisation et de publication de la totalité ou d'une partie importante de [son] travail de recherche pour des fins pédagogiques et non commerciales. Plus précisément, [l'auteur] autorise l'Université du Québec à Montréal à reproduire, diffuser, prêter, distribuer ou vendre des copies de [son] travail de recherche à des fins non commerciales sur quelque support que ce soit, y compris l'Internet. Cette licence et cette autorisation n'entraînent pas une renonciation de [la] part [de l'auteur] à [ses] droits moraux ni à [ses] droits de propriété intellectuelle. Sauf entente contraire, [l'auteur] conserve la liberté de diffuser et de commercialiser ou non ce travail dont [il] possède un exemplaire.»

REMERCIEMENTS

Dans un premier lieu, je tiens à exprimer ma profonde gratitude envers Monsieur Mounir Boukadoum, directeur de recherche exceptionnel. Sa présence constante et son écoute attentive ont été des piliers essentiels tout au long de la réalisation de ce mémoire. Les nombreux conseils judicieux qu'il m'a prodigués ont été d'une valeur inestimable, m'aidant à m'améliorer et à donner le meilleur de moi-même dans ce travail.

Je souhaite également adresser mes remerciements chaleureux au corps enseignant et administratif de l'Université du Québec à Montréal. Leur enseignement de qualité a contribué de manière significative à mon développement académique et intellectuel, et leurs efforts déployés pour nous accompagner malgré les défis posés sont dignes de reconnaissance.

Enfin, je tiens à exprimer ma profonde reconnaissance envers ma famille qui a été un soutien indéfectible tout au long de mes projets académiques, et à mes amis qui ont été des compagnons de route précieux, m'apportant un soutien inestimable tout au long de ce cheminement. Leur encouragement et leur compréhension ont été des éléments clés de cette expérience académique.

TABLE DES MATIÈRES

TABLE DES FIGURES	v
LISTE DES TABLEAUX	vii
ACRONYMES	viii
NOTATION	x
RÉSUMÉ	xi
INTRODUCTION	1
CHAPITRE 1 FONDAMENTAUX	6
1.1 Photopléthysmographie (PPG).....	6
1.2 Electrocardiogramme (ECG)	8
1.3 Techniques de conversion de signaux PPG en signaux ECG	10
1.3.1 Les modèles de régression	10
1.3.2 Intelligence artificielle	16
1.4 Réseau de neurones pour la prédiction	17
1.5 <i>Support vector machines</i> (SVM)	24
CHAPITRE 2 ÉTAT DE L'ART	25
2.1 Techniques de conversion de signaux PPG en signaux ECG	25
2.1.1 Techniques de décomposition	25
2.1.2 Intelligence artificielle	28
2.2 Réseau de neurones pour la prédiction	29
CHAPITRE 3 MÉTHODOLOGIE	31
3.1 Conversion de signal PPG en signal ECG.....	31
3.1.1 Base de données	31

3.1.2	Prétraitement des données	31
3.1.3	Apprentissage de la transformation linéaire par crête.....	35
3.2	Classificateur de maladie : réseau de neurone	37
3.2.1	Base de données	37
3.2.2	Préparation des données	38
3.2.3	Description du modèle	39
CHAPITRE 4 EXPÉRIENCES ET DISCUSSION		42
4.1	Conversion de PPG à ECG	42
4.2	Classificateur de maladie : réseau de neurone	55
CONCLUSION.....		58
BIBLIOGRAPHIE		59

TABLE DES FIGURES

Figure 1.1	image descriptive du fonctionnement du PPG de (Vandenberk <i>et al.</i> , 2017)	6
Figure 1.2	comparaison des absorbances à différentes longueurs d'onde du sang de (University of Iowa Health Care, 2024)	7
Figure 1.3	Exemple des douze dérivation (Handschin et Sticherling, 2009)	9
Figure 1.4	ondes d'un signal ECG (Zizoua <i>et al.</i> , 2012)	9
Figure 1.5	Placement des dérivation précordiales vers les électrodes thoraciques (ADInstruments,)	10
Figure 1.6	Mise en correspondance neurone biologique / neurone artificiel (Cornuéjols <i>et al.</i> , 2018)	18
Figure 1.7	ReLU	19
Figure 1.8	Leaky ReLU	20
Figure 1.9	Sigmoïde (Goulon, 2008)	21
Figure 1.10	tanh (Tafforeau, 2014)	21
Figure 1.11	Illustration de la descente de gradient.(Ananthram, 2018)	22
Figure 3.1	Architecture du modèle	41
Figure 4.1	Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant l'ondelette db4	45
Figure 4.2	Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant l'ondelette db4	45
Figure 4.3	Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant l'ondelette db4	45
Figure 4.4	Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant l'ondelette Haar	46
Figure 4.5	Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant l'ondelette Haar	46

Figure 4.6 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant l'ondelette Haar 47

Figure 4.7 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant l'EMD . 47

Figure 4.8 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant l'EMD 48

Figure 4.9 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant l'EMD 48

Figure 4.10 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant l'EMD et l'ondelette db6 49

Figure 4.11 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant l'EMD et l'ondelette db6 49

Figure 4.12 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant l'EMD et l'ondelette db6 50

Figure 4.13 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant la VMD 51

Figure 4.14 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant la VMD 51

Figure 4.15 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant la VMD 51

Figure 4.16 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant la VMD et l'ondelette db8 53

Figure 4.17 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant la VMD et l'ondelette db8 53

Figure 4.18 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant la VMD et l'ondelette db8..... 53

LISTE DES TABLEAUX

Table 3.1	Tableau de répartition des données	38
Table 4.1	Tableau de résultats du rMSE pour le DWT avec les ondelettes de Daubechies	44
Table 4.2	Tableau de résultats du $rMSE_{std}$ pour le DWT avec les ondelettes de Daubechies	44
Table 4.3	Tableau de résultats du rMSE et $rMSE_{std}$ pour le DWT avec l'ondelette Haar	46
Table 4.4	Tableau de résultats du rMSE et $rMSE_{std}$ pour l'EMD	47
Table 4.5	Tableau de résultats du rMSE pour l'EMD et la DWT avec les ondelettes de Daubechies	48
Table 4.6	Tableau de résultats du $rMSE_{std}$ pour l'EMD et la DWT avec les ondelettes de Daubechies	49
Table 4.7	Tableau de résultats du rMSE et $rMSE_{std}$ pour le VMD	50
Table 4.8	Tableau de résultats du rMSE pour le VMD et la DWT avec les ondelettes de Daubechies ..	52
Table 4.9	Tableau de résultats du $rMSE_{std}$ pour le VMD et la DWT avec les ondelettes de Daubechies	52
Table 4.10	Tableau de résultats du coefficient de détermination R2 et du coefficient de Pearson	54
Table 4.11	Résultats comparatifs des modèles de prédiction	57

ACRONYMES

Adagrad adaptative gradient.

Adam l'estimation du moment adaptatif.

ANFIS inférence neuro-fuzzy adaptatif.

cA coefficients d'approximation.

cD coefficients de détail.

CD Trouble de la conduction.

CNN réseau neuronal convolutif.

CWT transformée en ondelettes continue.

db Daubechies.

DCT transformée en cosinus discrète.

DFT transformée de Fourier discrète.

Dwt transformée en ondelette discrète.

ECG électrocardiogramme.

EMD décomposition en modes empiriques.

GAN réseaux antagonistes génératifs.

HYP Hypertrophie.

IA intelligence artificielle.

iDCT inverse de la transformée en cosinus discrète.

iDwt inverse de la transformée en ondelettes discrète.

IMF fonctions de mode intrinsèques.

IRM imagerie par résonance magnétique.

KNN Plus proche voisin.

LED diode électroluminescente.

LOOM leave-one-out.

LSTM Réseau de mémoire à long court terme.

MI Infarctus du myocarde.

MSE Erreur quadratique moyenne.

NORM Normal.

PPG photopléthysmogramme.

ReLU unité linéaire rectifiée.

RMSprop racine carrée de la moyenne des carrés.

RNN réseau de neurones récurrents.

SGD Descente de gradient stochastique.

SNR Rapport signal sur bruit.

SPO2 saturation de l'hémoglobine en oxygène.

STTC Changement ST-T.

SVM machine à vecteurs de support.

tanh tangente hyperbolique.

VMD Décomposition en mode variationnel.

NOTATION

Unités

Hz Herz.

km/h kilomètres par heure.

dB décibel.

RÉSUMÉ

Ce travail aborde deux problématiques liées aux signaux physiologiques : la conversion de signaux de pléthysmographie en signaux d'électrocardiogramme (ECG) et la classification des maladies cardiovasculaires à partir de signaux ECG. Motivé par le désir de déterminer la meilleure technique de conversion de signal PPG en ECG et de concevoir un modèle d'intelligence artificielle efficace et précis pour la classification, cette étude propose une approche complète. Le problème de la conversion de signaux PPG en ECG a été abordé durant les dernières décennies de diverses façons, dont les techniques statistiques et des méthodes basées sur l'Intelligence artificielle (IA). Cependant, aucune approche ne s'est imposée comme la norme incontestée. Concentré sur les techniques de régression, nous avons pour objectif de répondre à la question de quelle technique de décomposition offre la meilleure précision et la plus grande fiabilité dans la conversion du signal PPG en ECG. Dans le domaine de la classification basée sur l'IA, le problème des exigences computationnelles élevées des modèles suscite l'attention du monde scientifique. La question de la manière de réduire ces coûts se pose. Afin d'y répondre, nous évaluons des techniques de réduction des dimensions notamment la DWT afin de ne récupérer que des informations pertinentes et faire une prédiction sur ces données.

Pour la conversion PPG-ECG, l'étude évalue la technique de régression par crête avec différentes techniques de décompositions, dont la décomposition en modes empiriques ou *empirical mode decomposition* en anglais (EMD), la transformée en ondelettes discrète ou *discrete wavelet transform* en anglais (DWT), la décomposition en mode variationnel ou *variational mode decomposition* (VMD), ainsi que les combinaisons EMD+DWT et VMD+DWT. Les signaux ECG et PPG provenant de la base de données Capnobase sont soumis à un ensemble de prétraitements avant de passer à la décomposition et à la régression. Les performances sont évaluées de manière quantitative à l'aide de métriques telles que la racine de l'erreur quadratique moyenne (RMSE), le coefficient de Pearson, le coefficient de détermination R^2 . Le calcul de ces différentes métriques a permis d'observer l'impact des différentes techniques de décomposition sur la précision de la conversion notamment la puissance du VMD et aussi de la combinaison VMD et DWT mais aussi l'inefficacité de l'EMD. Les résultats de validation ont montré une performance de conversion inférieure à celle d'une étude témoin qui utilise la suppression de tendance et la décomposition du signal filtré par la transformée en cosinus discrète (DCT), mais ils montrent des perspectives prometteuses pour la conversion PPG-ECG dans les applications cliniques. En ce qui concerne la classification des maladies cardiovasculaires, un réseau de neurones convolutif est élaboré à partir de signaux ECG issus de la base PhysioNet PTB-XL. Une étape préliminaire de transformation par DWT avec l'ondelette db4 et avec l'ondelette Haar est intégrée pour optimiser le processus de classification. Les catégories considérées comprennent l'ECG normal, l'infarctus du myocarde, les changements ST-T, les troubles de conduction et l'hypertrophie. L'évaluation de la performance se fait avec les métriques de précision, rappel et score F1, fournissant ainsi une évaluation exhaustive de l'efficacité de l'approche proposée. Le modèle basé sur la DWT avec db4 se démarque avec une bonne précision et un bon score F1, offrant une solution efficace avec un nombre de paramètres significativement inférieur à celui de modèles complexes. Ces résultats soulignent l'efficacité de cette approche dans des contextes avec des contraintes de ressources matérielles et de temps d'entraînement.

Mots-clés : Traduction de signaux, Électrocardiogramme, Photopléthysmographie, ECG, PPG, CNN, réseau neuronal convolutif, prédiction de maladie cardio-vasculaire, DWT, EMD, VMD.

INTRODUCTION

Les maladies cardiovasculaires sont l'une des principales causes de morbidité et de mortalité dans le monde, mettant en péril la santé et le bien-être de millions de personnes. Leur détection précoce revêt une importance capitale pour la prévention, le traitement et la gestion efficace de ces affections. Parmi les méthodes de diagnostic non invasives, l'électrocardiogramme (ECG), qui donne une représentation graphique de l'activité électrique du cœur au cours de ses battements, grâce à des électrodes placées sur la poitrine, joue un rôle essentiel en fournissant des informations cruciales sur le cycle cardiaque. Depuis son introduction il y a plus d'un siècle, l'ECG a évolué de manière significative en allant d'un outil de visualisation des rythmes cardiaques à un outil de diagnostic puissant. L'ECG permet aujourd'hui la détection précoce de nombreuses pathologies cardiaques comme les arythmies, les blocages et des ischémies myocardiques, en identifiant des anomalies électriques du cœur avant que les symptômes cliniques se manifestent, facilitant ainsi une intervention rapide et une meilleure gestion des affections. Il sert également à mesurer l'activité électrique du cœur à chaque battement, fournissant une image précise et dynamique de la fonction cardiaque afin de détecter les troubles de la conduction électrique, les anomalies de la repolarisation et d'autres problèmes qui peuvent influencer la performance cardiaque. Cependant, l'ECG traditionnel nécessite plusieurs électrodes placées sur la peau à travers un gel conducteur d'électricité, limitant sa convivialité et sa portabilité.

Ces dernières années, la photopléthysmographie (PPG) a émergé comme une technologie polyvalente qui peut aussi offrir des informations précieuses sur la dynamique cardiovasculaire et la perfusion tissulaire. La PPG mesure les variations d'absorption de la lumière par les tissus biologiques, généralement à travers la peau, afin d'évaluer les changements de flux sanguin. Elle s'affiche comme une alternative prometteuse à l'ECG pour la surveillance cardiovasculaire continue non intrusive. Cette approche se démarque par son accessibilité, sa mobilité, sa capacité de détection précoce des maladies cardiovasculaires, et aussi sa capacité de surveillance continue et à distance.

L'ECG et la PPG permettent donc d'obtenir des informations précieuses sur le cœur et la circulation sanguine. L'ECG produit un tracé de plusieurs dérivations, révélant les ondes caractéristiques associées aux contractions cardiaques. Chaque cycle cardiaque est clairement discernable dans l'ECG, offrant des informations sur la séquence et la durée des événements électriques. En revanche, la PPG génère une onde continue qui reflète les variations cycliques du volume sanguin dans les vaisseaux. elle est prometteuse pour la surveillance continue de la fréquence cardiaque, la détection précoce des arythmies et la surveillance de la

perfusion périphérique, en plus de fournir un moyen de mesurer le taux d'oxygène dans le sang.

L'ECG et la PPG étant reliées, en convertissant les signaux PPG en signaux ECG, il devient possible d'obtenir certaines informations similaires à celles fournies par l'ECG conventionnel, tout en bénéficiant de la convivialité et facilité d'utilisation des capteurs PPG.

Problématique de la conversion d'un signal PPG en signal ECG

La détection des maladies cardiovasculaires revêt une importance capitale pour répondre à leurs effets néfastes. L'ECG traditionnel est l'un des moyens les plus répandus pour diagnostiquer les anomalies cardiaques. Cependant, son utilisation n'est pas exempte d'inconvénients et de limitations. Parmi elles, nous pouvons compter l'inconfort des patients qui doivent maintenir une position spécifique pendant l'enregistrement de l'ECG pour obtenir de bons signaux. On peut compter aussi la limitation temporelle, les enregistrements d'ECG fournissent des informations instantanées de l'activité cardiovasculaire pendant une période spécifique qui peut ne pas capturer des événements cardiaques intermittents ou des arythmies qui ne se produisent pas pendant la période d'enregistrement. Il y a aussi le fait que l'analyse des tracés ECG nécessite des compétences spécialisées pour interpréter les différents composants et identifier d'éventuelles anomalies. Enfin le coût et la disponibilité d'équipements ECG et les ressources humaines qualifiées pour effectuer et interpréter les enregistrements peuvent être coûteux et ne sont pas toujours facilement disponibles, en particulier dans les régions éloignées ou les infrastructures médicales moins développées.

L'utilisation du PPG peut être une solution aux difficultés citées ci-dessus, mais il possède également des limitations comme la limitation en profondeur de mesure, la sensibilité aux variations de volume sanguin dans les vaisseaux périphériques comme ceux des doigts et des oreilles, et il ne fournit qu'une fenêtre limitée sur la fonction cardiaque, ce qui peut réduire la capacité de détecter avec précision certaines de ses anomalies. Les signaux PPG peuvent également être sensibles aux artefacts de mouvements, aux variations de luminosité ambiante et à d'autres interférences, ce qui peut entraîner des distorsions dans les mesures et compromettre leur précision et fiabilité. Bien que le PPG puisse fournir des mesures continues et à long terme, leur utilisation pour la détection spécifique de maladies cardiovasculaires nécessite une validation clinique approfondie. La corrélation entre les données PPG et les diagnostics traditionnels doit être rigoureusement établie pour garantir la pertinence clinique et la fiabilité des résultats.

Les deux techniques de récupération de signaux cardiovasculaires citées ci-haut ont donc chacune des avan-

tages et des inconvénients, mais la PPG possède l'avantage de la convivialité et de la simplicité acquisition. Dans le cadre de ce mémoire, nous avons décidé d'étudier les techniques de conversion des signaux PPG en signaux ECG, car une corrélation intrinsèque existe entre les deux signaux. Cette démarche se heurte cependant à des obstacles, notamment le désalignement temporel entre les signaux PPG et ECG. Ce désalignement résulte de deux facteurs majeurs : les variations de fréquence cardiaque et les artefacts de mouvement. Les variations de fréquence cardiaque induisent des modifications dans la synchronisation des cycles cardiaques entre les deux signaux, tandis que les artefacts de mouvement peuvent introduire des décalages temporels en raison des mouvements physiques du sujet, ce qui peut compromettre la précision de la conversion. Il y a aussi la différence fondamentale de la nature des deux signaux par leur modalité de mesure et les informations qu'ils capturent. Les PPG reflètent les variations de volume sanguin dans les vaisseaux périphériques, tandis que l'ECG mesure l'activité électrique du cœur.

Plusieurs études ont été menées afin de permettre une conversion d'un signal PPG en signal ECG, mais jusqu'à présent, aucune approche ne s'est imposée comme la norme incontestée. Parmi ces approches, certaines sont basées sur l'intelligence artificielle, d'autres sur des techniques de régression. Si on met le focus sur les techniques statistiques, la question fondamentale qui persiste est de savoir laquelle offre la meilleure précision et la plus grande fiabilité dans la conversion du signal PPG en ECG. Face à cette diversité des méthodes, il devient impératif d'identifier les forces et les faiblesses de chaque approche afin d'évaluer de manière objective son application clinique ou de surveillance physiologique.

Problématique de la classification des maladies cardiovasculaire

Malgré les avancées significatives dans les techniques diagnostiques et les connaissances médicales, plusieurs obstacles peuvent entraver la détection efficace de ces affections potentiellement mortelles. Il faut préciser que certaines maladies cardiovasculaires, comme les maladies cardiaques congénitales peuvent être difficiles à diagnostiquer en raison de la complexité de leurs présentations cliniques. Dans certaines régions, l'accès à des équipements de diagnostic avancés peut être limité. Il faut aussi tenir compte du facteur humain car les médecins peuvent parfois être influencés par des biais cognitifs ou des préjugés, ce qui peut entraîner des erreurs de diagnostic. Il faut également garder en esprit que la médecine cardiovasculaire est en constante évolution en raison de la recherche médicale et scientifique, les médecins doivent constamment se maintenir à jour avec les dernières avancées pour pouvoir détecter et traiter efficacement les maladies cardiovasculaires.

La solution aux obstacles cités peut être l'intelligence artificielle (l'IA). Cependant, son potentiel prometteur est contraint par des limitations comme des données de formation incomplètes ou biaisées. En effet, les performances des modèles d'IA dépendent largement de la qualité et de la quantité des données utilisées pour leur entraînement. L'une des plus grandes limitations à ce jour est l'interprétabilité et la transparence des modèles d'IA. En particulier, les réseaux neuronaux profonds, sont souvent vu comme des boîtes noires, ce qui rend difficile de comprendre comment ils parviennent à leurs décisions. Dans le domaine médical, il est crucial de pouvoir expliquer et interpréter les raisonnements derrière les décisions prises.

A ce jour, plusieurs modèles ont fait leurs preuves dans le domaine de la classification, cependant, l'essor constant de l'IA pose de nouveaux défis, notamment celui de concilier performance et coût de calcul. Si des modèles complexes ont démontré leur efficacité dans la classification, leur utilisation entraîne des exigences computationnelles élevées, ce qui se traduit par des coûts substantiels en termes de ressources matérielles et énergétiques. Dans ce contexte, la problématique qui émerge est la suivante : comment concevoir un modèle d'IA qui, tout en étant efficace sur le plan de la précision, et aussi efficient pour les coûts de calcul associés à son déploiement et à son fonctionnement ?

La motivation de ce mémoire participe du besoin de répondre à ces problématiques émergentes, où la demande croissante d'efficacité et d'efficience des modèles de classification de signaux physiologiques impose une réflexion approfondie. Dans le domaine de la conception d'un modèle d'IA à la fois performant et économique, notre démarche consistera à explorer des approches novatrices comme la décomposition de signal afin de réduire la taille des entrées tout en récupérant des informations cruciales. En équilibrant habilement ces aspects, nous visons à créer un modèle capable de rivaliser avec des architectures complexes tout en offrant des avantages significatifs en termes de coûts de calcul.

Contribution

Comme cité plus haut, ce mémoire se propose de naviguer dans les eaux complexes de l'intelligence artificielle et de la conversion de signaux physiologiques en apportant une contribution à la résolution de ces défis émergents. À travers une approche axée sur la décomposition de signal, nous chercherons à exploiter des informations plus riches, permettant ainsi d'améliorer non seulement l'efficacité des modèles d'IA, mais également de mieux s'orienter pour la conversion du signal PPG en ECG. Nous pouvons ainsi identifier les contributions suivantes :

1. L'évaluation comparative de diverses méthodes de décomposition de signaux pour servir d'entrée à un système de conversion de signaux PPG en ECG.
2. La mise en place de réseaux neuronaux efficaces et peu gourmands en ressources permettant la conversion, ainsi que la comparaison avec des réseaux témoins.
3. L'identification d'obstacles et la proposition de solutions pour des travaux futurs.

Structure du mémoire

La première section de ce mémoire explore les bases théoriques liées à la thématique de l'étude suivie d'un examen approfondi de la littérature, ces sections exposent les avancées variées des techniques de décomposition sur les signaux physiologiques, ainsi que les diverses approches de prédiction des maladies cardiovasculaires. La troisième section décrit la conception et la mise en œuvre de l'étude comparative, en détaillant les bases de données utilisées, les métriques d'évaluation et les protocoles expérimentaux. Les résultats obtenus sont ensuite analysés et discutés en profondeur dans la quatrième section, mettant en évidence les performances respectives des différentes techniques de décomposition, des modèles de classification et les solutions ou améliorations à apporter à la recherche. Finalement, une conclusion clôt ce travail.

CHAPITRE 1

FONDAMENTAUX

Cette section introduit les bases théoriques des signaux PPG et ECG afin de se familiariser avec différents termes et les comprendre en vue d'une analyse documentaire ultérieure.

1.1 Photopléthysmographie (PPG)

En 1937, les scientifiques Hertzman et Spealman découvrirent qu'ils pouvaient utiliser des cellules photo-électriques pour mesurer les changements dans la transmission de la lumière à travers un doigt, et que ces changements permettaient d'estimer avec précision la fréquence cardiaque. En effet, à chaque battement du cœur, le sang afflue dans les vaisseaux sanguins lors d'une phase appelée systole. En raison de l'afflux de sang riche en hémoglobine, le volume sanguin dans les capillaires augmente et le tissu devient légèrement plus épais et plus rouge comme illustré dans l'image 1.1. Au fur et à mesure que le cœur régurgite, pendant la diastole, la quantité de sang dans les tissus diminue et ceux-ci deviennent moins opaques. C'est sur ces principes physiologiques et optiques que reposent la mesure des signaux d'un photopléthysmogramme.

Comme expliqué ci-dessus, la PPG est une méthode non invasive d'exploration fonctionnelle vasculaire qui permet de déterminer le fréquence cardiaque mais aussi le taux d'oxygène dans le sang, la pression artérielle.




Figure 1.1 image descriptive du fonctionnement du PPG de (Vandenberk *et al.*, 2017)

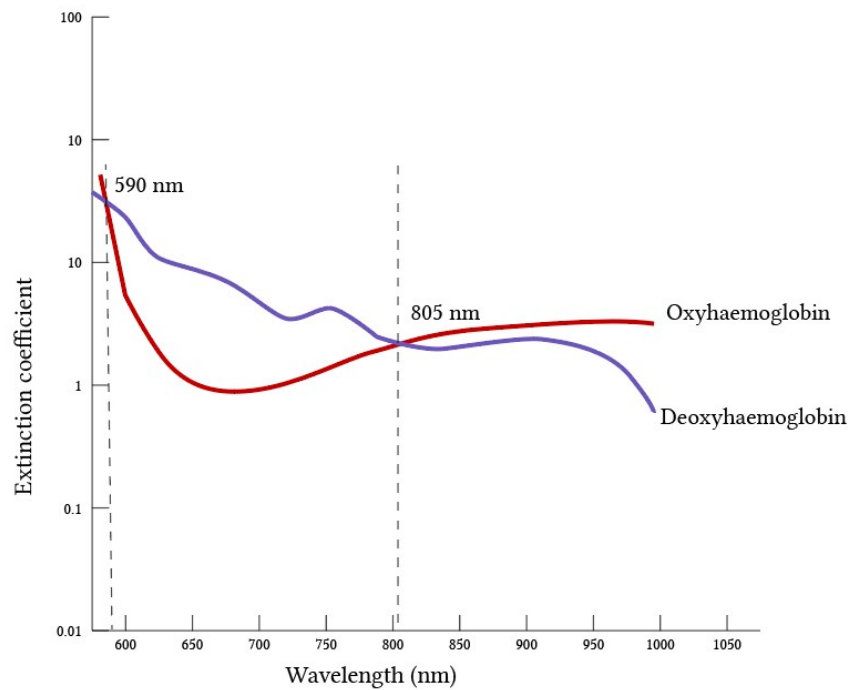


Figure 1.2 comparaison des absorbances à différentes longueurs d'onde du sang de (University of Iowa Health Care, 2024)

Un système utilisant la PPG est composé de diodes électroluminescentes (LED) et d'un capteur optique pour la récupération des informations. Les LEDs sont au nombre de deux, soit rouge et vert ou rouge et infrarouge. Cette différence de LED est choisie en fonction de l'absorbance à différentes longueurs d'onde du sang, comme illustré sur la figure 1.2. Il existe deux méthodes pour envoyer la lumière à travers le doigt :

- La transmission : les LED et le capteur optique sont placés sur des côtés opposés du membre. La lumière transmise par la source lumineuse passe à travers le volume d'hémoglobine dans les capillaires sous-cutanés, qui sont ensuite capturés par les photorécepteurs.
- La réflexion : les deux LED et le photorécepteur sont disposés sur le même côté du doigt, de l'oreille ou du poignet. Ainsi la lumière rebondit de l'Émetteur au détecteur.

La PPG a une gamme d'applications cliniques importantes, notamment la détection des troubles du rythme cardiaque, l'évaluation de la perfusion sanguine périphérique, la surveillance de la saturation en oxygène (SpO2) (Allen, 2007) etc.

Les capteurs utilisant la PPG comme technique d'exploration non invasive sont sujets à un problème de mouvement. En effet, la partie du corps où sont placés les capteurs doit être le plus stable possible. De nombreuses études ont déjà été menées sur le placement optimal des capteurs PPG, comme (Longmore *et al.*, 2019) qui vise à déterminer l'emplacement anatomique non traditionnel approprié pour recueillir la fréquence cardiaque, la saturation de l'hémoglobine en oxygène (SpO₂) et la fréquence respiratoire. Huit capteurs ont été placés sur différentes parties du corps comme le front, la tempe, le cou, ... L'étude a été menée dans deux situations : au repos et en marchant à quatre km/h. Ainsi, le pourcentage d'erreur pour les trois paramètres a été calculé pour une bonne comparaison. Après les tests menés, les résultats ont montré que le doigt est l'emplacement idéal pour un capteur PPG. Ces résultats justifient le choix d'emplacement des appareils commerciaux.

1.2 Electrocardiogramme (ECG)

L'ECG est une méthode diagnostique fondamentale dans le domaine de la cardiologie, permettant d'évaluer l'activité électrique du cœur. C'est un outil non invasif qui fournit des informations précieuses sur le rythme cardiaque, la conduction électrique, les anomalies cardiaques et les affections cardiovasculaires. Il se base sur le principe que les contractions cardiaques génèrent des signaux électriques qui peuvent être enregistrés à la surface de la peau. Ces signaux électriques résultent de l'activité des cellules cardiaques et de la propagation des impulsions électriques à travers les différentes régions du cœur. L'ECG détecte ces variations de potentiel électrique et les convertit en une représentation graphique.

Pour obtenir un ECG, les électrodes qui captent les différences de potentiel électrique sont placées sur la peau de différentes parties du corps dont les membres et la poitrine, comme illustré sur la figure 1.5. Pour obtenir une vue complète des différents aspects de la dépolarisation et de la repolarisation du cœur, des configurations spécifiques d'électrodes sont utilisées. Ces configurations donnent les douze dérivations de l'ECG, tel qu'indiqué dans l'illustration 1.3. Le tracé d'un ECG est composé de différentes ondes et complexes, dont les plus connus sont les ondes P, QRS et T, tel qu'indiqué dans l'illustration 1.4 :

- L'onde P représente la dépolarisation auriculaire.
- Le complexe QRS représente la dépolarisation ventriculaire.
- L'onde T représente la repolarisation ventriculaire.
- L'onde U représente la repolarisation du muscle papillaire.




Figure 1.3 Exemple des douze dérivation (Handschin et Sticherling, 2009)

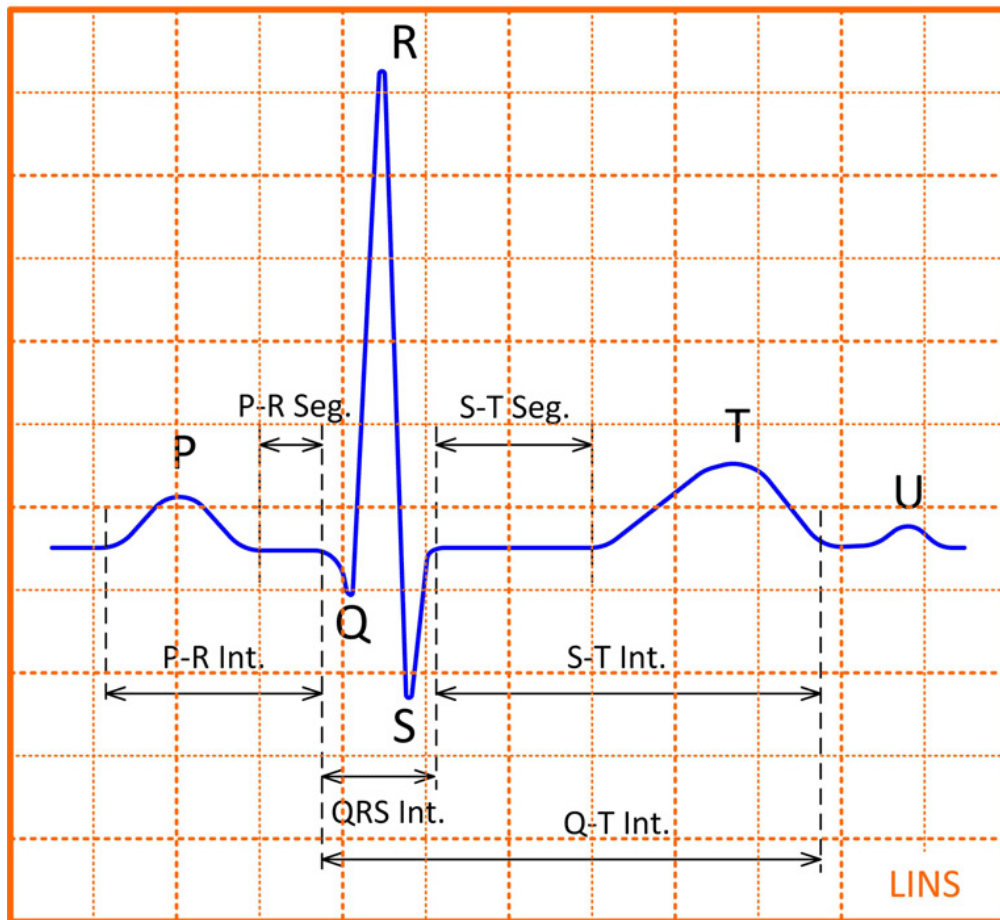


Figure 1.4 ondes d'un signal ECG (Zizoua *et al.*, 2012)

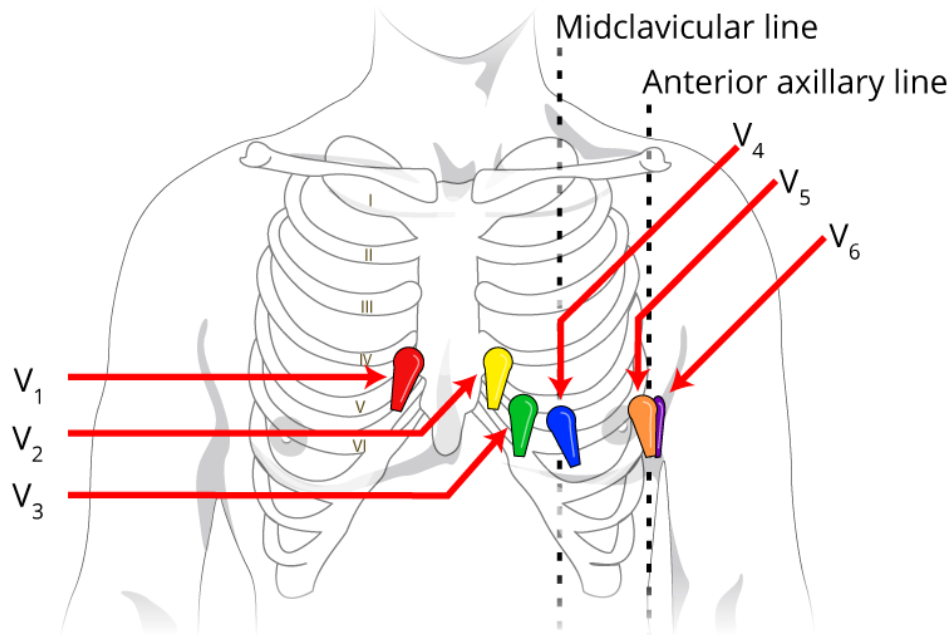


Figure 1.5 Placement des dérivation précordiales vers les électrodes thoraciques (ADInstruments,)

L'ECG a une gamme d'applications cliniques importantes, notamment la détection des troubles du rythme cardiaque, la détection des infarctus du myocarde, l'évaluation de la conduction cardiaque, mais aussi la surveillance des pathologies cardiaques structurelles (Wagner *et al.*, 2009).

1.3 Techniques de conversion de signaux PPG en signaux ECG

En prenant en compte les propriétés des signaux ECG et PPG, des points communs, existent comme leurs relations avec le rythme cardiaque, les pulsations cardiaques, leurs réponses aux stimuli, etc. Cela permet d'avancer la possibilité de convertir l'un en l'autre, dont celle d'un signal PPG en signal ECG à l'aide de modèles appropriés. Parmi eux, nous pouvons citer les réseaux de neurones artificiels et des techniques statistiques comme les modèles de régression.

1.3.1 Les modèles de régression

Les modèles de régression sont des techniques statistiques pour modéliser la relation entre une variable dépendante et une ou plusieurs variables indépendantes. Ainsi, les modèles peuvent être utilisés pour pré-

dire ou estimer la variable dépendante en fonction des valeurs des variables indépendantes. Le modèle de régression le plus courant est la régression linéaire simple qui s'exprime par la formule suivante :

$$y = \beta_0 + \sum_{i=1}^n (\beta_i x_i) + \epsilon$$

avec y qui est la variable dépendante, x_i les variables indépendantes, β_i les coefficients correspondants et ϵ qui est le terme d'erreur, qui capture les variations résiduelles non expliquées par la relation linéaire entre les variables X et Y. Elle est utilisée lorsque la relation entre la variable dépendante et la variable indépendante peut être modélisée par une droite.

Dans notre cas de figure, la régression linéaire simple n'est pas adaptée pour la conversion en raison des différences fondamentales entre les deux types de signaux. Il existe également la régression linéaire par crête. C'est une technique de régression linéaire régularisée qui peut être utilisée lorsque les données présentent des problèmes de multicollinéarité (corrélation élevée entre les variables indépendantes) ou de surajustement (*overfitting*). Elle s'exprime par la formule suivante :

$$y = \beta_0 + \sum_{i=1}^n (\beta_i x_i) + \lambda \sum_{i=1}^n (\beta_i)^2 + \epsilon$$

avec y qui est la variable dépendante, x_i les variables indépendantes, β les coefficients correspondants, λ le paramètre de régularisation et ϵ le terme d'erreur.

Cette technique peut certes être une solution pour notre problème de conversion ; cependant, son utilisation directe pour convertir un signal PPG en un signal ECG complet présente des défis importants en raison des différences fondamentales entre ces deux types de signaux. Afin de surmonter ces défis, il serait idéal d'explorer la possibilité d'extraire des caractéristiques représentatives du signal PPG qui pourraient être directement liées à certaines caractéristiques observées dans les signaux ECG, avec par exemple des méthodes de décomposition. Les méthodes de décomposition sont des outils puissants dans ce contexte, car elles permettent d'analyser et d'isoler les composantes spécifiques du signal PPG qui sont corrélées aux aspects essentiels des signaux ECG. En ce sens, les méthodes de décomposition servent de pont en permettant une extraction ciblée des informations pertinentes, une réduction des dimensions des données facilitant ainsi le processus de conversion en minimisant les distorsions potentielles et en améliorant la fidélité de la prédiction du signal ECG à partir du signal PPG. Parmi ces techniques de décomposition, nous avons : la transformée en cosinus discrète (DCT), la transformée en ondelettes discrètes (DWT), l'*empirical mode decomposition* (EMD), la *variational mode decomposition* (VMD) et la combinaison de EMD-DWT et VMD-DWT

1.3.1.1 Transformée en cosinus discrète (DCT)

La DCT est une technique de traitement du signal largement utilisée pour convertir un signal discret en une série de coefficients de fréquence. A l'instar de la transformée de Fourier discrète (DFT), la DCT permet de convertir un signal discret en une série de coefficients de fréquence qui représentent les composantes fréquentielles du signal. Ces coefficients sont ensuite utilisés pour traiter, stocker ou transmettre un signal de manière plus efficace. Cette transformée s'exprime par la formule (Huang *et al.*, 2010) :

$$X_k = \alpha(k) \sum_{n=0}^{N-1} x_n \cos \left(\frac{\pi}{N} \left(n + \frac{1}{2} \right) k \right)$$

où :

- X_k est le coefficient DCT à la position k ,
- x_n est la valeur du signal à la position n ,
- N est la longueur de la séquence,
- k est la fréquence spatiale,
- $\alpha(k)$ est un facteur d'échelle défini comme suit :
 - $\alpha(k) = \frac{1}{\sqrt{N}}$ si $k = 0$
 - $\alpha(k) = \frac{2}{\sqrt{N}}$ sinon

Il existe une technique permettant de passer des coefficients d'une DCT au signal original. Il s'agit de l'inverse de la DCT (iDCT), l'opération mathématique inverse de la DCT. Il permet de reconstruire un signal à partir de ses coefficients DCT préalablement calculés. Mathématiquement, la formule de l'iDCT pour une séquence unidimensionnelle de N échantillons est très similaire à celle de la DCT, mais elle utilise les coefficients DCT au lieu des valeurs du signal.

1.3.1.2 Transformée en ondelette discrète (DWT)

La DWT est une méthode puissante largement utilisée dans le domaine du traitement du signal et de l'analyse de données. Elle offre des avantages significatifs par rapport à d'autres techniques de transformation, en particulier pour l'analyse de signaux non stationnaires et la décomposition multirésolution. Introduite comme une extension de la transformée en ondelettes continue (CWT), la DWT est une transformation qui décompose un signal donné en un certain nombre d'ensembles, chaque ensemble étant une série temporelle de coefficients décrivant l'évolution temporelle du signal dans la bande de fréquence correspondante.

Elle est exprimée par l'équation suivante (Srivastava, 2018) :

$$D[a, b] = \frac{1}{\sqrt{b}} \sum_{m=0}^{P-1} f[t_m] \psi \left(\frac{t_m - a}{b} \right)$$

où :

- $D[a, b]$ représente le coefficient de la DWT à une certaine échelle a et position b ,
- $f[t_m]$ est la valeur du signal original à l'instant t_m ,
- $\psi \left(\frac{t_m - a}{b} \right)$ est la fonction ondelette.

L'utilisation d'une DWT nécessite le choix du type d'ondelette qui peut varier selon les besoins. Parmi ces ondelettes, on peut citer :

- Ondelettes de Haar : elles sont discontinues et adaptées pour détecter les changements abrupts dans les signaux.
- Ondelettes de Daubechies (db) : cette famille d'ondelettes offre des ondelettes d'ordre supérieur qui sont continues et régulières. Elles ont des propriétés de conservation et sont adaptées à la détection des bords.
- Ondelettes Coiflet : cette famille d'ondelettes est conçue pour minimiser les oscillations indésirables dans les coefficients de détail, ce qui peut être utile pour la décomposition de signaux bruités.
- Ondelettes de Symlet : les ondelettes de Symlet sont similaires aux ondelettes de Daubechies mais ont un support plus long. Elles sont utiles pour la décomposition de signaux avec des variations plus lentes.

A la sortie d'une DWT, nous obtenons deux types de coefficients : les coefficients d'approximation (cA) et les coefficients de détail (cD). Les cA représentent les basses fréquences et l'information globale du signal. Ils correspondent à la composante moyenne ou lissée du signal. Les coefficients d'approximation fournissent une vue d'ensemble du signal à une échelle réduite. Les cD représentent les hautes fréquences et les variations locales du signal. Ils captent les détails fins ou les composantes à haute fréquence du signal. Les coefficients de détail permettent de détecter des variations brèves et de capturer des caractéristiques spécifiques du signal.

La transformée en ondelettes inverse discrète (iDWT) est l'opération inverse de la DWT. Elle est utilisée pour inverser la DWT et restaurer le signal ou l'image d'origine à partir de ses coefficients d'ondelettes transformés. En général, l'iDWT est réalisée en effectuant une série d'opérations de convolution et d'addition sur les coefficients d'ondelettes à différents niveaux de résolution spatiale. Elle est exprimée par la formule

suivante (Srivastava, 2018) :

$$f[t_m] = \sum_{k=0}^{P-1} A_n[k] \phi(n, k)[t_m] + \sum_{j=1}^N \sum_{k=0}^{P-1} D_j[k] \psi(j, k)[t_m]$$

où :

- $A_n[k]$ est le $k^{\text{ème}}$ coefficient d'approximation,
- $D_j[k]$ est le $k^{\text{ème}}$ coefficient de détail,
- $\phi(n, k)[t_m]$ est une ondelette d'approximation de l'échelle n à l'instant t_m ,
- $\psi(j, k)[t_m]$ est une ondelette de détail de l'échelle n à l'instant t_m .

1.3.1.3 Empirical mode decomposition (EMD)

L'EMD est une technique d'analyse de données et de décomposition de signaux qui a gagné en popularité en raison de sa capacité à traiter des signaux non linéaires et non stationnaires. Elle permet de décomposer un signal complexe en composantes intrinsèques appelées fonctions de modes intrinsèques (IMF). L'EMD se caractérise par sa décomposition adaptative qui ne requiert pas de signal de base comme la DCT ou la DWT. En effet, l'EMD adapte la décomposition en fonction des caractéristiques locales du signal, les IMF sont adaptés à l'échelle et à la fréquence du signal en cours d'analyse. Elle se caractérise aussi par sa méthode récursive qui extrait successivement les composantes oscillantes du signal original jusqu'à ce qu'il ne reste plus aucune variation significative (Lahmiri et Boukadoum, 2013). Chaque étape de cette décomposition est appelée «*sifting*» (Lahmiri et Boukadoum, 2015). Pour qu'une fonction soit considérée comme une IMF, elle doit satisfaire deux critères (Lahmiri et Boukadoum, 2013) :

- Critère de nombre d'extrema : le nombre d'extrema de l'IMF et son nombre de passages par zéro sont égaux ou diffèrent d'au plus un. Cela garantit que l'IMF ne présente pas de variations excessives et capture une tendance intrinsèque du signal.
- Critère de moyenne nulle : la moyenne des valeurs maximales et minimales de l'IMF est nulle ou proche de zéro. Cela garantit que l'IMF ne présente pas de décalage ou de tendance globale importante.

Ces critères appelé critères de monotonie visent à assurer que les IMF captent les variations locales du signal sans inclure de tendances globales, de bruit excessif ou de variations inappropriées. L'application rigoureuse de ces critères est essentielle pour obtenir une décomposition précise du signal en IMF significatives. Les formules de ces critères de monotonie sont disponibles dans (Lahmiri et Boukadoum, 2013). Pour obtenir le signal d'origine à partir des IMFs, une simple addition suffit.

1.3.1.4 Variational mode decomposition (VMD)

La VMD a été proposée comme une alternative à l'EMD, visant à résoudre les limitations de l'approche adaptative de l'EMD. La VMD formule le problème de décomposition comme une optimisation variationnelle, permettant un contrôle plus fin des modes extraits. En effet, à la différence de l'EMD qui découpe un signal en modes intrinsèques en déterminant les extrema locaux de manière itérative, la VMD formule le problème de décomposition sous la forme d'une fonction de coût à minimiser. Cette fonction de coût prend en compte à la fois la fidélité des modes extraits aux données originales et des termes de régularisation pour contrôler le lissage des modes et la séparation entre eux.

La VMD est un processus séquentiel qui décompose le signal d'entrée en un nombre discret de sous-signaux (modes), où chaque mode a une bande passante limitée. Chaque mode k a une pulsation centrale ω_k . Le nombre de modes peut être sélectionné, ce qui détermine la pulsation centrale. Pour évaluer la bande passante d'un mode, les signaux analytiques associés sont calculés au moyen de la transformée de Hilbert de manière à obtenir un spectre de fréquence unilatéral. En ajustant l'exposant à la fréquence centrale estimée respective, le spectre du mode est déplacé vers la bande de base. La formule du problème variationnel contraint est donnée par (Dragomiretskiy et Zosso, 2014) :

$$\min(u_k, \omega_k) = \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] \exp(-j\omega_k t) \right\|_2 \right\}$$

où :

$$\sum_k u_k = s$$

avec s qui correspond au signal, u_k est le $k^{\text{ème}}$ mode, ω_k est la fréquence centrale, k est le mode, $\delta(t)$ est la distribution de Dirac, t est le temps et $*$ est la convolution.

Cette approche offre à la VMD plusieurs avantages significatifs par rapport à l'EMD. Sa formulation variationnelle confère une plus grande stabilité à la décomposition des signaux, garantissant des résultats cohérents et reproductibles. En introduisant des termes de régularisation, la VMD permet de contrôler la fidélité des modes extraits ainsi que leur séparation et leur lissage. Cette adaptabilité accrue la rend applicable à une gamme plus large de signaux tel que des signaux biomédicaux complexes. L'addition des sous-signaux issus d'une VMD permet de retrouver le signal d'origine. Il est à noter cependant que VMD demande un effort de calcul plus grand que l'EMD.

1.3.1.5 La combinaison de différentes techniques de décomposition

La combinaison de différentes techniques de décomposition constitue une approche puissante d'analyse de signaux complexes pour extraire des informations significatives à partir des données brutes. Cette approche permet de fédérer les avantages des différentes méthodes et de mitiger leurs limitations. Lorsqu'il s'agit de décomposer des signaux en modes intrinsèques ou en composantes significatives, la combinaison de plusieurs techniques de décomposition peut améliorer la qualité des résultats et permettre une meilleure interprétation des caractéristiques du signal.

a) EMD + DWT

Cette approche consiste à décomposer le signal d'origine en utilisant d'abord l'EMD pour extraire les modes intrinsèques. Ensuite, les modes intrinsèques sont soumis à une DWT pour analyser ses variations à différentes échelles. Cette approche permet d'obtenir une décomposition en modes intrinsèques avec des détails de fréquence spécifiques à chaque échelle et ainsi atteindre les objectifs souhaités.

b) VMD + DWT

Cette approche comme celle d'au-dessus, consiste à décomposer le signal d'origine en utilisant d'abord la VMD pour extraire les modes intrinsèques. Ensuite, les IMF sont soumis à une DWT pour analyser ses variations à différentes échelles. Cette approche permet d'obtenir une décomposition en modes intrinsèques avec des détails de fréquence spécifiques à chaque échelle.

1.3.2 Intelligence artificielle

L'intégration croissante de l'intelligence artificielle (IA) dans le domaine médical a ouvert de nouvelles voies pour résoudre des problèmes complexes tels que la conversion de signaux PPG en signaux ECG. Parmi ces IA, nous pouvons citer :

- Réseaux de neurones récurrents (RNN) : ils sont utiles pour capturer les relations temporelles dans les signaux PPG, en prenant en compte les variations rythmiques et les transitions.
- Réseaux génératifs adverses (GAN) : les GAN peuvent être utilisés pour générer des signaux ECG

simulés à partir de signaux PPG, en utilisant des générateurs pour imiter la relation entre les deux types de signaux.

Les architectures GAN reposent sur deux réseaux de neurones antagonistes qui essaient chacun de prendre le dessus sur l'autre lors de l'apprentissage : un réseau génératif et d'un réseau discriminant. Le réseau génératif a pour rôle de générer à partir de valeurs aléatoires (vecteurs) des données qui ressemblent à celles du jeu de données d'entraînement et celui du discriminant est de différencier les données générées de celle des données d'entraînement. Ainsi il peut arriver que :

- Le générateur arrive avec succès à reproduire la distribution initiale et que le discriminant n'arrive pas à faire la différence.
- Le discriminant arrive avec succès à différencier les nouvelles données générées.
- Aucun des deux n'arrivent à dominer l'autre, cela les pousse à faire plus d'efforts.

1.4 Réseau de neurones pour la prédiction

Les réseaux de neurones artificiels ont émergé comme l'une des percées les plus significatives dans le domaine de l'IA et de l'apprentissage automatique au cours des dernières décennies. Inspirés par le fonctionnement du cerveau humain, ces modèles informatiques complexes sont devenus un pilier fondamental de la recherche en intelligence artificielle, de l'automatisation de tâches cognitives à la résolution de problèmes complexes dans des domaines allant de la vision par ordinateur à la compréhension du langage naturel.

Un réseau de neurones est composé d'un ensemble de nœuds interconnectés appelés neurones artificiels. Ces neurones sont organisés en couches, généralement avec une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie comme illustré sur l'image 1.6. Chaque neurone reçoit des entrées, effectue des calculs et transmet une sortie. Chaque couche d'un réseau est composée d'un ou plusieurs neurones artificiels, et chaque neurone a des composants fondamentaux qui sont :

- Entrées : le neurone reçoit des signaux de la couche précédente du réseau ou d'autres sources. Elles sont utilisées pour calculer la sortie du neurone.
- Biais : une entrée supplémentaire dans un neurone qui permet de régler la flexibilité du neurone.
- Poids : les poids sont des facteurs multiplicateurs qui affectent l'influence de chaque entrée sur la sortie du neurone.
- Noyau : c'est la partie qui intègre toutes les entrées (y compris le biais) et effectue un calcul pour produire la sortie du neurone.

— Sortie : la sortie du neurone est la valeur calculée par le noyau en réponse aux entrées.




Figure 1.6 Mise en correspondance neurone biologique / neurone artificiel (Cornuéjols *et al.*, 2018)

Le fonctionnement du noyau d'un neurone se décompose principalement en deux phases. La première consiste à calculer la somme pondérée des entrées. Chaque entrée x_i est multipliée par le poids de son lien W_i et ces produits sont ensuite additionnés pour obtenir valeur unique. Cela peut être exprimé par l'équation :

$$sortie = \sum_i (W_i x_i)$$

La deuxième phase consiste à appliquer une fonction d'activation à la somme pondérée calculée à l'étape précédente. Elle introduit de la non-linéarité dans le modèle du neurone et détermine si le neurone doit s'activer (c'est-à-dire produire une sortie non nulle) en fonction de la valeur résultante de la somme pondérée.

Les réseaux de neurones peuvent être classés en deux catégories principales : les réseaux monocouches et les réseaux multicouches. Un réseau monocouche est le type le plus simple de réseau de neurones artificiels, composé d'une seule couche de neurones. Les réseaux monocouches sont généralement utilisés pour des tâches de classification binaire simples ou de régression linéaire. Ils sont adaptés aux problèmes où une simple ligne ou un simple plan peut séparer les différentes classes de données mais ne sont pas capables de capturer des relations non linéaires complexes entre les données. A l'inverse des réseaux monocouches, les réseaux multicouches ou perceptrons multicouches sont composés de plusieurs couches de neurones, y compris une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Les réseaux multicouches sont formés à l'aide d'algorithmes d'apprentissage supervisé, tels que la rétropropagation. Pendant l'apprentissage, les poids des connexions entre les neurones sont ajustés pour minimiser une fonction de perte qui mesure la différence entre les prédictions du réseau et les valeurs réelles. Les

réseaux multicouches sont capables de capturer des relations non linéaires complexes entre les données, ce qui les rend adaptés à une grande variété de tâches, notamment la classification d'images.

1.4.0.1 Fonction d'activation

Une fonction d'activation est une fonction mathématique appliquée à la sortie pondérée d'un neurone pour déterminer la sortie réelle du neurone. C'est-à-dire quelle calcule la valeur de l'état du neurone. Parmi les fonctions d'activation on peut citer :

a) *Rectified linear unit* (ReLU)

C'est l'une des fonctions d'activation les plus couramment utilisées dans les réseaux de neurones artificiels, en particulier dans le domaine de l'apprentissage profond pour sa simplicité, sa non-linéarité et son efficacité. Elle est définie comme :

$$f(x) = \max(0, x)$$

où x est la valeur d'entrée et la fonction max renvoie la valeur maximale entre 0 et x . L'inconvénient de cette fonction est la possibilité d'avoir des neurones morts c'est-à-dire des neurones qui restent inactifs et ne contribuent pas à l'apprentissage.

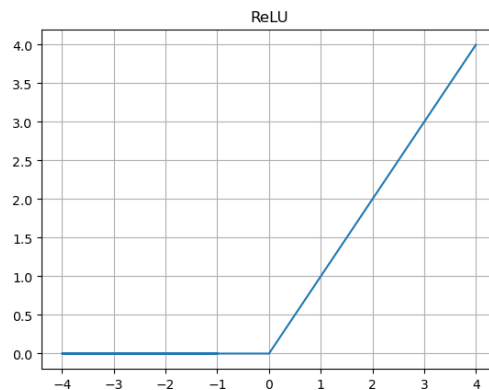


Figure 1.7 ReLU

b) *Leaky ReLU*

C'est une variante de la fonction d'activation ReLU. Contrairement à la fonction ReLU, qui met toutes les valeurs négatives à zéro, la fonction Leaky ReLU les réduit à une petite valeur positive déterminée par le «taux de fuite» (*leakage rate*). La fonction Leaky ReLU a été introduite pour résoudre le problème potentiel

de neurones morts. La fonction Leaky ReLU s'exprime par :

$$f(x) = \begin{cases} x & \text{si } x \geq 0 \\ \alpha \cdot x & \text{si } x < 0 \end{cases}$$

où x est la valeur d'entrée et α est le taux de fuite qui est souvent très petit (par exemple 0,01).




Figure 1.8 Leaky ReLU

c) Sigmoide

C'est une fonction mathématique qui transforme une valeur d'entrée en une sortie dans l'intervalle (0, 1). C'est une fonction stable pour des valeurs d'entrée positives et négatives, ce qui peut contribuer à la stabilité numérique lors de l'entraînement du réseau de neurones. Elle peut être exprimée comme suit :

$$f(x) = \frac{1}{1 + e^{-x}}$$




Figure 1.9 Sigmoide (Goulon, 2008)

d) Tangente hyperbolique (tanh)

C'est une fonction d'activation couramment utilisée dans les réseaux de neurones artificiels. Elle transforme une valeur d'entrée en une sortie dans l'intervalle $(-1, 1)$. Elle a pour définition mathématique :

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$




Figure 1.10 tanh (Tafforeau, 2014)

1.4.0.2 Optimisation de l'apprentissage

Lors de l'entraînement d'un réseau de neurones, plusieurs étapes distinctes sont entreprises pour garantir un apprentissage efficace. Ainsi dans un premier temps, l'algorithme d'apprentissage commence par déterminer l'erreur courante à la sortie et la rétropropager à travers les couches du réseau.

Ensuite, la métaheuristique de descente de gradient est appliquée pour chercher l'erreur minimale. L'algorithme fonctionne de manière itérative avec, à chaque étape, le calcul du gradient de la fonction d'erreur

globale (coût) par rapport aux paramètres du modèle, indiquant ainsi la direction dans laquelle les paramètres doivent être ajustés pour réduire la valeur de la fonction de coût.

Enfin, un optimiseur d'apprentissage est utilisé pour la mise à jour des poids en fonction du gradient calculé précédemment, notamment en ajustant les paramètres du modèle en proportion d'un taux d'apprentissage spécifié. Ce processus d'optimisation se répète jusqu'à ce que la fonction de coût atteigne un minimum ou que d'autres conditions d'arrêt soient remplies.

Ainsi, en suivant cette séquence, l'algorithme d'apprentissage utilise de concert la rétropropagation d'erreur, la descente de gradient et l'optimiseur d'apprentissage pour permettre au réseau de neurones d'apprendre efficacement à partir des données d'entraînement.



Figure 1.11 Illustration de la descente de gradient.(Ananthram, 2018)

Dans la famille des algorithmes d'optimisation, on peut citer :

- *Adaptive moment estimation* (Adam) : il s'agit d'une amélioration de la descente de gradient stochastique (SGD) qui ajuste le taux d'apprentissage de manière adaptative pour chaque paramètre et utilise des moments pour suivre le gradient.
- *Root mean square propagation* (RMSprop) : RMSprop adapte également le taux d'apprentissage pour chaque paramètre, mais il l'ajuste en tenant compte des gradients précédents. Il utilise une moyenne mobile exponentielle des carrés de ces gradients pour ajuster le taux d'apprentissage.
- *Adaptive gradient algorithm* (Adagrad) : Adagrad adapte le taux d'apprentissage en fonction de la fréquence d'apparition des gradients pour chaque paramètre. Cela permet d'ajuster automatiquement le taux d'apprentissage pour des paramètres qui sont mis à jour plus fréquemment.

1.4.0.3 *Overfitting*

L'*overfitting* ou surapprentissage en français est un phénomène où un modèle apprend les détails et le bruit dans les données d'entraînement au lieu de généraliser à partir des données. En conséquence, le modèle devient très performant sur les données d'entraînement, mais ne généralise pas bien pour les nouvelles données, ce qui peut entraîner des performances médiocres sur un ensemble de données de test ou dans des applications réelles. Il peut être causé par la complexité du modèle, c'est-à-dire un modèle avec un grand nombre de paramètres peut augmenter le risque de surapprentissage. Il peut aussi être causé par le manque de données ou des données redondantes. Pour y remédier, il existe plusieurs approches dont l'usage de fonctions de régularisation et de l'extinction de neurones (*dropout*). On peut aussi avoir un meilleur aperçu de la performance du réseau en utilisant la validation croisée qui consiste à diviser de manière répétitive les données en des données d'entraînement, de validation, et de test différentes pour évaluer le modèle et ajuster les paramètres qui contrôlent le comportement global de l'algorithme d'apprentissage et influencent la manière dont le modèle est entraîné (hyperparamètres). Il est également important d'éliminer les données redondantes et si les données sont insuffisantes, de les augmenter de manière artificielle en appliquant des transformations légères aux exemples existants.

1.4.0.4 Transfert d'apprentissage

Dans l'optique d'accélérer l'apprentissage et améliorer les performances d'un modèle, une approche reposant sur le principe que les connaissances et les représentations apprises par un modèle sur une tâche peuvent être transférées et réutilisées pour résoudre d'autres tâches a vu le jour. Cette approche se nomme le transfert d'apprentissage. Le transfert d'apprentissage permet souvent de réduire considérablement la quantité de données d'entraînement requise pour obtenir de bonnes performances sur une nouvelle tâche, car le modèle a déjà appris des représentations générales à partir de données massives. Cependant, il faut s'assurer que les connaissances apprises ont un rapport avec les données à disposition.

1.4.0.5 Réseau de neurone convolutif

Appelé *convolutional neural network* (CNN) en anglais, ce réseau de neurone a été spécialement conçu pour le traitement d'images et la vision par ordinateur. Il est devenu l'une des architectures de base dans le domaine de l'apprentissage automatique et a révolutionné de nombreuses applications, notamment la reconnaissance d'images, la détection d'objets, la segmentation d'images, la classification d'images médi-

cales, etc. Il se caractérise par son architecture en couches. En effet, les CNN sont composés de plusieurs couches de convolution responsables de l'extraction des caractéristiques, de couches de *pooling* qui sont des couches responsables de la réduction de la dimensionnalité des cartes de caractéristiques en conservant uniquement les informations les plus importantes et de couches entièrement connectées (couches denses) utilisées pour la classification finale, qui forment une architecture en cascade. Conçus pour les données bidimensionnelles telles que des images, les CNN peuvent également être adaptés pour traiter des données unidimensionnelles. La principale différence réside dans la structure du réseau et la façon dont les opérations de convolution sont appliquées. En effet, au lieu d'appliquer des convolutions bidimensionnelles, il suffit d'utiliser des convolutions unidimensionnelles. Il faut aussi adapter la couche d'entrée du CNN pour qu'il soit compatible avec les données unidimensionnelles.

1.5 *Support vector machines (SVM)*

Les SVM, développés par Vladimir Vapnik et son équipe dans les années 1990 (Isabelle, 2021), sont une classe d'algorithmes d'apprentissage automatique largement utilisés dans la classification. Ils sont particulièrement populaires pour leur capacité à gérer efficacement des problèmes de classification à grande dimension et à bien généraliser à partir de données limitées. Le principe fondamental des SVM réside dans leur capacité à identifier un hyperplan optimal, qui peut prendre la forme d'une ligne en deux dimensions, d'un plan en trois dimensions, ou d'un hyperplan en dimensions supérieures. Cet hyperplan est soigneusement positionné de manière à maximiser la marge entre deux classes distinctes dans un problème de classification binaire. La marge est la zone située entre l'hyperplan et les exemples les plus proches de chaque classe, appelés vecteurs de support.

CHAPITRE 2

ÉTAT DE L'ART

Ce chapitre fournit une analyse critique des avancées récentes dans les deux domaines interdépendants qui sont le traitement de signal par la décomposition et la classification. D'une part, nous explorerons les différents écrits montrant l'efficacité des techniques de décomposition et leurs impacts sur des signaux physiologiques tels que l'ECG et la PPG. D'autre part, nous passerons en revue les réseaux de neurones qui peuvent être utilisés pour la classification de maladies cardiovasculaires.

2.1 Techniques de conversion de signaux PPG en signaux ECG

2.1.1 Techniques de décomposition

2.1.1.1 Transformée en cosinus discrète (DCT)

Dans (Zhu *et al.*, 2019), les auteurs ont reconstruit un signal d'ECG à partir d'un signal de PPG. Pour atteindre l'objectif, ils ont proposé d'apprendre un modèle qui relie les signaux PPG et ECG sur le plan fréquentiel. Ainsi, ils ont appliqué une DCT sur des cycles PPG et ECG. Sur les coefficients obtenus, les auteurs ont pris les douze premiers coefficients du PPG et les 100 premiers coefficients de l'ECG pour représenter la forme d'onde correspondante car l'énergie d'un signal se concentrait dans les plus bas coefficients de fréquence issus de sa DCT. Après la récupération de ces valeurs, les auteurs passent à l'entraînement. Ils utilisent la régression de crête pour mapper les coefficients DCT du PPG au ECG. Après les tests, le système arrive à reconstruire quasi parfaitement l'ECG et conserver la forme d'origine de la forme d'onde et l'emplacement de chaque pic PQRST.

2.1.1.2 Transformée en ondelettes discrètes (DWT)

Dans (Tang *et al.*, 2016), la DWT a été utilisée dans la réduction du bruit d'un signal PPG. Après cette reconstruction, les auteurs ont effectué le calcul du nombre de battement par minute et ont constaté une amélioration de 67% de l'erreur quadratique moyenne (MSE). Également dans (Liu *et al.*, 2020), un travail basé sur la DWT et l'algorithme de classification SVM met en œuvre un système matériel comprenant l'acquisition du signal ECG, l'extraction des caractéristiques et la classification. Après la récupération du signal et le prétraitement, les auteurs sont passés à la phase d'extraction. Pour cela ils ont utilisé les cA du signal

décomposé à l'aide du DWT avec l'ondelette Daubechies 2 (db2) construites à partir de deux filtres d'analyse et de deux filtres de synthèse. Le cA est ensuite envoyé à un ensemble de circuits pour obtenir un cA en quatre couches qui est envoyé au circuit SVM optimisé. Lors de la phase de test, le système conçu a obtenu un gain de temps de classification pour chaque battement de cœur de $280\mu s$ contre $313\mu s$ pour le système témoin. Il a également eu une meilleure précision de 98,7% contre 98,4%. Ce système permet de mettre en évidence la puissance du SVM mais aussi du DWT dans l'extraction des fonctionnalités.

2.1.1.3 *Empirical mode decomposition (EMD)*

Dans (Lahmiri et Boukadoum, 2013), les auteurs ont proposé une approche pour distinguer les images de résonance magnétique (IRM) cérébrales normales et anormales. Pour cela, ils utilisent la décomposition de mode empirique (EMD) et la classification par machines à vecteurs de support (SVM). Afin d'atteindre les objectifs, les auteurs ont tout d'abord effectué un ensemble de traitement sur les données brutes et ont ensuite effectué l'EMD pour obtenir des IMF qui seront ensuite utilisés pour extraire des caractéristiques. Avec l'hypothèse que les signaux élémentaires à haute fréquence captent des changements soudains dans le tissu biologique, cinq caractéristiques texturales statistiques sont extraites. Ces statistiques sont ensuite évaluées et classées en fonction de leur entropie conditionnelle de classe respective. Cette mesure permet d'évaluer à quel point chaque caractéristique est informative pour différencier les classes de données. Ensuite les auteurs ont utilisé le SVM avec la fonction de noyau quadratique et la méthode de validation croisée *leave-one-out (LOOM)*. Après les tests, les auteurs ont obtenu une précision de 98,98%. Afin d'évaluer l'efficacité de l'approche basée sur l'EMD, les auteurs ont également utilisé le DWT comme méthode alternative d'extraction de caractéristiques. Avec le DWT, le SVM a donné une précision de 97,28%. Cette approche permet de montrer le potentiel et la puissance d'une approche basée sur l'EMD. Cette dernière pourrait être utilisée dans l'analyse des signaux et des séries temporelles, l'extraction de caractéristiques intrinsèques à différentes échelles spatiales. Avec les résultats obtenus, les auteurs ont eu une meilleure précision par rapport aux approches étudiées dans la revue de littérature.

2.1.1.4 *Variational mode decomposition (VMD)*

L'article (Fauzan *et al.*, 2022) présente la conception d'un système biométrique exploitant un signal ECG à une seule dérivation, en utilisant le moniteur de fréquence cardiaque à sonde unique AD8232 comme dispositif d'acquisition de signal. Le processus de décomposition du signal repose sur la VMD et l'EMD pour extraire des caractéristiques, générant IMF-1 à IMF-5. L'analyse de la complexité du signal se fait par l'extrac-

tion de caractéristiques statistiques, suivie d'une classification avec la méthode des k plus proches voisins (KNN) utilisant différentes métriques de distance. Le mémoire démontre que le VMD atteint une précision élevée de 93% avec KNN utilisant la distance de Manhattan à $K = 1$. Comparativement aux études antérieures, cette approche simplifie le calcul en se basant uniquement sur des caractéristiques statistiques des signaux IMF, et elle augmente le nombre de sujets mesurés. Bien que les signaux ECG soient difficiles à imiter, les faiblesses résident dans les défis liés à l'obtention du signal ECG et sa dépendance à la condition physique du sujet. L'étude propose des solutions en obtenant des signaux ECG de diverses conditions physiques, bien que le nombre de sujets reste limité, suggérant des perspectives pour des recherches futures avec des ensembles de données plus vastes.

2.1.1.5 La combinaison de différentes techniques de décomposition

Comme dit précédemment, la combinaison de différentes techniques de décomposition est une approche puissante qui permet d'analyser des signaux complexes et extraire des informations significatives et qui peut améliorer la qualité des résultats et permettre une meilleure interprétation des caractéristiques du signal.

a) EMD + DWT

L'avantage de cette combinaison a été démontré dans l'élaboration d'une nouvelle technique pour la diminution de l'interférence présente dans un signal ECG en utilisant la méthode de bord polyvalente basée sur la EMD et la DWT (Immaculate Joy *et al.*, 2023). Cette technique supprime les bruits tels que l'errance de la ligne de base, les interférences des lignes électriques et produit une qualité de signal dont le rapport signal sur bruit (SNR) est égale à 35 dB. Les signaux d'ECG obtenus sont dans un premier temps transformés en IMF à l'aide de l'EMD. Les auteurs ont ainsi introduit à cette étape une technique de débruitage pour le bruit additif. En effet, après l'EMD, une DWT est appliquée sur les IMF pour donner des coefficients sur lesquels sera appliqué un filtrage adaptatif non linéaire parfois appelé seuillage. La valeur seuil est déterminée à l'aide d'une estimation de la variation du bruit qui influence le signal utilisable. Après ce filtrage, l'inverse de la DWT (iDWT) est appliqué pour obtenir les IMF filtrés qui seront additionnés pour obtenir le signal débruité. Cette technique a permis aux utilisateurs d'obtenir une bonne qualité de signal pour déterminer les attributs du battement cardiaque.

b) VMD + DWT

Dans (Lahmiri et Boukadoum, 2015), la recherche a porté sur une nouvelle méthode de débruitage des signaux physiologiques. La procédure que les auteurs ont utilisée commence par la décomposition d'un signal bruité à l'aide du VMD. La procédure continue avec la DWT et le seuillage. Le signal d'entrée est décomposé par la DWT en composantes d'ondelettes ce qui donne des coefficients d'ondelettes, qui sont ensuite seuillés de sorte que, si un coefficient est inférieur au seuil, il est mis à zéro. Ensuite, sur les coefficients seuillés, on applique une DWT inverse puis une addition des IMF du VMD pour obtenir le signal. La valeur seuil optimale est déterminée en minimisant l'estimateur de risque sans biais de Stein (SURE pour *Stein's unbiased risk estimate*) appelé *SureShrink*. Et la procédure se conclut par l'optimisation des moindres carrés contraints. Pour évaluer leur méthode, les auteurs comparent les résultats avec celle de leur référence qui utilise l'EMD qui est souvent sensible au bruit et peut générer des IMF avec du bruit amplifié. A la suite des essais faits sur Matlab, les résultats des mesures de performances (le SNR et la MSE) ont prouvé que la méthode proposée obtient de meilleur résultat que celle de la référence. Cependant il faut préciser que cette méthode a un coût plus élevé en temps de calcul que celle de la référence.

2.1.2 Intelligence artificielle

Comme dit plus haut, les réseaux GAN ont pour rôle de générer de nouvelles données ressemblant le plus à celles des données d'entraînement. Leur efficacité a été démontrée dans (Abdelmadjid, 2022) dont l'objectif était de transformer la représentation temporelle d'un signal d'un format vers un autre, plus précisément des signaux ECG fournis par une nouvelle méthode de récolte de données en signaux ECG standards. Pour atteindre cet objectif, les auteurs ont proposé un modèle génératif de type CycleGAN simplifié. Ce modèle est basé sur le CycleGAN à la différence que le CycleGAN de base utilise des données bidimensionnelles durant son traitement alors que les auteurs ont utilisé des données unidimensionnelles. Ils ont effectué un prétraitement des données, plus précisément une réforme et la normalisation des données. Les résultats ont prouvé l'efficacité du modèle proposé par rapport à PIX2PIX, LSTM sur une bonne partie des données. Cependant, de mauvaises traductions sont présentes. Cela a été attribué au manque d'exemples pour l'entraînement.

2.2 Réseau de neurones pour la prédiction

2.2.0.1 Type de réseau de neurones

a) *Convolutional neural network* (CNN)

Les CNN sont utilisés pour la prédiction de maladie cardiovasculaire. En effet, dans (Haque et Akhtar, 2022), cinq CNN différents avec des nombres de couches différents ont été utilisés :

1. AlexNet : composé de huit couches de neurones, dont cinq sont des couches de convolution, suivies de couches de pooling, et trois sont des couches entièrement connectées (couches denses).
2. Vgg16 : composé de 16 couches de neurones, d'où son nom. Ces couches sont principalement des couches de convolution, entrecoupées de couches de pooling (généralement de la max-pooling).
3. Inception : ils sont conçus pour être profonds et larges. Le nombre de couches de neurones (ou couches cachées) dans une architecture Inception dépend de la version spécifique de l'architecture. Dans l'architecture V1 il y a 22 couches, dans le V2 et V3 il y a 48 couches.
4. Resnet50 : composé de 50 couches de neurones, d'où son nom. Cependant, il existe également des variantes de ResNet avec des nombres différents de couches, tels que ResNet-18, ResNet-34, ResNet-101, et ainsi de suite
5. CNN : c'est un modèle conçu dans le cadre de cette étude et qui possède six couches de réseau de neurones

Les auteurs ont utilisé un système de vote sur les prédictions des cinq CNN pour améliorer les performances du modèle, produisant des résultats idéalement meilleurs que tous les résultats de n'importe quel modèle individuel inclus dans l'ensemble. Les tests faits sur la base de données PTB-XL ont prouvé avec une précision de 86,80% que le système de vote est meilleur que l'utilisation des modèles de manière individuelle.

b) *Support vector machines* (SVM)

Les SVM ont été utilisés dans la détection de maladie cardiovasculaire. Dans (Mahgoub *et al.*, 2018), les auteurs ont présenté un algorithme de classification basé sur les caractéristiques extraites de la DWT des signaux ECG. Ces derniers ont obtenu une précision de 95% dans la détection de chaque classe. Dans (Cruz *et al.*, 2016), l'étude a porté sur la comparaison entre le système d'inférence neuro-fuzzy adaptatif (ANFIS)

et la machine à vecteurs de support (SVM) pour la classification d'ECG. Ils ont également utilisé la DWT comme extracteur de caractéristiques, l'ondelette mère Daubechies associée au SVM et l'ondelette mère Haar associée au ANFIS. Après les tests effectués, le modèle DWT-SVM s'est avéré plus performant que celui du DWT-ANFIS avec 95% contre 90% respectivement.

CHAPITRE 3

MÉTHODOLOGIE

Cette partie a pour objectif de décrire les méthodes utilisées et les processus suivis afin d'atteindre les objectifs de l'étude. Elle se divise en deux parties :

- Conversion de signal PPG en signal ECG : elle décrit le processus suivi afin d'évaluer les différentes techniques de décomposition de signal dans la conversion de signal PPG en signal ECG.
- Réseau de neurones classificateur de maladie : cette partie décrit le processus suivi pour la conception du réseau de neurones

3.1 Conversion de signal PPG en signal ECG

3.1.1 Base de données

Dans le cadre de cette étude qui consiste à comparer les différentes méthodes de décompositions de signal dans la conversion des signaux PPG en ECG, nous avons utilisé la base de données Capnabase TBME-RR (Karlen *et al.*, 2013). Le jeu de données se compose de 42 sessions, chacune d'une durée de huit minutes, comprenant des enregistrements simultanés de mesures de PPG et d'ECG. Ces enregistrements proviennent de 29 interventions chirurgicales pédiatriques et de 13 interventions chirurgicales pour adultes, et ils ont été échantillonnés à une fréquence de 300 Hz. Chaque session correspond à un individu unique, avec le signal PPG collecté à partir des extrémités des sujets en utilisant un oxymètre de pouls. Le jeu de données offre une grande diversité en termes d'âges et de poids des patients, ce qui le rend particulièrement approprié pour évaluer les performances de notre système.

3.1.2 Prétraitement des données

Dans la phase de prétraitement, nous nous sommes inspirés de (Zhu *et al.*, 2019). Ce prétraitement passe par la détection de pics, l'alignement, le filtrage, la segmentation et la normalisation des données.

3.1.2.1 Détection des pics

La détection des pics dans les signaux PPG et ECG est essentielle pour surveiller la santé cardiovasculaire, diagnostiquer les arythmies cardiaques mais aussi pour leur conversion. Notre technique de détection de pics repose sur l'analyse de deux principales caractéristiques : l'amplitude du pic et la variation périodique du signal. Pour cela, nous avons utilisé le module `scipy.signal` qui est dédié au traitement de signal. SciPy est une bibliothèque open-source en Python qui fournit un ensemble de modules et de fonctionnalités pour résoudre des problèmes scientifiques et d'ingénierie. Parmi les fonctionnalités de `scipy.signal`, nous avons utilisé :

- `scipy.signal.find_peaks` : détection de pics dans un signal unidimensionnel.
- `scipy.signal.peak_prominences` : calcul des hauteurs et des largeurs des pics détectés.

La procédure utilisée pour la détection des pics commence par une détection des pics des 1000 premiers échantillons du signal en utilisant une fonction `find_peaks` pour détecter sans exception tous les pics du signal. Ensuite, la moyenne entière des distances est calculée en fonction des pics obtenus. Une boucle `while` est utilisée pour itérer afin d'obtenir les pics réels PPG ou ECG. À chaque itération de la boucle `while`, les pics sont détectés à nouveau dans les 1000 premiers échantillons du signal en utilisant la distance les séparant basée sur la moyenne. Une nouvelle moyenne des distances est calculée à partir des pics détectés dans cette portion de signal. La boucle continue tant que la nouvelle moyenne des distances est différente de la précédente. Lorsque les pics ne changent plus, la moyenne ne change plus donc la boucle se termine. À l'aide des pics des 1000 premiers échantillons, nous déterminons la proéminence entière minimum des 1000 premiers pics avec `scipy.signal.peak_prominences`. En utilisant cette valeur, nous recommençons les étapes décrites ci-dessus à la différence que nous utilisons la proéminence en plus pour détecter les pics dans la boucle `while`. Après ces étapes, nous déterminons les pics de tout le signal avec la moyenne stabilisée moins 10. Le choix de cette valeur a été le fruit d'une série d'expérimentations visant à accorder une marge de retard dans l'apparition des pics, permettant ainsi de récupérer le maximum, voire la totalité des pics. Cette marge assure une détection optimale des pics et permet de contourner les retards dans leur apparition, souvent causés par des artefacts de mouvement ou des anomalies.

Cette procédure permet de récupérer la quasi-totalité des pics, cependant, elle s'est révélée limitée lorsque le signal présente des phases de perturbation. Parmi ces perturbations, nous pouvons citer le fait que des pics R, P et T du signal ECG ont les mêmes tailles rendant ainsi leur détection compliquée. Ainsi, nous avons

retirés les couples de signaux présentant de fortes perturbations du jeu de données. Nous avons aussi des irrégularités dans l'apparition des pics R, c'est-à-dire que le pic apparaît plus tôt ne respectant ainsi pas la marge de point de retard accordée. Pour remédier à cela, nous avons récupéré les pics manquants dans les parties spécifiques du signal en y appliquant le même procédé de détection de pics sur les 1000 premiers échantillons, puis nous avons mis à jour les positions réelles des pics.

3.1.2.2 Alignement des signaux

Cette étape de traitement des données a été faite l'aide de la méthode de (Zhu *et al.*, 2019). Les signaux PPG et ECG étant pris en même temps, il y a une possibilité de désalignement du couple de signaux à chaque essai. Pour s'assurer que les données des signaux PPG et ECG sont correctement synchronisés et y remédier si ce n'est pas le cas, le processus d'alignement se déroule en deux étapes distinctes. La première consiste à déterminer le temps de retard ou d'avance du signal ECG sur le signal PPG. Pour cela, nous utilisons une formule qui minimise la somme des différences absolues entre les décalages des pics PPG et ECG :

$$n^{\text{delay}} = \arg \min_{n \in D} \sum_{i=1}^{N-k} |t'_{sp}(i - n \cdot H(n < 0)) - t'_{rp}(i + n \cdot H(n > 0))|$$

avec N le nombre total de cycle, H qui est une fonction de Heaviside, $t_{sp}(i)$ est le $i^{\text{ème}}$ cycle PPG, $t_{rp}(i)$ est le $i^{\text{ème}}$ cycle ECG, D est l'ensemble des candidats x tels que $-k \leq x \leq k$, k est le rayon de recherche de l'ensemble de candidats D , $[-k, k]$, où le rayon de recherche $k = 5$.

Cette formule permet déterminer si les signaux sont alignés ou non, trois cas de figure s'offre à nous :

- $n^{\text{delay}} = 0$: le premier pic du signal ECG correspond au premier pic du signal PPG.
- $n^{\text{delay}} < 0$: le signal ECG est en retard par rapport au signal PPG.
- $n^{\text{delay}} > 0$: le signal ECG est en avance par rapport au signal PPG.

Après avoir déterminé le temps de retard ou d'avance, nous pouvons passer à l'alignement du signal. Avant cela, il faut se rappeler que le pic R de l'ECG est un événement qui correspond approximativement à l'ouverture de la valve aortique du cœur, et que le point de départ du PPG est le moment où l'onde de pouls atteint le capteur PPG, ce qui indique l'arrivée de l'onde de pouls. Le point de départ du PPG correspond au point minimum local avant le pic systolique (Zhu *et al.*, 2019). En prenant ces deux points, nous supprimons le temps de transit de l'impulsion et alignons les signaux, ce qui permet d'obtenir une synchronisation précise des données cardiaques dans les deux signaux. Pour déterminer le point de départ du PPG, nous avons

utilisé la caractéristique de la variation périodique du signal. Le point de départ étant le point le plus bas avant un pic, nous avons posé comme hypothèse que le point de départ d'un pic PPG p_i est le creux le plus bas situé entre le pic précédent p_{i-1} additionné de 3/4 de la moyenne des distances entre les pics du signal et le pic p_i en question. En utilisant n^{delay} , le pic R et le point de départ du PPG, nous alignons les signaux.

3.1.2.3 Filtrage des signaux

Dans le cadre de la préparation des données, un processus essentiel consiste à appliquer un filtrage passe-bande afin de cibler les fréquences pertinentes et d'atténuer les composantes indésirables. Pour les données PPG, le contenu pertinent se situe dans les fréquences inférieures à 15 Hz, donc un filtre passe-bande est mis en œuvre avec des fréquences de coupure égales à 0,5 Hz et 15 Hz (Chowdhury *et al.*, 2023). Cette configuration vise à extraire spécifiquement les informations cruciales contenues dans la plage de fréquences caractéristiques du PPG. De manière similaire, pour les données ECG, où les informations significatives sont présentes dans une plage allant de 0.5 à 100 Hz (Kligfield *et al.*, 2007), un filtre passe-bande est appliqué avec des fréquences de coupure de 0,5 Hz à 100 Hz (Chowdhury *et al.*, 2023). Cette approche de filtrage sélectif permet de préserver les composantes essentielles des signaux physiologiques tout en éliminant le bruit et les fréquences indésirables, contribuant ainsi à une représentation plus précise et fidèle des signaux PPG et ECG avant d'entreprendre la phase de conversion.

3.1.2.4 Segmentation, égalisation et normalisation des signaux

Après avoir aligné les données, nous obtenons des signaux alignés et une liste mise à jour des pics. À l'aide de cette liste, nous pouvons procéder à la phase de segmentation. (Zhu *et al.*, 2019) a introduit deux types de segmentation en fonction du signal ECG :

- La segmentation SR, qui consiste à utiliser comme point de segmentation un point situé à 1/3 de la longueur du cycle à gauche des pics R du signal ECG, car cela permet d'obtenir approximativement la forme standard du rythme sinusal.
- La segmentation R2R, qui consiste à utiliser le pic R comme point de segmentation, car cela permet d'atténuer l'erreur de reconstruction du complexe QRS.

Nous avons décidé de prendre la segmentation R2R car elle minimise l'erreur de reconstruction du complexe QRS, qui est essentielle pour évaluer l'activité électrique des ventricules cardiaques, et s'est avérée

meilleure lors des tests (Zhu *et al.*, 2019). Après cette étape de segmentation, une phase d'interpolation a été effectuée pour équilibrer les données. Cette opération consiste à calculer des valeurs intermédiaires entre les points du signal. Cette opération a été réalisée à l'aide de la fonction `interp1D` de la bibliothèque SciPy. Cette interpolation a permis une égalisation des données segmentées à 300 points pour ceux dont la longueur est comprise entre 150 et 300 points. Pour les signaux de longueur supérieure à 300 points, nous les avons réduits à 300, et pour ceux de longueur inférieure à 150 points, nous avons ajouté des zéros jusqu'à atteindre le quota.

Avant de passer à la phase d'entraînement, nous avons normalisé les données. Cela permet de rendre les données comparables et de les mettre dans une plage commune, ce qui peut améliorer les performances des algorithmes d'apprentissage automatique et faciliter l'interprétation des données. Nous avons calculé la moyenne et l'écart-type des signaux, puis nous avons effectué une standardisation en soustrayant de chaque cycle la moyenne calculée, puis en divisant par l'écart-type. Les données ont ensuite été divisées en deux ensembles distincts : 70% (13722 données) ont été alloués à l'entraînement pour permettre au modèle d'apprendre, tandis que les 30% (5881 données) restants ont été réservés aux tests. Cette division assure une évaluation impartiale de la performance du modèle sur des données non vues lors de l'entraînement.

3.1.3 Apprentissage de la transformation linéaire par crête

Cette partie a pour objectif de décrire l'apprentissage de la transformation linéaire. Pour cela, nous avons utilisé la fonction `Ridge()` de la bibliothèque `scikit-learn`. Le scénario se décompose en trois phases, comme suit :

- Décomposition du signal
- Entraînement
- Test

La principale idée derrière la régression linéaire par crête est d'ajouter une pénalité à la somme des carrés des coefficients de régression dans la fonction de coût. Cette pénalité est contrôlée par un hyperparamètre appelé «alpha». Plus il est grand, plus la pénalité est forte, et cela peut conduire à une réduction plus importante des coefficients de régression. Dans notre cas, nous avons mené l'expérience avec les valeurs suivantes pour alpha : 0,1, 1,0 et 10,0.

Voici les techniques de décomposition du signal que nous avons utilisées :

3.1.3.1 Décomposition DWT

Afin d'obtenir les coefficients de la DWT, nous avons utilisé la fonction `dwt` de la bibliothèque SciPy. Nous avons obtenu les coefficients cD et cA sur lesquels nous effectuons un entraînement et une prédiction séparés. Après l'entraînement et la prédiction, nous réassemblons les coefficients en effectuant une `IDWT` afin d'obtenir le signal prédit reconstruit et ainsi évaluer la méthode. Lors de la phase de décomposition, nous avons utilisé les ondelettes `db4`, `db6`, `db8`, `db10`, `db12`, `db14` et l'ondelette Haar.

3.1.3.2 Décomposition EMD

Pour l'obtention des IMFs de nos signaux, nous avons utilisé la fonction `EMD` de Matlab. La raison pour laquelle nous avons utilisé Matlab est son authenticité dans la reconstruction du signal. Cependant, nous sommes restés dans l'environnement Python en utilisant l'API `Matlab Engine` (MathWorks, 2023). Cet API fournit un paquet permettant à Python d'appeler MATLAB en tant que moteur de calcul. Il permet d'avoir accès aux fonctions de Matlab, mais aussi d'avoir accès à nos propres fonctions. L'inconvénient de cet API est qu'il ne prend pas en charge les paramètres des fonctions, c'est-à-dire que nous ne pouvons pas transmettre depuis Python les paramètres d'une fonction Matlab. Pour y remédier, nous avons créé notre propre fonction qui renvoie les IMF d'un signal. La fonction `EMD` prend comme paramètre le nombre d'IMF maximal, égal à trois. Cette limitation a été choisie parce que la fonction n'arrivait pas à obtenir plus d'une IMF pour certains de nos signaux, surtout pour les signaux PPG. Les données n'ayant pas obtenu plus de trois IMF sont supprimées des données, ce qui nous laisse un total de 10536 sur 19605.

À la fin de l'exécution sur un signal de la fonction, nous obtenons une matrice de dimension (300x3) qui contient les trois IMF que nous transformons dans un premier temps en une matrice de dimension (3x300), puis en un vecteur en les concaténant ligne par ligne. Les données sont ensuite envoyées vers la phase d'entraînement et de prédiction. Après la prédiction, le signal est reconstruit en faisant une somme des IMFs afin d'être évalué.

3.1.3.3 Décomposition VMD

Tout comme l'EMD, nous avons utilisé l'API Matlab Engine pour obtenir les IMF de la VMD. La fonction VMD a pris comme paramètre le nombre d'IMF égal à quatre. Nous avons procédé au même traitement sur les signaux que celui de l'EMD avant qu'ils ne passent à la phase d'entraînement et de prédiction. Après la prédiction, le signal est reconstruit en faisant une somme des IMF afin d'être évalué.

3.1.3.4 Combinaison de méthode de décomposition

EMD+DWT : cette méthode suit le même principe que l'EMD simple, sauf qu'après la phase de récupération des IMF et de leur mise en forme, nous appliquons la technique de DWT, qui suit également le même schéma que celui décrit ci-dessus. Ensuite, nous passons à la phase d'entraînement. Après la prédiction sur les données de test, nous effectuons une iDWT pour obtenir les IMF, qui sont à leur tour additionnées pour obtenir le signal prédit, afin d'évaluer le modèle.

VMD+DWT : cette méthode suit la même logique que l'EMD+DWT, sauf que nous utilisons la VMD.

3.2 Classificateur de maladie : réseau de neurone

3.2.1 Base de données

La base de données utilisée pour la phase de prédiction de maladie cardiovasculaire est l'ensemble de données ECG PTB-XL (Wagner *et al.*, 2022) de PhysioNet (Goldberger *et al.*, 2000), qui est une base de données d'ECG annotée, étiquetée et rendue accessible au public en 2020. C'est la plus grande base de données d'ECG publique disponible à ce jour, avec 21799 enregistrements d'ECG cliniques provenant de 18869 patients différents, destinée à être utilisée dans la recherche sur l'analyse ECG et l'apprentissage automatique.

L'ensemble de données PTB-XL comprend des enregistrements d'ECG à douze dérivations, dont chacune dure 10 secondes, et a deux fréquences d'échantillonnage de 500 Hz et de 100 Hz que nous utiliserons. Chaque ECG est associé à un ou plusieurs diagnostics médicaux qui ont été annotés par des médecins qualifiés à l'aide de plusieurs sources d'informations, notamment les dossiers médicaux des patients et les rapports de cardiologie. Les ECG ont été regroupés en cinq catégories :

- NORM : ECG normal (9514)

- MI : infarctus du myocarde (5469)
- STTC : changement ST-T (5235)
- CD : trouble de la conduction (4898)
- HYP : hypertrophie (2649)

3.2.2 Préparation des données

En fonction du nombre de vérifications des enregistrements par les médecins, les concepteurs de la base de données ont catégorisé les données de 1 à 10 (Wagner *et al.*, 2020). Ce paramètre porte le nom de *Cross-validation Folds* (plis de validation croisée en français). Les enregistrements ayant un *Cross-validation Fold* de 9 et 10 ont subi au moins une évaluation humaine et sont donc d'une qualité d'étiquette particulièrement élevée. Les auteurs ont donc conseillé l'utilisation des données ayant un *Cross-validation Fold* de 1 à 8 pour les données d'entraînement, de 9 pour la validation et un *Cross-validation Fold* de 10 pour le test. Cela nous donne la répartition suivante :

Classe	Entraînement	Validation	Test
NORM	7596	955	963
MI	4378	540	550
STTC	3107	378	378
CD	1588	209	211
HYP	415	64	56

Table 3.1 Répartition des données par classe pour les ensembles d'entraînement, de validation et de test

Après une séparation, nous procédons à une transformation du signal en coefficients DWT pour récupérer uniquement les cA. Un signal brut ayant une dimension de (1000x12), c'est-à-dire que la ligne t correspond à la mesure à l'instant t de l'ECG et de ses dérivations. Avant de procéder à la décomposition, nous transformons d'abord le signal pour qu'il ait une dimension de (12x1000), c'est-à-dire que la ligne t correspond à l'intégralité du signal ECG ou d'une dérivation. Ainsi, nous pouvons appliquer la DWT ligne par ligne sur la totalité d'un seul signal. Nous avons utilisé les ondelettes db4 et Haar pour la DWT. Après avoir obtenu les coefficients, nous procédons à une transformation inverse des dimensions de celle faite précédemment.

Ayant nos données transformées en coefficients, nous effectuons une normalisation de ces données. Lors de la préparation des données pour l'entraînement des modèles, il est important de normaliser les don-

nées afin d'obtenir des résultats précis et cohérents. La normalisation consiste à mettre les données sur une même échelle, généralement entre 0 et 1 ou -1 et 1, afin de faciliter la comparaison des différentes variables. Elle permet également d'éviter que certaines variables aient un poids disproportionné dans le modèle en raison de leur échelle de mesure différente. Il existe plusieurs types de normalisation, tels que la normalisation min-max, la normalisation z-score, etc. Nous avons utilisé une normalisation qui standardise la moyenne et l'écart-type. Elle consiste à soustraire la moyenne de la variable à chaque observation et à diviser le résultat par l'écart-type de la variable. Cette opération permet de centrer les données autour de zéro et de les mettre sur une échelle commune.

3.2.3 Description du modèle

Le modèle décrit ici est un CNN qui a pour objectif de permettre la classification des maladies cardiovasculaires. Le modèle 3.1 se compose de deux parties principales : la phase d'extraction des caractéristiques et la phase de classification.

La phase d'extraction est responsable de la capture des caractéristiques pertinentes à partir des données d'entrée. Elle repose sur une architecture en couches de convolution à une dimension, avec des couches d'activation ReLU et de normalisation par lots (*Batch Normalization*) entre chaque couche de convolution. La phase d'extraction des caractéristiques est composée de deux branches principales, chacune prenant comme entrée les données et suivant la même architecture. Chaque branche effectue trois fois une série de convolution, d'activations ReLU et de normalisations par lots. La première convolution possède 64 filtres et une fenêtre de trois unités de longueur, la deuxième convolution possède 128 filtres et une fenêtre de trois unités de longueur et la troisième possède 64 filtres et une fenêtre de sept unités de longueur. Les sorties des deux branches sont ensuite combinées en utilisant une opération d'addition, ce qui permet de capturer des caractéristiques complémentaires à partir des données d'entrée. Après cette addition, une fonction d'activation ReLU est appliquée, ainsi qu'une série de convolution avec 32 filtres et une fenêtre de sept unités, d'activations ReLU et une couche *dropout* avec un taux de 0,5, ce qui signifie que la moitié des unités seront désactivées de manière aléatoire à chaque itération d'entraînement. Le nombre d'époques est égal à 25 et le *batch_size* est égale à 50.

Après l'extraction des caractéristiques, la phase de classification prend le relais. Elle commence par aplatir les caractéristiques extraites en une seule dimension, puis les fait passer à travers une seule couche dense qui possède cinq unités de neurones. Enfin, une couche d'activation *softmax* est utilisée pour obtenir les

probabilités de classe. Il faut préciser que les paramètres du modèle d'intelligence artificielle ont été sélectionnés à l'aide d'une technique d'optimisation avancée appelée *Hyperopt*. Cette méthode a permis de déterminer la combinaison optimale pour des paramètres cruciaux, tels que les filtres et les tailles de noyau, qui jouent un rôle essentiel dans l'architecture du modèle. Les choix effectués lors du processus d'optimisation comprenaient la sélection des filtres parmi les options de 32, 64, 128, et 256, la taille du noyau parmi les options de 3, 5, et 7, le nombre d'époques parmi les options 25, 50, 75, ainsi que le *batch_size* parmi les options 35, 50, 75. Ces options ont été choisies car elles sont les plus utilisées pour des modèles simples ne nécessitant pas une complexité excessive, ce qui permet une convergence plus rapide et une meilleure généralisation du modèle.

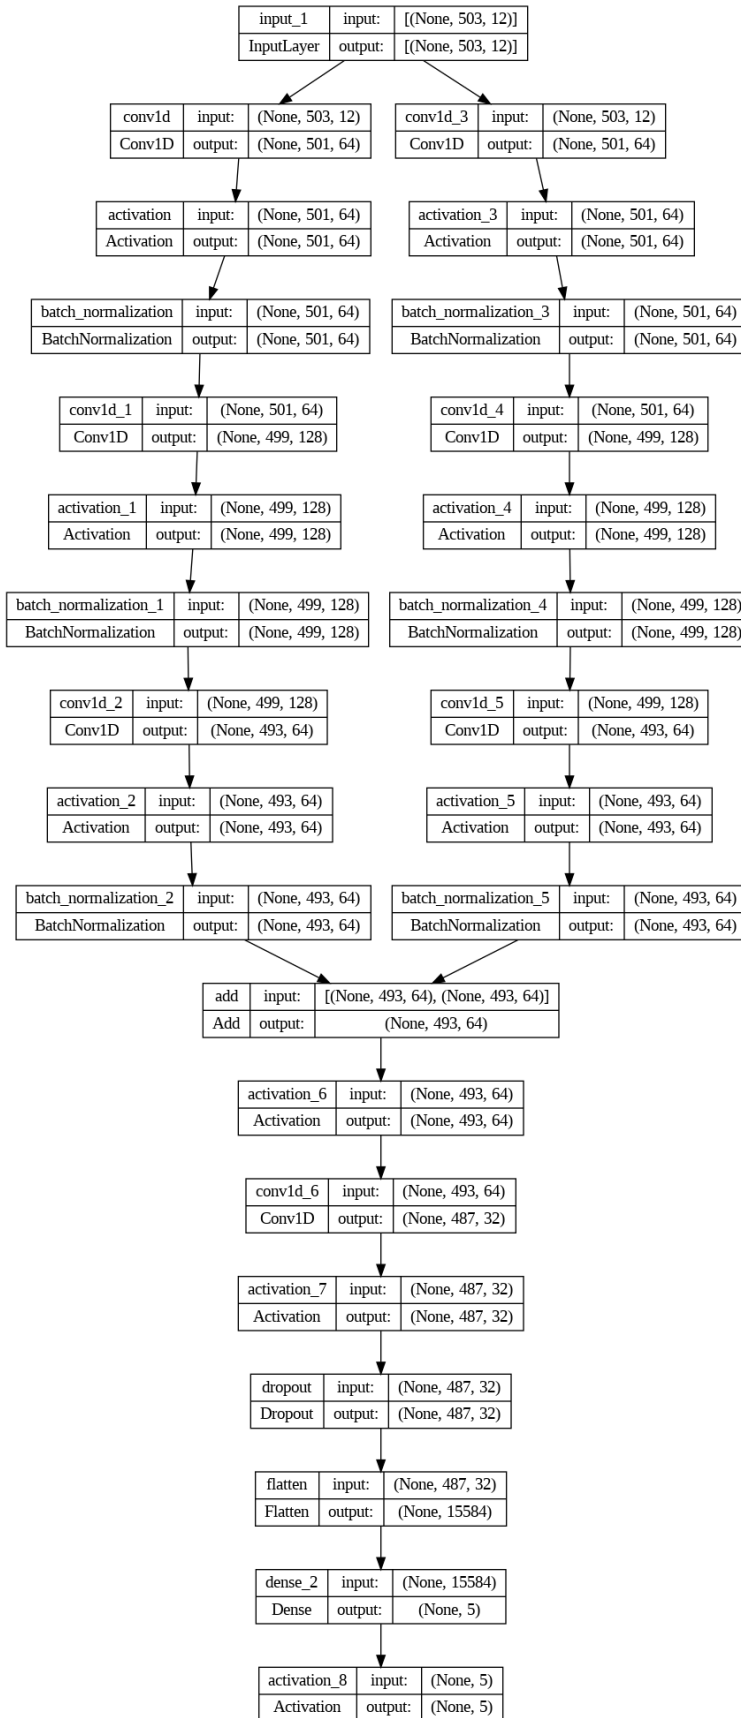


Figure 3.1 Architecture du modèle

CHAPITRE 4

EXPÉRIENCES ET DISCUSSION

Cette partie a pour objectif de présenter les résultats obtenus grâce aux méthodes utilisées et aux processus suivis pour atteindre les objectifs de l'étude. Elle se divise en parties :

- Conversion de signal PPG en signal ECG : elle expose les résultats obtenus à partir de l'évaluation des différentes techniques de décomposition de signal dans la conversion de signal PPG en signal ECG.
- Classificateur de maladie par réseau de neurones : cette partie détaille les résultats issus du processus suivi pour la conception du réseau de neurones.

Puisque l'objectif de cette étude est de convertir un signal PPG en un signal ECG avec une classification ultérieure, il est impératif de valider entièrement le modèle proposé. Malheureusement, la base de données PPG publique que nous avons utilisée ne comporte pas d'étiquettes. Cela nous a contraint à employer cette base de données pour valider la phase de conversion et une autre base de données ECG étiquetée a été utilisée pour valider la phase de classification.

4.1 Conversion de PPG à ECG

À chaque itération d'expérimentation et de mise en œuvre, nous répétons systématiquement le processus d'évaluation des performances du modèle. En d'autres termes, nous utilisons la métrique rMSE, rMSE avec correction de biais, le coefficient de détermination R2 et le coefficient de Pearson pour évaluer les techniques de décomposition mentionnées sur les données de test. La rMSE s'exprime par la formule :

$$rMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

avec y le vecteur réel de l'observation, y' le vecteur prédit par le modèle pour l'observation et n le nombre de points, nous avons utilisé la fonction `MeanSquaredError()` de la bibliothèque `scikit-learn`. Plus la valeur du rMSE est basse plus on a une meilleure précision.

La rMSE avec correction de biais s'exprime par la formule :

$$rMSE_{std} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - (\hat{y}_i - me))^2}$$

avec

$$me = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)$$

Cette métrique permet de prendre en compte à la fois les erreurs aléatoires mesurées par le rMSE et les erreurs systématiques mesurées par le *me*. Nous avons utilisé la fonction `MeanSquaredError()` de la bibliothèque `scikit-learn`. Une rMSE avec correction de biais plus faible indique une meilleure précision de conversion.

Le coefficient de détermination R2 est une métrique d'erreur de régression qui évalue la précision et l'efficacité d'un modèle lorsqu'il est appliqué à des valeurs de données spécifiques. Il s'exprime par :

$$R^2 = 1 - \frac{SS_{\text{res}}}{SS_{\text{tot}}}$$

avec SS_{res} la somme des carrés des erreurs résiduelles et SS_{tot} la somme totale des erreurs. Nous avons utilisé la fonction `r2_score()` de la bibliothèque `scikit-learn`. Le coefficient de détermination R2 varie de 0 à 1, où une valeur plus proche de 1 indique que le modèle explique une plus grande partie de la variance de la variable dépendante, ce qui est souvent interprété comme une meilleure adéquation du modèle aux données observées.

Le coefficient de Pearson mesure la relation linéaire entre deux ensembles de données. Comme tout autre coefficient de corrélation, celui-ci varie entre -1 et +1. Des valeurs de -1 ou +1 impliquent une relation linéaire et 0 implique aucune relation exacte. Nous avons utilisé la fonction `pearsonr()` de la bibliothèque `Scipy`. Il s'exprime par :

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

avec x_i, y_i les valeurs individuelles des deux variables, \bar{x} et \bar{y} leurs moyennes respectives.

Après les tests, nous obtenons des résultats décrits dans les tableaux suivants avec les meilleurs valeurs mises en gras et les images comparatifs.

1. DWT avec les ondelettes de Daubechies

— rMSE

Alpha	db4	db6	db8	db10	db12	db14
0,1	0,3650	0,36517	0,36518	0,3650	0,3650	0,36513
1,0	0,3655	0,36555	0,3656	0,36551	0,3654	0,36552
10,0	0,3667	0,36673	0,3666	0,3666	0,3666	0,3667

Table 4.1 Résultats du rMSE pour différentes valeurs d'Alpha et ondelettes.

— $rMSE_{std}$

Alpha	db4	db6	db8	db10	db12	db14
0,1	0,3690	0,3704	0,3684	0,3681	0,3699	0,3699
1,0	0,3716	0,3724	0,3716	0,3710	0,3719	0,3722
10,0	0,3757	0,3755	0,3756	0,3755	0,3756	0,3756

Table 4.2 Résultats du rMSE avec biais pour différentes valeurs d'Alpha et ondelettes.




Figure 4.1 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant l'ondelette db4




Figure 4.2 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant l'ondelette db4




Figure 4.3 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant l'ondelette db4

2. DWT avec l'ondelette Haar

Alpha	rMSE	$rMSE_{std}$
0,1	0,3629	0,3636
1,0	0,3639	0,3657
10,0	0,3655	0,3685

Table 4.3 Résultats pour différentes valeurs d'Alpha et métriques.

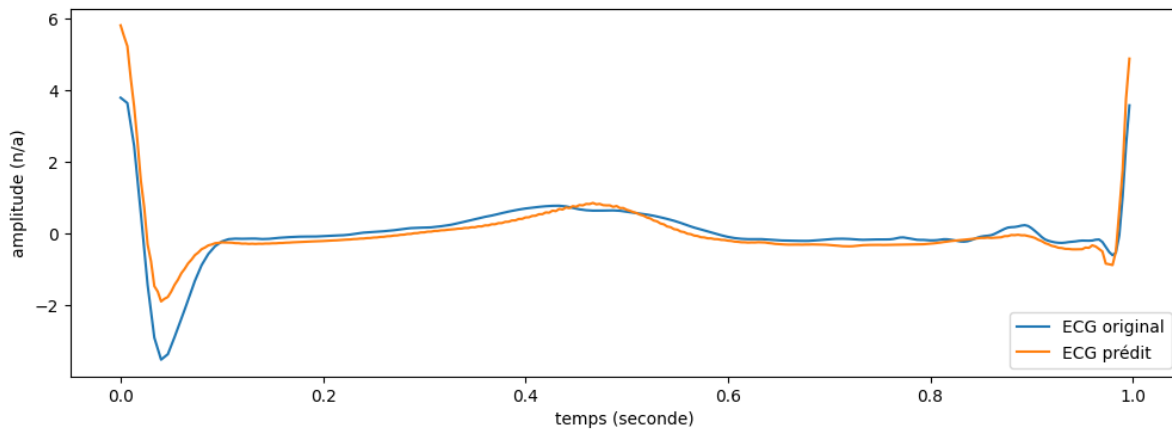


Figure 4.4 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant l'ondelette Haar




Figure 4.5 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant l'ondelette Haar




Figure 4.6 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant l'ondelette Haar

3. EMD

Alpha	rMSE	$rMSE_{std}$
0,1	2,085	314,93
1,0	2,057	314,61
10,0	2,015	311,99

Table 4.4 Résultats pour différentes valeurs d'Alpha et métriques.




Figure 4.7 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant l'EMD




Figure 4.8 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant l'EMD




Figure 4.9 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant l'EMD

4. EMD + DWT

— $rMSE$

Alpha	db4	db6	db8	db10	db12	db14
0,1	2,071	2,069	2,070	2,069	2,070	2,079
1,0	2,052	2,048	2,049	2,052	2,051	2,049
10,0	2,018	2,015	2,018	2,020	2,018	2,017

Table 4.5 Résultats pour différentes valeurs d'Alpha et ondelettes.

— $rMSE_{std}$

Alpha	db4	db6	db8	db10	db12	db14
0,1	315,722	315,39	315,01	315,22	315,37	315,45
1,0	315,76	315,30	315,33	315,73	315,66	315,47
10,0	313,12	312.88	313,48	313,60	313,33	313,36

Table 4.6 Résultats pour différentes valeurs d'Alpha et ondelettes.

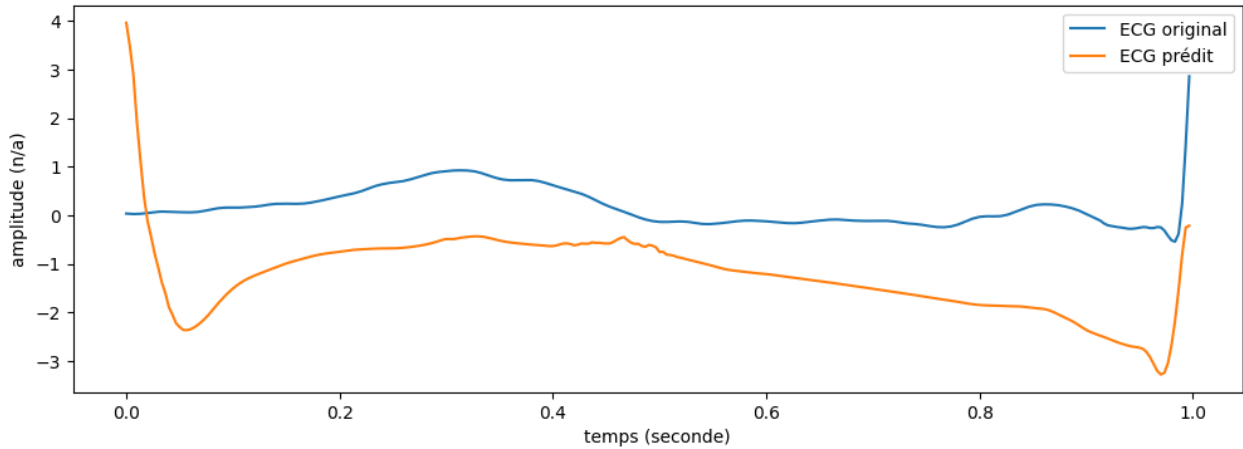


Figure 4.10 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant l'EMD et l'ondelette db6




Figure 4.11 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant l'EMD et l'ondelette db6




Figure 4.12 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant l'EMD et l'ondelette db6

5. VMD

Alpha	rMSE	$rMSE_{std}$
0,1	0,3415	0,3419
1,0	0,3436	0,3436
10,0	0,3472	0,3484

Table 4.7 Résultats pour différentes valeurs d'Alpha et métriques.

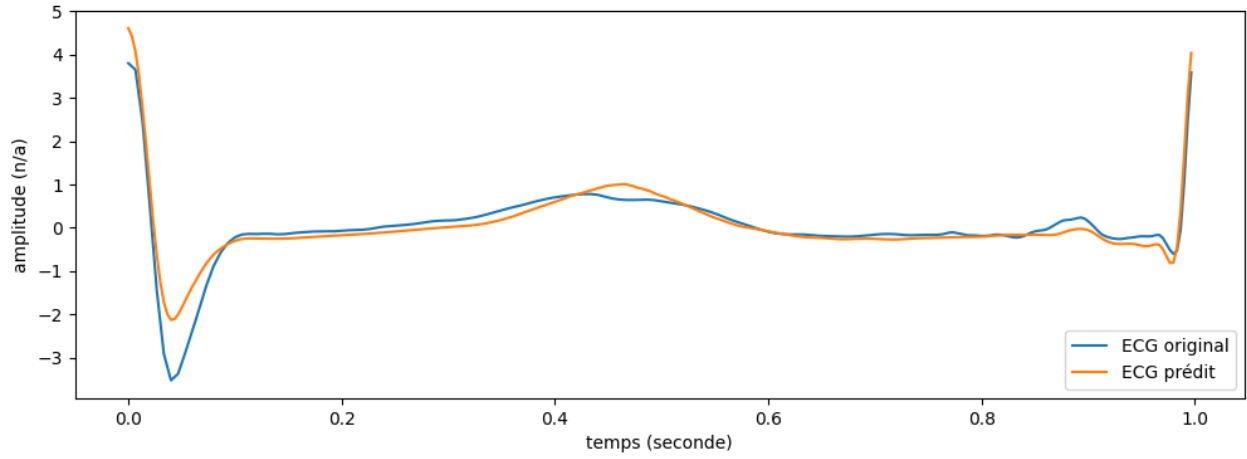


Figure 4.13 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant la VMD




Figure 4.14 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant la VMD




Figure 4.15 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant la VMD

6. VMD +DWT

— rMSE

Alpha	db4	db6	db8	db10	db12	db14
0,1	0,3419	0,3418	0,3417	0,3418	0,3418	0,3418
1,0	0,3439	0,3438	0,3438	0,3438	0,3439	0,3438
10,0	0,3475	0,3474	0,3473	0,3474	0,3475	0,3474

Table 4.8 Résultats pour différentes valeurs d'Alpha et ondelettes.

— $rMSE_{std}$

Alpha	db4	db6	db8	db10	db12	db14
0,1	0,3420	0,3421	0,3421	0,3420	0,3420	0,3421
1,0	0,3440	0,3439	0,3438	0,3439	0,3439	0,3438
10,0	0,3488	0,3486	0,3485	0,3486	0,3486	0,3485

Table 4.9 Résultats pour différentes valeurs d'Alpha et ondelettes.




Figure 4.16 Comparaison d'un cycle ECG original avec sa version prédite, obtenue en utilisant la VMD et l'ondelette db8




Figure 4.17 Comparaison d'un signal ECG original avec sa version prédite, obtenue en utilisant la VMD et l'ondelette db8




Figure 4.18 Comparaison d'un signal PPG original avec le signal ECG prédit correspondant en utilisant la VMD et l'ondelette db8

Method	R2	Coef Pearson
DWT (db4)	0,3432	0,9039
DWT (Haar)	0,3519	0,9044
EMD	-101,19	0,6383
EMD + DWT (db6)	-101,41	0,6334
VMD	0,4222	0,9136
VMD + DWT (db8)	0,4217	0,9133

Table 4.10 Les meilleurs résultats pour chaque technique de réduction utilisée.

Les tableaux ci-dessus montrent les résultats des techniques de décomposition. Dans un premier temps, les résultats de DWT indiquent qu'elle est capable de conserver de manière efficace l'information essentielle des différentes composantes en obtenant comme meilleure $rMSE$ 0,3650, $rMSE_{std}$ 0,3690 pour l'ondelette db4 avec une valeur alpha égale à 1. Avec l'ondelette Haar, nous obtenons des résultats semblables à celles utilisant les ondelettes de Daubechies. Cette technique obtient un $rMSE$ égal à 0,3629, $rMSE_{std}$ égal à 0,3636 avec alpha égal à 1. Contrairement à la DWT, les résultats de l'EMD affichent des valeurs de $rMSE$ plus élevées, ce qui suggère que l'EMD pourrait être moins efficace pour conserver l'information essentielle du signal. Elle obtient le plus haut $rMSE$ avec 2,0150. En la combinant avec la DWT, aucune amélioration ne se fait sentir. Elle obtient 2,0158 comme meilleur $rMSE$ avec alpha égal à 10. Le VMD, quant à lui, se distingue par des valeurs de $rMSE$ relativement faibles, indiquant une bonne performance en termes de préservation de l'information. Les valeurs d'alpha n'ont pas un impact significatif sur l'erreur $rMSE$, contrairement aux autres, ce qui renforce la robustesse de cette technique. Il obtient un $rMSE$ minimum égal à 0,3415 avec alpha égal à 1. En le combinant avec la DWT, nous n'obtenons pas d'amélioration. La $rMSE$ passe à 0,3417 avec alpha égal à 1. Cependant, tous les modèles ont un $rMSE_{std}$ supérieur au $rMSE$. Cela traduit l'introduction d'un biais dans les résultats, c'est-à-dire la présence d'une erreur constante ou prévisible dans les prédictions. Le $rMSE_{std}$ le plus faible a été obtenu par le VMD avec 0,3419 avec alpha égal à 1. En deuxième position, nous avons la combinaison VMD+DWT avec 0,3421 en utilisant l'ondelette db8 et alpha égal à 1. Les techniques VMD et VMD + DWT se sont distinguées par une précision élevée, une stabilité, et une corrélation positive substantielle en obtenant des résultats de coefficient de Pearson de 0,9136 et 0,9133 respectivement et des résultats R^2 de 0,4222 et 0,4217 respectivement.

Les faibles résultats fournis par l'EMD et de l'EMD+DWT peuvent être attribués, dans un premier temps, à la différence de nombre de données par rapport aux autres techniques. En effet, n'ayant pas réussi à

obtenir trois IMF sur tous les signaux, nous avons réduit le nombre de données. Ces résultats peuvent aussi être attribués à la sensibilité de l'EMD aux propriétés des signaux. L'EMD est connue pour être sensible aux caractéristiques spécifiques des signaux, et elle peut être plus ou moins efficace en fonction de la nature des signaux traités. Les signaux ECG, quant à eux, se caractérisent par une variabilité considérable, en termes de fréquence cardiaque, d'amplitude des ondes, de forme d'onde, de durée des complexes QRS, etc. Nous savons aussi que les signaux ECG sont des signaux non stationnaires, et pour que l'EMD puisse bien les décomposer, il est essentiel que les signaux se conforment à l'hypothèse qu'ils soient "quasi-périodiques" ou "quasi-monotones". Ces résultats peuvent aussi être dus aux composantes complexes, notamment des ondes P, QRS et T des signaux ECG qui ne sont pas purement sinusoïdales, alors que l'EMD suppose que les signaux puissent être décomposés en IMF qui sont presque sinusoïdales.

Les résultats des autres techniques peuvent être expliqués par leurs propriétés propres. En effet, les bons résultats du VMD peuvent s'expliquer par sa capacité d'adaptation aux signaux non linéaires et sa décomposition adaptative. La DWT a de bons résultats grâce à sa capacité à capturer efficacement les caractéristiques de fréquence et de temps des signaux ECG. Cependant, ces résultats sont élevés par rapport à l'étude précédente (Zhu *et al.*, 2019), qui a utilisé la DCT. Cette différence peut être due à l'efficacité de la DCT à représenter les signaux dans le domaine de fréquence, ainsi qu'à sa capacité à concentrer l'énergie du signal dans un petit nombre de coefficients, ce qui peut simplifier la représentation des signaux. De plus, les auteurs de l'étude précédente ont effectué un détrendage adaptative sur les signaux, ce qui a pu entraîner une réduction du bruit et des composantes indésirables et ainsi apporter un plus surtout dans la conversion du complexe QRS.

4.2 Classificateur de maladie : réseau de neurone

Après chaque expérimentation et mise en œuvre, nous appliquons le même processus pour comprendre les performances du modèle. En d'autres termes, nous utilisons des métriques sur les données de test pour évaluer notre modèle par rapport à d'autres. Nous utilisons également les paramètres entraînaibles, qui sont des valeurs apprises par le modèle pendant la phase d'entraînement, pour déterminer la capacité du modèle à effectuer des classifications. Comme témoins, nous utilisons notre propre modèle sur les données brutes, le modèle ResNet50 (Sachan, 2019), VGG16 (Learning, 2021), Inception-ResNet-V2 (Szegedy *et al.*, 2016) également sur les données brutes.

Parmi les métriques, nous utilisons :

- La métrique *accuracy* (exactitude) est une métrique d'évaluation qui est définie comme le ratio des prédictions correctes par rapport au nombre total d'exemples.

$$\text{Accuracy} = \frac{\text{Nombre d'exemples correctement classés}}{\text{Nombre total d'exemples}}$$

- La métrique précision est une mesure d'évaluation qui fournit une indication de la qualité des prédictions positives faites par le modèle.

$$\text{Précision} = \frac{\text{Nombre d'exemples positifs correctement classés}}{\text{Nombre total d'exemples positifs prédits par le modèle}}$$

- La métrique rappel (*recall* en anglais), également appelée sensibilité (*sensitivity*) ou taux de vrais positifs (*true positive rate*), est une mesure d'évaluation qui mesure la capacité du modèle à identifier correctement tous les exemples positifs dans l'ensemble de données, en évitant les faux négatifs.

$$\text{Recall} = \frac{\text{Nombre d'exemples positifs correctement classés}}{\text{Nombre total d'exemples réels positifs dans les données}}$$

- La mesure F1 (ou F1-score) est une métrique d'évaluation couramment utilisée en classification, en particulier lorsque les classes ne sont pas équilibrées dans l'ensemble de données. Il combine à la fois la précision et le rappel (*recall*) en une seule métrique, offrant ainsi une mesure globale de la performance d'un modèle de classification.

$$\text{F1 score} = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$$

Ces métriques, ainsi que le total des paramètres entraînaables, auront pour objectif de donner une idée claire de l'efficacité de l'approche de la décomposition DWT de signal pour la classification.

Après les tests, nous obtenons des résultats décrits dans le tableau suivant :

Modèle	Total paramètres	Accuracy	Precision	Recall	F1 score
Model+DWT+db4	261 253	0,7117	0,7525	0,7117	0,7316
Model+DWT+Haar	254 277	0,6890	0,7401	0,6890	0,7137
Model+données Brutes	414 277	0,4462	0,4462	0,4462	0,4462
Resnet50	32 791 426	0,844	0,844	0,844	0,844
VGG16	86 729 989	0,6756	0,7363	0,6793	0,7066
Inception-resnet-v2	48 433 547	0,7015	0,7788	0,7015	0,7381

Table 4.11 Résultats comparatifs des modèles de prédiction

Parmi les modèles évalués, Resnet50 se distingue avec des performances globales les plus élevées, avec une *accuracy*, une précision, un rappel et un F1-score de 84,47%. Cependant, il convient de noter que Resnet50 est également un modèle complexe en termes de nombre de paramètres, avec un total de 32 791 426 paramètres. Cette complexité peut entraîner des temps d'entraînement plus longs et une utilisation plus intensive des ressources matérielles. Il est suivi par notre modèle utilisant la DWT avec db4 offrant des performances solides avec une *accuracy* de 71,22% et un F1-score de 73,16%. De plus, il présente un nombre de paramètres considérablement moins élevé, à savoir 261 253 paramètres. Cette efficacité en termes de nombre de paramètres en fait une option attrayante en particulier pour les situations où les ressources matérielles et le temps d'entraînement sont limités. En prenant en compte le nombre de paramètres à celui du VGG16 et de l'Inception-resnet V2, il offre une meilleure précision dans la classification des maladies avec un taux de paramètres entraînaibles clairement inférieur.

L'analyse comparative des performances des modèles de classification révèle l'efficacité remarquable de la DWT lors de l'extraction de caractéristiques pour la classification. Notre modèle utilisant la DWT avec db4, malgré sa simplicité en termes de nombre de paramètres, affiche des performances solides. Cette performance est d'autant plus impressionnante compte tenu de la légèreté du modèle en termes de complexité, avec seulement 261 253 paramètres.

CONCLUSION

Cette étude s'est centrée sur la transformation de signal PPG en ECG à travers l'évaluation de différentes techniques de décomposition, notamment l'EMD, la DWT, la VMD, ainsi que les combinaisons DWT+EMD et DWT+VMD. Au cours de cette recherche, nous avons examiné attentivement les performances de ces approches, mettant en évidence leurs forces et faiblesses respectives dans la conversion de ces signaux physiologiques.

Parallèlement, nous avons apporté une contribution en concevant un réseau de neurones convolutif visant à réduire le temps de calcul et le nombre de paramètres utilisés par ce dernier tout en rivalisant avec des architectures plus complexes. Notamment, nous avons intégré une étape préliminaire de transformation par la DWT avant le traitement par le réseau neuronal, soulignant ainsi l'efficacité de cette méthode dans l'optimisation du processus global.

En synthèse, cette recherche offre une perspective novatrice en combinant habilement des techniques de décomposition avancées avec un réseau de neurones convolutif. Les résultats obtenus ouvrent des opportunités dans le domaine de la conversion de signaux physiologiques, soulignant l'équilibre entre l'efficacité computationnelle et la performance prédictive. Ce mémoire contribue ainsi à l'avancement des approches de traitement des signaux biomédicaux, suggérant des applications potentielles pour des développements futurs dans ce domaine en constante évolution. En vue des prochaines étapes de cette étude, il serait opportun de conduire des essais cliniques en collaboration avec des experts médicaux ou d'acquérir et d'exploiter des bases de données cliniques incluant à la fois des signaux PPG et leurs équivalents ECG classés. Ces expériences pourraient offrir des données précieuses quant à l'applicabilité pratique des méthodes étudiées et, par conséquent, ouvrir la voie à l'idée de substituer l'ECG par la PPG.

BIBLIOGRAPHIE

- Abdelmadjid, M. A. (2022). *Réseau génératif antagoniste pour la traduction de signaux de capteurs avec application à l'ECG*. (Mémoire de maîtrise). Université du Québec à Montréal.
- ADInstruments. Settings : Sampling panels lt ecg and heart rate. <https://www.adinstruments.com/support/documentation/settings-sampling-panels-lt-ecg-and-heart-rate>. Accessed on [date].
- Allen, J. (2007). Photoplethysmography and its application in clinical physiological measurement. *Physiological measurement*, 28(3), R1-R39. <http://dx.doi.org/10.1088/0967-3334/28/3/R01>
- Ananthram, A. (2018). Optimizers be tensorflow's appetizers. *Towards Data Science*. Récupéré de <https://towardsdatascience.com/optimizers-be-deeps-appetizers-511f3706aa67>
- Chowdhury, A., Das, D., Cheung, R. C. et Chowdhury, M. H. (2023). Hardware/software co-design of an ecg-ppg preprocessor : A qualitative quantitative analysis. Dans *2023 International Conference on Electrical, Computer and Communication Engineering (ECCE)*, 1-6. <http://dx.doi.org/10.1109/ECCE57851.2023.10101536>
- Cornuéjols, A., Miclet, L. et Barra, V. (2018). *Apprentissage artificiel : 3e édition*. Eyrolles.
- Cruz, C. I. M., Marasigan, J. P., Perez, A. P. G., Pillejera, J. E. V., Veron, N. P. et dela Cruz, A. R. (2016). A comparative study between dwt-anfis and dwt-svm in ecg classification. Dans *2016 IEEE Region 10 Conference (TENCON)*, 2052-2055. <http://dx.doi.org/10.1109/TENCON.2016.7848386>
- Dragomiretskiy, K. et Zosso, D. (2014). Variational mode decomposition. *IEEE Transactions on Signal Processing*, 62(3), 531-544. <http://dx.doi.org/10.1109/TSP.2013.2288675>
- Fauzan, M. R. A., Rizal, A. et Hadiyoso, S. (2022). Ecg biometric using statistical feature of eemd and vmd. Dans *2022 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology (IAICT)*, 113-118. <http://dx.doi.org/10.1109/IAICT55358.2022.9887431>
- Goldberger, A., Amaral, L., Glass, L. et al. (2000). Physiobank, physiotoolkit, and physionet : Components of a new research resource for complex physiologic signals. *Circulation*, 101(23), e215-e220. Récupéré de <https://www.physionet.org/>
- Goulon, A. (2008). A new approach to learning from structured data and its applications to computer-aided drug design.
- Handschin, R. et Sticherling, C. (2009). Etendu inconscient sur le terrain de football. *Forum Médical Suisse - Swiss Medical Forum*, 9. <http://dx.doi.org/10.4414/fms.2009.06746>
- Haque, A. et Akhtar, N. (2022). Ensemble model for ecg classification. Dans *2022 5th International Conference on Multimedia, Signal Processing and Communication Technologies (IMPACT)*, 1-5. <http://dx.doi.org/10.1109/IMPACT55510.2022.10029230>

- Huang, H., Sung, T.-Y. et Shieh, Y.-S. (2010). A novel vlsi linear array for 2-d dct/idct. Dans *2010 3rd International Congress on Image and Signal Processing*, volume 8, 3686–3690.
<http://dx.doi.org/10.1109/CISP.2010.5647650>
- Immaculate Joy, S., Venkatesh, C. et Bhargav, B. (2023). Improved emd algorithm for electrocardiogram denoising and feature extraction for detection of cardiovascular disease. Dans *2023 5th International Conference on Smart Systems and Inventive Technology (ICSSIT)*, 135–139.
<http://dx.doi.org/10.1109/ICSSIT55814.2023.10061053>
- Isabelle, G. (2021). Des algorithmes qui apprennent et classent.
<https://www.universite-paris-saclay.fr/actualites/des-algorithmes-qui-apprennent-et-classent-le-travail-disabelle-guyon-recompense>.
 Accessed on [date].
- Karlen, W., Raman, S., Ansermino, J. M. et Dumont, G. A. (2013). Multiparameter respiratory rate estimation from the photoplethysmogram. *IEEE Transactions on Biomedical Engineering*, 60(7), 1946–1953. <http://dx.doi.org/10.1109/TBME.2013.2246160>
- Kligfield, P., Gettes, L., Bailey, J., Childers, R., Deal, B., Hancock, E., Herpen, G., Kors, J., Macfarlane, P., Mirvis, D., Pahlm, O., Rautaharju, P., Wagner, G., Josephson, M., Mason, J., Okin, P., Surawicz, B. et Wellens, H. (2007). Recommendations for the standardization and interpretation of the electrocardiogram. part i : The electrocardiogram and its technology a scientific statement from the american heart association electrocardiography and arrhythmias committee, council on clinical cardiology; the american college of cardiology foundation; and the heart rhythm society endorsed by... *Journal of the American College of Cardiology*, 49, 1109–27.
<http://dx.doi.org/10.1016/j.jacc.2007.01.024>
- Lahmiri, S. et Boukadoum, M. (2013). An application of the empirical mode decomposition to brain magnetic resonance images classification. Dans *2013 IEEE 4th Latin American Symposium on Circuits and Systems (LASCAS)*, 1–4. <http://dx.doi.org/10.1109/LASCAS.2013.6518997>
- Lahmiri, S. et Boukadoum, M. (2015). Physiological signal denoising with variational mode decomposition and weighted reconstruction after dwt thresholding. Dans *2015 IEEE International Symposium on Circuits and Systems (ISCAS)*, 806–809. <http://dx.doi.org/10.1109/ISCAS.2015.7168756>
- Learning, G. (2021). Everything you need to know about vgg16. Récupéré de <https://medium.com/@mygreatlearning/everything-you-need-to-know-about-vgg16-7315defb5918>
- Liu, Y., Dong, L., Zhang, B., Xin, Y. et Geng, L. (2020). Real time ecg classification system based on dwt and svm. Dans *2020 IEEE International Conference on Integrated Circuits, Technologies and Applications (ICTA)*, 155–156. <http://dx.doi.org/10.1109/ICTA50426.2020.9332052>
- Longmore, S. K., Lui, G. Y., Naik, G., Breen, P. P., Jalaludin, B. et Gargiulo, G. D. (2019). A comparison of reflective photoplethysmography for detection of heart rate, blood oxygen saturation, and respiration rate at various anatomical locations. *Sensors (Basel, Switzerland)*, 19(8), 1874.
<http://dx.doi.org/10.3390/s19081874>
- Mahgoub, A., Tanveer, A. et Qidwai, U. (2018). Arrhythmia classification using dwt-coefficient energy ratios. Dans *2018 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)*,

- 259-264. <http://dx.doi.org/10.1109/IECBES.2018.8626726>
- MathWorks (2023). MATLAB Engine for Python. Consulté le 26 octobre 2023. Récupéré de <https://www.mathworks.com/help/matlab/matlab-engine-for-python.html>
- Sachan, A. (2019). Understanding and implementing residual networks (resnets) in keras. Récupéré de <https://cv-tricks.com/keras/understand-implement-resnets/>
- Srivastava, M. (2018). *improving signal resolution and reducing experiment time in electron spin resonance spectroscopy via data processing methods*. (Thèse de doctorat). Cornell University. <http://dx.doi.org/10.7298/X4W957F2>. Récupéré de <https://doi.org/10.7298/X4W957F2>
- Szegedy, C., Ioffe, S., Vanhoucke, V. et Alemi, A. (2016). Inception-v4, inception-resnet and the impact of residual connections on learning. Dans *AAAI Conference on Artificial Intelligence*. <http://dx.doi.org/10.1609/aaai.v31i1.11231>
- Tafforeau, J. (2014). Deep neural network for part-of-speech tagging.
- Tang, S. K. D., Goh, Y. Y. S., Wong, M. L. D. et Lew, Y. L. E. (2016). Ppg signal reconstruction using a combination of discrete wavelet transform and empirical mode decomposition. Dans *2016 6th International Conference on Intelligent and Advanced Systems (ICIAS)*, 1-4. <http://dx.doi.org/10.1109/ICIAS.2016.7824118>
- University of Iowa Health Care (2024). Pulse oximetry : Basic principles and interpretation. <https://medicine.uiowa.edu/iowaprotocols/pulse-oximetry-basic-principles-and-interpretation>. Accessed on [date].
- Vandenberk, T., Stans, J., Van Schelvergem, G., Pelckmans, C., Smeets, C., Lanssens, D., De Cannière, H., Storms, V., Thijs, I. et Vandervoort, P. (2017). Clinical validation of heart rate apps : Mixed-methods evaluation study. *JMIR Mhealth Uhealth*, 5, e129. <http://dx.doi.org/10.2196/mhealth.7254>
- Wagner, G. S., Macfarlane, P., Wellens, H., Josephson, M., Gorgels, A., Mirvis, D. M., Pahlm, O., Surawicz, B., Kligfield, P., Childers, R., Gettes, L. S., Bailey, J. J., Deal, B. J., Gorgels, A., Hancock, E. W., Kors, J. A., Mason, J. W., Okin, P., Rautaharju, P. M., van Herpen, G. et Society, . H. R. (2009). Aha/accf/hrs recommendations for the standardization and interpretation of the electrocardiogram : part vi : acute ischemia/infarction : a scientific statement from the american heart association electrocardiography and arrhythmias committee, council on clinical cardiology ; the american college of cardiology foundation ; and the heart rhythm society. endorsed by the international society for computerized electrocardiology. *Journal of the American College of Cardiology*, 53(11), 1003-1011. <http://dx.doi.org/10.1016/j.jacc.2008.12.016>
- Wagner, P., Strodthoff, N., Bousseljot, R. D. et al. (2020). Ptb-xl, a large publicly available electrocardiography dataset. *Sci Data*, 7, 154. <http://dx.doi.org/10.1038/s41597-020-0495-6>
- Wagner, P., Strodthoff, N., Bousseljot, R.-D., Samek, W. et Schaeffter, T. (2022). Ptb-xl, a large publicly available electrocardiography dataset. PhysioNet. Récupéré de <https://doi.org/10.13026/kfzx-aw45>

Zhu, Q., Tian, X., Wong, C.-W. et Wu, M. (2019). Ecg reconstruction via ppg : A pilot study. Dans *2019 IEEE EMBS International Conference on Biomedical Health Informatics (BHI)*, 1-4.
<http://dx.doi.org/10.1109/BHI.2019.8834612>

Zizoua, C., Chouana, O., Attari, M., Ouadjaout, A., Remram, Y., Boukhenous, S. et Meziane, N. (2012). Un réseau de capteurs sans fil dédié au monitoring de l'activité cardiaque.