Aix Marseille Université

NNT : 0000AIXM0000

THÈSE DE DOCTORAT

Soutenue à Aix-Marseille Université
le 27 Février 2025 par

Abir BOULIF

Apport de l'Intelligence Artificielle au diagnostic automatisé des arythmies

Discipline
Informatique

École doctorale
ED 184 – Mathématiques et Informatique

Laboratoire/Partenaires de recherche
Laboratoire d'Informatique et des Systèmes (LIS, UMR 7020)
Centre de Recherche en CardioVasculaire et Nutrition (C2VN)

Composition du jury

Valérie LOUIS Professeure des Universités Université de Lorraine	Rapporteure
Vincent COCQUEMPOT Professeur des Universités Université de Lille	Rapporteur
Abdessamad KOBI Professeur des Universités Université d'Angers	Président du jury
Mustapha OULADSINE Professeur des Universités Aix-Marseille Université	Directeur de thèse
Stéphane DELLIAUX Maître de conférences (MCU-PH), HDR Aix-Marseille Université	Co-directeur de thèse
Bouchra ANANOU Maître de conférences Aix-Marseille Université	Co-encadrante de thèse

LIS Laboratoire d'Informatique & des Systèmes

C2VN Centre de Recherche en CardioVasculaire et Nutrition

Affidavit

Je soussignée, Abir BOULIF, déclare par la présente que le travail présenté dans ce manuscrit est mon propre travail, réalisé sous la direction scientifique de Mustapha OULADSINE, Stéphane DELLIAUX et Bouchra ANANOU, dans le respect des principes d'honnêteté, d'intégrité et de responsabilité inhérents à la mission de recherche. Les travaux de recherche et la rédaction de ce manuscrit ont été réalisés dans le respect à la fois de la charte nationale de déontologie des métiers de la recherche et de la charte d'Aix-Marseille Université relative à la lutte contre le plagiat.

Ce travail n'a pas été précédemment soumis en France ou à l'étranger dans une version identique ou similaire à un organisme examinateur.

Fait à Marseille, le 09 Octobre 2024



Cette œuvre est mise à disposition selon les termes de la Licence Creative Commons Attribution - Pas d'Utilisation Commerciale - Pas de Modification 4.0 International.

Liste de publications et participation aux conférences

1. Boulif, A., Ananou, B., Ouladsine, M., Delliaux, S. (2023). A literature review: ECG-based models for arrhythmia diagnosis using artificial intelligence techniques. *Bioinformatics and Biology Insights, 17*. https://doi.org/10.1177/11779322221149600

2. Boulif, A., Ananou, B., Ouladsine, M., Delliaux, S. (2024). Focal-Based Deep Learning Model for Automatic Arrhythmia Diagnosis. *24th International Conference on Computational Science (ICCS 2024). Lecture Notes in Computer Science*, vol 14835. Springer, Cham. https://doi.org/10.1007/978-3-031-63772-8_31

3. Boulif, A., Ananou, B., Ouladsine, M., Delliaux, S. (2024). Feature fusion for multi-class arrhythmia detection using focal-based deep learning architecture. *18th International Conference on Control, Automation, Robotics and Vision (ICARCV 2024)*, 435–440. https://doi.org/10.1109/ICARCV63323.2024.10821679

Résumé

Selon le rapport 2023 de la World Heart Federation (WHF) [1], les maladies cardiovasculaires (MCV) représentent une menace globale pour la population, puisque les décès dus aux MCV ont augmenté de 60 % dans le monde au cours des 30 dernières années. En 2020, les maladies cardiovasculaires étaient la deuxième cause de mortalité en France, avec 134 763 décès, selon Drees - Ministère des Solidarités et de la Santé [2], ce qui représente 20.2 % de l'ensemble des décès de cette année-là. Pour contribuer à faire baisser le taux de mortalité par les MCV, il est essentiel de mettre en place en priorité des outils de prévention des infarctus du myocarde (IDM) et des accidents vasculaires cérébraux (AVC) prématurés, puisque 80 % d'entre eux peuvent être évités.

Les arythmies étant un facteur de risque des crises cardiaques, leur détection précoce revêt une importance majeure dans le domaine médical. Cependant, ce processus peut être chronophage en raison du temps considérable nécessaire pour analyser manuellement les enregistrements d'électrocardiogramme (ECG), souvent perturbés par du bruit et des artefacts, ce qui complique davantage l'interprétation des données.

Différentes méthodes traditionnelles d'apprentissage automatique (Machine Learning, ML) ont été mises en œuvre pour le diagnostic des arythmies, montrant des résultats prometteurs mais également certaines limitations. Parmi celles-ci, la phase d'extraction manuelle des caractéristiques constitue un point critique. Cette étape dépend fortement de la qualité des caractéristiques sélectionnées, ce qui peut entraîner des biais et une efficacité limitée si les caractéristiques importantes ne sont pas correctement identifiées.
De plus, les signaux ECG contiennent souvent du bruit provenant de diverses sources. Les algorithmes de ML classiques sont sensibles à ces perturbations, bien qu'elles puissent être atténuées par des techniques de filtrage lors du prétraitement. Les approches classiques de ML, telles que les arbres de décision ou les régressions logistiques, peuvent également être limitées dans leur capacité à capturer des relations complexes ou non linéaires présentes dans les signaux ECG. En outre, ces méthodes peuvent rencontrer des difficultés dans le traitement de grandes bases de données en raison de leur complexité algorithmique.
Le déséquilibre des classes dans les ensembles de données complique davantage l'entraînement des modèles, rendant difficile la reconnaissance des arythmies rares sans augmenter le nombre de faux positifs. En somme, ces limitations peuvent compromettre la robustesse de la classification.

Deux contributions majeures sont proposées dans cette thèse. Tout d'abord, une nouvelle variante de la technique d'augmentation des données SMOTE est développée, pour augmenter le nombre de battements cardiaques appartenant aux classes rares, en trouvant les battements voisins les plus similaires, à l'aide de la mesure de similarité DTW. Ensuite, ce travail s'est appuyé sur des architectures avancées du Deep Learning, incluant et fusionnant plusieurs types des réseaux de neurones. Des blocs de Modulation Focale sont appliqués aux signaux ECG pour la première fois dans ce travail. Ils permettent au modèle de classification de se concentrer de

manière sélective sur des parties spécifiques des entrées, tout en s'appuyant sur des opérations plus légères. Ce processus repose d'abord sur une agrégation des informations, suivie d'une interaction entre les différentes parties agrégées de l'entrée. Cet ordre permet au modèle de se focaliser mieux sur les parties pertinentes de l'information.

Les résultats expérimentaux ont révélé que la nouvelle variante de la méthode SMOTE a significativement amélioré la précision du diagnostic des battements cardiaques par rapport à la méthode SMOTE classique. Par ailleurs, les deux approches d'apprentissage profond développées ont atteint des valeurs d'accuracy de 98,99 % et 98,61 %, ainsi que des F1-score de 94,77 % et 94,08 %, respectivement, et un temps de classification de 0.0002 s par échantillon pour la deuxième approche. De surcroît, en comparaison avec d'autres méthodes rapportées dans la littérature, les résultats obtenus témoignent d'une amélioration notable de la détection des arythmies grâce aux méthodes proposées.

Mots-clés : Arythmie, ECG, diagnostic, battement cardiaque, prétraitement, apprentissage profond, apprentissage automatique, classification, DTW, Modulation Focale, intelligence artificielle.

Abstract

According to the 2023 report of the World Heart Federation (WHF) [1], cardiovascular diseases (CVD) represent a global threat to the population, since deaths due to CVD have increased by 60% worldwide in the past 30 years. In 2020, cardiovascular diseases were the second leading cause of death in France, with 134,763 deaths, according to Drees - Ministère des Solidarités et de la Santé [2], this represents 20.2% of all deaths in that year. To help bring down the rate of CVD mortality, it is essential to prioritize implementing tools to prevent premature myocardial infarction (MI) and strokes, since 80% of these can be avoided.

As arrhythmias are a risk factor for heart attacks, their early detection is of major medical importance. However, this process can be time-consuming due to the considerable amount of time required to manually analyse electrocardiogram (ECG) recordings, which are often disturbed by noise and artefacts, further complicating data interpretation.

Various traditional machine learning (ML) methods have been used to diagnose arrhythmias, showing promising results but also certain limitations. Among these, the manual feature extraction phase is a critical point. This stage is highly dependent on the quality of the features selected, which can lead to bias and limited effectiveness if important features are not correctly identified. In addition, ECG signals often contain noise from a variety of sources. Conventional ML algorithms are sensitive to these disturbances, although they can be mitigated by filtering techniques during pre-processing. Classical ML approaches, such as decision trees or logistic regressions, may also be limited in their ability to capture complex or non-linear relationships present in ECG signals. Moreover, these methods may encounter difficulties in processing large databases due to their algorithmic complexity. Class imbalance in datasets further complicates model training, making it difficult to recognise rare arrhythmias without increasing the number of false positives. In conclusion, these limitations can compromise the robustness of classification.

Two major contributions are proposed in this thesis. First, a new variant of the SMOTE data augmentation technique is developed, to increase the number of heartbeats belonging to rare classes, by finding the most similar neighbouring beats, using the DTW similarity measure. Next, this thesis relied on advanced Deep Learning architectures, including and merging several types of neural networks. Focal Modulation blocks are applied to ECG signals for the first time in this work. They allow the classification model to focus selectively on specific parts of the inputs, while relying on light-weight operations. This process is based firstly on an aggregation of the information, followed by an interaction between the different aggregated parts of the input. This order allows the model to focus more effectively on the relevant parts of the information.

Experimental results revealed that the new variant of the SMOTE method significantly improved the accuracy of heartbeat diagnosis compared with the conventional SMOTE method. In addition, the two deep learning approaches developed achieved accuracy values of 98.99%

and 98.61%, as well as F1-scores of 94.77% and 94.08%, respectively, and a classification time of 0.0002 s per sample for the second approach. Furthermore, compared with other methods reported in the literature, the results obtained show a significant improvement in arrhythmia detection using the proposed methods.

Keywords: Arrhythmia, ECG, diagnosis, heartbeat, pre-processing, deep learning, machine learning, classification, DTW, Focal Modulation, artificial intelligence.

Table des matières

Affidavit 2
Liste de publications et participation aux conférences 3
Résumé 4
Abstract 6
Table des matières 8
Table des figures 11
Liste des tableaux 11
Introduction générale 14
1. Contexte et problématique médicale 16
1.1. Introduction 17
1.2. Le système cardiovasculaire 17
1.2.1. Introduction au système circulatoire 17
1.2.2. Anatomie et fonction du cœur 18
1.2.3. Le système de conduction électrique 20
1.3. L'électrocardiogramme (ECG) 25
1.3.1. Principe de l'ECG 25
1.3.2. La fréquence cardiaque 35
1.4. Pathologies cardiaques : les arhythmies 38
1.4.1. Définition de l'arythmie 38
1.4.2. Les mécanismes de déclenchement des arythmies cardiaques 38
1.4.3. Les types d'arythmies cardiaques 40
1.5. Problématique et contribution de la thèse 46
1.5.1. Battements cardiaques : types et caractéristiques 46
1.5.2. Défis liés au diagnostic des arythmies 53
1.5.3. Contributions de la thèse 54
1.6. Conclusion 54
2. Etat de l'art 55
2.1. Introduction 56
2.2. Prétraitement du signal ECG 56
2.2.1. Réduction du bruit 56
2.2.2. Détection des pics R et des complexes QRS 63
2.2.3. Segmentation du signal ECG 66
2.2.4. Normalisation des données 68
2.2.5. Compression des données ECG 68
2.3. Extraction des caractéristiques ECG 69
2.3.1. Domaine temporel 70
2.3.2. Domaine fréquentiel/spectral 71
2.3.3. Domaine temps-fréquence 71
2.3.4. Domaine de la décomposition 72

2.3.5. Caractéristiques profondes 73
2.4. Génération des signaux synthétiques ECG 74
2.4.1. Modèles paramétriques 74
2.4.2. Modèles basés sur des processus stochastiques 75
2.4.3. Méthodes basées sur la simulation physiologique 75
2.4.4. Méthodes basées sur des modèles génératifs (Deep Learning) 75
2.4.5. Techniques d'augmentation des données 76
2.5. Classification des arythmies cardiaques 77
2.5.1. Classification par les méthodes classiques du Machine Learning 77
2.5.2. Classification par le Deep Learning 78
2.5.3. Métriques d'évaluation 79
2.6. Conclusion 81
3. Développement de la variante DTW-SMOTE pour l'augmentation des données 82
3.1. Introduction 83
3.2. Méthodologie proposée 83
3.3. Description des bases de données ECG 84
3.4. Prétraitement des données ECG 86
3.4.1. Réduction de bruit 86
3.4.2. Normalisation du signal ECG 91
3.4.3. Segmentation des battements cardiaques 91
3.5. Augmentation des battements cardiaques 95
3.5.1. Principe de la méthode SMOTE classique 95
3.5.2. La distance de similarité DTW 95
3.5.3. Implémentation de la méthode DTW-SMOTE 96
3.6. Evaluation de la performance de la variante DTW-SMOTE 99
3.7. Conclusion 100
4. Classification des battements cardiaques : Approche basée sur l'extraction des caractéristiques spatiales 101
4.1. Introduction 102
4.2. Aperçu 103
4.3. Extraction des caractéristiques par un Réseau Résiduel profond (ResNet) 103
4.3.1. Réseau Convolutionnel classique (CNN) Vs Réseau Résiduel (ResNet) 104
4.3.2. Application aux battements cardiaques 105
4.4. Construction du modèle de classification 109
4.4.1. Classification par mécanisme d'Attention 109
4.4.2. Classification par Modulation Focale 110
4.4.3. Architecture globale du modèle de classification 111
4.5. Evaluation de la performance des modèles de classification 113
4.6. Conclusion 117
5. Classification des battements cardiaques : Approche hybride par fusion de caractéristiques spatiales et temporelles 119
5.1. Introduction 120
5.2. Aperçu 120
5.3. Extraction hybride des caractéristiques ECG 121

5.3.1. Extraction des caractéristiques temporelles par le Matching Pursuit Orthogonal (OMP) 121
5.3.2. Extraction des caractéristiques spatiales profondes par le réseau Résiduel (ResNet) 123
5.3.3. Fusion des caractéristiques ResNet-OMP 123
5.4. Modèle de classification 124
5.5. Evaluation de la performance des modèles de classification 124
5.6. Discussion et comparaison 128
5.7. Conclusion 130
Conclusion générale et perspectives **131**
Bibliographie **134**
Liste des acronymes **157**
Annexes **162**
A. Annotations des battements ECG selon PhysionetBank-MITDB. 162
B. Annotations des battements ECG selon la norme ANSI/AAMI EC57 ; 2012. 163

Table des figures

Figure 1.1. La circulation sanguine. 18
Figure 1.2. La structure du cœur humain. 19
Figure 1.3: Les composants du système de conduction cardiaque. 21
Figure 1.4. Phases de potentiel d'action des oreillettes, ventricules et réseau de conduction His-Purkinje (à gauche). Phases de potentiel d'action du nœud sinusal et du nœud AV (à droite). 24
Figure 1.5. Morphologie des potentiels d'action des différentes cellules cardiaques. 24
Figure 1.6: Tracé normal d'un enregistrement ECG ambulatoire accessible sur le répertoire Physionet [11], recueilli à l'hôpital Beth Israel de Boston. 25
Figure 1.7. L'organisation des dérivations des membres. L'électrode de la jambe droite n'est incluse dans aucune dérivation, mais sert de fil de terre. 26
Figure 1.8. Les dérivations précordiales. 27
Figure 1.9. Un exemple d'ECG illustrant les 12 dérivations standard : Dérivations périphériques (à droite) et dérivations précordiales (à gauche). 28
Figure 1.10. Cycle cardiaque et tracé ECG. (1) Début Onde P : Dépolarisation du nœud sinusal (SA). (2) Onde P : Dépolarisation auriculaire complète. (3) Segment PR : L'influx traverse le nœud AV, le faisceau de His et ses branches. (4) Complexe QRS : Dépolarisation ventriculaire. (5) Segment ST : Fin de la dépolarisation et début de la repolarisation ventriculaire. (6) Onde T : Repolarisation ventriculaire. 29
Figure 1.11: Les composantes du cycle électrique cardiaque. 31
Figure 1.12: Représentation de l'onde P en rythme sinusal normal, montrant les polarités dans les dérivations aVR et II. 32
Figure 1.13. Mécanisme de réentrée. 40
Figure 1.14. Rythme sinusal normal. 45
Figure 1.15. Bradyarythmie. Exemple : Bloc AV du premier degré avec intervalle PR prolongé > 0.20 seconde. 45
Figure 1.16. Tachyarythmie supraventriculaire. Exemple : Fibrillation auriculaire avec des ondes f fibrillatoires et des complexes QRS irréguliers. 45
Figure 1.17. Tachyarythmie ventriculaire. Exemple : Fibrillation ventriculaire où aucune onde P, complexe QRS ou onde T n'est visible. 45
Figure 1.18. Contraction auriculaire prématurée (PAC) avec onde P prématurée ayant une morphologie différente de l'onde P sinusale. 46
Figure 1.19: Représentation d'un battement ventriculaire prématuré (PVC). 48
Figure 1.20. Représentation d'un Bloc de Branche Droit (à gauche) et d'un Bloc de Branche Gauche (à droite) sur les dérivations frontales et les dérivations précordiales. 50
Figure 1.21: Un stimulus (A) est observé avant chaque onde P, lorsque l'électrode du stimulateur cardiaque est placée dans l'oreillette droite. 51
Figure 1.22: Représentation d'un battement de Fusion (F) en lead V1. 52
Figure 1.23: Représentation d'un battement de fusion (f) 53
Figure 2.1. Exemple d'un signal ECG avec les bruits de la dérive de la ligne de base et les interférences des lignes électriques, extrait du Record '100' de la base de données « MIT-BIH Arrhythmia database », accessible sur le répertoire Physionet [11]. 57

Figure 2.2. Exemple d'un signal ECG affecté par le bruit électromyographique, extrait du Record '203' de la base de données « MIT-BIH Arrhythmia database », accessible sur le répertoire Physionet [11]..... 58
Figure 3.1. Diagramme synoptique de la méthodologie proposée..... 84
Figure 3.2. Signal ECG extrait de MITDB de l'enregistrement '100', représentant deux dérivations. 85
Figure 3.3. Signal ECG extrait de NSRDB de l'enregistrement '16539', représentant deux dérivations. 86
Figure 3.4. Signal ECG bruité Vs signal ECG débruité. La ligne rouge illustre la correction de la dérive de la ligne de base. 88
Figure 3.5. Application de la méthode "Butterworth et FIR" à l'enregistrement '102' de la base de données MITDB..... 90
Figure 3.6. Application de la méthode DWT à l'enregistrement '102' de la base de données MITDB.90
Figure 3.7. Positions des pics R. 91
Figure 3.8. Calcul des coefficients d'approximation et de détail pour la délimitation des ondes P et T de l'ECG : Exemple avec un niveau de décomposition de 4..... 93
Figure 3.9. Segmentation des battements cardiaques par la transformée en ondelette discrète (DWT). 94
Figure 3.10. Correspondance euclidienne (à gauche) Vs correspondance DTW (à droite) entre deux séquences..... 96
Figure 3.11. (a)-Trajectoire de déformation de deux battements cardiaques, (b)-comparaison DTW point par point. 97
Figure 3.12. Battement Prématuré Auriculaire réel et Battement Prématuré Synthétique généré par DTW-SMOTE. 98
Figure 4.1. Schéma de la méthodologie adoptée pour la classification des battements cardiaques. . 103
Figure 4.2. Comparaison entre le bloc de convolution classique et le bloc résiduel..... 105
Figure 4.3. Le bloc de prédiction basé sur les couches LSTM-Focal. 112
Figure 4.4. Accuracy d'entraînement et de validation du modèle LSTM-Focal (a) et du modèle LSTM-Attention (b)..... 115
Figure 4.5. Matrice de confusion du modèle LSTM-Focal à partir des données de test. 116
Figure 5.1. Schéma de la méthodologie adoptée pour la classification des battements cardiaques basée sur la fusion de caractéristiques hybrides..... 121
Figure 5.2. Matrice de confusion du modèle LSTM-Focal à partir des données de test. 126
Figure 5.3. Courbe ROC micro-moyenne du modèle LSTM-Focal (ligne rouge en pointillés) et courbes ROC de toutes les classes de battements cardiaques..... 127

Liste des tableaux

Tableau 1.1: Vitesse de conduction et fréquence cardiaque des structures de la voie de conduction cardiaque. 23
Tableau 1.2: Valeurs normales (amplitudes) de l'ECG pour le rythme sinusal. 35
Tableau 1.3: Valeurs normales (durées) de l'ECG pour le rythme sinusal. 35
Tableau 1.4: Quelques mesures de la variabilité de la fréquence cardiaque en domaine temporel, fréquentiel et non linéaire. 37
Tableau 1.5: Les sous-catégories des bradyarythmies. 41
Tableau 1.6: Les sous-catégories des tachyarythmies supraventriculaires. 42
Tableau 1.7: Les sous-catégories des tachyarythmies ventriculaires. 43
Tableau 1.8: Description de l'arythmie sinusal, du rythme jonctionnel et du rythme idioventriculaire. 44
Tableau 2.1. Comparaison entre les méthodes de réduction du bruit. 62
Tableau 2.2. Comparaison entre les méthodes de détection des pics R et complexes QRS. 65
Tableau 2.3. Comparaison entre les méthodes d'extraction des caractéristiques ECG. 73
Tableau 2.4. Comparaison entre les méthodes du Deep Learning pour la classification des arythmies cardiaques. 78
Tableau 3.1. Description des bases de données utilisées dans l'analyse du signal ECG. 85
Tableau 3.2. Combinaison de 63 paramètres pour la réduction du bruit avec la méthode DWT. 89
Tableau 3.3. Distribution des battements cardiaques. 98
Tableau 3.4. Métriques d'évaluation (en %) des modèles d'Arbre de décision et du SVM sur les données augmentées par SMOTE et par DTW-SMOTE. 100
Tableau 4.1. Principales couches du bloc résiduel utilisé pour l'extraction des caractéristiques ECG. 106
Tableau 4.2. Résultats d'ajustement des hyper-paramètres par l'optimisation bayésienne. 114
Tableau 4.3. Métriques d'évaluation (en %) du modèle LSTM-Focal à partir des données de test. .. 116
Tableau 4.4. Métriques d'évaluation (en %) du modèle LSTM-Focal et du modèle LSTM-Attention. 117
Tableau 5.1. Comparaison de différents types d'ondelettes pour l'algorithme OMP. 122
Tableau 5.2. Comparaison entre les modèles 12-ResNet et 34-ResNet pour l'extraction des caractéristiques ECG. 123
Tableau 5.3. Métriques d'évaluation (en %) du modèle LSTM-Focal sur les données de test issues de l'extraction hybride des caractéristiques. 125
Tableau 5.4. Les performances (%) du modèle LSTM-Focal appliqué aux caractéristiques hybrides Vs le modèle LSTM-Focal appliqué uniquement aux caractéristiques ResNet. 128
Tableau 5.5. Tableau récapitulatif comparatif des approches de Deep Learning pour la classification des battements cardiaques. 129

Introduction générale

Les maladies cardiovasculaires sont la première cause de mortalité dans le monde, représentant une préoccupation majeure pour la santé publique. Parmi ces maladies, les arythmies cardiaques, qui se manifestent par des irrégularités du rythme cardiaque. Le diagnostic précoce des arythmies est essentiel pour prévenir des complications graves telles que les accidents vasculaires cérébraux et les arrêts cardiaques. L'électrocardiogramme (ECG) est l'outil de référence pour l'analyse du rythme cardiaque et la détection des arythmies. Toutefois, les méthodes actuelles de diagnostic, qu'elles soient manuelles ou basées sur les techniques traditionnelles de Machine Learning (ML), présentent des limitations en termes d'efficacité et de précision.

En général, les défis liés au diagnostic par les méthodes traditionnelles du Machine Learning sont nombreux. D'abord, les caractéristiques du signal ECG sont souvent définies et extraites manuellement (hand-crafted) ce qui ne permet pas toujours de s'adapter aux formes atypiques du signal, plus particulièrement chez les patients avec des arythmies rares. De plus, il existe des méthodes du Machine Learning, telles que les forêts aléatoires, les machines à vecteurs de support (SVM), et les k-plus proches voisins (kNN), qui sont souvent sensibles au bruit et aux artefacts présents dans les données ECG, ce qui peut conduire à des erreurs de classification. En outre, les modèles de ML traditionnels sont limités en terme d'adaptation et de flexibilité face à des données ECG massives et hétérogènes, d'autant que le signal ECG présente une grande variabilité.

Dès lors, il est important de développer des techniques plus avancées et automatisées pour améliorer la détection et la classification des arythmies cardiaques à partir des signaux ECG. L'intégration de l'intelligence artificielle, notamment des méthodes d'apprentissage profond, offre de nouvelles perspectives pour analyser de grands volumes de données ECG de manière plus précise et efficace. Cette approche permet non seulement d'améliorer la détection des arythmies, mais aussi de mieux comprendre les dynamiques sous-jacentes du rythme cardiaque.

Les objectifs de ce travail de recherche sont multiples. Premièrement, développer et évaluer des méthodes d'augmentation des données ECG, afin de renforcer les performances des modèles de classification puisque ceci permet aux modèles de mieux apprendre les caractéristiques des classes rares, réduisant le risque de sur-apprentissage sur un petit nombre d'exemples. Deuxièmement, améliorer les techniques de traitement et d'analyse des signaux ECG pour la détection des arythmies. Et troisièmement, proposer des approches hybrides combinant différentes techniques d'extraction de caractéristiques et de classification pour améliorer le diagnostic des battements cardiaques pathologiques.

Ce travail de recherche a été réalisé au sein du Laboratoire d'Informatique et des Systèmes (LIS, UMR 7020) à Marseille, en collaboration avec le Centre de Recherche en CardioVasculaire et Nutrition (C2VN) qui traite les grands enjeux de santé publique, les maladies cardiovasculaires et leur prévention par la Nutrition. Le laboratoire LIS mène des

recherches fondamentales dans les domaines de l'informatique, de l'automatique, du traitement de signal et d'image, et qui sont appliquées aux métiers divers tels que le transport, la santé, l'énergie, l'environnement, la défense, etc. Cette thèse s'inscrit dans le cadre des activités du pôle ACS (Analyse et Contrôle des Systèmes), au sein de l'équipe DIAPRO qui élabore de nouvelles approches pour le diagnostic et le pronostic des systèmes.

Ce manuscrit est structuré en cinq chapitres, comme suit :

— Le **Chapitre 1**, présente une introduction détaillée du système cardiovasculaire et du signal ECG, ainsi qu'une discussion sur les arythmies cardiaques, leurs caractéristiques, leurs types, et leur impact clinique. Ce chapitre présente également la problématique et les contributions de thèse.
— Le **Chapitre 2**, est consacré à l'état de l'art des méthodes existantes pour le traitement et l'analyse des signaux ECG, incluant l'élimination du bruit, la détection des pics R et des complexes QRS, la segmentation du signal ainsi que la compression des données. L'extraction et la sélection des caractéristiques ECG sont également présentées, avec un accent sur les techniques d'apprentissage profond pour la classification des signaux ECG. Nous abordons également la génération de signaux ECG synthétiques, essentielle pour augmenter les données utilisées en apprentissage profond.
— Le **Chapitre 3**, propose une nouvelle variante de la méthode SMOTE pour l'augmentation des battements cardiaques. Quelques algorithmes du Machine Learning ont été appliqués aux donnés synthétiques générées par cette variante, afin de mesurer sa capacité à améliorer la qualité de classification.
— Le **Chapitre 4**, décrit l'approche proposée pour l'extraction des caractéristiques ECG par un réseau neuronal profond, et la classification des battements cardiaques à l'aide de la Modulation Focale, qui est appliquée au signal ECG pour la première fois dans ce travail de recherche. Le processus complet de détection d'arythmies est présenté, en commençant par la réduction du bruit, la segmentation dynamique des battements, leur augmentation selon la variante SMOTE proposée, et finalement la classification et l'évaluation des battements cardiaques.
— Le **Chapitre 5**, propose une approche hybride de classification des battements, basée sur la fusion des caractéristiques spatiales extraites par un réseau résiduel et des caractéristiques temporelles extraites par l'algorithme « Orthogonal Matching Pursuit ». Les résultats de cette approche sont comparés à ceux de l'approche proposée dans le chapitre 4.

Le manuscrit se conclut par une synthèse des résultats obtenus et des perspectives pour les recherches futures.

1. Contexte et problématique médicale

Sommaire

1.1. Introduction 17
1.2. Le système cardiovasculaire 17
1.2.1. Introduction au système circulatoire 17
1.2.2. Anatomie et fonction du cœur 18
1.2.3. Le système de conduction électrique 20
1.3. L'électrocardiogramme (ECG) 25
1.3.1. Principe de l'ECG 25
1.3.2. La fréquence cardiaque 35
1.4. Pathologies cardiaques : les arhythmies 38
1.4.1. Définition de l'arythmie 38
1.4.2. Les mécanismes de déclenchement des arythmies cardiaques 38
1.4.3. Les types d'arythmies cardiaques 40
1.5. Problématique et contribution de la thèse 46
1.5.1. Battements cardiaques : types et caractéristiques 46
1.5.2. Défis liés au diagnostic des arythmies 53
1.5.3. Contributions de la thèse 54
1.6. Conclusion 54

1.1. Introduction

Ce chapitre présente un aperçu global du système cardiovasculaire et de ses composantes essentielles, en soulignant l'importance de l'électrocardiogramme (ECG) dans l'analyse des fonctions cardiaques et la détection des pathologies. D'abord, nous explorons le système circulatoire, comprenant l'anatomie et la fonction du cœur, ainsi que le rôle des chambres et des valves cardiaques. Nous aborderons également le système de conduction électrique du cœur, qui joue un rôle crucial dans la genèse et le maintien d'un rythme cardiaque normal.

Ensuite, nous nous concentrons sur le signal électrocardiogramme (ECG), en détaillant ses déterminants, l'acquisition des signaux électriques cardiaques, et les différents types d'électrocardiographes. Une attention particulière est portée à la description des événements du cycle cardiaque électrique tels qu'ils apparaissent sur un ECG et à l'interprétation d'un ECG normal, caractérisé par un rythme sinusal régulier.

Par la suite, le chapitre examinera les pathologies cardiaques, en particulier les arythmies, qui peuvent avoir des conséquences graves pour la santé. Nous définissons les différents types d'arythmies et leurs causes, telles que les anomalies de la génération ou/et de la conduction des impulsions électriques.

Enfin, la problématique de la thèse sera exposée, en mettant en lumière les défis associés à l'analyse des battements cardiaques. Nous présenterons les contributions proposées par cette recherche, visant à améliorer la détection des arythmies cardiaques pour une prise en charge clinique plus efficace.

1.2. Le système cardiovasculaire

1.2.1. Introduction au système circulatoire

Pompé par le cœur au rythme d'environ 5 litres à la minute, le sang circule dans un réseau de vaisseaux sanguins. Ceux-ci jouent un rôle crucial dans le système cardiovasculaire, collaborant pour garantir un transport efficace de l'oxygène, des nutriments et des déchets à travers tout le corps.

Le sang circule à l'intérieur d'un réseau de canalisations, constitué de trois principaux vaisseaux [3] :

- Les artères, depuis la grosse aorte jusqu'aux petites artérioles, conduisent le sang chargé d'oxygène du cœur vers les organes,
- Les capillaires, assurent à l'intérieur de chaque organe la circulation du sang,
- Les veines, ramènent au cœur le sang chargé de gaz carbonique.

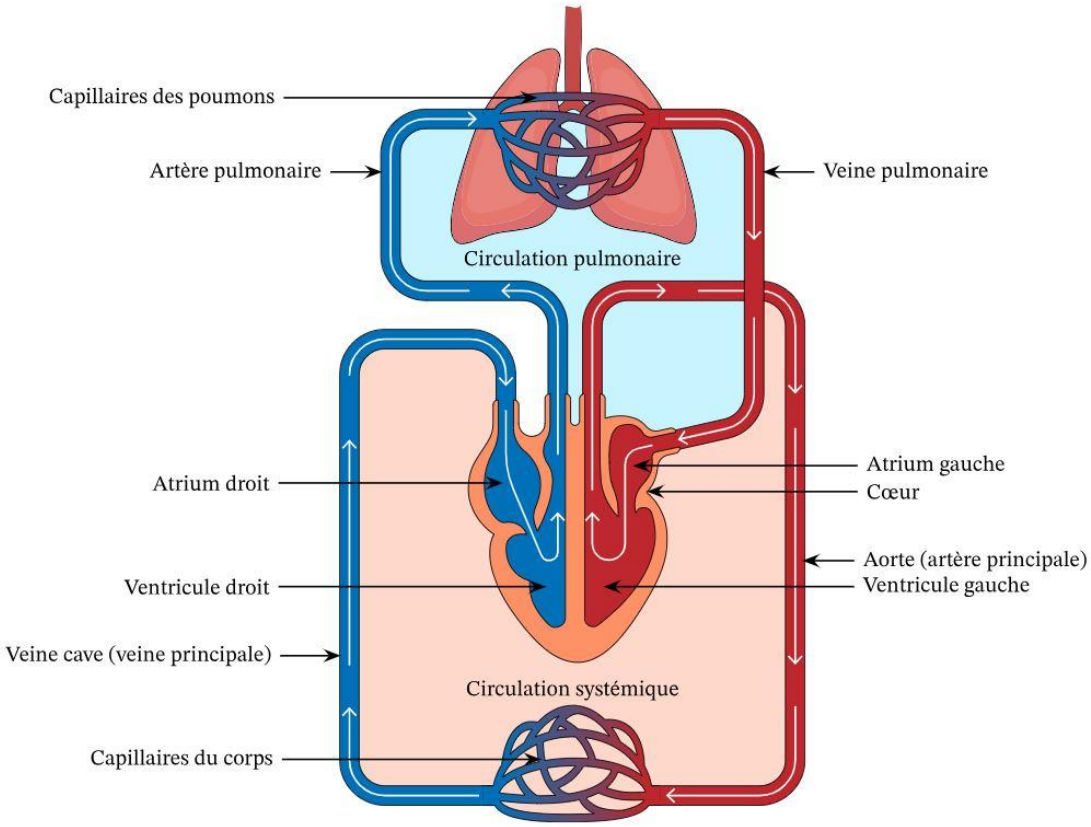

Figure 1.1. La circulation sanguine[1].

Les artères et les veines représentent deux voies distinctes par lesquelles le sang circule, chacune remplissant des fonctions physiologiques uniques qui sont essentielles au maintien de l'homéostasie et au soutien du métabolisme cellulaire. La Figure 1.1 schématise la circulation sanguine ; le sang non oxygéné arrive dans l'oreillette droite du cœur puis dans le ventricule droit et repart vers la circulation pulmonaire (circuit en bleu). Dans les capillaires pulmonaires, le sang s'enrichit en oxygène et revient au cœur, passant par l'oreillette gauche puis le ventricule gauche, avant d'être redistribué pour fournir de l'oxygène à tous les tissus du corps (circuit en rouge). Ensuite, le sang, désormais appauvri en oxygène et chargé en dioxyde de carbone, retourne vers le cœur [4].

1.2.2. Anatomie et fonction du cœur

Le cœur, organe vital du corps humain, est une pompe musculaire chargée de la circulation du sang dans l'ensemble du système circulatoire. Situé légèrement à gauche du centre de la poitrine, il est protégé par la cage thoracique et repose entre les poumons. Le cœur mesure 12 × 8,5 × 6 cm et pèse environ 310 g chez les hommes et environ 255 g chez les femmes. Chaque jour, il bat en moyenne 100 000 fois, pompant environ 7571 litres de sang [5]. Le cœur comprend quatre cavités, les oreillettes gauche et droite, et les ventricules gauche et droit. Chaque cavité joue un rôle important dans le fonctionnement du cœur, en assurant la circulation continue du sang riche en oxygène vers les organes et les tissus.

[1] Source : Nagwa, (n.d.), Schéma de la circulation sanguine, https://www.nagwa.com/fr/explainers/912123271719/.

1.2.2.1. Les quatre chambres cardiaques

Le cœur est composé de tissu musculaire et de tissu nerveux. Il contient quatre cavités. Les oreillettes (atriums) sont entourées par des parois minces faites de tissu musculaire, tandis que les ventricules ont des parois plus épaisses et musclées, qui sont utiles pour leur rôle dans le pompage du sang.

- L'oreillette droite : Elle reçoit le sang désoxygéné de l'ensemble de l'organisme, à l'exception des poumons (circulation systémique), via les veines caves supérieure et inférieure. En outre, le sang désoxygéné provenant du muscle cardiaque lui-même s'écoule dans l'oreillette droite via le sinus coronaire. L'oreillette droite agit donc comme un réservoir pour récupérer le sang désoxygéné. De là, le sang traverse la valve tricuspide pour remplir le ventricule droit, qui est la principale chambre de pompage du cœur droit [6].
- Le ventricule droit : Le sang est pompé à travers la voie de sortie du ventricule droit, à travers la valve pulmonaire et dans l'artère pulmonaire qui le transporte vers les poumons pour l'oxygénation. Dans les poumons, le sang s'oxygène lorsqu'il passe dans les capillaires, où il est suffisamment proche de l'oxygène contenu dans les alvéoles pulmonaires. Ce sang oxygéné est réceptionné par les quatre veines pulmonaires, deux par poumon [6].
- L'oreillette gauche : Suite à l'échange de gaz dans les capillaires des poumons, le sang oxygéné fait son chemin vers l'oreillette gauche grâce à l'une des quatre veines pulmonaires. Le sang circule continuellement des veines pulmonaires vers l'oreillette, qui agit comme une chambre de réception. De là, il passe par un orifice et se dirige vers le ventricule gauche. La valve mitrale s'ouvre pour faire passer le sang depuis l'oreillette gauche dans le ventricule gauche du cœur [7].
- Le ventricule gauche : À travers la valve mitrale, le ventricule gauche se remplit de sang oxygéné. La valve aortique permet au ventricule gauche, qui est la principale chambre de pompage du cœur gauche, d'envoyer le sang oxygéné dans la circulation systémique. Le prochain battement de cœur marquera une nouvelle répétition du cycle cardiaque [6].

La Figure 1.2 représente la structure du cœur humain, illustrant les quatre cavités, les quatre valves et les principaux vaisseaux sanguins qui l'entourent.

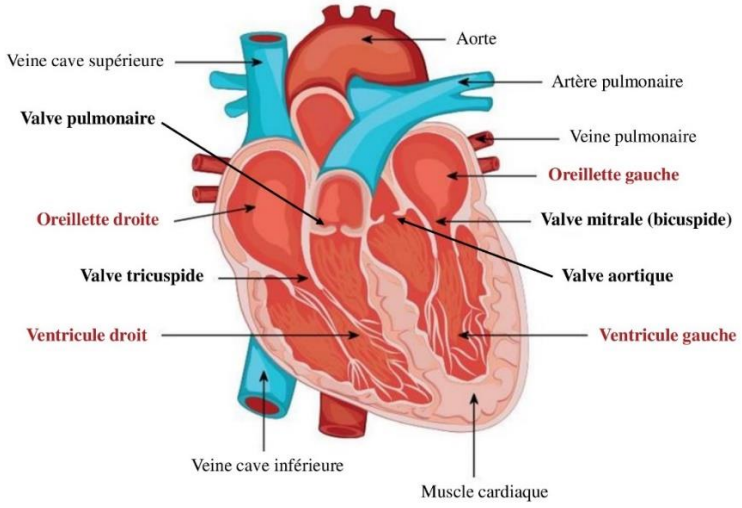

Figure 1.2. La structure du cœur humain.

1.2.2.2. Les valves cardiaques

De chaque côté du cœur, les passages entre les oreillettes et les ventricules sont protégés par des structures appelées valves. Les valves se composent de feuillets faits de tissu conjonctif dense ; elles aident à réguler le flux sanguin dans le cœur. Elles sont illustrées sur la Figure 1.2.

- La valve tricuspide : appelée aussi valve auriculo-ventriculaire droite, régule le flux sanguin entre l'oreillette droite et le ventricule droit. Le sang est transporté de l'oreillette droite vers le ventricule droit à travers l'orifice auriculo-ventriculaire. Quand le ventricule droit se contracte, la valve tricuspide maintient le sang dans le ventricule et l'empêche de refluer vers l'oreillette.
- La valve pulmonaire : Pendant la systole ventriculaire, le sang est pompé du ventricule droit vers le tronc pulmonaire et les artères en direction des poumons. Lorsque le ventricule droit se relâche, en diastole, le sang est empêché de retourner dans le ventricule par la valve pulmonaire.
- La valve mitrale (bicuspide) : Le sang est pompé de l'oreillette gauche au ventricule gauche par l'orifice auriculo-ventriculaire gauche. Lorsque le ventricule gauche se contracte, la valve bicuspide empêche le sang de retourner dans l'oreillette.
- La valve aortique : Elle est située à la base de l'aorte. Pendant la systole ventriculaire, le sang est pompé du ventricule gauche dans l'artère aortique vers tous les tissus de l'organisme. Lorsque le ventricule gauche se relâche en diastole, la valve aortique semi-lunaire empêche le sang de retourner dans le ventricule.

1.2.3. Le système de conduction électrique

Les cavités cardiaques, qui assurent la circulation du sang à travers le cœur, dépendent d'une synchronisation précise pour garantir un pompage efficace. Cette synchronisation est orchestrée par le système de conduction électrique du cœur, qui coordonne les contractions des différentes cavités. Ce système repose sur la capacité unique des cellules musculaires cardiaques à générer un potentiel électrique régulier, qui se propage rapidement de cellule en cellule. Cette propriété, appelée autorythmicité, est essentielle au déclenchement du mécanisme de contraction, permettant ainsi un fonctionnement harmonieux du cœur. La modulation de la fréquence cardiaque est ensuite assurée par les systèmes endocrinien et nerveux, adaptant la fonction cardiaque aux besoins de l'organisme.

1.2.3.1. Les notions de dépolarisation et repolarisation

Le cycle électrique cardiaque repose sur deux processus essentiels : la dépolarisation et la repolarisation des cellules cardiaques.

La **dépolarisation** est l'étape où une impulsion électrique provoque un changement dans la charge électrique des membranes cellulaires, ce qui déclenche la contraction des fibres musculaires cardiaques. Elle correspond à l'entrée d'ions positifs, principalement le sodium (Na^+) et le calcium (Ca^{2+}), dans les cellules du cœur.

La **repolarisation**, en revanche, est le retour à l'état de repos, où la cellule retrouve son potentiel électrique initial après la contraction. Ce processus implique la sortie des ions potassium (K^+), permettant ainsi aux cellules de se préparer pour la prochaine impulsion électrique.

1.2.3.2. Les composants du système de conduction électrique cardiaque

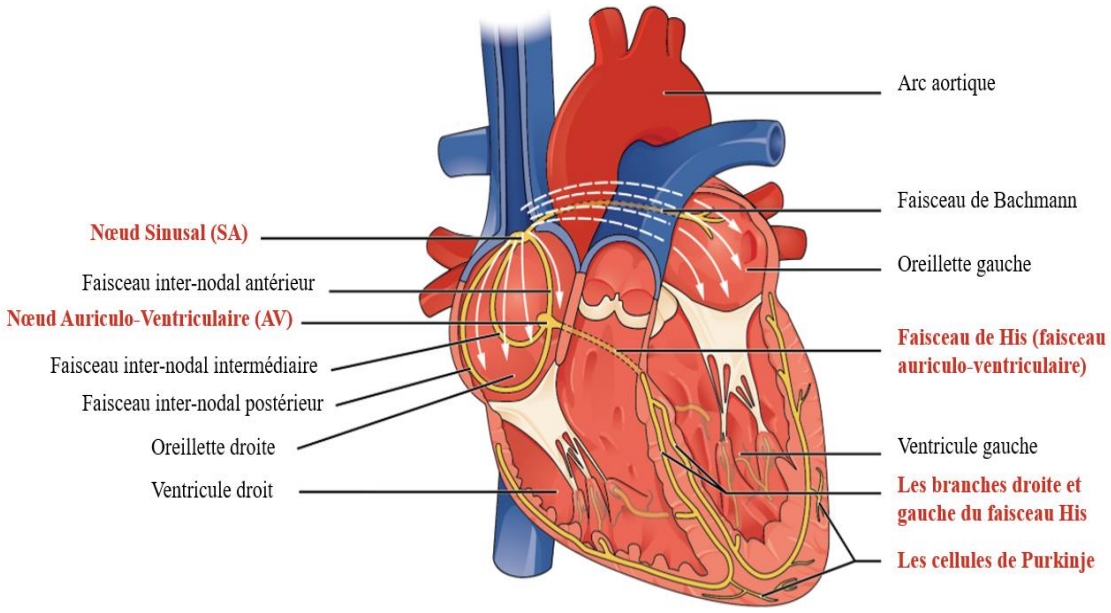

Figure 1.3: Les composants du système de conduction cardiaque[2].

Les composants du système de conduction cardiaque comprennent le nœud sinusal (SA), le nœud auriculo-ventriculaire (AV), le faisceau auriculo-ventriculaire (His), les branches du faisceau auriculo-ventriculaire et les cellules de Purkinje [8, 9]. Ils sont présentés sur la Figure 1.3 :

- Le nœud sinusal (SA) : C'est un groupe de cellules conductrices myocardiques spécialisées, se trouvant dans les parois supérieure et postérieure de l'oreillette droite près de la veine cave supérieure. C'est ce nœud qui établit le rythme cardiaque normal. Il présente le taux de dépolarisation inhérent le plus élevé et est connu sous le nom de pacemaker.
  Depuis son déclenchement dans le nœud sinusal, l'impulsion électrique se propage à travers les oreillettes en utilisant des voies inter-nodales spécialisées provoquant la contraction coordonnée des oreillette droite et gauche, jusqu'aux cellules contractiles du muscle cardiaque auriculaire et au nœud auriculo-ventriculaire. Le système de conduction comprend trois faisceaux, à savoir le faisceau antérieur, intermédiaire et postérieur, reliant directement le nœud SA au nœud AV. Il faut environ 50 ms pour que l'impulsion se propage d'un nœud à l'autre. De plus, il y a également une voie spécifique connue sous le nom de faisceau de Bachmann qui permet la conduction de l'impulsion vers le nœud AV.
- Le nœud auriculo-ventriculaire (AV) : C'est un groupe de cellules conductrices spécialisées qui sont présentes dans le tissu myocardique, il est situé dans la partie inférieure de l'oreillette droite, plus précisément à l'intérieur du septum auriculo-

[2] Source: [Betts et al.], [Anatomy and Physiology], [2nd ed], [2019], p. [774].

ventriculaire. Celui-ci bloque la propagation directe de l'impulsion vers les ventricules avant de passer par le nœud AV. Il faut environ 100 ms pour que l'impulsion traverse le nœud.

Avant que le faisceau auriculo-ventriculaire ne transmette l'impulsion, il y a une pause cruciale durant laquelle le nœud AV se dépolarise. Cette pause est nécessaire au bon fonctionnement du cœur ; elle permet aux cardiomyocytes auriculaires de terminer leur contraction, permettant ainsi au sang d'être pompé dans les ventricules avant que l'impulsion ne se propage aux cellules ventriculaires. Lorsque le nœud SA est fortement stimulé, le nœud AV peut transmettre des impulsions à une fréquence maximale de 220 par minute. Il s'agit de la fréquence cardiaque maximale typique d'un jeune individu en bonne santé.

- Le faisceau de His et ses branches : Le faisceau auriculo-ventriculaire, également connu sous le nom de faisceau de His, émerge du nœud AV et traverse d'abord le septum interventriculaire avant de se séparer en deux branches : la branche droite et la branche gauche du faisceau. Il y a deux fascicules sur la branche gauche. Celle-ci conduit les impulsions vers le ventricule gauche, alors que la branche droite les conduit vers le ventricule droit. Comme le ventricule gauche est considérablement plus large que son homologue droit, il en va de même pour la branche gauche du faisceau qui se révèle nettement plus large que la branche droite. Les muscles papillaires droits reçoivent des impulsions provenant de la branche droite du faisceau, notamment dans la bande modératrice. En raison de cette connexion, chaque muscle papillaire reçoit l'impulsion pratiquement simultanément, ce qui entraîne leur contraction synchronisée juste avant les autres cellules contractiles des ventricules du myocarde. Les deux branches du faisceau descendent jusqu'à l'apex du cœur où elles se raccordent aux fibres de Purkinje. La durée de ce passage est d'environ 25 millisecondes.
- Les cellules de Purkinje : Ce sont des fibres conductrices myocardiques supplémentaires qui ont pour rôle d'assurer la transmission de l'impulsion aux cellules contractiles du myocarde dans les ventricules. Elles se propagent à travers tout le muscle cardiaque, partant de l'extrémité inférieure du cœur et atteignant le septum auriculo-ventriculaire ainsi que la base du cœur. Grâce à leur vitesse de conduction intrinsèquement élevée, les fibres de Purkinje permettent à l'impulsion électrique de se diffuser efficacement à toutes les cellules musculaires ventriculaires en environ 75 millisecondes (ms). Lorsque le stimulus électrique débute à l'apex, la contraction se produit d'abord à cet endroit avant de se propager vers la base du cœur. Cela favorise le pompage du sang des ventricules vers l'aorte et le tronc pulmonaire. Environ 225 ms s'écoulent depuis le début de l'impulsion dans le nœud SA jusqu'à la dépolarisation des ventricules.

Le fonctionnement des composants susmentionnés du système de conduction électrique du cœur peut être résumé comme suit : D'abord, le nœud sinusal génère le potentiel électrique, qui se propage ensuite à travers les oreillettes, cette dépolarisation permet la contraction des oreillettes de manière synchrone, droite et gauche. Une fois le potentiel électrique atteint le nœud auriculo-ventriculaire, il y a un délai d'environ 100 ms pendant lequel les oreillettes terminent de pomper le sang avant que l'impulsion ne passe au faisceau de His.

Une fois ce laps de temps écoulé, l'impulsion se propage à travers le faisceau de His ainsi que les différentes branches du faisceau jusqu'à atteindre les fibres de Purkinje qui conduisent l'onde de dépolarisation aux cellules musculaires des ventricules. De plus, elle parvient également au

muscle papillaire droit grâce à la bande modératrice. Après sa propagation aux fibres contractiles du ventricule, l'impulsion déclenche le début de la contraction simultanée et coordonnée des deux ventricules droit et gauche ; l'onde de dépolarisation atteint en premier les cellules de la pointe des ventricules pour remonter ensuite vers leur base. Cette propagation rétrograde optimise ainsi la contraction ventriculaire, facilitant l'éjection du sang vers les artères principales (aorte et artère pulmonaire). Enfin, les cellules musculaires des ventricules retournent à leur état de repos : c'est la repolarisation ventriculaire. Ce processus est essentiel pour préparer le cœur au prochain cycle électrique.

Le Tableau 1.1 récapitule les vitesses de conduction et les fréquences du pacemaker de diverses structures de la voie de conduction cardiaque. Les structures sont énumérées dans l'ordre d'activation au cours d'une contraction cardiaque normale [10].

Tableau 1.1: Vitesse de conduction et fréquence cardiaque des structures de la voie de conduction cardiaque.

Ordre d'activation normale	Structure cardiaque	Vitesse de conduction (m/s)	Fréquence cardiaque (battements/min)
1	Nœud sinusal (SA)	< 0.01	60 - 100
2	Myocarde auriculaire	1.0 - 1.2	Néant
3	Nœud auriculo-ventriculaire (AV)	0.02 - 0.05	40 - 55
4	Faisceau de His	1.2 – 2.0	25 - 40
5	Les branches de His	2.0 - 4.0	25 - 40
6	Le réseau Purkinje	2.0 - 4.0	25 - 40
7	Myocarde ventriculaire	0.3 - 1.0	Néant

La succession de dépolarisation et de repolarisation repose sur un mécanisme cellulaire plus profond, directement lié à l'activité électrique intrinsèque de chaque cellule cardiaque : le potentiel d'action. Il correspond à l'activité électrique mesurée directement à l'intérieur de la cellule cardiaque. Cette activité est gouvernée par les mouvements transmembranaires d'ions tels que le sodium, le calcium, le potassium et le magnésium, qui jouent un rôle clé dans la génération de l'électricité cardiaque (électro-genèse). Le potentiel d'action est divisé en cinq phases, chacune associée à des mouvements ioniques spécifiques :

- Phase 0 : La phase initiale, ou phase de dépolarisation, est marquée par l'entrée rapide et importante d'ions sodium (Na^+) et calcium (Ca^{2+}), ce qui provoque un changement brusque du potentiel transmembranaire de -90 mV à +30 mV. Cette transition rapide donne lieu à une phase 0 de grande amplitude, pratiquement verticale.
- Phase 1 : La repolarisation commence à cette phase, de manière rapide et avec une faible amplitude, caractérisée par une entrée d'ions chlorure (Cl^-), amorçant le retour vers le potentiel de repos.
- Phase 2 : Pendant cette phase, la poursuite de l'entrée des ions calcium (Ca^{2+}) maintient le potentiel d'action à une valeur relativement stable pour une période prolongée. Cette phase est cruciale pour déterminer la durée totale du potentiel d'action.

- Phase 3 : La pénétration de calcium diminue fortement, tandis qu'une sortie massive et rapide d'ions potassium (K^+) ramène progressivement le potentiel d'action à sa valeur de repos.
- Phase 4 : Enfin, au cours de cette phase, l'activité métabolique de la membrane rétablit l'équilibre ionique initial : les ions sodium (Na^+) qui étaient entrés lors de la phase 0 sont expulsés, tandis que les ions potassium (K^+) retournent dans la cellule, rétablissant ainsi la distribution ionique d'origine, de part et d'autre de la membrane.

La Figure 1.4 illustre les phases de potentiel d'action et la Figure 1.5 montre l'hétérogénéité des potentiels d'action des différentes cellules cardiaques.

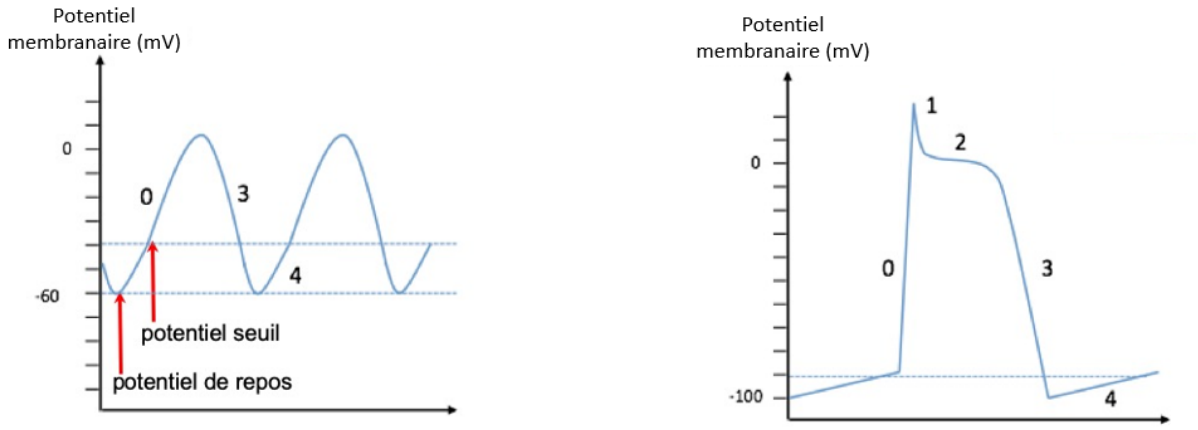

Figure 1.4. Phases de potentiel d'action des oreillettes, ventricules et réseau de conduction His-Purkinje (à gauche). Phases de potentiel d'action du nœud sinusal et du nœud AV (à droite)[3].

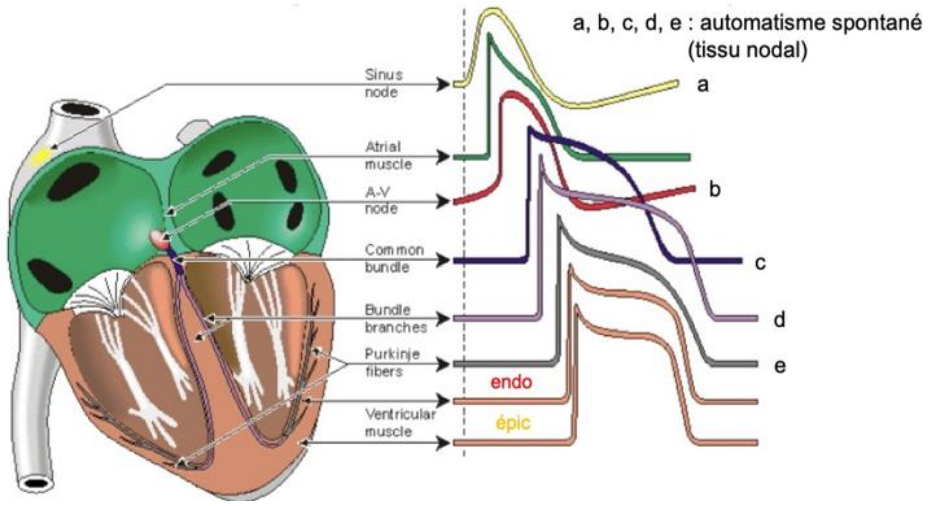

Figure 1.5. Morphologie des potentiels d'action des différentes cellules cardiaques[4].

[3] Source : e-cardiogram, (2024), Potentiels d'action des fibres automatiques, https://www.e-cardiogram.com/potentiel-d-action/.

[4] Source : e-cardiogram, (2024), Activation électrique du cœur, https://www.e-cardiogram.com/potentiel-d-action/.

1.3. L’électrocardiogramme (ECG)

1.3.1. Principe de l’ECG

L'électrocardiogramme (ECG ou EKG) est un tracé spécifique illustrant les variations de l'activité électrique du cœur à chaque instant. Plus précisément, l'ECG offre un graphique temps-tension de l’activité cardiaque. Cet outil permet d’explorer de manière détaillée différentes propriétés cardiaques dont la rythmicité. Il est un outil clinique indispensable. Un tracé ECG bruité est illustré dans la Figure 1.6.

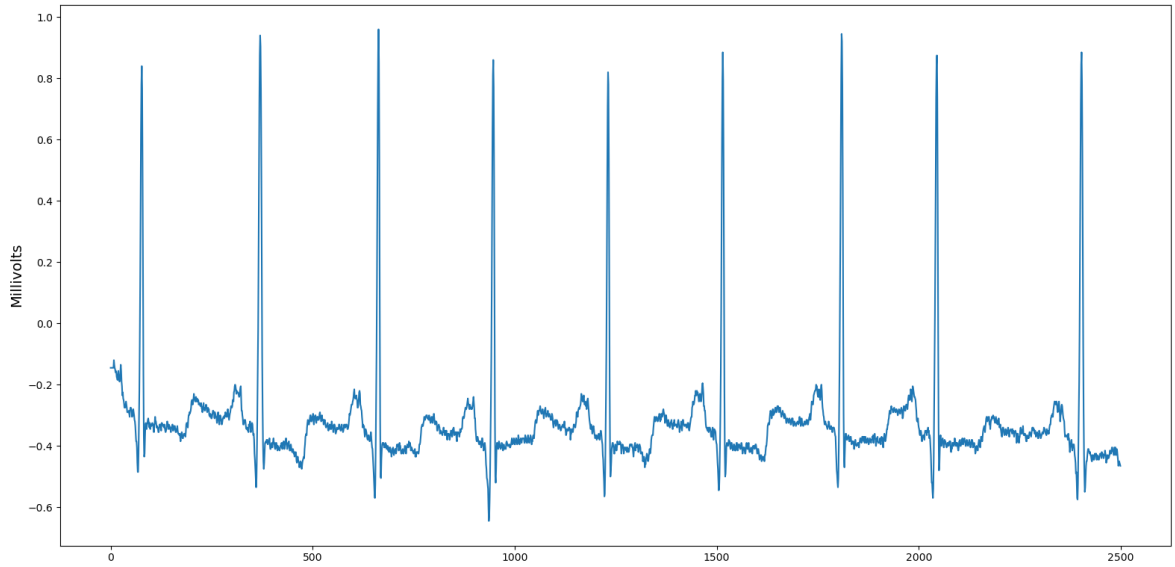

Figure 1.6: Tracé normal d'un enregistrement ECG ambulatoire accessible sur le répertoire Physionet [11], recueilli à l'hôpital Beth Israel de Boston.

1.3.1.1. Acquisition des signaux électriques cardiaques

L'appareil permettant d'obtenir et d'afficher un ECG conventionnel s'appelle l'électrocardiographe. Cet appareil enregistre les courants électriques du cœur (tensions ou potentiels) à l'aide de capteurs, nommés électrodes, placés stratégiquement sur la surface du corps. Pour un enregistrement ECG standard, les électrodes sont positionnées sur les membres inférieurs, les bras et la paroi thoracique (précordium). Un électrocardiographe peut avoir 3, 5 ou 12 dérivations. Plus le nombre de dérivations est élevé, plus l'ECG fournit d'informations détaillées. Le terme "dérivation" désigne un ensemble formé d’électrodes entre lesquelles est mesurée la différence de potentiel électrique.
Les dérivations de l’ECG sont divisées en deux groupes principaux : les six dérivations des membres et les six dérivations thoraciques.

— **Les dérivations des membres (périphériques) :**

Les dérivations des membres, nommées I, II, III, aVR, aVL et aVF, mesurent les différences de tension grâce à des électrodes placées sur les extrémités. Elles se subdivisent en deux catégories : les trois dérivations bipolaires standards (I, II, III), développées par Einthoven, et les trois dérivations unipolaires augmentées (aVR, aVL, aVF), développées par Goldberger.

Les dérivations I, II, III, aVF, aVL et aVR sont obtenues à partir de trois électrodes positionnées sur le bras droit, le bras gauche et la jambe gauche. Ces électrodes forment le triangle d'Einthoven, comme est montré dans la Figure 1.7. En raison de la disposition de ces électrodes par rapport au cœur, ces dérivations enregistrent essentiellement l'activité électrique dans le plan frontal [12].

Conformément à la loi de Kirchhoff, la somme de tous les courants dans un circuit fermé doit être nulle. Étant donné que le triangle d'Einthoven peut être vu comme un circuit, cette règle s'applique également à lui. C'est ainsi que se formule la loi d'Einthoven :

$$Lead\ I\ +\ Lead\ III\ =\ Lead\ II \tag{1.1}$$

Puisque les dérivations de Goldberger utilisent les mêmes électrodes que celles d'Einthoven, il est logique qu'elles soient liées par une relation mathématique. Les équations correspondantes sont les suivantes (1.2-1.4) :

$$aVL: \frac{Lead\ I - Lead\ II}{2} \tag{1.2}$$

$$-aVR: \frac{Lead\ I + Lead\ II}{2} \tag{1.3}$$

$$aVF: \frac{Lead\ II + Lead\ III}{2} \tag{1.4}$$

L'interprétation de l'ECG est améliorée en inversant la dérivation aVR en -aVR. Cette inversion comble le décalage de 30° dans le système de coordonnées et permet un meilleur diagnostic de l'ischémie aiguë et des infarctus.
La Figure 1.7 présente le triangle d'Einthoven et les dérivations des membres.

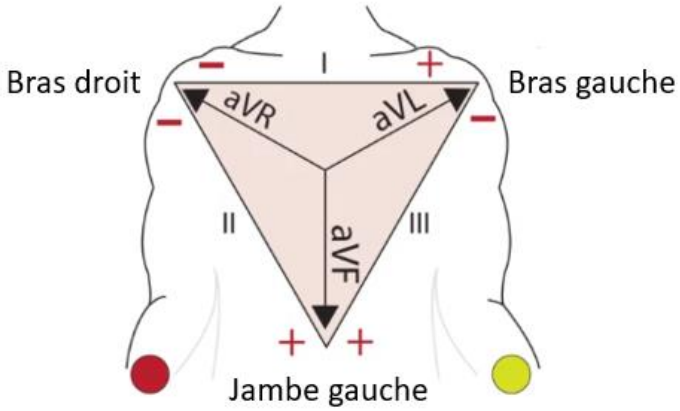

Figure 1.7. L'organisation des dérivations des membres. L'électrode de la jambe droite n'est incluse dans aucune dérivation, mais sert de fil de terre[5].

[5] Source : ECGWaves.com, n.d., Einthoven triangle, https://ecgwaves.com/topic/ekg-ecg-leads-electrodes-systems-limb-chest-precordial/

— Les dérivations thoraciques (précordiales) :

Les dérivations thoraciques, identifiées comme V1, V2, V3, V4, V5 et V6, captent les différences de tension à l'aide de six électrodes positionnées à divers endroits sur la paroi thoracique. En effet, ces dérivations sont obtenues en comparant les potentiels électriques dans le terminal central de Wilson (WCT), qui est un point de référence théorique situé au centre du triangle d'Einthoven, aux potentiels enregistrés par chacune des électrodes placées sur la paroi thoracique [12].

Chaque dérivation thoracique fournit des informations uniques qui ne peuvent pas être obtenues mathématiquement à partir des autres dérivations. La Figure 1.8 présente les dérivations précordiales.

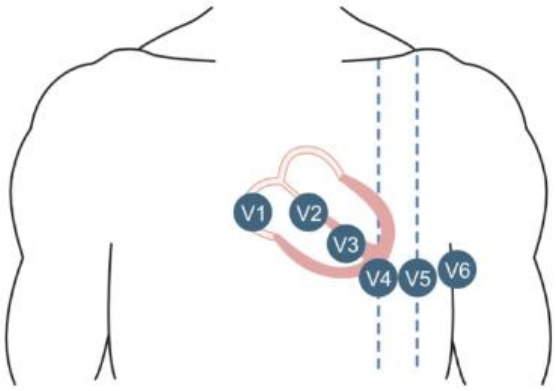

Figure 1.8. Les dérivations précordiales[6].

Par convention, ce sont les combinaisons et le placement des électrodes, définis de manière polaire, qui déterminent l'orientation positive ou négative des déflexions ou ondes enregistrées. Dans le complexe QRS, la première déflexion négative est appelée onde Q, la première déflexion positive est appelée onde R, et la seconde déflexion négative est nommée onde S. Une onde située sur la ligne de base est dite isoélectrique, tandis qu'une onde présentant à la fois des composantes positives et négatives est décrite comme biphasique.

Un électrocardiographe à 12 dérivations utilise 10 électrodes placées à des endroits spécifiques sur la peau du patient. Les 12 dérivations de l'ECG sont tous synchronisées sur les mêmes événements, comprenant le cycle P-QRS-T (Figure 1.11). La Figure 1.9 présente un ECG illustrant les 12 dérivations.

[6] Source : ECGWaves.com, n.d., Chest (precordial) leads, https://ecgwaves.com/topic/ekg-ecg-leads-electrodes-systems-limb-chest-precordial/

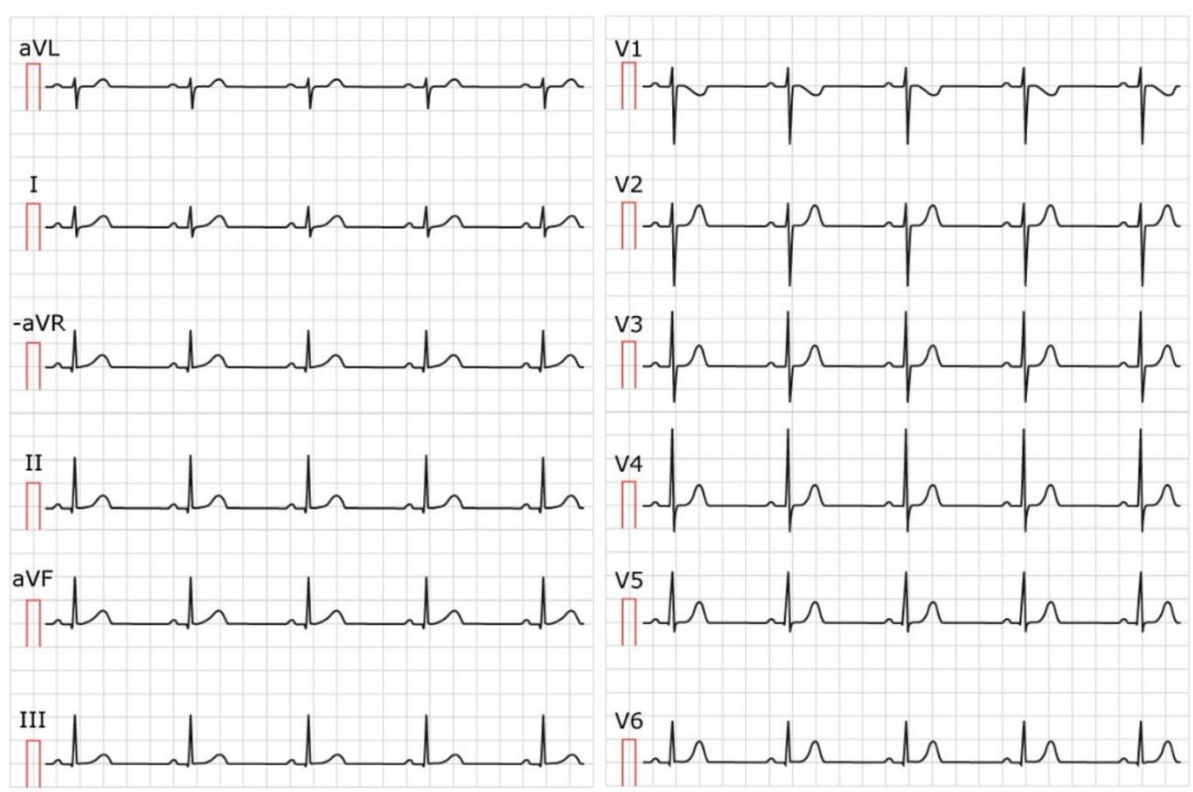

Figure 1.9. Un exemple d'ECG illustrant les 12 dérivations standard : Dérivations périphériques (à droite) et dérivations précordiales (à gauche)[7].

1.3.1.2. Types d'électrocardiographes

Parmi les principaux types d'électrocardiographes permettant l'acquisition de signaux ECG:

- Électrocardiographe à usage clinique : Utilisé dans les hôpitaux et les cliniques, ce dispositif est souvent intégré à d'autres systèmes de surveillance des patients. Il est capable de réaliser des enregistrements ECG sur 12 dérivations, fournissant une image complète de l'activité cardiaque. Cependant, il nécessite un personnel qualifié pour l'installation et l'interprétation des enregistrements.
- Moniteur Holter : ECG portable porté sur le corps pendant 24 à 48 heures pour enregistrer l'activité cardiaque en continu. Il est principalement utilisé pour la surveillance ambulatoire des patients présentant des symptômes cardiaques intermittents ou pour le dépistage des troubles du rythme cardiaque.
- Électrocardiographe d'implantation (Implantable Loop Recorder) : Dispositif miniature implanté sous la peau du patient lors d'une intervention chirurgicale simple. Il permet un enregistrement ECG continu pendant plusieurs mois jusqu'à 3 années. Utilisé pour diagnostiquer des arythmies rares et potentiellement dangereuses.
- Moniteur ECG portable : Dispositif industriel que les patients peuvent porter quotidiennement pour un suivi continu de l'activité cardiaque. Souvent connecté à des applications mobiles pour une analyse en temps réel et la transmission des données à des professionnels de santé.

[7] Source: ECGWaves.com, n.d., Sinus rhythm, https://ecgwaves.com/topic/normal-sinus-rhythm-ecg-criteria-sinoatrial-node/.

- Patchs ECG : Dispositifs adhésifs portables collés sur la peau du patient pour un enregistrement ECG continu. Ils sont discrets et confortables à porter sur de longues périodes.
- Montre ECG connectée : Montre intelligente intégrant des capteurs ECG pour fournir des informations sur la santé cardiaque et des enregistrements ECG de 30s. Bien que moins précis que les dispositifs médicaux, elle peut offrir des indications utiles et encourager un suivi médical en cas de détection d'anomalies.

Les études cliniques et expérimentales ont montré le rôle essentiel de l'ECG dans le diagnostic de plusieurs troubles cardiaques dangereux.

1.3.1.3. Le cycle électrique cardiaque

Chaque composante, segment et intervalle du tracé ECG correspond à des événements électriques importants, démontrant la relation entre ces événements et le système de conduction du cœur.

L'ECG comporte trois éléments principaux : l'onde P, le complexe QRS et l'onde T. Au départ, les oreillettes et les ventricules sont en phase de relaxation (diastole). L'impulsion électrique se déclenche dans le nœud sinusal puis se propage à travers les oreillettes ; l'influx dépolarise d'abord l'oreillette droite, puis l'oreillette gauche. L'onde P indique la dépolarisation complète des oreillettes. Le segment PR décrit le temps qui sépare la fin de la systole (contraction) de l'oreillette gauche du début de la systole électrique ventriculaire. Durant ce temps, les influx traversent le nœud AV, le faisceau de His et ses branches, sans traduction électrique sur l'ECG. Le complexe QRS illustre la dépolarisation des ventricules, suivie par la contraction ventriculaire. Le segment ST qui commence à la fin du complexe QRS et se termine au début de l'onde T, marque le début de la repolarisation ventriculaire. Enfin, l'onde T correspond à la repolarisation complète des ventricules. La fin de l'onde T coïncide avec la relaxation des ventricules (diastole ventriculaire).
La Figure 1.10 illustre les événements du cycle cardiaque et leurs correspondances sur le tracé ECG.

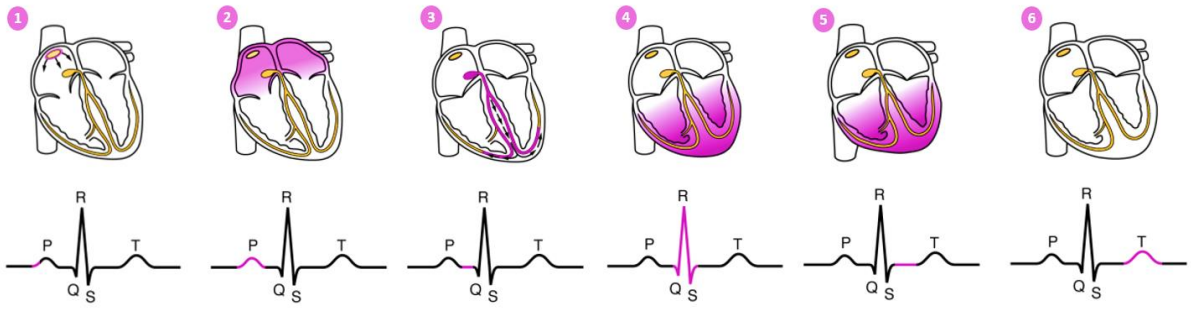

Figure 1.10. Cycle cardiaque et tracé ECG. (1) Début Onde P : Dépolarisation du nœud sinusal (SA). (2) Onde P : Dépolarisation auriculaire complète. (3) Segment PR : L'influx traverse le nœud AV, le faisceau de His et ses branches. (4) Complexe QRS : Dépolarisation ventriculaire. (5) Segment ST : Fin de la dépolarisation et début de la repolarisation ventriculaire. (6) Onde T : Repolarisation ventriculaire.

1.3.1.4. Description des composantes de l’ECG

Chaque phase de l'activité électrique cardiaque produit une onde ou une déflexion spécifique, comme est décrit dans la Figure 1.10. Les principales composantes du cycle électrique cardiaque peuvent être regroupées en formes d'ondes, intervalles et segments, comme le montre la Figure 1.11.

Les ondes et complexes de l’ECG sont regroupés comme suit :

- L’onde P : représente la propagation du stimulus dans les oreillettes (dépolarisation auriculaire).
- Le complexe QRS : représente la propagation du stimulus dans les ventricules (dépolarisation ventriculaire). Ce complexe se compose de plusieurs ondes spécifiques, désignées par Q, R, et S.
- L’onde T : représente le retour du muscle ventriculaire dépolarisé à l'état de repos (repolarisation ventriculaire). Le début du segment ST, à l'endroit où il rejoint le complexe QRS, est appelé le point J.
- L’onde U : une légère déflexion parfois visible juste après l'onde T, représentant la phase finale de la repolarisation ventriculaire, bien que son mécanisme exact reste incertain.

Les intervalles sont les sections de l'ECG qui incluent au moins une onde complète. Quatre intervalles sont régulièrement mesurés :

- L’intervalle RR : l'intervalle entre des complexes QRS consécutifs, mesuré du point R d'un complexe QRS au point R du complexe suivant.
- L’intervalle PR : il reflète le temps nécessaire pour que le stimulus se propage à travers les oreillettes et franchisse la jonction auriculo-ventriculaire (AV). Il est mesuré du début de l'onde P au début du complexe QRS.
- L’intervalle QT : il représente le retour des ventricules stimulés à leur état de repos. Il est mesuré du début de l'onde QRS à la fin de l'onde T.
  Un allongement de cet intervalle peut compliquer la mesure, car l'onde T peut se confondre avec l'onde U. En pratique clinique, il est souvent nécessaire d'ajuster l'intervalle QT en fonction de la fréquence cardiaque, utilisant diverses méthodes de correction d'intervalles QTc, telles que la méthode de Bazett, la méthode de Hodges, la méthode de Fridericia, et celle de Framingham.
- L’intervalle QRS : représente le temps nécessaire pour qu'un stimulus se propage dans les ventricules (dépolarisation ventriculaire). Cet intervalle est identique à l'intervalle RR.

Les segments constituent les parties de l'ECG délimitées par la fin d'une onde et le début d'une autre. Il existe 3 principaux segments :

- Le segment PR : il s'étend de la fin de l'onde P au début du complexe QRS, marquant le début de la repolarisation auriculaire. Il correspond au moment où l'impulsion électrique traverse le nœud AV, période durant laquelle aucune activité électrique n'est visible sur l'ECG. Le segment PR est souvent utilisé comme référence pour la ligne isoélectrique, en particulier en milieu clinique, afin d'évaluer l'élévation ou la dépression du segment ST.

- Le segment ST : il s'étend de la fin du complexe QRS au début de l'onde T suivante, et, avec cette onde, il représente la repolarisation ventriculaire.
- Le segment TP : il s'étend de l'onde T au début de l'onde P suivante, représentant l'état de repos électrique. Ce segment est considéré la ligne isoélectrique la plus précise, notamment lors de l'évaluation de la ligne de base de l'ensemble du tracé ECG. Cela s'explique par le fait qu'il se produit lorsque les oreillettes et les ventricules sont au repos.

Aucune des ondes ou complexes mentionnés ci-dessus ne représente le retour des oreillettes stimulées (dépolarisées) à leur état de repos. En effet, le segment ST auriculaire (STa) et l'onde T auriculaire (Ta) sont généralement invisibles sur l'ECG en raison de leur faible amplitude [13].

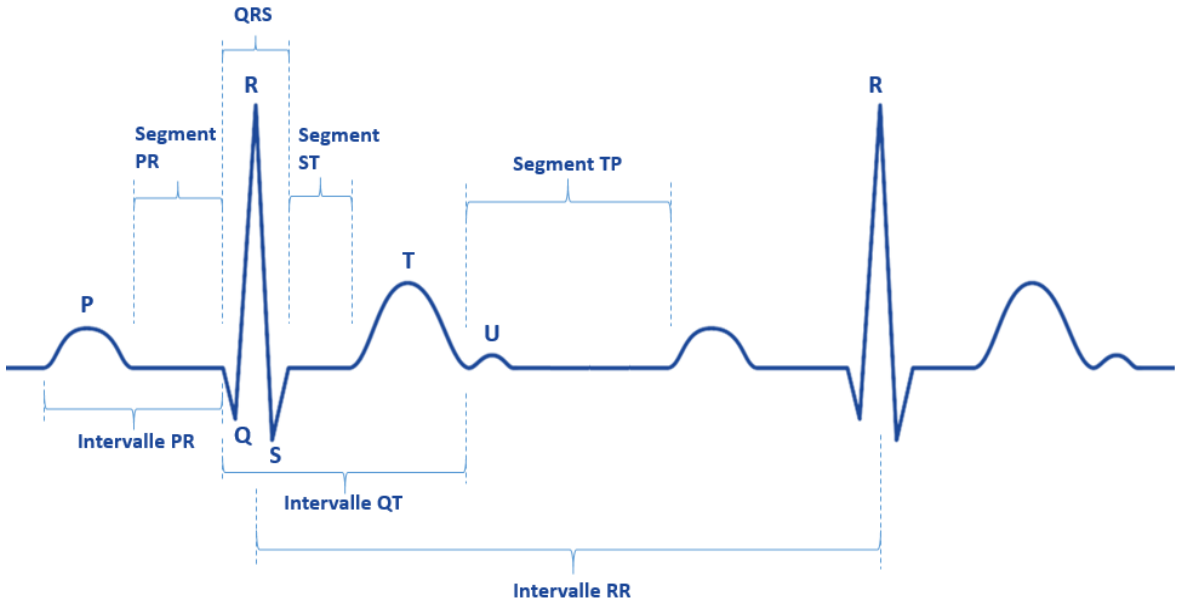

Figure 1.11: Les composantes du cycle électrique cardiaque.

1.3.1.5. Description de l'ECG normal : rythme sinusal normal

Pour comprendre comment une arythmie peut se produire, il est essentiel d'expliquer d'abord l'ECG normal, la physiologie, l'amplitude et la durée de chaque composante.

1.3.1.5.1. Les lois de base de l'électrocardiographie

Pour caractériser un rythme cardiaque normal, il n'est pas nécessaire de mémoriser 12 modèles distincts pour les 12 dérivations de l'ECG. Il suffit de comprendre les principes fondamentaux liés à la synchronisation et à l'orientation des forces de dépolarisation et de repolarisation cardiaques (vecteurs) pour prédire les tracés normaux de l'ECG dans les différentes dérivations.
En réalité, trois lois essentielles de l'électrocardiographie permettent d'expliquer la diversité des apparences des complexes ECG dans les différentes dérivations [15] :

1. Lorsque l'onde de dépolarisation moyenne (globale) se dirige vers le pôle positif d'une dérivation, elle génère une déflexion positive (vers le haut).
2. Lorsqu'elle se dirige vers le pôle négatif (en s'éloignant du pôle positif) d'une dérivation, elle engendre une déflexion négative (vers le bas).
3. Lorsqu'elle se propage perpendiculairement à l'axe d'une dérivation, elle produit une déflexion biphasique.

Ces lois fondamentales s'appliquent aussi bien à l'onde P (dépolarisation auriculaire) qu'au complexe QRS (dépolarisation ventriculaire). Un exemple est illustré sur la Figure 1.12.
En rythme sinusal, une onde P normale apparaît négative (orientée vers le bas) dans la dérivation aVR et positive (orientée vers le haut) dans la dérivation II. Cela s'explique par le fait qu'en cas de dépolarisation auriculaire normale, le vecteur de dépolarisation se dirige vers le bas et vers la gauche du patient, s'éloignant ainsi du pôle positif de la dérivation aVR et se rapprochant du pôle positif de la dérivation II.

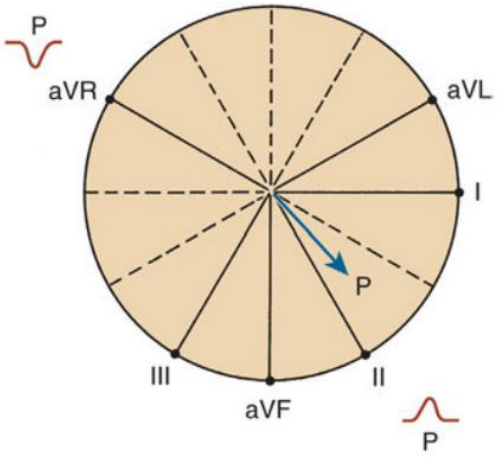

Figure 1.12: Représentation de l'onde P en rythme sinusal normal, montrant les polarités dans les dérivations aVR et II[8].

1.3.1.5.2. Le rythme sinusal normal

Le "rythme sinusal normal" se caractérise par la présence d'une onde P avant chaque complexe QRS et d'un QRS après chaque onde P, ainsi que par un rythme régulier de 60 à 100 battements par minute. D'un point de vue physiologique, cela se traduit par une "conduction AV 1:1" et un intervalle PR normal, ce qui indique qu'à chaque contraction auriculaire correspond une contraction ventriculaire [15]. Le nœud sino-auriculaire (SA) est le stimulateur cardiaque dans des conditions normales.
Nous décrivons ci-dessous l'aspect détaillé des caractéristiques P-QRS-T observées dans l'ECG normal [12, 15].

— **L'onde P** : Sa faible amplitude s'explique par la faible masse musculaire des oreillettes.
- L'onde P est toujours positive dans la dérivation II en rythme sinusal.
- L'onde P peut présenter une seconde bosse proéminente dans les dérivations des membres inférieurs, notamment dans la dérivation II.

[8] Source: [Goldberger et al.], [Goldberger's clinical electrocardiography], [9th ed], [2018], p. [33].

- Elle est presque toujours positive dans les dérivations aVL, aVF, -aVR, I, V4, V5 et V6, et négative dans la dérivation aVR.
- L'onde P est souvent biphasique dans la dérivation V1 (parfois dans V2), avec une déflexion négative généralement inférieure à 0.1 mV.
- Dans les dérivations précordiales, l'amplitude de l'onde P doit être inférieure à 0.15 mV.
- L'amplitude de l'onde P doit être inférieure à 0.25 mV dans les dérivations des membres.
- La durée de l'onde P ne doit pas dépasser 0,12 seconde.

— **L'intervalle PR** : Il est évalué pour déterminer si la conduction de l'impulsion entre les oreillettes et les ventricules est normale.
- L'intervalle PR ne doit être ni trop long, ni trop court, ni dépassé.
- Un intervalle PR normal se situe entre 0,12 seconde et 0,20 seconde.

— **Le Complexe QRS** : Il se compose d'une onde Q, d'une onde R et d'une onde S. Certaines dérivations de l'ECG peuvent montrer toutes les ondes du complexe, tandis que d'autres n'en montrent qu'une seule.
Le complexe QRS peut être qualifié de positif net ou négatif net, en fonction de sa direction globale. On considère qu'un complexe QRS est positif net si la somme des zones positives (au-dessus de la ligne de base) est supérieure à celle des zones négatives (au-dessous de la ligne de base).
- La durée du complexe QRS est généralement inférieure à 0,12 seconde (habituellement entre 0,06 et 0,10 seconde).
- De petites ondes Q septales peuvent être observées dans les dérivations I, aVL, V5 et V6, avec une durée inférieure ou égale à 0,04 seconde et une amplitude inférieure à un tiers de celle de l'onde R dans la même dérivation.
- Le complexe QRS est représenté par une déflexion positive avec une onde R large et droite dans les dérivations I, II, et V4 à V6, et une déflexion négative avec une onde S large et profonde dans les dérivations aVR, V1, et V2.
- Le complexe QRS est globalement positif dans les dérivations I et II
- On détaille ci-dessous les propriétés de chaque onde du complexe QRS.

— **L'onde Q** : Elle reflète la dépolarisation normale du septum interventriculaire, de gauche à droite.
- De petites ondes Q sont normales dans la plupart des dérivations.
- Des ondes Q plus profondes (>0.2 mV) peuvent être observées dans les dérivations III et aVR, considérées comme une variante normale.
- La durée de l'onde Q peut aller jusqu'à 40 ms dans les dérivations autres que III et aVR.
- L'amplitude est généralement inférieure à 0,2 mV, bien qu'elle puisse atteindre 0,3 mV ou même 0,4 mV.

— **L'onde R** : Elle représente la dépolarisation de la masse principale des ventricules. La progression normale de l'onde R se traduit par une augmentation progressive de son amplitude de la dérivation V1 à V5, suivie d'une diminution de V5 à V6.
- L'amplitude de l'onde R doit être inférieure à 2.6 mV dans les dérivations V5 et V6.
- L'amplitude de l'onde R dans la dérivation aVL ne doit pas dépasser 1.2 mV.

- L'amplitude de l'onde R dans les dérivations I, II et III doit être inférieure ou égale à 2 mV.
- L'intervalle RR doit être compris entre 0,6 et 1,2 seconde.

— **L'onde S** : Elle reflète la dépolarisation finale des ventricules.
- L'onde S est la plus profonde dans les dérivations précordiales droites. Elle est souvent absente dans les dérivations V5 et V6.
- La profondeur de l'onde S ne doit pas dépasser 3 mV chez un individu normal.

— **Le segment ST** : Représente la phase initiale de la repolarisation ventriculaire.
- Le segment ST est isoélectrique, bien qu'une légère élévation ou dépression (généralement inférieure à 0.1 mV) puisse être observée normalement.
- La transition entre le segment ST et l'onde T doit être progressive, sans être brusque.

— **L'onde T** : Représente la repolarisation ventriculaire. L'onde T normale est asymétrique, la première moitié ayant une pente plus graduelle que la seconde. Elle doit être aussi concordante avec le complexe QRS, ce qui signifie qu'un complexe QRS positif net doit être suivi d'une onde T positive, et vice versa.
- Dans les dérivations I, II, -aVR, V5 et V6, l'onde T doit t être positive chez les adultes.
- Dans les dérivations III et aVL, l'onde T peut être inversée.
- Dans la dérivation aVF, l'onde T est généralement positive mais peut parfois être plate.
- Dans V1, une onde T inversée ou plate est relativement fréquente, notamment chez les femmes.
- Une onde T positive apparait sur les dérivations V7 à V9.
- L'amplitude de l'onde T est la plus élevée dans V2 et V3 pour les dérivations précordiales, et dans la dérivation II pour les dérivations des membres.
- L'amplitude de l'onde T doit être inférieure à 0.5 mV dans les dérivations des membres et à moins de 1 mV dans les dérivations précordiales.

— **L'onde U** : Elle résulte de la repolarisation des cellules de Purkinje.
- L'onde U est généralement orientée dans la même direction que l'onde T.
- Elle est plus prononcée dans les dérivations V2 à V4.
- La hauteur de l'onde U est généralement équivalente à un quart de celle de l'onde T, avec une première moitié plus raide que la seconde.
- L'amplitude maximale normale de l'onde U est de 0.1 à 0.2 mV.

— **L'intervalle QT** : Il représente le temps total nécessaire à la dépolarisation et à la repolarisation des ventricules.
- L'intervalle QT doit être mesuré dans les dérivations II ou V5-V6.
- L'intervalle QT doit être compris entre 0,35 et 0,45 seconde et ne doit pas dépasser la moitié de l'intervalle RR.

— **L'intervalle QT corrigé** : La durée de l'intervalle QT est inversement proportionnelle à la fréquence cardiaque : elle augmente lorsque la fréquence cardiaque est faible et vice versa.

La formule de Bazett est la plus couramment utilisée en raison de sa simplicité. Bien qu'elle tende à sur-corriger pour les fréquences cardiaques supérieures à 100 bpm et

sous-corriger pour celles inférieures à 60 bpm, elle offre une correction adéquate pour les fréquences cardiaques comprises entre 60 et 100 bpm. Pour les fréquences cardiaques en dehors de cette plage, les corrections selon les méthodes de Fredericia ou de Framingham sont plus précises et devraient être privilégiées.
Par conséquent, la durée de l'intervalle QTc doit être inférieure à 0,45 seconde chez les hommes et 0,470 seconde chez les femmes.

Les Tableaux 1.2 et 1.3 synthétisent respectivement les amplitudes et les durées des caractéristiques de l'ECG normal de la dérivation II.

Tableau 1.2: Valeurs normales (amplitudes) de l'ECG pour le rythme sinusal.

Composante ECG	Valeur normale (amplitude)	Tolérance
Onde P	0.15 mV	±0.05 mV
Complexe QRS	1.5 mV	±0.5 mV
Segment ST	0 mV	±0.1 mV
Onde T	0.3 mV	±0.2 mV
Onde U	0.15 mV	±0.05 mV

Tableau 1.3: Valeurs normales (durées) de l'ECG pour le rythme sinusal.

Composante ECG	Valeur normale (durée)	Tolérance
Onde P	100 ms	±20 ms
Complexe QRS	80 ms	±20 ms
Intervalle PR	160 ms	±40 ms
Intervalle QT	400 ms	±50 ms
Intervalle RR	900 ms	±300 ms
Segment ST	100 ms	±20 ms

L'ECG est un outil de diagnostic puissant, mais l'interprétation des tracés est soumise à l'influence de nombreux facteurs, tels que la configuration des dérivations, la fréquence cardiaque, les schémas respiratoires, les médicaments, le sexe, les maladies et l'activité du système nerveux autonome. Ces facteurs peuvent modifier l'amplitude, la durée et la morphologie des ondes de l'ECG, rendant leur prise en compte indispensable lors de l'évaluation de la santé cardiaque d'un patient.

1.3.2. La fréquence cardiaque

Dans la partie précédente, nous avons exposé les différents événements du cycle cardiaque, leurs significations et les formes leur correspondants sur le tracé ECG. Dans cette partie, nous définissons la fréquence cardiaque et présentons quelques méthodes d'étude de la variabilité de la fréquence cardiaque (VFC), puisque les mesures de VFC permettent d'identifier des battements irréguliers qui échappent aux normes de la variabilité normale, pointant ainsi vers des arythmies potentielles.

1.3.2.1. Définition de la fréquence cardiaque

La fréquence cardiaque désigne le nombre de battements du cœur par minute et se mesure en bpm (battements par minute). Elle est contrôlée par les deux branches du système nerveux autonome (SNA). Le système nerveux sympathique (SNS) et le système nerveux parasympathique (SNP). Les hormones (catécholamines - adrénaline et noradrénaline) libérées

par le système nerveux sympathique augmentent la fréquence cardiaque, tandis que l'hormone acétylcholine libérée par le système nerveux parasympathique diminue celle-ci.
Chez un adulte en bonne santé et au repos, la fréquence cardiaque varie entre 60 et 100 battements par minute. La tachycardie désigne une fréquence cardiaque supérieure à 100 bpm, tandis que la bradycardie correspond à une fréquence inférieure à 60 bpm.
La fréquence cardiaque peut être mesurée manuellement en comptant le nombre de pulsations à un point artériel comme le poignet, le côté du cou, l'arrière des genoux, le dessus du pied ou encore à l'aine.
La fréquence cardiaque est inversement liée à l'intervalle RR, qui correspond à la distance entre deux complexes QRS successifs. Cet intervalle est essentiel pour évaluer la fréquence cardiaque et la variabilité (VFC) de celle-ci. L'Equation 1.9 mesure la fréquence cardiaque instantanée.

$$Fréquence\ Cardiaque\ Instantanée\ (bpm) = \frac{60}{Intervalle\ RR\ (en\ secondes)} \qquad (1.5)$$

La fréquence cardiaque moyenne est calculée sur une période spécifique (par exemple, 10 secondes ou une minute). Pour ce faire, on calcule la moyenne des fréquences cardiaques instantanées selon l'Equation 1.10 :

$$Fréquence\ cardiaque\ (bpm) = \frac{1}{n}\sum_{i=1}^{n} HR_i \qquad (1.6)$$

- n est le nombre total des fréquences cardiaque instantanés.
- HR_i est la fréquence cardiaque instantanée à l'intervalle i.

1.3.2.2. Variabilité de la fréquence cardiaque

La variabilité de la fréquence cardiaque VFC (ou HRV, Heart Rate Variability) mesure les variations dans les intervalles de temps entre les battements cardiaques. Elle reflète la capacité du système nerveux autonome (SNA) à moduler les réponses cardiovasculaires en fonction des besoins physiologiques. L'évaluation de la HRV repose généralement sur l'analyse des intervalles RR, qui correspondent aux intervalles de temps entre les pics R sur un électrocardiogramme, chaque pic représentant un cycle cardiaque complet.

Les méthodes de calcul de la variabilité de la fréquence cardiaque (HRV) peuvent être globalement classées en trois catégories : les méthodes temporelles (statistiques et géométriques), les méthodes fréquentielles et les méthodes non linéaires. Le Tableau 1.4 rassemble quelques méthodes de calcul du HRV les plus utilisées [16, 17] :

- Les méthodes temporelles se concentrent sur l'analyse des variations des intervalles de temps entre les battements cardiaques successifs, appelés intervalles NN (Normal-to-Normal) ou RR lorsqu'ils concernent deux battements cardiaques normaux consécutifs. Ces méthodes, simples à calculer, fournissent des informations sur la variabilité globale et à court terme de la fréquence cardiaque. Parmi les variables temporelles couramment calculées, on trouve l'intervalle NN moyen, la fréquence cardiaque moyenne, ainsi que la différence entre l'intervalle NN le plus long et le plus court.

- Les méthodes fréquentielles permettent d'analyser la répartition de la puissance des signaux de variabilité de la fréquence cardiaque au sein de différentes bandes de fréquence. En décomposant la série temporelle des intervalles RR en composantes fréquentielles, ces méthodes offrent une évaluation précise de l'activité du système nerveux autonome (SNA), en particulier de l'équilibre entre les influences sympathique et parasympathique.
- Les méthodes non linéaires cherchent à saisir la complexité et la dynamique non linéaire de la fréquence cardiaque, aspects qui ne sont pas toujours bien capturés par les méthodes temporelles ou fréquentielles. Ces techniques sont particulièrement avantageuses pour identifier des comportements complexes du système nerveux autonome qui peuvent échapper aux méthodes linéaires traditionnelles.

Tableau 1.4: Quelques mesures de la variabilité de la fréquence cardiaque en domaine temporel, fréquentiel et non linéaire.

Méthode	Type d'analyse	Formule/Description
SDNN (Standard Deviation of NN Intervals)	Temporelle (statistique)	$SDNN = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(RR_i - \overline{RR})^2}$ Où RR_i est l'intervalle RR, et $\overline{RR}$ est la moyenne des RR.
RMSSD (Root Mean Square of Successive Differences)	Temporelle (statistique)	$RMSSD = \sqrt{\frac{1}{N-1}\sum_{i=1}^{N-1}(RR_{i+1} - RR_i)^2}$ Où RR_{i+1} et RR_i sont les intervalles RR successifs.
PNN50 (Percentage of NN50)	Temporelle (statistique)	$PNN50 = \frac{Nombre\ de\ pairs\ d'intervalles\ RR\ successifs > 50}{N-1} \times 100$
LF (Low Frequency) Power	Fréquentielle	Puissance spectrale dans la bande 0.04-0.15 Hz.
VLF (Very Low Frequency) Power	Fréquentielle	Puissance spectrale <0.04 Hz.
HF (High Frequency) Power	Fréquentielle	Puissance spectrale dans la bande 0.15-0.4 Hz.
LF/HF Ratio	Fréquentielle	Rapport entre les puissances LF et HF.
Total Power	Fréquentielle	Somme des puissances dans toutes les bandes de fréquences (LF, HF, VLF).
Poincaré Plot	Non-linéaire	Représentation graphique des intervalles RR successifs avec des paramètres comme SD1 (dispersion transverse) et SD2 (longitudinale).
Sample Entropy (SampEn)	Non-linéaire	Mesure de la complexité et de l'imprévisibilité des intervalles RR.
Approximate Entropy (ApEn)	Non-linéaire	Mesure similaire à SampEn, mais moins robuste pour les séries temporelles courtes.
HRV Triangular Index	Temporelle (géométrique)	$HRV\ index = \frac{Nombre\ total\ des\ intervalles\ RR}{Hauteur\ de\ l'histogramme\ de\ tous\ les\ intervalles\ R}$

TINN (Triangular Interpolation of NN intervals)	Temporelle (géométrique)	La largeur de la ligne de base de l'histogramme des intervalles RR.

1.4. Pathologies cardiaques : les arhythmies

Dans la section précédente, nous avons présenté et détaillé les composants de l'ECG, un outil essentiel pour diagnostiquer les perturbations électriques cardiaques pouvant conduire à des arythmies potentiellement délétères.
Dans cette section, nous expliquons les mécanismes responsables au déclenchement des arythmies cardiaques.

1.4.1. Définition de l'arythmie

Selon l'American Heart Association [18], l'arythmie se définit comme un trouble du rythme cardiaque caractérisé par des battements irréguliers, trop rapides ou trop lents. Elle correspond à un rythme cardiaque non sinusal (non normal). Les arythmies peuvent être bénignes, mais elles peuvent également signaler des affections plus graves nécessitant une prise en charge médicale adaptée.

1.4.2. Les mécanismes de déclenchement des arythmies cardiaques

Les arythmies cardiaques sont dues à des anomalies de la génération ou/et de la conduction des impulsions électriques au sein du cœur :

- Les anomalies de la génération sont à l'origine de foyers d'activation anormaux (autres que le nœud sinusal) qui peuvent être en rapport soit avec une automaticité anormale, soit avec une activité déclenchée par des post-dépolarisations.
- Les anomalies de la conduction constituent le substrat pour les phénomènes de réentrée.

1.4.2.1. Automaticité anormale

L'automaticité est la propriété physiologique qui permet aux cellules cardiaques de se dépolariser spontanément jusqu'à atteindre un seuil où un potentiel d'action est déclenché.
D'abord, présentons les structures cardiaques possédant la propriété d'automaticité [12] :

- Nœud sinusal (SA) : C'est le principal pacemaker du cœur, responsable de l'initiation du rythme cardiaque normal, appelé rythme sinusal.
- Certaines régions du myocarde auriculaire : Des amas de cellules myocardiques situées autour de la crête terminale (crista terminalis), à l'entrée du sinus coronaire, près de la veine cave inférieure, ainsi qu'autour des valves mitrale et tricuspide, possèdent également une automaticité.
- Myocarde entourant le nœud auriculo-ventriculaire (AV) : Les cellules entourant le nœud AV sont pourvues d'automaticité. Par commodité, cette automaticité est attribuée au nœud AV.
- Réseau de His-Purkinje : Le faisceau de His et le réseau de fibres de Purkinje possèdent également une automaticité.

Le rythme cardiaque est régulé par le pacemaker principal, le nœud sino-auriculaire, car ce dernier se dépolarise plus rapidement que les autres stimulateurs cardiaques, et entraîne ainsi leur activité en les réinitialisant avant qu'ils n'émettent un potentiel d'action spontanément.
Ainsi, une **automaticité anormale** se manifeste lorsque le nœud sino-auriculaire (SA) devient dysfonctionnel et cesse de se dépolariser spontanément, et donc l'un des autres stimulateurs cardiaques prend le relais pour entraîner le cycle cardiaque électrique. Ces autres stimulateurs cardiaques sont souvent appelés stimulateurs latents. Dans ce contexte, tout rythme qui remplace le rythme sinusal est qualifié de rythme d'échappement. Si le nœud sinusal ne fonctionne pas correctement, le rythme d'échappement proviendra généralement de l'une des cellules du myocarde auriculaire, qui possède la deuxième fréquence de dépolarisation spontanée la plus élevé (Voir Tableau 1.1 : Les fréquences de dépolarisations des structures cardiaques). En l'absence d'activité dans le myocarde auriculaire, le rythme d'échappement sera probablement généré par les cellules situées autour du nœud auriculo-ventriculaire, et ainsi de suite.

1.4.2.2. Activité déclenchée par des post-dépolarisations

Un potentiel d'action peut entraîner une **post-dépolarisation**, c'est-à-dire une dépolarisation qui se produit pendant ou après la phase de repolarisation. Les post-dépolarisations se classifient en deux catégories :

- Dépolarisation précoce : Elle survient pendant la phase de repolarisation.
- Dépolarisation tardive : Elle se produit après la phase de repolarisation.

Ces post-dépolarisations peuvent être suffisamment intenses pour atteindre le seuil nécessaire à l'initiation d'un nouveau potentiel d'action, ce qui les rend capables de déclencher des potentiels d'action supplémentaires. Lorsqu'un potentiel d'action est généré par une post-dépolarisation, il est qualifié de potentiel d'action déclenché. Ces potentiels d'action peuvent provoquer des extrasystoles, c'est-à-dire des battements cardiaques supplémentaires entre les battements normaux.
Les dépolarisations précoces sont souvent observées dans les contextes suivants : bradycardie, hypokaliémie, hypoxie, acidose, hypocalcémie, effets secondaires de certains médicaments.
Les dépolarisations tardives peuvent se manifester en cas de surdosage de digoxine ou stimulation sympathique excessive par exemple.

Bien que les post-dépolarisations puissent engendrer des extrasystoles, elles ne provoquent généralement pas d'arythmies persistantes. Cependant, ces extrasystoles peuvent induire d'autres mécanismes arythmiques, tels que la réentrée, qui peuvent conduire à des arythmies persistantes [12].

1.4.2.3. Conduction anormale de l'impulsion : réentrée

La réentrée se caractérise par une impulsion, qu'elle soit d'origine sinusale ou ectopique (en dehors du nœud sinusal), qui ne s'éteint pas après avoir activé le cœur en totalité. Elle persiste en raison de la présence d'une conduction très lente, permettant de réactiver le cœur une fois qu'il est sorti de sa période réfractaire.
La réentrée se produit lorsque l'impulsion de dépolarisation rencontre une région où elle est bloquée et ne peut passer que d'un seul côté. L'impulsion contourne alors l'obstacle, tourne autour de la zone bloquée, et revient sur elle-même. Si la zone bloquée redevient excitable au

moment où l'impulsion y arrive, celle-ci la traversera et continuera son mouvement circulaire. Tant que l'impulsion rencontre du tissu excitable, elle maintiendra ce cycle de réentrée. Ce mouvement de cirque est généralement très rapide, envoyant des impulsions dépolarisantes au myocarde environnant à un rythme élevé, ce qui peut entraîner des arythmies sévères [12].
La Figure 1.13 illustre le mécanisme de réentrée.

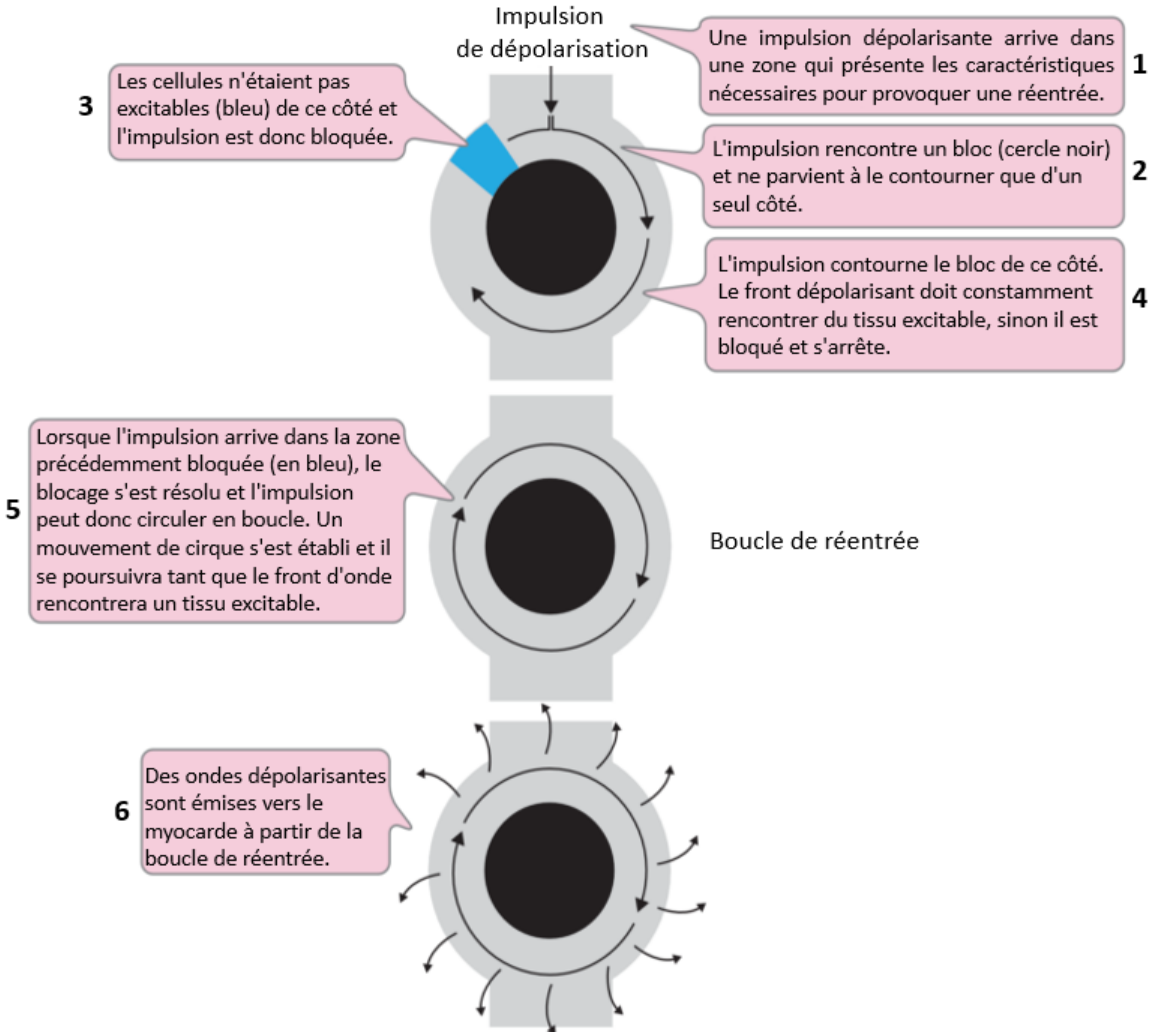

Figure 1.13. Mécanisme de réentrée[9].

1.4.3. Les types d'arythmies cardiaques

Les arythmies cardiaques peuvent être classées en quatre grandes catégories :

- Bradyarythmies (bradycardie) : Les bradyarythmies sont des troubles du rythme cardiaque caractérisés par une fréquence cardiaque anormalement lente, généralement inférieure à 60 battements par minute. Cela peut être causé par un dysfonctionnement du nœud sinusal, une défaillance de la conduction de l'influx électrique dans le cœur, ou

[9] Figure adaptée. Source: ECGWaves.com, n.d., Emergency of re-entry, https://ecgwaves.com/topic/mechanisms-cardiac-arrhythmias-automaticity-reentry-triggered-activity/

des blocages auriculo-ventriculaires. La bradycardie peut entraîner des symptômes tels que la fatigue, les étourdissements, et peut parfois nécessiter un stimulateur cardiaque si elle est sévère.

- Tachyarythmies supraventriculaires : Elles se caractérisent par une fréquence cardiaque généralement supérieure à 100 battements par minute. Elles prennent naissance au-dessus de la bifurcation du faisceau de His et qui nécessitent l'implication de l'oreillette, du nœud auriculo-ventriculaire (AV), ou des deux, pour leur initiation ou leur persistance. Ces arythmies peuvent être sporadiques ou persistantes et entraîner des palpitations, des essoufflements, voire des syncopes.
- Tachyarythmies ventriculaires : Elles se caractérisent par une fréquence cardiaque généralement supérieure à 100 battements par minute. L'origine de ce type d'arythmie est située en dessous de la bifurcation du faisceau de His (branches du faisceau de His, fibres de Purkinje, myocarde).
- Complexes prématurés : Ils sont des battements cardiaques survenant de manière anticipée, avant le prochain battement prévu dans le rythme normal du cœur. Ils peuvent provenir soit des oreillettes soit des ventricules. Bien que souvent bénins et asymptomatiques, un nombre élevé de complexes prématurés peut signaler un risque accru d'autres types d'arythmies plus graves.

1.4.3.1. Les bradyarythmies

Elles peuvent être subdivisées en sous-catégories, présentées dans le Tableau 1.5 [18, 19, 20].

Tableau 1.5: Les sous-catégories des bradyarythmies.

Type d'Arythmie	Description	Caractéristiques ECG
Bradycardie sinusale	Rythme cardiaque plus lent que la normale, émanant du nœud sinusal.	Onde P normale avant chaque complexe QRS. Intervalle PR dans les limites normales (120-200 ms). Complexe QRS généralement étroit.
Dysfonctionnement du nœud sinusal	Fonctionnement anormal du nœud sinusal, aussi appelé syndrome du sinus malade.	Variabilité des intervalles P-P. Possibilité de pauses ou de battements interrompus sans allongement préalable du PR. Pauses sinusales suivies d'un rythme d'échappement jonctionnel ou ventriculaire.
Bloc auriculo-ventriculaire	**Bloc AV du premier degré** : retard de conduction entre l'oreillette droite et les ventricules, sans obstruction des impulsions atriales les empêchant d'atteindre les ventricules. Ce retard est associé à une prolongation de la conduction au niveau du nœud auriculo-ventriculaire (AV)	Intervalle PR prolongé (>200 ms). Chaque onde P est suivie d'un complexe QRS.
	Bloc AV du second degré : Interruption de la conduction AV après certaines impulsions atriales. On distingue entre deux types du bloc AV 2° :	

	Mobitz Type I (Wenckebach) : Ce bloc est généralement localisé au niveau intranodal et tend à s'aggraver progressivement.	Allongement progressif de l'intervalle PR. Absence intermittente d'un complexe QRS après une onde P, ce qui marque une pause.
	Mobitz Type II : Ce bloc est généralement localisé dans le tronc du faisceau de His ou dans ses branches, et il peut évoluer de manière soudaine vers un bloc AV de troisième degré.	Intervalles PR constants. Certains complexes QRS sont manquants, les ondes P ne sont pas toujours suivies de complexes QRS.
	Bloc AV du troisième degré (bloc cardiaque complet) : Pas d'impulsions des oreillettes transmises aux ventricules. La lésion responsable du blocage est située soit dans le nœud AV, dans les branches ou plus rarement dans le tronc du faisceau de His.	Pas d'association entre les ondes P et les complexes QRS ; les oreillettes et les ventricules battent indépendamment, souvent avec un rythme d'échappement ventriculaire lent.

1.4.3.2. Les tachyarythmies supraventriculaires

Les tachyarythmies supraventriculaires peuvent être régulières ou irrégulières. La fibrillation auriculaire est la plus fréquente. Le Tableau 1.6 présente quelques types de tachyarythmies supraventriculaires [18, 19, 20].

Tableau 1.6: Les sous-catégories des tachyarythmies supraventriculaires.

Type d'Arythmie	Description	Caractéristiques ECG
Fibrillation auriculaire (FA)	Caractérisée par un battement rapide et irrégulier des oreillettes, la fibrillation auriculaire est la tachycardie supraventriculaire la plus fréquente. Elle peut se présenter sous trois formes : paroxystique (généralement < 48 heures ou au maximum < 7 jours), persistante (> 7 jours et/ou nécessitant une cardioversion), ou permanente (> 7 jours, où la cardioversion est inefficace ou jugée futile).	Absence d'ondes P distinctes, remplacées par des ondes fibrillatoires (ligne de base irrégulière), avec des complexes QRS irréguliers. La fréquence ventriculaire peut être lente, normale ou rapide.
Flutter auriculaire	Contractions rapides mais régulières des oreillettes, se manifestant par un tracé en « dents de scie » caractéristique sur l'ECG. Le flutter auriculaire est une forme de tachycardie due à un macro-circuit de réentrée dans l'oreillette.	Présence d'ondes F rapides et régulières sans retour à la ligne isoélectrique, avec une fréquence auriculaire typiquement de 300/min, et une réponse ventriculaire souvent à la moitié (environ 150/min) en raison du blocage des influx à l'entrée du nœud AV.
Tachycardie paroxystique supraventriculaire (TPSV)	**Tachycardie par réentrée nodale AV** : Due à un circuit de réentrée à l'intérieur ou à proximité du nœud AV.	Complexes QRS étroits avec un rythme régulier ; les ondes P peuvent être masquées dans le complexe QRS ou apparaître peu après, créant souvent une pseudo-

		onde S dans les dérivations inférieures.
	Tachycardie par réentrée AV : Implique une voie accessoire, comme dans le syndrome de Wolff-Parkinson-White (WPW).	Complexes QRS étroits avec un rythme régulier ; des ondes P rétrogrades peuvent apparaître après le complexe QRS, particulièrement visibles dans les dérivations II, III et aVF.
Tachycardie auriculaire multifocale	Résulte de foyers ectopiques multiples dans les oreillettes, provoquant une tachycardie irrégulière.	Rythme irrégulier avec au moins trois morphologies différentes d'ondes P. L'intervalle PR varie, et les complexes QRS sont généralement étroits.
Syndrome de Wolff-Parkinson-White (WPW)	Défini par la présence congénitale d'une voie de conduction anormale entre une oreillette et un ventricule, le syndrome de WPW entraîne des épisodes de tachycardies ou de tachyarythmies paroxystiques récurrentes.	Intervalle PR court (<120 ms), apparition d'une onde delta (montée floue du complexe QRS), et complexes QRS larges.

1.4.3.3. Les tachyarythmies ventriculaires

Les tachyarythmies ventriculaires peuvent être plus dangereuses que les tachyarythmies supraventriculaires, et peuvent rapidement devenir des urgences médicales en raison du risque de perte de conscience, de collapsus cardiovasculaire et de mort subite. Le Tableau 1.7 présente quelques types de tachyarythmies ventriculaires [18, 19, 20].

Tableau 1.7: Les sous-catégories des tachyarythmies ventriculaires.

Type d'Arythmie	Description	Caractéristiques ECG
Tachycardie ventriculaire (TV)	La tachycardie ventriculaire se caractérise par la survenue de trois extrasystoles ventriculaires ou plus, à une fréquence égale ou supérieure à 120 battements par minute. On distingue entre deux formes principales : **TV soutenue** : Épisode durant plus de 30 secondes ou nécessitant une intervention médicale en raison d'une instabilité hémodynamique. **TV non soutenue** : Épisode durant moins de 30 secondes, se terminant spontanément.	Présence de complexes QRS larges (>120 ms), avec un rythme régulier et une fréquence cardiaque typiquement comprise entre 100 et 250 battements par minute. La morphologie des QRS peut être monomorphe (forme constante) ou polymorphe (formes variables).
Fibrillation ventriculaire	Elle est caractérisée par une activité électrique désorganisée et chaotique au niveau des ventricules, ce qui empêche un pompage efficace du sang et peut conduire à une mort cardiaque subite.	Présence de formes d'ondes chaotiques et irrégulières, sans ondes P, complexes QRS ou ondes T identifiables. L'amplitude et la fréquence des ondes varient, entraînant des contractions rapides, désorganisées et inefficaces.
Torsades de pointes	Les torsades de pointes sont un type spécifique de TV polymorphe, caractérisé par la rotation en torsade des	La fréquence ventriculaire varie entre 200 et 250 battements par minute, avec une durée

	complexes ventriculaires, une durée non soutenue (< 30 sec) et un intervalle QT prolongé en rythme sinusal.	généralement inférieure à 30 secondes. Les torsades peuvent être incessantes (1 ou 2 par minute) ou intermittentes. Les complexes QRS sont peu discernables, et leur amplitude varie progressivement.

1.4.3.4. Les complexes prématurés

Les complexes prématurés sont des battements précoces qui se produisent avant le prochain battement prévu dans le rythme normal du cœur [19, 20]. On distingue entre :

- **Contractions Auriculaires Prématurées (PACs)** : Ces battements précoces prennent naissance dans les oreillettes. Ils font partie des arythmies supraventriculaires.
- **Contractions Ventriculaires Prématurées (PVCs)** : Ces battements précoces proviennent des ventricules. Ils font partie des arythmies ventriculaires.

Les pattern ECG des complexes prématurés sont présentés en détails dans les sections 1.5.1.2 et 1.5.1.3.

1.4.3.5. Autres types d'arythmies

Il existe également d'autres formes d'arythmie qui n'entrent pas dans les catégories ci-dessus ; elles sont exposées dans le Tableau 1.8 [12, 21] :

Tableau 1.8: Description de l'arythmie sinusal, du rythme jonctionnel et du rythme idioventriculaire.

Type d'Arythmie	Description	Caractéristiques ECG
Arythmie sinusale respiratoire	C'est une variation naturelle de la fréquence cardiaque liée à la respiration, influencée par les changements de tonus sympathique et parasympathique au cours du cycle respiratoire. Ce phénomène est généralement bénin.	Raccourcissement de l'intervalle R-R pendant l'inspiration (accélération cardiaque) et allongement de cet intervalle pendant l'expiration (ralentissement cardiaque). Présence d'ondes P sinusales normales et des intervalles P-P qui varient de plus de 160 ms.
Rythme jonctionnel	Il prend naissance près du nœud auriculo-ventriculaire (AV) lorsque le nœud sinusal ne parvient pas à générer des impulsions ou que celles-ci sont bloquées.	La fréquence cardiaque est généralement comprise entre 40 et 60 battements par minute. Les ondes P peuvent être absentes, inversées (si les oreillettes sont activées après les ventricules), ou apparaître avant ou après le complexe QRS avec un intervalle PR court. Le complexe QRS est habituellement étroit, sauf en présence d'un bloc de branche associé (bundle branch block).
Rythme idioventriculaire	Ce rythme se manifeste lorsque les stimulateurs cardiaques supérieurs, tels que le nœud sinusal (SA) et le nœud AV, sont défaillants, obligeant les	La fréquence cardiaque est typiquement lente, entre 20 et 40 battements par minute, avec des complexes QRS larges (>120 ms),

	ventricules à prendre le relais. Ce rythme peut être observé lors de bradycardies sévères ou en situation d'arrêt cardiaque, lorsque le cœur fonctionne en mode de survie.	réguliers, et sans ondes P préalables, car les oreillettes ne participent pas à ce rythme. Les ondes T souvent orientées dans la direction opposée aux complexes QRS.

Afin d'illustrer les différences cliniques entre les catégories d'arythmies, un type d'arythmie représentatif de chaque catégorie est sélectionné et son tracé ECG correspondant (dérivation II) est présenté dans les Figures 1.14 à 1.18.



Figure 1.14. Rythme sinusal normal[10].



Figure 1.15. Bradyarythmie. Exemple : Bloc AV du premier degré avec intervalle PR prolongé > 0.20 seconde[10].

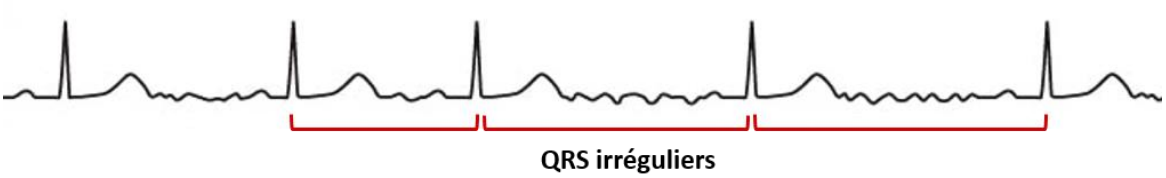

Figure 1.16. Tachyarythmie supraventriculaire. Exemple : Fibrillation auriculaire avec des ondes *f* fibrillatoires et des complexes QRS irréguliers[10].



Figure 1.17. Tachyarythmie ventriculaire. Exemple : Fibrillation ventriculaire où aucune onde P, complexe QRS ou onde T n'est visible[10].

[10] Source: ECGWaves.com, n.d., Arrhythmias and arrhythmology, https://ecgwaves.com/lesson/arrhythmias-and-arrhythmology/

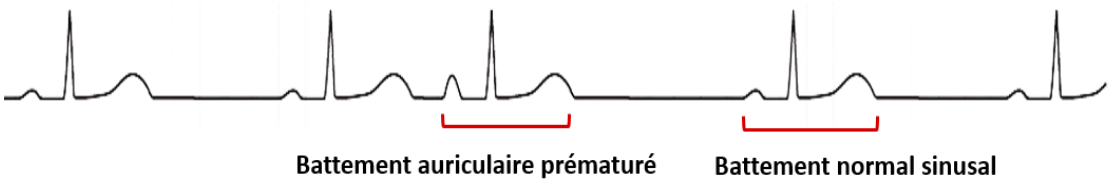

Figure 1.18. Contraction auriculaire prématurée (PAC) avec onde P prématurée ayant une morphologie différente de l'onde P sinusale[10].

Les principales catégories d'arythmies ont été abordées dans cette partie. Dans la section suivante, nous fournirons une présentation plus détaillée des arythmies étudiées dans notre approche.

1.5. Problématique et contribution de la thèse

L'objectif de cette partie est de définir les principales problématiques de recherche traitées dans cette thèse et de mettre en évidence les contributions de notre travail au domaine du diagnostic de l'arythmie cardiaque. Cette section présente les types de battements cardiaques qui seront classifiés dans notre approche pour la détection des arythmies et aborde les défis liés à leur diagnostic.

1.5.1. Battements cardiaques : types et caractéristiques

La classification des battements cardiaques est une étape essentielle de la détection et de la classification des arythmies, étant donné que la catégorie du rythme cardiaque peut être déterminée par la reconnaissance de classes de battements de cœur consécutifs.

Dans le présent travail, nous analysons et classifions huit types de battements cardiaques, chacun ayant une importance clinique particulière. Les battements normaux (N) sont des battements d'origine sinusale, représentant le rythme sinusal normal du cœur. Les battements auriculaires prématurés (A) surviennent de manière précoce à partir des oreillettes et, s'ils sont fréquents ou persistants, peuvent entraîner des arythmies soutenues. Les battements ventriculaires prématurés (V), bien que courants, peuvent conduire à des arythmies ventriculaires graves s'ils ne sont pas correctement pris en charge. Les battements associés à un bloc de branche gauche (L) reflètent un retard de conduction dans la branche gauche et peuvent indiquer un risque accru d'événements cardiovasculaires. Les battements liés à un bloc de branche droit (R), qui montrent un retard de conduction dans la branche droite, sont souvent associés à des maladies cardiaques structurelles et sont donc considérés comme graves.
Les battements stimulés (p) sont des battements initiés par un stimulateur artificiel plutôt que le nœud sinusal. La fusion des battements ventriculaires et normaux (F) se produit lorsque les signaux électriques d'un battement ventriculaire prématuré coïncident avec ceux d'un battement sinusal normal. De même, la fusion des battements stimulés et normaux (f) résulte de la combinaison d'un battement généré par un pacemaker avec un battement naturel initié par le nœud sinusal [22].

Ces types de battements ont été choisis en raison de leur potentiel à provoquer des problèmes de santé majeurs s'ils ne sont pas correctement identifiés. De plus, leur morphologie peut être difficile à différencier d'autres battements cardiaques, en particulier dans les cas de fusion de deux types de battements, ce qui complique leur détection.

1.5.1.1. Battement Normal (N)

Le pacemaker naturel du cœur (nœud sinusal) génère des signaux électriques qui entraînent une contraction normale des oreillettes, puis des ventricules.

— Caractéristiques ECG :
- Onde P positive, arrondie, et précède chaque complexe QRS.
- Complexe QRS étroit et pointu d'une durée normale de 0,06 à 0,10 secondes.
- Onde T généralement asymétrique et positive dans la plupart des dérivations de l'ECG.
- Intervalle PR entre 0,12 et 0,20 secondes et segment ST isoélectrique.

(Voir section 1.3.1.5.2 pour une description détaillée de la morphologie du battement normal.)

1.5.1.2. Contraction Auriculaire Prématuré (PAC ou A)

Causée par une impulsion émise par un foyer ectopique, qui peut se trouver n'importe où dans l'oreillette. Une contraction prématurée des oreillettes retarde le battement sinusal suivant, ce qui permet aux ventricules de se remplir davantage de sang (augmentant ainsi le remplissage ventriculaire). Les personnes qui souffrent de battements prématurés peuvent ressentir cela comme des palpitations, en raison des contractions ventriculaires plus fortes résultant de ce remplissage accru. Lorsque les battements prématurés sont fréquents, ils peuvent être perçus comme un rythme cardiaque irrégulier, malgré un rythme sinusal sous-jacent. Bien que ces battements prématurés soient généralement bénins, ils peuvent parfois déclencher des tachyarythmies supraventriculaires soutenues [12].

Les PACs peuvent se produire de manière fréquente ou sporadique. Lorsque deux PACs se produisent l'une après l'autre, on parle de couplets auriculaires. Il arrive également que chaque battement sinusal soit suivi d'un PAC, formant ainsi un schéma « groupé » connu sous le nom de bigéminisme auriculaire.

— Caractéristiques ECG [12, 23] :
- Une onde P prématurée se produit plus tôt que l'onde P normale attendue et a une morphologie différente que celle-là. Son apparence dépend de l'endroit où se trouve le foyer ectopique qui émet l'impulsion. Si cette impulsion provient d'une zone proche du nœud sinusal, l'onde P aura une forme similaire à celle d'une onde P normale. Cependant, si l'impulsion est déclenchée près du nœud auriculo-ventriculaire, les oreillettes seront dépolarisées dans le sens inverse, ce qui produira une onde P négative (rétrograde). Il est également possible que l'onde P prématurée se superpose à l'onde T précédente si elle est générée très tôt.
- L'intervalle PR est généralement normal, mais peut parfois être prolongé. De plus, l'impulsion atteint tôt le nœud AV (et le faisceau de His). Si l'impulsion auriculaire prématurée arrive au nœud AV (ou au faisceau de His) pendant sa période réfractaire complète, l'impulsion est bloquée et aucun complexe QRS n'est observé.

- Le complexe QRS apparaît lorsque l'impulsion auriculaire est conduite aux ventricules. Comme l'impulsion pénètre les ventricules via le faisceau de His, le complexe QRS apparaît normal (QRS < 0,12 s). Toutefois, un complexe QRS large (QRS > 0,12 s) peut se produire en cas de bloc de branche gauche ou droite. Il est courant que l'impulsion auriculaire prématurée arrive avant qu'une des branches du faisceau ne soit complètement repolarisée, entraînant ainsi un bloc de branche.

La Figure 1.18 illustre un battement auriculaire prématuré.

1.5.1.3. Battement Ventriculaire Prématuré (PVC ou V)

Un complexe ventriculaire prématuré résulte d'une impulsion émise par un foyer ectopique situé n'importe où dans les ventricules. Ce type d'impulsion remplace un battement sinusal normal et retarde le battement sinusal suivant, ce qui permet aux ventricules de se remplir davantage de sang (augmentation du remplissage ventriculaire).
Les PVCs peuvent se produire en tant qu'événement unique, mais aussi dans des schémas de bigéminisme (alternance de battements sinusaux et de PVC) et de trigéminisme (deux battements sinusaux suivis d'un PVC).

Les personnes souffrant de PVCs peuvent ressentir des palpitations, car les ventricules se contractent plus fortement en raison de cet excès de remplissage. Bien que les PVCs soient généralement sans danger, elles peuvent parfois déclencher des tachyarythmies ventriculaires soutenues, qui nécessitent une attention médicale [12, 23].

— Caractéristiques ECG [12, 23] :
- Les PVCs ne sont pas précédées d'une onde P, car l'impulsion ectopique provient directement des ventricules, sans affecter les oreillettes.
- Étant donné que l'impulsion se produit dans les ventricules, elle peut se propager partiellement ou entièrement en dehors du système de conduction normal, ce qui entraîne un complexe QRS anormal et élargi (QRS >= 0,12 s).
- L'intervalle R-R est prolongé après un PVC, en raison du retard du battement sinusal suivant.
- Le vecteur ST-T est orienté à l'opposé du vecteur QRS, car l'impulsion ectopique n'est pas transmise aux ventricules par le faisceau de His.

La Figure 1.19 illustre un battement ventriculaire prématuré.

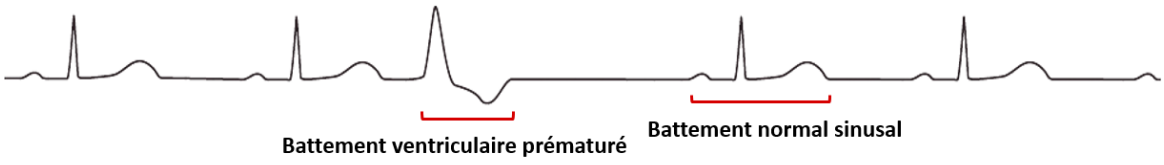

Figure 1.19: Représentation d'un battement ventriculaire prématuré (PVC)[11].

[11] Source (Adaptée) : ECG Waves, n.d., Premature ventricular contraction (PVC), https://ecgwaves.com/topic/premature-ventricular-contractions-complex-beats-ecg/.

1.5.1.4. Bloc de Branche Droit (RBBB ou R)

Le bloc de branche droit (RBBB) résulte d'un dysfonctionnement, qu'il soit anatomique ou fonctionnel, de la branche droite du faisceau de His, entraînant un blocage de l'impulsion électrique. Lorsque ce blocage survient, la dépolarisation du ventricule droit dépend des impulsions électriques qui se propagent à partir du ventricule gauche. Cette propagation se fait lentement parce qu'elle circule partiellement ou totalement en dehors du système de conduction normal. Ce retard de propagation provoque une activation anormale et plus lente du ventricule droit, ce qui se manifeste par un complexe QRS élargi et de forme atypique sur l'ECG [12].
Dans la majorité des cas, RBBB est bénin. Toutefois, l'apparition d'un RBBB au cours d'un infarctus du myocarde antérieur aigu est importante car elle indique un risque accru de bloc cardiaque complet. En outre, le RBBB peut être associé à certaines maladies telles que certaines affections neuromusculaires héréditaires [23].

— Caractéristiques ECG [12, 24] :
  - Durée du complexe QRS ≥ 0,12 s, avec une grande onde R' observée en V1/V2 et une onde S large et profonde en V5/V6.
  - Morphologie du complexe QRS : Présence d'un motif rsr', rsR' ou rSR' dans les dérivations V1-V2. Parfois, l'onde S n'atteint pas la ligne de base. La deuxième onde R (notée R') est presque toujours plus grande que la première.
  - Dérivations V5, V6, I, aVL : Une onde S large, souvent d'une durée supérieure à celle de l'onde R, ou dépassant 40 ms dans les dérivations V6 et I.
  - Les dérivations V1 et V2 montrent des segments ST en pente descendante et des ondes T inversées, tandis que les dérivations V5, V6, I, et aVL présentent des ondes T positives.

La Figure 1.20 illustre un bloc de branche droit sur différentes dérivations de l'ECG.

1.5.1.5. Bloc de Branche Gauche (LBBB ou L)

Le bloc de branche gauche (LBBB) résulte d'un dysfonctionnement, qu'il soit anatomique ou fonctionnel, de la branche gauche du faisceau de His, ce qui bloque la transmission de l'impulsion électrique. Dans ce cas, la dépolarisation du ventricule gauche se fait à partir d'impulsions provenant du ventricule droit. En raison du dysfonctionnement de la branche gauche, l'impulsion traverse partiellement ou complètement en dehors des voies de conduction habituelles, ralentissant ainsi la propagation de l'impulsion et allongeant la durée du complexe QRS.
Le bloc de branche gauche est une condition sérieuse qui indique toujours la présence d'une pathologie sous-jacente et peut affecter négativement la capacité du cœur à se contracter et à pomper correctement. Cette anomalie est associée à divers problèmes cardiovasculaires, tels que l'hypertension, l'hypertrophie ventriculaire, les maladies des valves cardiaques, la myocardite, les maladies coronariennes, l'insuffisance cardiaque et les cardiomyopathies [12].

— Caractéristiques ECG [12, 24] :
  - Complexe QRS d'une durée ≥0,12 s.
  - Présence d'une onde S large et profonde dans les dérivations V1-V2.
  - Une onde R large, à la forme irrégulière, complètement positive et souvent encochée, visible dans les dérivations V5, V6, I et aVL.

- Inversion de l'onde T et dépression du segment ST dans les dérivations gauches (V5, V6, I et aVL). Élévation du segment ST et ondes T positives dans les dérivations V1-V3, avec une élévation du segment ST rarement dépassant 0,5 mV.

La Figure 1.20 illustre un bloc de branche gauche sur différentes dérivations de l'ECG.

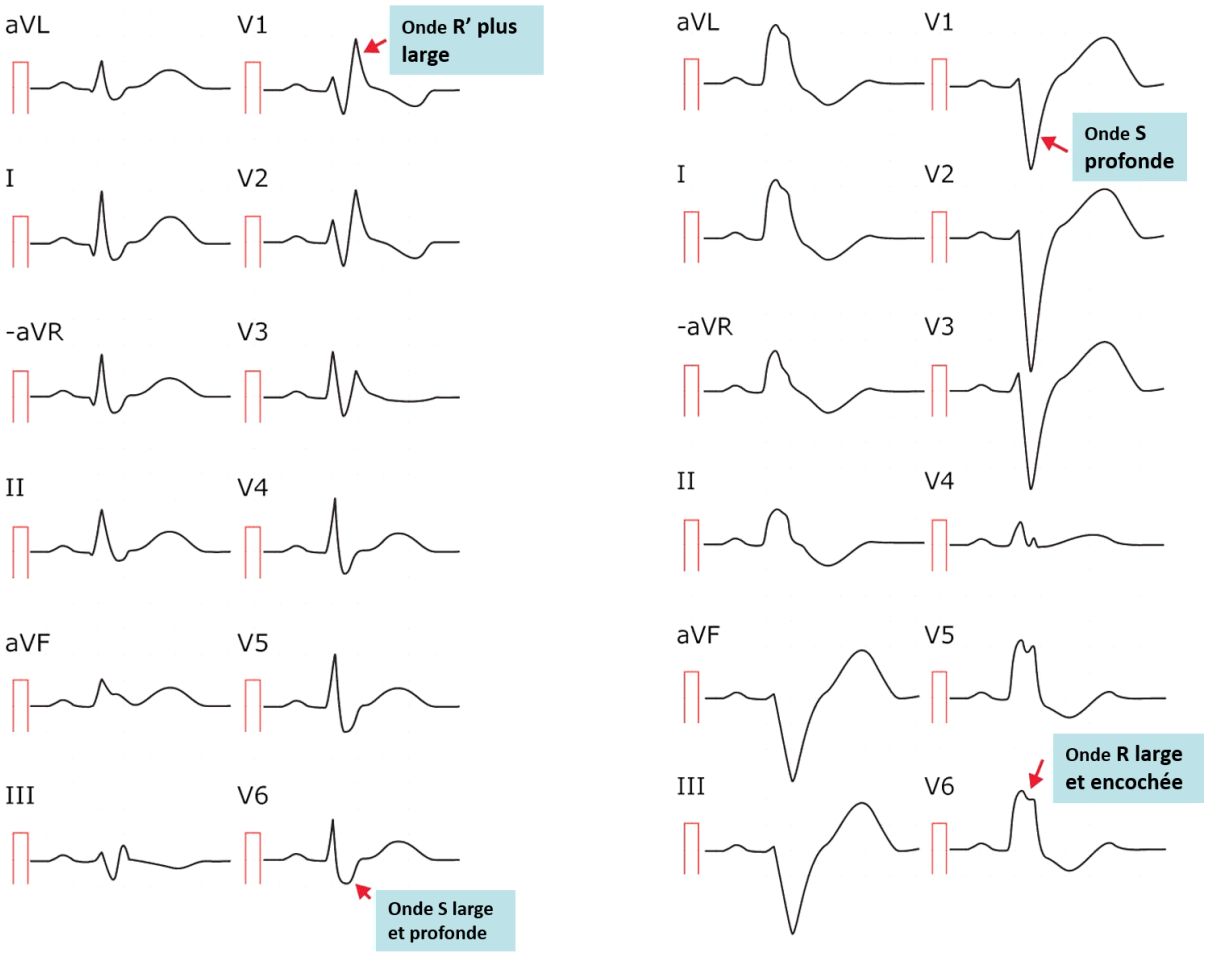

Figure 1.20. Représentation d'un Bloc de Branche Droit (à gauche) et d'un Bloc de Branche Gauche (à droite) sur les dérivations frontales et les dérivations précordiales[12].

1.5.1.6. Battement stimulé (p)

Il s'agit d'un battement généré par un stimulateur cardiaque. Les stimulateurs cardiaques sont des dispositifs électroniques conçus pour corriger ou compenser les anomalies symptomatiques de la formation des impulsions cardiaques (dysfonctionnement du nœud sinusal) et/ou de la conduction (bloc auriculo-ventriculaire ou retards de conduction du ventricule gauche). Les stimulateurs cardiaques **mono-dérivation** ou (mono-chambre), sont utilisés pour stimuler uniquement l'oreillette droite ou le ventricule droit. Les stimulateurs cardiaques auriculaires (dont l'électrode est placée dans l'oreillette droite) peuvent être utilisés pour traiter un dysfonctionnement isolé du nœud sinusal avec une conduction AV normale. Les stimulateurs cardiaques ventriculaires (avec l'électrode dans le ventricule droit) sont principalement utilisés

[12] Source (Adaptée): ECG Waves, n.d., Right bundle branch block (RBBB), https://ecgwaves.com/topic/right-bundle-branch-block-rbbb-ecg-criteria-treatment/.

pour générer un rythme cardiaque fiable chez les patients souffrant de fibrillation auriculaire chronique avec une réponse ventriculaire excessivement lente.
Dans les stimulateurs cardiaques à **double chambre**, les électrodes sont insérées à la fois dans l'oreillette droite et dans le ventricule droit. Le circuit est conçu pour permettre un délai physiologique (synchronisation normale) entre la stimulation auriculaire et la stimulation ventriculaire.
Les battements ventriculaires stimulés peuvent parfois conduire de manière rétrograde vers les oreillettes, provoquant une dépolarisation et une contraction quasi simultanées des oreillettes et des ventricules. Cela peut provoquer des symptômes connus sous le nom de « syndrome du stimulateur cardiaque » ; par exemple : palpitations, pulsations dans le cou, vertiges et chutes de tension artérielle [25].

— Caractéristiques ECG [25] :
  - Pic de stimulation : Les battements stimulés sont identifiés par une forte déflexion verticale connue sous le nom de pic de stimulation. Ce pic est l'impulsion électrique délivrée par le stimulateur cardiaque. Son amplitude peut être très faible, en particulier si le seuil de stimulation est bas, et peut passer inaperçue sur un ECG standard.
  - Onde P de stimulation : En cas de stimulation auriculaire, l'ECG montre un pic de stimulation suivi d'une onde P. Cela indique que le stimulateur cardiaque est en train de stimuler l'oreillette.
  - Pour la stimulation ventriculaire, un pic de stimulation précède un complexe QRS large. Ce dernier reflète une activation ventriculaire lente qui part de la chambre de stimulation et se propage à l'autre ventricule par le biais d'un myocarde à conduction lente, similaire aux schémas observés avec les blocs de branche, les PVC ou les battements d'échappement ventriculaires.
  - La morphologie du QRS ressemble typiquement à un bloc de branche gauche lors de la stimulation à partir de l'apex du ventricule droit, avec une déflexion négative du QRS dans les dérivations II, III et aVF et positive dans les dérivations I et aVL.
  - Les ondes T des battements stimulés sont normalement discordantes, c'est-à-dire qu'elles sont dirigées à l'opposé de la direction principale du QRS.

La Figure 1.21 illustre des battements stimulés par un stimulateur cardiaque.



Figure 1.21: Un stimulus (A) est observé avant chaque onde P, lorsque l'électrode du stimulateur cardiaque est placée dans l'oreillette droite[13].

[13] Source: [Goldberger et al.], [Goldberger's clinical electrocardiography], [9th ed], [2018], p. [227].

1.5.1.7. Fusion du battement ventriculaire et normal (F)

Si une impulsion auriculaire normale est transmise aux ventricules à peu près en même temps qu'une impulsion ventriculaire prématurée, les ventricules peuvent être dépolarisés par ces deux impulsions. Cela se produit généralement si l'impulsion ventriculaire prématurée est déchargée tardivement, à peu près au moment de l'impulsion sinusale normale. Il en résulte un battement de fusion [12].

— Caractéristiques ECG [26] :
- Une onde P peut être visible ou non en fonction de la chronologie des activations auriculaires et ventriculaires. Si une onde P est présente, elle est généralement suivie du complexe QRS de fusion, mais l'intervalle PR peut être plus court ou modifié en raison de l'activation simultanée.
- Le complexe QRS a une forme intermédiaire ; Il n'est pas aussi étroit qu'un complexe QRS normal ni aussi large qu'un complexe QRS provenant uniquement des ventricules.
- Contrairement à un PVC, un battement de fusion ne présente généralement pas de pause compensatoire complète. Le nœud sinusal continue à se déclencher régulièrement et le prochain battement sinusal se produit généralement au moment prévu.

La Figure 1.22 illustre une fusion d'un battement normal et d'un battement ventriculaire.



Figure 1.22: Représentation d'un battement de Fusion (F) en lead V1[14].

1.5.1.8. Fusion du battement stimulé et normal (f)

Ces battements se produisent lorsqu'un battement stimulé et un battement normal coïncident, donnant lieu à un complexe QRS hybride. Ce phénomène est souvent observé chez les patients porteurs d'un stimulateur cardiaque.

Les battements de fusion **ventriculaires** peuvent se produire lorsque le rythme sinusal du cœur et l'impulsion d'un stimulateur cardiaque coïncident pour activer la même partie d'un ventricule au même moment, tandis que la collision des impulsions dans les chambres **auriculaires** produit des battements de fusion auriculaires [27].

— Caractéristiques ECG [27] :
- L'onde P associée à un battement de fusion peut différer de l'onde P habituelle, selon que le battement intrinsèque est auriculaire ou ventriculaire.
- Morphologie hybride : Le complexe QRS d'un battement de fusion présente une forme unique, différente des complexes QRS normaux et stimulés. Il combine généralement des éléments des deux types.
- Rythme irrégulier : Les battements de fusion peuvent perturber le rythme régulier du cœur, entraînant une fréquence cardiaque variable.

[14] Source: Wikidoc, 2012, Fusion beats, https://www.wikidoc.org/index.php/Fusion_beats/.

- Synchronisation : Les battements de fusion se produisent souvent lorsque la fréquence cardiaque est relativement lente, ce qui permet la coïncidence des battements stimulés et normaux.

La Figure 1.23 illustre une fusion d'un battement stimulé et d'un battement normal.

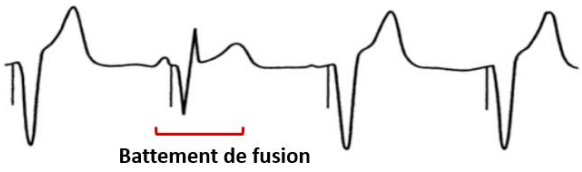

Figure 1.23: Représentation d'un battement de fusion (f) [15].

1.5.2. Défis liés au diagnostic des arythmies

La classification des battements cardiaques pour le diagnostic de l'arythmie à partir de l'électrocardiogramme (ECG) présente plusieurs défis. Les principales problématiques liées à l'interprétation de ces battements sur un ECG peuvent être résumées comme suit :

— Variabilité des présentations ECG : Les battements cardiaques, tels que les battements prématurés auriculaires et ventriculaires, ou les battements de fusion, peuvent varier considérablement dans leur apparence sur l'ECG. Cette variabilité complique l'identification précise, car les mêmes types de battements peuvent avoir différentes manifestations ECG en fonction du patient et des facteurs de risque sous-jacents.
— Ressemblance avec d'autres anomalies : Certaines arythmies peuvent être confondus avec d'autres anomalies cardiaques ou même des artefacts causés par des mouvements musculaires ou des interférences électriques. Cette similitude peut entraîner des faux positifs ou des erreurs de diagnostic.
— Identification des battements de fusion : Dans le contexte d'un stimulateur cardiaque (pacemaker), les battements fusionnés peuvent être difficiles à distinguer des battements purement induits par le pacemaker ou des battements normaux, nécessitant une expertise considérable pour les identifier correctement sur l'ECG.
— Acquisition de signal bruité : La qualité de l'enregistrement ECG peut être affectée par divers facteurs externes, tels que la mauvaise position des électrodes, les interférences électriques, et les mouvements du patient. Ceci peut modifier l'apparence des battements sur l'ECG, compliquant ainsi le diagnostic.
— Analyse automatisée limitée : Bien que de nombreux systèmes ECG modernes, basés sur des méthodes traditionnelles du Machine Learning, offrent un diagnostic automatique des arythmies, ces systèmes ne sont pas toujours fiables et peuvent manquer des battements subtils ou les interpréter incorrectement. Ce problème est accentué lorsque les données pathologiques (les cas d'arythmie) sont rares ou sous-représentées dans les données d'entraînement du modèle.

L'examen humain battement par battement peut prendre beaucoup de temps et s'avérer fastidieux dans de nombreux cas. En outre, l'analyse automatique de l'ECG est importante pour la surveillance à temps réel et à long terme de l'activité cardiaque. Par conséquent, la classification automatique des battements cardiaques, par les méthodes du Deep Learning, peut

[15] Source: [Conover, M. B.], [Understanding electrocardiography], [8th ed], [2002], p. [458].

contribuer au diagnostic des arythmies cardiaques et fait l'objet d'une étude dans le présent travail.

1.5.3. Contributions de la thèse

Cette thèse explore l'utilisation des techniques d'intelligence artificielle pour classifier les battements cardiaques afin de détecter les arythmies. Voici les principales contributions de notre travail :

- Mise en œuvre d'un pipeline de traitement des données cardiaques :
  - Segmentation des battements cardiaques : Extraction des battements à partir des signaux ECG recueillis dans des bases de données médicales publiques.
  - Réduction du bruit des signaux ECG : Amélioration de la qualité des signaux pour faciliter le diagnostic.
  - Augmentation des battements cardiaques : Introduction d'une nouvelle variante de la méthode SMOTE (Synthetic Minority Oversampling Technique) pour équilibrer les données et mieux représenter les battements cardiaques anormales.
- Extraction des caractéristiques :
  - Caractéristiques spatiales : Utilisation d'un réseau de neurones résiduel pour identifier des motifs abstraits et complexes dans les données ECG.
  - Caractéristiques temporelles : Application de l'algorithme Matching Pursuit pour extraire des informations temporelles pertinentes.
- Conception d'un modèle d'apprentissage profond supervisé, intégrant une couche de Modulation Focale pour améliorer la classification des battements cardiaques.

1.6. Conclusion

Dans ce chapitre, nous avons introduit le système cardiovasculaire, en expliquant la structure et le fonctionnement du cœur, et avons présenté les principes de base de l'acquisition du signal ECG.

Nous avons également mis l'accent sur les arythmies cardiaques, en détaillant leurs principales causes et en classifiant les différents types, tels que les bradyarythmies, les tachyarythmies, et les contractions prématurées. Cette compréhension des arythmies est essentielle pour développer des méthodes de diagnostic plus précises.

Enfin, le chapitre a défini les objectifs de la thèse, en soulignant les défis associés à la classification des battements cardiaques pour le diagnostic des arythmies. Ce chapitre a établi le cadre théorique pour le développement des chapitres suivants.

Dans le prochain chapitre, nous présenterons l'état de l'art lié aux méthodes de prétraitement des signaux ECG, de segmentation des battements cardiaques, d'extraction des caractéristiques ECG et de diagnostic de l'arythmie par les méthodes du Machine Learning et du Deep Learning.

2. Etat de l'art

Sommaire

2.1. Introduction 56
2.2. Prétraitement du signal ECG 56
2.2.1. Réduction du bruit 56
2.2.2. Détection des pics R et des complexes QRS 63
2.2.3. Segmentation du signal ECG 66
2.2.4. Normalisation des données 68
2.2.5. Compression des données ECG 68
2.3. Extraction des caractéristiques ECG 69
2.3.1. Domaine temporel 70
2.3.2. Domaine fréquentiel/spectral 71
2.3.3. Domaine temps-fréquence 71
2.3.4. Domaine de la décomposition 72
2.3.5. Caractéristiques profondes 73
2.4. Génération des signaux synthétiques ECG 74
2.4.1. Modèles paramétriques 74
2.4.2. Modèles basés sur des processus stochastiques 75
2.4.3. Méthodes basées sur la simulation physiologique 75
2.4.4. Méthodes basées sur des modèles génératifs (Deep Learning) 75
2.4.5. Techniques d'augmentation des données 76
2.5. Classification des arythmies cardiaques 77
2.5.1. Classification par les méthodes classiques du Machine Learning 77
2.5.2. Classification par le Deep Learning 78
2.5.3. Métriques d'évaluation 79
2.6. Conclusion 81

2.1. Introduction

L'analyse des signaux électrocardiographiques (ECG) constitue un domaine clé dans le diagnostic des maladies cardiaques, en particulier les arythmies. Ce chapitre se propose d'explorer l'état de l'art en matière de traitement et d'analyse des signaux ECG, en se concentrant sur les méthodes de prétraitement, d'extraction des caractéristiques, de génération de signaux synthétiques et de classification.

Dans un premier temps, nous aborderons le prétraitement du signal ECG, une étape cruciale qui permet de réduire le bruit, d'identifier les complexes QRS et de segmenter les données pour obtenir des mesures précises et fiables. Ensuite, nous examinerons diverses techniques d'extraction des caractéristiques, en mettant en évidence les approches temporelles, fréquentielles, et les méthodes de décomposition. La génération de signaux synthétiques ECG sera également discutée, en explorant les modèles paramétriques et stochastiques ainsi que les méthodes basées sur l'apprentissage profond.

Enfin, nous nous pencherons sur la classification des signaux ECG, en comparant les techniques classiques de Machine Learning à celles utilisant le Deep Learning, et en présentant les différentes métriques d'évaluation pertinentes pour mesurer l'efficacité de ces méthodes. Ce chapitre vise à fournir un aperçu complet des avancées récentes dans le domaine, tout en mettant en lumière les applications pratiques qui en découlent pour l'amélioration du diagnostic des maladies cardiovasculaires.

2.2. Prétraitement du signal ECG

Le traitement préliminaire du signal ECG est essentiel dans l'étude des informations cardiaques, car il permet de convertir le signal brut en informations exploitables. Ce processus comprend différentes étapes clés telles que la suppression du bruit, la normalisation des données et la réduction de la dimensionnalité. Le prétraitement réduit le taux d'erreur dans les résultats, ce qui améliore la fiabilité du diagnostic en fournissant aux modèles de classification un signal de haute précision.

2.2.1. Réduction du bruit

Un ECG est une série temporelle non linéaire et non stationnaire, avec des caractéristiques quasi-périodiques. Il est souvent affecté par divers types de bruits, à la fois de hautes et basses fréquences, pouvant entraîner des erreurs d'interprétation. Par conséquent, nous examinons différents bruits qui peuvent corrompre le signal, tels que les interférences des lignes électriques, le bruit du canal, la dérive de la ligne de base, le bruit résultant des électrodes, ainsi que d'autres perturbations qui affectent la ligne de base [28]. Ensuite, nous exposons les méthodes proposées dans la littérature pour le traitement de ces types de bruit.

2.2.1.1. Types de bruit dans le signal ECG

a. La dérive de la ligne de base

La dérive de la ligne de base est l'un des bruits prédominants dans le signal ECG. Il s'agit d'un type de bruit à basse fréquence couramment présent dans les enregistrements ECG. Il est causé par des facteurs tels que les mouvements du patient, la respiration ou un mauvais contact

avec les électrodes. Par conséquent, la qualité d'interprétation de l'ECG diminue, en particulier lorsque la dérive de la ligne de base provoque une distorsion du segment ST. Ce bruit possède une amplitude d'environ 15 % de déflexion à pleine échelle (FSD[16]) lorsqu'il provient de la respiration et se situe dans un intervalle de fréquences inférieures à 1 Hz. Néanmoins, lors de certains examens tels que l'épreuve d'effort électrocardiographique ou encore dans les systèmes Holter utilisés pour enregistrer des signaux ECG à long terme, la fréquence peut être considérablement plus élevée et atteindre plusieurs Hz. Pour l'éliminer efficacement, un filtre passe-haut avec une fréquence de coupure d'environ 0,5 Hz est souvent utilisé dans le traitement du signal ECG [29, 30]. La Figure 2.1 illustre un exemple de la dérive de la ligne de base.

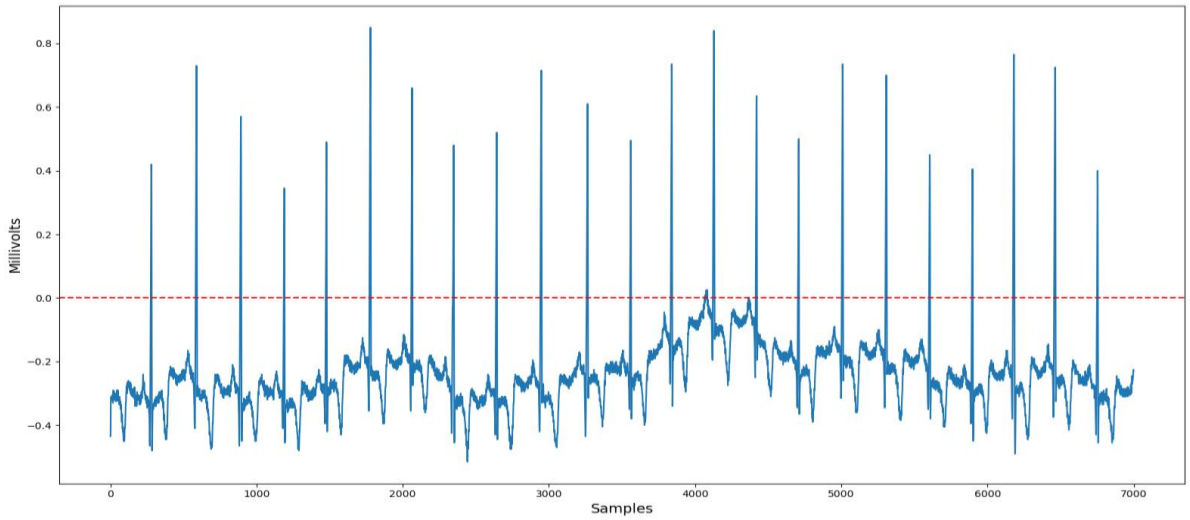

Figure 2.1. Exemple d'un signal ECG avec les bruits de la dérive de la ligne de base et les interférences des lignes électriques, extrait du Record '100' de la base de données « MIT-BIH Arrhythmia database », accessible sur le répertoire Physionet [11].

b. Interférence des lignes électriques

Le bruit des interférences des lignes électriques est un bruit électrique provenant de sources d'alimentation en courant alternatif (AC). Il est dû à des interférences électromagnétiques provenant d'appareils électriques situés à proximité, à une mauvaise mise à la terre ou à des problèmes d'électrodes et de câbles. Ce bruit est centré autour de 50 Hz dans la plupart des régions du monde (et 60 Hz en Amérique du Nord), avec une amplitude allant jusqu'à 50 % de FSD. Ce bruit, s'il est important, peut altérer la morphologie de l'ECG, affectant des éléments comme l'amplitude, la durée et la forme des ondes de faible amplitude, comme l'onde P, et mener ainsi à des erreurs de diagnostic, notamment pour les arythmies auriculaires [29, 31]. La Figure 2.1 présente un bruit d'interférence des lignes électriques sur un signal ECG.

c. Bruit électromyographique (EMG)

Le bruit de l'électromyogramme (EMG) est produit par l'activité électrique des contractions des muscles. Ce bruit peut atteindre des fréquences allant jusqu'à 10 kHz avec une amplitude moyenne représentant environ 10 % de la FSD. Comme le bruit EMG se superpose largement aux fréquences de l'ECG, situées entre 0,01 Hz et 100 Hz, il entraîne des distorsions

[16] Déflexion à pleine échelle (FSD) : est utilisée comme référence pour exprimer la quantité de bruit présente par rapport au signal maximal que le système peut détecter. Dans le cas de l'ECG, c'est l'amplitude pic à pic.

morphologiques de certains éléments de l'ECG. L'élimination des artefacts musculaires est donc un véritable défi [29, 31].
Si le signal est échantillonné à une fréquence inférieure à 1 kHz, la bande de 10 kHz peut ne pas être applicable. Dans ce cas, il est conseillé d'utiliser la plage de fréquences 30-500 Hz pour la détection du bruit musculaire.
La Figure 2.2 présente un bruit électromyographique sur un signal ECG.

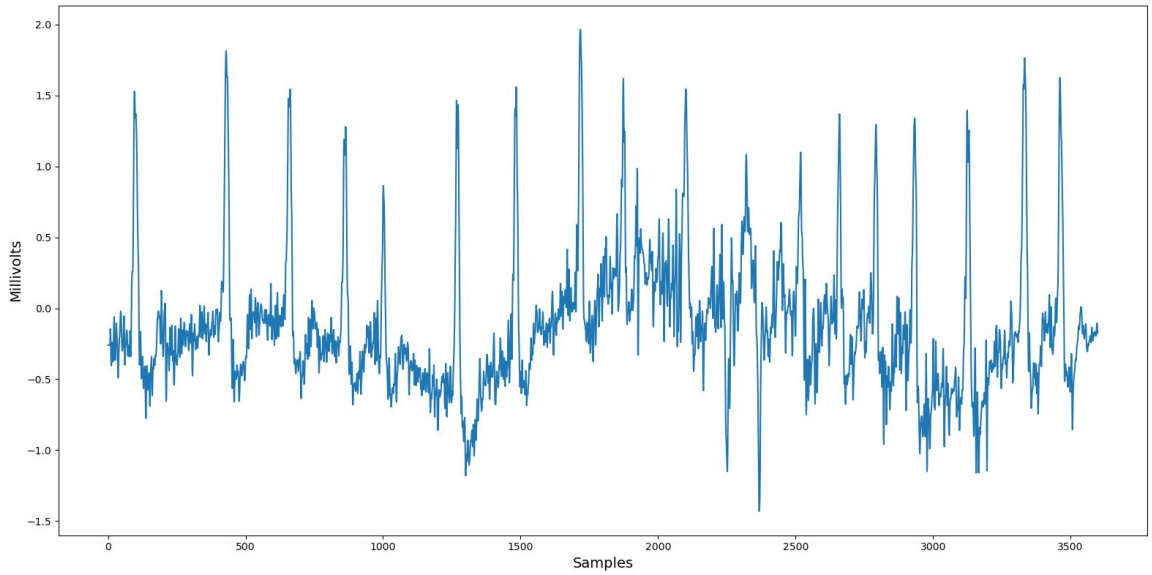

Figure 2.2. Exemple d'un signal ECG affecté par le bruit électromyographique, extrait du Record '203' de la base de données « MIT-BIH Arrhythmia database », accessible sur le répertoire Physionet [11].

d. Bruit de mouvement

Les artefacts de mouvement sont des distorsions indésirables du signal ECG causées par une mauvaise fixation des électrodes ECG ou des changements d'impédance entre la peau et les électrodes. Ils se caractérisent par des pics ou des sauts rapides mais continus, qui ne correspondent pas à l'activité cardiaque réelle et vont jusqu'à 0,5 s avec une amplitude de 500 % de la FSD [29, 31].

e. Bruit de contact des électrodes

Le bruit de contact de l'électrode survient lorsque l'électrode perd son contact avec la peau, provoquant des variations soudaines de la saturation aux niveaux de la FSD pendant environ une seconde sur l'ECG. Cela se produit généralement lorsqu'une électrode est partiellement ou totalement détachée. La perte de contact peut être temporaire ou permanente. Ce type de bruit peut être modélisé par une transition rapide et aléatoire de la ligne de base, suivie d'un retour progressif à la normale avec une composante de 60 Hz superposée [29, 31].

Outre les types de bruit susmentionnés, nous sommes souvent confrontés à un signal ECG corrompu par un mélange de bruits divers, comme le mélange de la dérive de la ligne de base, d'artefacts musculaires et d'interférences des lignes électriques.
Il existe aussi d'autres sources de bruit moins importantes, comme celles liées aux instruments, causées par des défauts dans le processus de conversion analogique-numérique, des circuits

internes ou d'autres problèmes matériels. Le bruit électro-chirurgical peut aussi être généré par d'autres appareils médicaux présents lors de prise en charge du patient. De plus, certains artefacts de traitement du signal, comme les oscillations de Gibbs, ou des variations de température affectant l'impédance de la peau et des électrodes, peuvent également contribuer au bruit qui apparait sur l'ECG [31].

2.2.1.2. Techniques de réduction du bruit

Les signaux ECG bruités peuvent conduire à un diagnostic erroné de l'arythmie cardiaque. Par conséquent, ils doivent être filtrés avant l'étape de classification, à l'aide de techniques de traitement des signaux spécifiques au bruit.
De nombreuses méthodes dans la littérature ont été élaborées pour traiter les différents types de bruit :

a. Le filtrage linéaire

C'est une méthode essentielle employée dans le traitement des signaux ECG afin d'éliminer le bruit tout en préservant les caractéristiques cruciales du signal. Différents types de filtres linéaires sont largement employés pour cibler des sources de bruit spécifiques. Il s'agit notamment des filtres passe-haut, des filtres passe-bas, des filtres passe-bande et des filtres coupe-bande (filtre de Notch) [32, 33, 34, 35].

b. La transformation en ondelettes (Wavelet Transform WT)

C'est une méthode très efficace dans le traitement des signaux, particulièrement pour la réduction du bruit dans l'ECG. Contrairement à la transformée de Fourier traditionnelle, la WT est capable d'analyser des signaux non stationnaires présentant des variations à la fois dans le temps et la fréquence [35, 36, 37].
La réduction de bruit avec la transformée en ondelettes (WT) comporte trois étapes fondamentales : décomposition du signal en différentes bandes de fréquence, seuillage des composantes haute fréquence pour éliminer le bruit, et reconstruction du signal en appliquant la transformée inverse. Les ondelettes de Daubechies, Symlet et Coiflet sont couramment utilisées, et le seuillage peut être dur ou doux selon le niveau de réduction de bruit souhaité.
Dans la pratique, la transformée en ondelettes discrète (DWT) est utilisée pour la réduction de bruit de l'ECG, car elle permet un calcul rapide des coefficients d'ondelettes pour les données de séries temporelles discrètes.

c. La décomposition en mode empirique (Empirical Mode Decomposition EMD)

Contrairement aux techniques de filtrage traditionnelles, l'EMD est une méthode de décomposition adaptative basée sur les données qui ne nécessite pas de fonction de base prédéfinie (comme dans le cas des ondelettes ou des transformées de Fourier). Elle est bien adaptée à l'analyse des signaux non linéaires et non stationnaires, tels que l'ECG, car elle décompose le signal en modes oscillatoires intrinsèques plus simples, appelés fonctions de mode intrinsèque (Intrinsic Mode Functions IMF) [38, 39, 40].
L'un des défis de l'EMD est le mélange des modes, lorsqu'une seule IMF peut contenir des composants d'échelles très différentes. Des méthodes avancées telles que l'EMD d'Ensemble

(EEMD) ou l'EMD d'Ensemble Complet avec bruit adaptatif (CEEMDAN) ont été introduites pour atténuer ce problème et améliorer les performances de réduction de bruit [41, 42].

d. L'analyse en composantes indépendantes (ICA)

L'ICA est une méthode statistique de réduction de bruit permettant d'identifier et de séparer les sources indépendantes sous-jacentes d'un signal mixte. Dans le cadre de l'ECG, l'ICA permet de différencier l'activité cardiaque des sources de perturbations telles que la dérive de la ligne de base, les artefacts musculaires et les interférences des lignes électriques [43, 44, 45]. Les étapes d'élimination du bruit à l'aide de l'ICA sont :
Des versions améliorées de l'ICA ont été proposées pour assurer une meilleure qualité de filtrage. Par exemple, [46] ont proposé « FastICA » qui utilise des statistiques d'ordre supérieur comme l'aplatissement (Kurtosis) et la néguentropie (Negentropy) pour maximiser la non-gaussianité, en séparant le bruit du signal désiré même s'ils partagent des fréquences similaires. D'autre part, une méthode appelée « Redundant Denoising ICA » a été développée spécifiquement pour atténuer les artefacts de mouvement dans les signaux ECG [47].

e. Le filtrage adaptatif

Il permet d'ajuster automatiquement les coefficients du filtre afin de réduire au maximum la divergence entre le signal désiré et le signal observé. Il utilise couramment des algorithmes comme la méthode des moindres carrés moyens (LMS) ou la méthode des moindres carrés récursifs (RLS) pour ajuster les paramètres du filtre.
Le filtrage adaptatif permet de traiter les bruits non stationnaires, tels que les artefacts musculaires et les dérives de la ligne de base, qui peuvent varier dans le temps [32, 35, 48].
En ce qui concerne certaines versions améliorées, [49] a proposé une approche d'annulation adaptative du bruit (ANC) qui intègre la transformée en ondelettes avec un filtre IIR-Notch. Une autre méthode d'amélioration de la qualité l'ECG a été proposée dans [50], qui combine la décomposition en mode empirique d'ensemble (EEMD) et le filtrage adaptatif.

f. Le filtre de Kalman

C'est une méthode efficace pour le filtrage des signaux ECG en raison de sa capacité à estimer et prédire l'état d'un système dynamique en présence de bruit. Ce filtre récursif estime de façon optimale le signal sous-jacent en minimisant l'impact du bruit, le rendant ainsi adapté aux applications ECG en temps réel.
Le filtre de Kalman, avec d'autres versions étendues ou améliorées, a été appliqué à divers types de bruit, y compris l'élimination de la dérive de la ligne de base, de l'interférence des lignes électriques et des artefacts de mouvement [51, 52, 53, 54].

g. L'analyse en composantes principales (PCA)

Il s'agit d'une méthode statistique qui transforme un ensemble de variables corrélées (telles que des données ECG bruyantes) en un ensemble de variables linéairement non corrélées appelées composantes principales, permettant ainsi L'analyse en composantes principales (PCA) permet de réduire la dimensionnalité des données, en éliminant le bruit (généralement associé aux composantes ayant des valeurs propres plus faibles).
La PCA a été efficacement utilisée pour le bruit provenant de sources multiples telles que les variations de la ligne de base, les artefacts musculaires et les interférences des lignes électriques

[55, 56]. Elle a été aussi appliquée aux coefficients de décomposition de la transformée en ondelettes discrète (DWT), ce qui permet de ne conserver que les composantes principales essentielles, optimisant ainsi la résolution spatiale [57, 58].

h. Le filtre de Savitzky-Golay

C'est une méthode de lissage couramment employée pour le filtrage du signal ECG. Elle ajuste les données en utilisant des polynômes successifs sur des sous-ensembles de points de données adjacents, et remplace le point central de chaque fenêtre par la valeur prédite par le polynôme.
Le filtre de Savitzky-Golay réduit le bruit aléatoire, tel que la dérive de la ligne de base et le bruit à haute fréquence, tout en préservant la netteté des caractéristiques importantes de l'ECG grâce à son ajustement polynomial [59, 60]. Lorsqu'il est combiné avec la méthode DWT, le filtre Savitzky-Golay permet d'obtenir des résultats améliorés pour le filtrage de l'ECG [61].

i. Les méthodes basées sur le Deep Learning

Ces méthodes ont gagné en importance dans la réduction du bruit des signaux ECG en raison de leur capacité à apprendre automatiquement des motifs complexes dans les données, les rendant très efficaces dans les tâches de suppression du bruit sans avoir besoin de caractéristiques élaborées manuellement. Par exemple, les réseaux neuronaux convolutionnels (CNN) peuvent extraire des caractéristiques hiérarchiques qui aident à distinguer le bruit de la forme d'onde ECG réelle [62, 63]. Les auto-encodeurs de débruitage (DAE) sont spécialement entraînés pour reconstruire un ECG propre à partir d'une entrée bruyante [64], ce qui permet de réduire le bruit.
Les réseaux de neurones récurrents (RNN) et les réseaux de mémoire à court-long terme (LSTM) prennent en compte la nature séquentielle des signaux ECG, leur permettant de gérer le bruit qui affecte plusieurs points temporels en apprenant les dépendances temporelles [63, 65]. Les réseaux génératifs antagonistes (GAN) sont également explorés pour la réduction du bruit de l'ECG [66]. Ils sont généralement combinés avec un réseau convolutif comme dans [67, 68].

Dans cette section, nous avons présenté les méthodes les plus utilisées pour la réduction de bruit de l'ECG, mais d'autres méthodes de filtrage peuvent être utilisées également, comme le filtrage des moyennes non locales (NLM) basé sur le calcul de la moyenne de parcelles similaires du signal pour réduire le bruit [69], ou le débruitage par variation totale (TVD) qui minimise la variation totale du signal, conduisant à une reconstruction du signal à la fois lisse et précise [70].

Nous avons compilé les méthodes couramment utilisées dans la littérature dans un tableau comparatif (Tableau 2.1) pour illustrer les avantages et les inconvénients de chacune.

Tableau 2.1. Comparaison entre les méthodes de réduction du bruit.

Méthodes	Avantages	Limitations
Filtrage linéaire	Simple à mettre en œuvre, efficace pour les fréquences connues.	Peut altérer les caractéristiques du signal, non adaptatif.
Transformée en Ondelette (WT)	Excellente pour l'analyse multi-résolution, adaptatif.	La sélection du seuil peut être difficile. Le seuil sélectionné peut altérer le signal utile, ou peut ne pas être efficace vu la variabilité des sources de bruit.
Décomposition en Modes Empiriques (EMD)	Adaptatif aux caractéristiques du signal, efficace pour les signaux non-stationnaires.	Le phénomène du « mode mixing » complique le seuillage, car une composante IMF peut contenir plusieurs échelles de fréquence, rendant difficile la séparation du bruit. De plus, l'EMD étant une méthode itérative, elle peut être coûteuse en calculs.
Analyse en Composantes Indépendantes (ICA)	Efficace pour séparer les sources de bruit mélangées, bonne pour le bruit identifiable.	Peut fonctionner mal lorsque les sources de bruit ne sont pas constantes ou distinctes, vu que le bruit dans un ECG peut varier en fréquence et en amplitude.
Filtrage Adaptatif (LMS, RLS)	Adaptation dynamique aux conditions changeantes du signal.	Dépend de la sélection d'un paramètre de pas d'apprentissage, qui peut affecter la convergence et la stabilité.
Filtre de Kalman	Robuste pour les systèmes dynamiques, bon pour le bruit variable.	Intensif en calcul, nécessite une modélisation du système.
Analyse en Composantes Principales (PCA)	Réduit la dimensionnalité, utile pour le bruit multivarié.	Suppose un bruit gaussien, peut ne pas gérer tous les types de bruit.
Filtre de Savitzky-Golay	Préserve les caractéristiques du signal, efficace pour le lissage.	Peut ne pas gérer bien le bruit non-stationnaire.
Apprentissage profond	Avancé, adaptatif à divers types de bruit.	Nécessite de grands ensembles de données d'entraînement, coûteux en calcul.

Bien que les filtres linéaires ne soient pas adaptatifs, leur simplicité, leur efficacité face aux types de bruit bien identifiés, leur faible coût computationnel et leur faible risque de sur-apprentissage en font un outil efficace pour le traitement des signaux ECG. C'est pourquoi nous avons opté pour le filtrage linéaire afin de réduire le bruit. Les techniques appliquées à notre signal seront décrites en détail dans les chapitres suivants.

2.2.1.3. Métriques d'évaluation de la qualité de réduction du bruit

L'évaluation de la réduction du bruit dans un signal ECG nécessite des métriques qui mesurent à quel point le signal nettoyé se rapproche de la version "idéale" ou d'origine, tout en

conservant les caractéristiques physiologiques importantes telles que les complexes PQRST. Voici les principales métriques utilisées dans la littérature pour évaluer la qualité de la réduction du bruit dans un signal ECG :

— **Rapport Signal/Bruit (SNR - Signal-to-Noise Ratio)**

Le SNR mesure la quantité de signal par rapport au bruit. Un SNR élevé indique une meilleure qualité, car il suggère que le bruit a été réduit par rapport au signal.

$$SNR\ (dB) = 10\ \log_{10}\left(\frac{\sum_{i=1}^{N} x_{signal}^{2}\ (i)}{\sum_{i=1}^{N}\left(x_{signal}(i)\ -\ x_{débruité}(i)\right)^{2}}\right) \qquad (2.1)$$

— **Rapport signal/bruit maximal (PSNR - Peak Signal-to-Noise Ratio)**

Le PSNR compare l'amplitude maximale du signal original à l'erreur introduite par l'algorithme de réduction de bruit. Une valeur élevée de PSNR indique une meilleure qualité du signal traité, car elle signifie que l'erreur entre le signal original et le signal traité est faible.

$$PSNR\ (dB) = 20\ \log_{10}\left(\frac{\max\{x_{signal}(i)\}}{\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(x_{signal}(i)\ -\ x_{débruité}(i)\right)^{2}}}\right) \qquad (2.2)$$

— **Erreur Quadratique Moyenne (RMSE - Root Mean Square Error)**

Le RMSE mesure la différence moyenne quadratique entre le signal original et le signal débruité. Un RMSE faible indique une meilleure qualité de réduction de bruit.

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(x_{original}(i)\ - x_{débruité}(i)\right)^{2}} \qquad (2.3)$$

2.2.2. Détection des pics R et des complexes QRS

La détection des pics R (l'onde positive la plus élevée du complexe QRS) et du complexe QRS dans les signaux ECG est essentielle pour l'analyse du rythme cardiaque et le diagnostic des arythmies.

En détectant les pics R, il est possible de déterminer la durée entre deux battements cardiaques successifs, appelée intervalle RR. Cela permet de mesurer la fréquence cardiaque et d'évaluer la régularité du rythme. La détection des complexes QRS permet de segmenter l'ECG en battements cardiaques individuels pour identifier les pathologiques cardiaques.

Pour ce faire, plusieurs méthodes ont été proposées dans la littérature. Elles incluent des approches basées sur des filtres numériques, des transformations de signaux, ainsi que des techniques plus récentes utilisant l'apprentissage automatique et les réseaux neuronaux profonds. On présente ces méthodes selon la catégorisation proposée dans [71].

Plusieurs méthodes qui seront présentées dans cette section ont été préalablement introduites dans la partie précédente de réduction du bruit, dans la mesure où plusieurs d'entre elles permettent à la fois de réduire les interférences et de détecter les complexes QRS.

2.2.2.1. Techniques de détection des pics R et des complexes QRS

a. Méthodes basées sur la Transformée en Ondelettes

Ces méthodes décomposent le signal ECG en différentes bandes de fréquences à l'aide des ondelettes, ce qui permet de détecter les discontinuités ou singularités dans le signal où les composants haute fréquence prédominent, comme les complexes QRS. L'un des premiers algorithmes reposant sur les transformées par ondelettes (WT) a été conçu dans [72] pour détecter les points caractéristiques de l'ECG en différenciant le complexe QRS des ondes P ou T de grande amplitude, ainsi que du bruit. La transformée en ondelettes discrète (DWT) permet une analyse multi-échelle pour identifier les pics R, elle permet également de délimiter les ondes P et T [73, 74].
Différents types de transformations en ondelettes ont été adaptés pour une détection plus efficace des complexes QRS, tels que la transformée en ondelettes stationnaire (SWT) [75], la transformée en ondelettes continue (CWT) [76], et la combinaison de plusieurs fonctions d'ondelettes [77].

b. Méthodes basées sur le filtrage numérique

Ces méthodes utilisent des filtres numériques linéaires, tels que les filtres passe-bas, passe-haut et Notch, pour éliminer le bruit et isoler le complexe QRS. L'idée est d'éliminer le bruit d'abord puis appliquer une différentiation pour accentuer la pente du complexe QRS, et par la suite intégrer le signal pour renforcer les pics R.
L'une des premières études basées sur le filtrage numérique a été développée en 1985 par Pan et Tompkins [78]. Hamilton et al. [79] ont proposé un filtrage linéaire et non linéaire pour prétraiter les signaux ECG, en générant des vecteurs d'événements à partir des complexes QRS et du bruit. D'autres travaux ont utilisé, pour la détection du QRS, le filtre médian [80], le filtre quadratique [81], le filtre MaMeMi [82] ou le filtre FIR [83].

c. Méthodes basées sur le filtrage morphologique mathématique

Ces méthodes appliquent des opérations morphologiques (dilatation, érosion) pour détecter les complexes QRS en mettant en valeur les formes dans le signal ECG qui ressemblent aux complexes QRS. [84] est l'une des premières approches proposant l'application d'un opérateur morphologique simple. Cet opérateur fonctionne comme un extracteur pic-creux et est contrôlé par un élément structurel qui est présenté par la forme d'un ensemble de lignes horizontales. [85] propose un algorithme basé sur la morphologie mathématique et le principe de l'enveloppe qui agrège la plupart des magnitudes et des énergies du signal et ignore la partie de faible distorsion. [86] propose l'extraction des points de référence des complexes QRS en utilisant une approche de morphologie mathématique avec un élément structurel adaptatif, qui est mis à jour sur la base des caractéristiques des complexes QRS précédemment détectés.

d. Méthodes basées sur l'Énergie de Shannon et la Transformée de Hilbert

En principe, l'énergie de Shannon permet de détecter les changements d'énergie du signal, et la Transformée de Hilbert est utilisée pour obtenir l'enveloppe du signal, mettant en valeur les complexes QRS. L'une des premières études utilisant l'énergie fractionnaire de Shannon et la transformée de Hilbert pour la détection des pics R dans le signal ECG a été réalisée en 2001 par Benitez et al. [87]. Bien que la plupart des travaux se concentrent sur l'adaptation exclusive de l'énergie de Shannon et de la transformée de Hilbert pour la détection des pics R, certains combinent ces techniques avec d'autres méthodes telles que le filtre moyen ou la transformée en ondelettes discrète [88-91].

e. Méthodes basées sur l'Apprentissage Automatique

Ces méthodes permettent d'entraîner un modèle à l'aide de données étiquetées (signaux ECG avec annotations des QRS) puis appliquer le modèle entraîné à de nouvelles données ECG pour prédire les pics R. Ces méthodes ne requièrent pas de prétraitement du signal ECG, mais elles peuvent s'appuyer sur des architectures complexes nécessitant des ressources de calcul importantes. [92] ont proposé une méthode combinant un réseau de neurones convolutifs (CNN) à une dimension et un perceptron multicouche (MLP) pour la détection des complexes QRS. Dans [93], les machines à vecteurs de support (SVM) sont utilisées comme classificateur pour délimiter les régions QRS et non QRS dans un ECG à 12 dérivations. Avec des modèles plus récents, [94] ont proposé un réseau neuronal profond à auto-encodeur empilé pour extraire directement les complexes QRS de l'ECG. Le réseau U-net, combiné avec des blocs Résiduels et des blocs d'Inception, a été appliqué pour l'extraction des pics R [95].

f. Méthodes hybrides

Certaines méthodes hybrides ont également été proposées pour la détection des pics R et des complexes QRS, visant à améliorer les performances en combinant les avantages de plusieurs techniques. Par exemple, on trouve l'application de la première dérivée avec les transformées de Hilbert et en ondelettes [96], la transformée de Stockwell fractionnaire avec l'énergie de Shannon [97], la transformée en ondelettes empirique avec l'algorithme de pollinisation des fleurs [98], l'analyse en composantes principales avec un seuil adaptatif [99], et la transformée en ondelettes stationnaire avec des filtres de convolution séparés [100].

Le tableau ci-dessous (Tableau 2.2) récapitule les méthodes abordées dans cette section, en soulignant les avantages et les inconvénients de chacune.

Tableau 2.2. Comparaison entre les méthodes de détection des pics R et complexes QRS.

Méthodes	Avantages	Limitations
Transformée en Ondelettes	Excellente capacité à analyser les signaux non stationnaires. Précision dans la détection des pics R et des complexes QRS à différentes échelles de fréquence.	Sensible au choix de la fonction d'ondelette et du seuil pour la sélection des coefficients. Peut-être difficile à implémenter en temps réel, vu la complexité de calcul élevée pour certaines applications.
Filtrage numérique	Simple à mettre en œuvre et rapide. Bonne détection des complexes QRS en limitant le bruit.	Moins précis pour les signaux très bruités. Peut rater des détections en cas de faible SNR, car le bruit peut

	Faible coût de calcul.	contenir des composantes de fréquence similaires à celles du signal ECG ce qui peut altérer les pics R.
Filtrage Morphologique Mathématique	Efficace pour extraire des formes spécifiques comme les complexes QRS.	Sensible aux variations morphologiques du signal. Dépend fortement de la sélection des éléments structurels. Peut manquer de généralisation pour des variations inter-patients.
Énergie de Shannon et Transformée de Hilbert	Met en évidence les pics d'énergie associés aux complexes QRS. Moins sensible au bruit.	Moins efficace pour les signaux à faibles amplitudes ou les pics R peuvent avoir une amplitude suffisamment faible pour ne pas ressortir clairement dans l'enveloppe calculée par la transformée de Hilbert.
Apprentissage Automatique	Capacité d'adaptation aux variations des données. Potentiel d'amélioration avec des données d'entraînement de qualité. Ne nécessite pas de prétraitement lourd.	-Besoin d'un grand volume de données annotées pour l'entraînement. -Complexité et coût de calcul élevé pour certains modèles.

Les méthodes présentées ci-dessus, pour la détection des pics R/complexes QRS, varient en termes de complexité et de précision. Le choix de la méthode dépend des spécificités du signal ECG traité. Pour notre approche, on s'est basé sur les annotations des pics R proposées dans les bases de données du répertoire Physionet[17]. En effet, ces bases de données sont largement utilisées dans la recherche sur l'ECG. Elles contiennent des annotations manuelles précises des pics R et des complexes QRS réalisés par des experts. Ces annotations sont fiables et servent de référence pour évaluer la performance d'autres algorithmes de détection des pics R.

2.2.3. Segmentation du signal ECG

Dans le traitement des signaux ECG, les techniques de segmentation sont utilisées pour diviser le signal en sections significatives pour l'analyse. Ces techniques peuvent être catégorisées en trois catégories : la segmentation des battements cardiaques, la segmentation par fenêtre glissante, et l'entrée sans segmentation (séquence complète).

a. Segmentation des battements cardiaques

Cette technique segmente le signal ECG en fonction des battements cardiaques individuels. Chaque segment contient un cycle cardiaque complet, comprenant l'onde P, le complexe QRS et l'onde T. La segmentation est effectuée en détectant les pics R et les régions environnantes (avant et après le pic R) sont extraites pour inclure l'ensemble du battement cardiaque.

[17] Physionet : « Research Resource for Complex Physiologic Signals », créé en 1999 sous les auspices des National Institutes of Health (NIH). https://physionet.org/

On distingue entre segmentation statique et segmentation dynamique des battements cardiaques :

— Segmentation statique (segments de taille fixe) : Le pic R est d'abord détecté à l'aide d'un algorithme de détection du complexe QRS. Ensuite, une fenêtre fixe est définie autour du pic R pour capturer l'ensemble du battement cardiaque. Ce processus se répète pour chaque battement cardiaque. Différentes longueurs peuvent être utilisés, en fonction de la fréquence d'échantillonnage du signal et du type des battements à extraire. Des battements cardiaques à 200 [101], 250 [102], 256 [103], 260 [104] ou encore 360 [103] échantillons de longueur peuvent être extraits, ce qui correspond à des durées entre 500 ms et 1s.

— Segmentation dynamique : La segmentation dynamique repose sur l'analyse multi-échelle du signal ECG, décomposé par la transformée en ondelettes. Les composants à haute fréquence, comme le complexe QRS, apparaissent dans les niveaux supérieurs (coefficients de détail), tandis que les ondes P et T sont détectées dans les coefficients d'approximation des niveaux inférieurs. Après la détection du complexe QRS, la segmentation des battements s'effectue en identifiant les ondes P et T à l'aide des coefficients d'approximation. Par exemple, [72] ont utilisé la transformée en ondelettes pour distinguer le complexe QRS des ondes P, T, du bruit et des artefacts. L'algorithme de [105], basé sur les maxima et minima locaux à différentes échelles, identifie les limites du complexe QRS et les limites et pics des ondes P et T.

La segmentation des battements permet de détecter directement les événements physiologiques et de se concentrer sur la capture du cycle cardiaque complet, ce qui la rend utile pour la détection des arythmies. Cependant, elle nécessite une détection fiable des pics R.

b. Segmentation par fenêtre glissante

Dans cette approche, le signal ECG est divisé en segments superposés ou non, d'une durée généralement fixe (taille de la fenêtre), indépendamment de l'endroit où se trouvent les battements de cœur. La fenêtre se déplace dans le signal d'un nombre d'échantillons (taille du pas), glissant ainsi sur l'ensemble du signal. [106] ont proposé d'utiliser une fenêtre d'une longueur équivalente à 1,2 fois la durée moyenne de l'intervalle RR afin d'inclure des battements plus longs, tels que les contractions ventriculaires prématurées (PVC), avec un pas de 5 % de la longueur de la sous-séquence. [107] ont proposé une méthode de segmentation basée sur une fenêtre glissante à taille variable, avec un pas adaptatif.
Cette approche est simple et ne repose pas sur la détection des pics R, et est utile lorsqu'il s'agit de grands ensembles de données. Cependant, elle peut produire des segments qui ne contiennent que des battements de cœur partiels ce qui peut engendrer un manque des caractéristiques importantes si la taille de la fenêtre et le pas ne sont pas choisis avec soin.

c. Séquence complète (pas de segmentation)

Cette technique évite la segmentation de séquences courtes et traite de longues séquences du signal ECG comme entrée continue. Des modèles tels que les réseaux neuronaux récurrents (RNN) ou les transformateurs qui peuvent traiter des données séquentielles sont souvent utilisés pour ce type d'entrée. Celui-ci permet de capturer les dépendances et les tendances à long terme du signal et évite les problèmes potentiels causés par la segmentation, comme la perte de caractéristiques importantes aux limites des segments. En revanche, ce type d'entrée peut être

coûteux en termes de calcul et de mémoire, ainsi que certains modèles peuvent avoir du mal à capturer efficacement les schémas locaux sur l'ECG.

Dans notre approche, nous avons segmenté les battements cardiaques à l'aide de la transformée en ondelettes dynamique, afin de capturer de manière dynamique le cycle cardiaque complet dans le signal ECG, l'objectif étant d'appliquer une classification des battements cardiaques et non pas de longues séquences ECG.

2.2.4. Normalisation des données

La normalisation est une technique de prétraitement des données qui consiste à ajuster la plage de valeurs d'un ensemble de données pour faciliter l'analyse et l'interprétation. Parmi les techniques courantes de normalisation du signal ECG :

a. Normalisation Min-Max

Elle consiste à redimensionner les valeurs du signal dans un intervalle défini, entre 0 et 1. Elle permet d'éviter que certaines caractéristiques dominent d'autres en raison de leurs échelles différentes. Elle est souvent utilisée dans la littérature [103, 108, 109].

b. Normalisation Z-score (Standardisation)

C'est une technique utilisée pour transformer les données de manière à ce qu'elles aient une moyenne de 0 et un écart type de 1. Elle est souvent employée pour mettre les données sur une échelle standard, facilitant les comparaisons et améliorant les performances de certains algorithmes d'apprentissage automatique sensibles à l'échelle des données comme les modèles de régression linéaire ou les réseaux neuronaux.
La normalisation Z-score est fréquemment employée lors de l'entraînement des modèles d'apprentissage profond pour la classification des battements cardiaques [102, 104, 110].

c. Normalisation Min-Max modifiée

Elle consiste à redimensionner les valeurs du signal dans un intervalle défini, entre -1 et 1.

$$x' = 2\,\frac{x - \min(x)}{\max(x) - \min(x)} - 1 \qquad (2.4)$$

Ce type de normalisation est souvent utilisé lorsque l'on souhaite conserver une symétrie autour de zéro, ce qui peut être utile dans certaines architectures de réseaux neuronaux pour améliorer la stabilité [111, 112].
Il existe aussi des méthodes de normalisation adaptative permettant d'ajuster la normalisation en fonction des caractéristiques locales du signal.

2.2.5. Compression des données ECG

La compression des données est une technique utilisée pour réduire la quantité de données nécessaires pour représenter les signaux ECG tout en préservant les informations cliniques essentielles. Elle se divise en deux types : compression sans perte, qui conserve intégralement les données mais avec un taux de réduction limité (10-50 %), et compression avec perte, qui réduit davantage (jusqu'à 90 %) mais peut affecter la précision clinique si mal maîtrisée. Selon [113], les algorithmes de compression se classent en trois catégories : (1) compression directe,

(2) compression par transformation, et (3) extraction de paramètres. Les méthodes sans perte relèvent principalement des deux premières catégories. Les méthodes d'extraction seront abordées en Section 2.3.

a. Méthodes de compression directe des données (DDC)

Les méthodes de compression de données directes (DDC) exploitent la corrélation entre les échantillons pour éliminer la redondance dans le signal. Elles utilisent des techniques comme la prédiction, l'interpolation ou des codeurs à longueur variable. Les méthodes DDC se répartissent en plusieurs catégories [114] :

— Méthodes de codage entropique : Elles permettent de représenter efficacement l'information sur la base des propriétés statistiques des données [115-118].
— Méthodes de réduction de la redondance : Elles reposent sur l'utilisation de seuils prédéfinis, de prédictions et d'interpolations pour réduire la taille des données [119].
— Méthodes d'échantillonnage adaptatif : L'échantillonnage adaptatif est une technique employée pour la compression des signaux ECG, où le taux d'échantillonnage est ajusté dynamiquement selon les caractéristiques du signal [119-122].
— Modulation différentielle du code d'impulsion (DPCM) : Plutôt que d'encoder les valeurs réelles des échantillons, le DPCM se concentre sur la différence entre les échantillons consécutifs qui sont généralement plus petites que les valeurs des échantillons eux-mêmes [119, 123].

b. Méthodes basées sur des transformations

Les techniques de compression de l'ECG basées sur des transformées permettent de convertir le signal original du domaine temporel vers un autre domaine, tel que celui des fréquences ou des ondelettes, grâce à des méthodes mathématiques, avec une perte d'informations légère. Ce processus décompose le signal en coefficients qui capturent ses caractéristiques essentielles, concentrant ainsi l'énergie dans quelques coefficients significatifs. Voici quelques techniques de transformation couramment utilisées pour la compression de l'ECG : la transformée en ondelettes discrète (DWT) [124, 125], la transformée en cosinus discrète (DCT) [126-128], la transformée de Karhunen-Loève (KLT) [129, 130], et la transformée de Fourier rapide (FFT) [131, 132].
D'autres méthodes pouvant également être employées pour la compression incluent les fonctions d'Hermite discrètes [133, 134] et le codage en sous-bande [135, 136].

Dans le présent travail, nous n'avons utilisé aucune des méthodes de compression au signal ECG.

2.3. Extraction des caractéristiques ECG

L'extraction des caractéristiques ECG vise à capturer les informations les plus importantes du signal tout en réduisant la complexité des données. Des caractéristiques temporelles, fréquentielles, non linéaires et statistiques sont utilisées pour diagnostiquer les pathologies cardiaques. Dans cette section, nous passerons en revue les méthodologies d'extraction de caractéristiques communes qui ont été appliquées aux signaux ECG, qu'il s'agisse d'ECG à une seule dérivation ou d'ECG à plusieurs dérivations.

2.3.1. Domaine temporel

L'extraction des caractéristiques temporelles de l'ECG consiste à analyser les différentes phases du cycle cardiaque dans le domaine du temps pour en extraire des informations essentielles sur le fonctionnement du cœur.

a. Caractéristiques morphologiques et géométriques

Les caractéristiques morphologiques extraites du signal ECG sont essentielles pour analyser la santé cardiaque et peuvent être utilisées pour la détection d'arythmies. Voici quelques-unes des principales caractéristiques : Durées et amplitudes des ondes P, QRS et T, intervalles PR et QT, Intervalle RR, élévation et déviation du segment ST.

D'autres caractéristiques géométriques non linéaires caractérisant le signal ECG sont : le diagramme Poincaré, les indices CSI et CVI reflétant les activités sympathique et parasympathique, les indices d'asymétrie de la fréquence cardiaque (Guzik's Index GI, Slope Index SI, Area Index AI, Porta's Index PI), et les indices de fragmentation de la fréquence cardiaque (PIP, IALS, PSS, PAS) qui évaluent la structure des séries d'intervalles RR [137].

b. Caractéristiques statistiques

L'extraction des caractéristiques statistiques d'un signal ECG consiste à analyser le signal à travers des métriques statistiques afin de fournir des informations utiles sur la variabilité et la distribution des données. Les principales métriques sont : la moyenne, l'écart-type, la médiane, le premier quartile Q1 et le troisième quartile Q3, l'intervalle interquartile (IQR), l'asymétrie (Skewness), l'aplatissement (Kurtosis), le coefficient de variation et la moyenne des différences successives (MSSD). Le calcul de ces métriques est souvent appliqué aux intervalles RR [138-141]. D'autres paramètres ont été présentés dans la section sur la variabilité de la fréquence cardiaque (Voir Section 1.3.2.2).

D'autres méthodes statistiques comme l'analyse en composantes principales (PCA), l'analyse en composantes indépendantes (ICA) et l'analyse discriminante linéaire (LDA) peuvent être employées à la fois pour l'extraction de caractéristiques, la réduction de la dimensionnalité et la réduction de bruit. La PCA, largement employée pour classer les rythmes cardiaques à partir des signaux ECG [142-145], a plusieurs variantes telles que la PCA robuste, locale, généralisée, multilinéaire et à noyau. L'ICA, particulièrement efficace pour les signaux ECG multi-dérivations, décompose les signaux en composantes indépendantes en minimisant leur dépendance statistique [145, 146]. La LDA, quant à elle, utilise des combinaisons linéaires de caractéristiques comme classificateur linéaire pour l'extraction des caractéristiques ECG et la réduction des dimensions [145, 147, 148], avec des extensions comme la LDA régularisée, nulle, directe et à noyau.

c. Modèles autorégressifs (AR)

Les modèles autorégressifs (AR) sont largement utilisés pour l'extraction des caractéristiques des signaux ECG, car ils permettent de modéliser un signal en fonction de ses valeurs passées, offrant ainsi une représentation concise des données complexes. Les modèles autorégressifs multivariés (MAR) sont une extension des modèles autorégressifs (AR) univariés, ils tiennent compte de plusieurs séries temporelles simultanément, ce qui permet d'analyser les anomalies dans les interactions entre différentes composantes ou dérivations du signal ECG [149, 150].

d. Modèles de Markov cachés (HMM)

Les signaux ECG sont cycliques et complexes, mais ils suivent une séquence régulière d'événements (dépolarisation auriculaire, dépolarisation ventriculaire, repolarisation ventriculaire), ce qui correspond bien à la structure des HMM. Chaque segment du cycle cardiaque (onde P, complexe QRS, onde T) peut être modélisé comme un état caché. Les HMM sont utilisés pour estimer la transition entre ces états en fonction des observations du signal. Ces observations sont les caractéristiques extraites du signal ECG [151-153].

e. Dynamiques non-linéaire

D'autres caractéristiques issues des domaines temporel et des dynamiques non linéaires, ainsi que de l'analyse statistique [137], incluent : les mesures d'entropie (ApEn, SampEn, ShanEn, FuzzyEn, MSEn et ses variantes), qui évaluent la complexité et la prévisibilité du signal ; les mesures fractales (dimension de corrélation, dimensions fractales de Higuchi et de Katz), décrivant la structure du signal ; la complexité de Lempel-Ziv (LZC) et ses variantes, quantifiant la régularité via la détection de nouveaux motifs ; et l'analyse DFA, se concentrant sur les fluctuations et corrélations dans les séries temporelles.

2.3.2. Domaine fréquentiel/spectral

Parmi les méthodes utilisées dans le domaine fréquentiel pour l'extraction des caractéristiques ECG :

— La transformée de Fourier rapide (FFT) : C'est une méthode rapide pour calculer la transformée de Fourier discrète (DFT), réduisant la complexité de calcul de $O(N^2)$ à $O(N\,logN)$. La FFT permet d'analyser la distribution de l'énergie d'un signal ECG au fil du temps en fonction de ses composantes fréquentielles. Une fois la fréquence du spectre identifiée, un ensemble de caractéristiques spectrales peut être utilisé pour la classification des maladies cardiovasculaires [154-156].

— La méthode Welch : Elle améliore la stabilité de l'estimation de la densité spectrale de puissance par rapport à la FFT en divisant le signal en plusieurs segments qui se chevauchent, en calculant la transformée de Fourier de chaque segment, puis en moyennant les densités spectrales obtenues. Ce processus réduit la variance de l'estimation, offrant une représentation plus stable et lisse du spectre de puissance, particulièrement utile pour les signaux comportant des fluctuations importantes [157].

— La transformée en cosinus discrète (DCT) : Elle consiste à diviser le signal ECG en segments, puis à calculer les coefficients DCT pour chacun d'eux. Parmi ces coefficients, seuls les plus significatifs, souvent les premiers, sont retenus, car ils contiennent la majorité de l'énergie du signal [158].

2.3.3. Domaine temps-fréquence

L'analyse conjointe temps-fréquence est particulièrement pertinente pour traiter la non-stationnarité des signaux ECG. Dans cette partie, nous présentons les méthodes du domaine temps-fréquence qui permettent d'extraire des caractéristiques du signal ECG.

— La transformée de Fourier à court terme (STFT) : C'est une méthode puissante pour analyser des signaux non stationnaires. Elle divise le signal en segments de courte durée

et applique la Transformée de Fourier à chaque segment. Cela permet d'obtenir une représentation en temps et en fréquence. La STFT permet d'extraire des caractéristiques clés de l'ECG en observant les changements dans le spectre au fil du temps [159].

— La transformée en ondelettes (WT) : La WT permet d'identifier les pics R et segmenter les battements cardiaques par la décomposition à plusieurs niveaux. Les coefficients de décomposition peuvent être combinés aux mesures d'énergie, d'entropie et de variance des coefficients d'ondelettes pour former une entrée aux modèles d'apprentissage automatique afin de détecter les arythmies cardiaques [138, 160].

— La Distribution de Wigner-Ville (WVD) : Elle fournit une estimation de la densité spectrale de puissance instantanée avec une bonne résolution temps-fréquence, utile pour l'analyse dynamique des signaux ECG grâce à sa nature bilinéaire. Cependant, pour les signaux non stationnaires, elle présente des interférences croisées compliquant l'interprétation, ce qui peut être atténué par la distribution de Pseudo Wigner-Ville lissée (SPWVD). La WVD, en tant que représentation quadratique, permet d'extraire des caractéristiques temps-fréquence pour la classification des signaux [161, 162].

Il existe d'autres méthodes du domaine temps-fréquence qui peuvent être utilisées pour l'analyse et l'extraction de caractéristiques ECG, telles que la représentation par noyau en cône (CKR) et la distribution de Choi-Williams (CWD) [163, 164].

2.3.4. Domaine de la décomposition

Le principe fondamental des méthodes de décomposition repose sur la décomposition du signal ECG afin de sélectionner les composants pertinents et de rejeter ceux qui sont indésirables, contribuant ainsi également à la compression des données :

— La méthode de décomposition en mode empirique (EMD) divise le signal ECG en fonctions de mode intrinsèque (IMF), qui reflètent la distribution des fréquences du signal, allant des plus basses aux plus élevées. Les caractéristiques dérivées de l'EMD sont souvent utilisées pour la détection des arythmies [165].

— La décomposition en valeurs singulières (SVD) permet de décomposer une matrice en vecteurs singuliers capturant l'essentiel du signal. En ne conservant que les premières valeurs singulières, on obtient des caractéristiques globales représentant l'énergie des composantes principales du signal ECG [166, 167].

— La Décomposition en Échelles de Temps Intrinsèques (ITD) est une méthode qui se concentre sur la séparation des composantes du signal en fonction de leurs échelles temporelles intrinsèques. Elle a été introduit par [168] pour assurer une analyse temps-fréquence-énergie efficace.

— Le Matching Pursuit (MP) est une méthode itérative d'analyse de signaux qui permet d'extraire des caractéristiques pertinentes en représentant un signal comme une somme de fonctions de base (ou "atomes") choisies dans un dictionnaire de fonctions. Ces caractéristiques peuvent servir pour classifier les arythmies cardiaques [169]. L' Orthogonal Matching Pursuit (OMP), qui impose une condition d'orthogonalité à chaque étape de la décomposition, est aussi utilisé pour l'extraction des caractéristiques ECG [170].

2.3.5. Caractéristiques profondes

Les réseaux neuronaux profonds (DNN) apprennent automatiquement des caractéristiques complexes et non linéaires à partir des données brutes, sans nécessiter d'ingénierie manuelle. Les réseaux convolutionnels (CNN) capturent les motifs locaux des signaux ECG, tandis que les réseaux récurrents (RNN), comme LSTM et GRU, modélisent les dépendances temporelles à long terme. Les modèles hybrides CNN-LSTM combinent l'extraction locale et globale de caractéristiques, et les auto-encodeurs ainsi que les Deep Belief Networks (DBN) permettent une extraction non supervisée en apprenant des représentations compressées du signal [171, 172]. Les Transformers, grâce à l'attention, saisissent les dépendances globales des séquences ECG.

Par ailleurs, le Transfer Learning utilise des modèles pré-entraînés, comme ResNet, Inception ou VGG, ajustés pour les signaux ECG 1D afin de compenser le manque de données annotées et de réduire le temps d'entraînement, comme l'ont montré [173] et [174] dans des applications de classification des battements cardiaques.

Le Tableau 2.3 récapitule les méthodes d'extraction des caractéristiques ECG (par domaine) en citant les avantages et limitations de chacune.

Tableau 2.3. Comparaison entre les méthodes d'extraction des caractéristiques ECG.

Méthodes	Description	Avantages	Limitations
Domaine temporel	Extraction de caractéristiques directement à partir des valeurs du signal dans le temps (exemple : amplitude des pics, intervalles RR…).	Simple à implémenter et interpréter.	Sensible aux variations de bruit et aux artefacts.
Domaine fréquentiel	Analyse du signal ECG en utilisant des transformées pour extraire des caractéristiques fréquentielles (Ex : puissance des bandes de fréquence).	Permet de révéler des motifs cachés en fréquence.	Ne tient pas compte des variations temporelles; les signaux non stationnaires peuvent être mal interprétés.
Domaine temps-fréquence	Combinaison des analyses temporelles et fréquentielles, souvent via des méthodes comme la STFT ou la transformée en ondelettes.	Permet de capturer les variations dans le temps et la fréquence, adapté aux signaux non stationnaires.	Calcul coûteux, nécessite une bonne sélection des paramètres.
Domaine de décomposition	Utilisation de méthodes comme l'EMD ou la SVD pour décomposer le signal en composantes significatives.	Permet de séparer les composantes importantes du signal, aide à la compression de données. Robuste aux variations.	Les résultats de la décomposition peuvent varier en fonction des paramètres ou de la structure du signal, ce qui rend difficile la reproductibilité. Décomposition peut être coûteuse en calcul.

Caractéristiques profondes	Utilisation de modèles du Deep Learning (CNN, LSTM) pour apprendre automatiquement des caractéristiques à partir des données brutes.	Capacité à capturer des motifs complexes et des dépendances à long terme sans intervention humaine.	Nécessite un grand volume de données et des ressources de calcul ; peut manquer d'interprétabilité.

Dans le présent travail, nous avons utilisé un réseau résiduel, que nous avons entraîné, pour l'extraction des caractéristiques spatiales et hiérarchiques de l'ECG, tandis que les caractéristiques temporelles ont été obtenues par la méthode Orthogonal Matching Pursuit (OMP).

2.4. Génération des signaux synthétiques ECG

La génération de signaux ECG synthétiques est essentielle pour des applications telles que l'entraînement de modèles d'apprentissage automatique, le test de systèmes médicaux et l'amélioration de la robustesse des algorithmes de détection d'anomalies cardiaques. Il existe plusieurs méthodes pour générer des signaux ECG synthétiques réalistes, chacune avec ses avantages et ses limitations. Les modèles mathématiques et physiologiques offrent un contrôle précis sur les caractéristiques du signal, mais sont limités dans leur capacité à générer des variations réalistes. En revanche, les modèles du Deep Learning, comme les GANs (réseau antagoniste génératif), permettent de générer des signaux très réalistes, mais nécessitent une grande quantité de données et des ressources de calcul puissantes.

Dans cette section, nous présentons les principales méthodes de génération des données synthétiques.

2.4.1. Modèles paramétriques

Ces modèles utilisent des équations mathématiques basées sur des paramètres physiologiques pour reproduire les cycles cardiaques.

— Modèles sinusoïdaux : Ils génèrent des signaux à partir de la somme de plusieurs sinusoïdes. Les séries de Fourier ont été largement utilisées pour modéliser le signal ECG normal et pathologique car celui-ci est quasi-périodique [175, 176]. Chaque onde est modélisée par des sinusoïdes avec des paramètres ajustés (fréquence, amplitude, phase) pour calculer les coefficients de Fourier. Souvent les ondes Q, R et S sont modélisées par des formes triangulaires et les ondes P, T et U par des formes sinusoïdales ou paraboliques.

— Modèles à base d'équations différentielles : L'un des modèles mathématiques les plus connus est celui de McSharry [177]. C'est un modèle dynamique qui permet de générer des signaux ECG synthétiques à l'aide d'équations différentielles couplées pour modéliser les principales ondes (P, QRS, T) et les intervalles des cycles cardiaques. Les paramètres physiologiques, tels que l'intervalle RR ou la fréquence cardiaque, peuvent être ajustés pour générer des signaux réalistes dans des conditions normales ou pathologiques.

2.4.2. Modèles basés sur des processus stochastiques

Ces méthodes génèrent des signaux ECG en modélisant les signaux comme des processus stochastiques.

— Modèles ARMA (AutoRegressive Moving Average) : Ils génèrent des signaux ECG en représentant les données comme une combinaison d'un processus autorégressif (AR) et d'une moyenne mobile (MA). Le modèle est particulièrement utile pour représenter les signaux ECG comme des processus stationnaires avec des dynamiques temporelles simples. Le modèle ARMA peut être utilisé avec les équations de Yule-Walker pour estimer les paramètres et les variances de bruit [178]. D'autres variantes, comme le modèle GARMA [179] et la combinaison ARIMA-EGARCH [180], ont également été employées pour modéliser le signal ECG.
— Modèles Gaussiens : Les signaux ECG peuvent également être générés en modélisant chaque onde (P, QRS, T) avec des processus gaussiens qui suivent une distribution aléatoire mais cohérente avec les propriétés statistiques du signal réel. Les paramètres du modèle sont estimés par optimisation non linéaire. Par exemple, l'algorithme de Gauss-Newton a été utilisé dans [181] pour identifier les paramètres du modèle gaussien et modéliser les battements normaux et les contractions ventriculaires prématurées (PVC).

2.4.3. Méthodes basées sur la simulation physiologique

Ces méthodes modélisent les processus électro-physiologiques du cœur pour produire des signaux ECG synthétiques.

— Modèle d'activation cellulaire : Ce modèle simule les courants ioniques dans les cellules myocardiques pour générer des signaux ECG. L'équation de base est issue du modèle de Hodgkin-Huxley pour décrire la propagation des potentiels d'action [182].
— Modèle de réaction-diffusion : Ce modèle représente la propagation des potentiels d'action à travers le cœur, capturant l'activité à grande échelle (tissulaire). Il combine des équations différentielles qui décrivent la génération de potentiels d'action (réaction) et la diffusion de ces potentiels à travers les tissus cardiaques (diffusion) [183].

Les modèles physiologiques sont bien détaillés et capables de reproduire la physiologie réelle du cœur, mais possèdent une complexité élevée et ont besoin de ressources informatiques importantes.

2.4.4. Méthodes basées sur des modèles génératifs (Deep Learning)

Les modèles génératifs d'apprentissage profond permettent de générer des signaux ECG synthétiques en apprenant les caractéristiques des signaux ECG réels.

— Réseaux antagonistes génératifs (GAN) : Ces réseaux peuvent générer des signaux réalistes avec une grande variabilité, même pour des signaux complexes, mais nécessitent beaucoup de données d'entraînement. Plusieurs travaux proposent des modèles génératifs pour synthétiser des signaux ECG, servant de données d'entraînement supplémentaires afin d'améliorer la classification des rythmes cardiaques [184, 185].
— Auto-encodeur variationnels (VAE) : Ces réseaux apprennent à encoder les caractéristiques latentes du signal ECG pour générer de nouvelles instances, capturant des distributions complexes et des variations subtiles [186, 187]. Cependant, les signaux produits peuvent être moins réalistes que ceux générés par les GANs.

Les modèles génératifs de diffusion (Diffusion Models), récemment popularisés, ajoutent puis inversent progressivement du bruit, générant ainsi des données à partir du bruit.

2.4.5. Techniques d'augmentation des données

Des méthodes d'augmentation des données, telles que l'ajout de bruit ou l'interpolation entre les points de données, sont utilisées pour créer des variations réalistes des signaux ECG à partir de données existantes. Le but est d'augmenter le nombre d'exemples des classes minoritaires dans un ensemble de données déséquilibré. Voici un aperçu des techniques d'augmentation des données ECG.

a. Sur-échantillonnage simple

Cette méthode consiste simplement à dupliquer les échantillons de la classe minoritaire jusqu'à ce qu'elle atteigne la taille désirée. Bien que cette approche soit simple, elle n'augmente pas la diversité des données et peut conduire à un sur-apprentissage. La duplication peut être utilisée, dans le cas d'un petit ensemble de données ECG, pour obtenir un nombre d'exemples suffisant pour un entraînement initial. Un sur-échantillonnage aléatoire a été appliqué dans [188] pour générer des duplicates pour les classes d'arythmies.

b. SMOTE (Synthetic Minority Over-sampling Technique)

SMOTE est une technique qui génère des exemples synthétiques pour la classe minoritaire en interpolant entre des instances existantes. Pour chaque point dans la classe minoritaire, SMOTE identifie ses voisins proches (généralement définis par la distance euclidienne) et génère des exemples synthétiques le long des lignes qui relient le point aux voisins [189].
Si x_i est un point de la classe minoritaire et x_j est l'un de ses voisins, le nouvel exemple synthétique x_{new} est donné par :

$$x_{new} = x_i + \lambda \left(x_j - x_i\right) \tag{2.5}$$

Où λ est un coefficient aléatoire choisi dans l'intervalle $[0,1]$.

SMOTE est très efficace pour créer des ensembles de données ECG plus équilibrés, plus particulièrement dans des scénarios où les battements cardiaques sont rares [190, 191].

Plusieurs variantes de SMOTE ont été développées [192], notamment SMOTE-ENC, conçue pour les données avec caractéristiques numériques et catégorielles, utile pour enrichir les données ECG avec des métadonnées ; Borderline-SMOTE, qui génère des exemples synthétiques à partir des données près de la frontière entre classes minoritaires et majoritaires ; ADASYN, qui ajuste le nombre d'exemples synthétiques selon la difficulté de classer chaque point de la classe minoritaire ; et SMOTE-ENN, qui combine SMOTE avec une édition permettant d'éliminer les exemples mal classés par rapport à leurs voisins, améliorant ainsi la qualité des données augmentées avec un bruit réduit.

Dans cette thèse, nous avons adopté une variante de la méthode SMOTE, que nous avons développée, pour l'augmentation des données ECG.

2.5. Classification des arythmies cardiaques

La classification est une tâche d'apprentissage supervisé où l'objectif est d'assigner des entrées à des catégories prédéfinies. Dans le contexte du diagnostic des arythmies, les algorithmes de classification peuvent analyser des données ECG pour identifier différents types d'arythmies. Cela peut être réalisé à l'aide des méthodes classiques de Machine Learning (apprentissage automatique) ou par le biais des techniques de Deep Learning (apprentissage profond).

2.5.1. Classification par les méthodes classiques du Machine Learning

Dans la littérature, plusieurs méthodes ont été employées pour l'analyse et la classification des maladies cardiovasculaires à partir des signaux ECG. Les méthodes les plus couramment utilisées incluent [193, 194] : le **kNN (k plus proches voisins)** qui classifie les vecteurs de caractéristiques en fonction des étiquettes des échantillons d'apprentissage les plus proches dans l'espace des caractéristiques. Il a été appliqué dans plusieurs études sur la classification des signaux ECG [195-197]. Les **SVM (Machines à vecteurs de support)** repose sur la recherche d'une frontière de décision qui sépare les classes tout en maximisant la marge entre les points de données des différentes classes. Ils sont capables de traiter des problèmes de classification plus complexes et non linéaires [101, 103, 144, 160]. Les **arbres de décision** sont largement utilisés pour la classification des battements cardiaques en raison de leur capacité à segmenter les données selon des caractéristiques spécifiques [141, 198, 199]. Pour améliorer la précision et réduire le risque de sur-apprentissage, les **forêts aléatoires** combinent plusieurs arbres de décision, chaque arbre étant construit sur un sous-ensemble aléatoire des données d'apprentissage [108, 138, 197]. Le **classificateur bayésien**, fondé sur la théorie de la décision de Bayes, peut également être appliqué à la classification des arythmies cardiaques en utilisant certaines de ses variantes, comme les réseaux bayésiens, le Naïve Bayes, ou le classificateur de vraisemblance maximale de Bayes [200-202].

En complément des méthodes de classification précédemment citées, plusieurs autres classificateurs ont été utilisés pour la classification des signaux ECG, parmi lesquels : le classificateur à logique floue [203], le modèle de mélange gaussien [204, 205], la régression linéaire [206], la régression logistique [207, 208], l'algorithme de colonie d'abeilles artificielles [209], ainsi que des modèles d'ensemble tels que le Bagging et AdaBoost [207], la méthode Bootstrap [210], les modèles de Markov cachés [211] et le Boosting avec sous-échantillonnage

aléatoire [212]. En outre, des techniques d'apprentissage non supervisé comme le clustering flou [213, 214] et le k-means [200, 215] sont également employées.

2.5.2. Classification par le Deep Learning

Les méthodes de Deep Learning reposent sur des réseaux neuronaux multicouches permettant d'apprendre des représentations hiérarchiques des données. Nous avons sélectionné plusieurs méthodes pour leur apport spécifique dans l'analyse des caractéristiques et la classification des signaux ECG. Celles-ci sont synthétisées dans un tableau comparatif (Tableau 2.4), qui en présente la description, les avantages et les limitations [216, 217].

Tableau 2.4. Comparaison entre les méthodes du Deep Learning pour la classification des arythmies cardiaques.

Méthode	Description	Avantages	Limitations
Perceptron multicouches (MLP)	Réseau multicouche d'interconnexions pour capturer les relations non linéaires dans l'ECG [218-220].	Adapté à la classification des arythmies à partir des séquences ECG de longueur fixe et à la représentation des relations complexes dans les données ECG.	Incapable de capturer les connexions temporelles entre les données d'entrée.
Réseau de neurones convolutionnel (CNN)	Utilisation de noyaux pour extraire des motifs spatiaux dans les données ECG. Les 1D-CNN appliquent les noyaux le long de la dimension temporelle [112, 121, 122] et les 2D-CNN opèrent sur des données convertis en images ou formats bidimensionnels [223-225].	Efficace pour extraire des caractéristiques locales telles que la forme des ondes. Capable de différencier entre le rythme normal et rythme anormal.	Difficultés à capturer les dépendances temporelles à long terme.
Réseau de neurones récurrent (RNN)	Réseau doté de mécanisme de rétroaction pour capturer les corrélations temporelles grâce aux connexions cycliques [222, 226, 227].	Utile pour analyser les séquences temporelles dans les signaux ECG et identifier les anomalies cardiaques.	Problème d'évanescence du gradient, limitant l'apprentissage des dépendances à long terme (moins performant sur les séquences longues).
Réseau à mémoire à long et court terme (LSTM)	Variante du RNN avec des cellules de mémoire et des portes qui régulent le flux d'informations dans ces cellules, capable de conserver des informations à long terme [102, 228, 229].	Surmonte l'évanescence du gradient, bien adapté aux séquences ECG longues.	Coût computationnel élevé, ce qui peut être limitant avec de grands ensembles de données.
Réseau récurrent à portes (GRU)	Variante des RNN. Il se distingue par l'intégration	Modélise efficacement les séquences	Requiert des ressources

	des portes de mise à jour et de réinitialisation pour filtrer les informations non pertinentes [222, 230, 231].	temporelles et les dépendances à long terme entre les battements cardiaques. Atténue le problème d'évanescence du gradient,	informatiques importantes pour les grandes bases de données, par rapport au LSTM.
Auto-encodeur	Constitué d'un encodeur qui représente le signal ECG dans un espace latent de dimension réduite, et d'un décodeur qui reconstruit le signal ECG. Des variantes telles que les CAE et VAE sont employées pour la classification des signaux ECG [232-234].	Variantes CAE et VAE qui exploitent les hiérarchies spatiales présentes dans les signal et sont adaptées aux données ECG en 1D et 2D.	Limités dans la capture des relations complexes et non linéaires dans un signal ECG. Mauvaise généralisation sur les nouvelles données.
Réseau de croyances profond (DBN)	Empile plusieurs couches de machines de Boltzman restreintes (RBM), avec une couche visible et une couche cachée, pour apprendre la distribution de probabilité des données en ajustant les pondérations entre ces couches [235-237].	Permet une abstraction de haut niveau pour l'identification de motifs cachés susceptibles d'indiquer des arythmies.	Nécessite un grand volume de données étiquetées, souvent rares pour les arythmies.
Transformer	Modèle basé sur l'auto-attention, capturant les dépendances à long terme et les informations contextuelles [238-241].	Extraire simultanément les motifs globaux et locaux dans les signaux ECG..	Haute complexité computationnelle et ajustement d'hyper-paramètres complexe.

Des modèles hybrides ont également été élaborés afin tirer parti de la puissance de chaque architecture. La majorité des travaux publiés a porté sur la combinaison des réseaux LSTM et CNN [191, 242-244]. D'autres études ont exploré des associations telles que la logique floue combinée aux réseaux de neurones [245], l'auto-encodeur convolutif couplé à un LSTM pour la compression des données avant la détection des arythmies [229], ainsi que la combinaison du CNN et du GRU bidirectionnel [246]. Par ailleurs, un classificateur en cascade, intégrant une forêt aléatoire et un perceptron multicouche, a aussi été utilisé [138]. Des architectures plus sophistiquées, telles que GoogLeNet [247], U-Net [110] et ResNet [248], ont également été employées pour la classification des battements cardiaques.

2.5.3. Métriques d'évaluation

Pour les tâches de classification, les principales métriques d'évaluation utilisées dans la plupart des études incluent : l'accuracy, la précision, le rappel ou sensibilité, le F1-score, la spécificité, le coefficient de corrélation de Matthews ainsi que l'aire sous la courbe ROC.

— Accuracy : Elle mesure la proportion de prédictions correctes par rapport au nombre total de prédictions effectuées. Elle est formulée comme suit :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.6)$$

Où TP est le nombre de prédictions correctes pour les instances positives, TN est le nombre de prédictions correctes pour les instances négatives, FN est le nombre de prédictions incorrectes pour les classes positives, et FP est le nombre de prédictions incorrectes pour les classes négatives.

— Précision : La précision est une métrique qui mesure la proportion des instances positives réelles par rapport au nombre total d'instances prédites positivement. Elle est formulée comme suit :

$$Précision = \frac{TP}{TP + FP} \quad (2.7)$$

— Rappel/Sensibilité : C'est la proportion des instances positives réelles parmi tous les exemples réellement positifs. Elle est formulée par :

$$Rappel = \frac{TP}{TP + FN} \quad (2.8)$$

— F1-score : C'est une mesure qui prend en compte à la fois la capacité du modèle à prédire correctement les instances positives (précision) et sa capacité à identifier toutes les instances positives (rappel).

$$F1 - score = 2 \frac{Précision \times Rappel}{Précision + Rappel} \quad (2.9)$$

— Spécificité : Elle est aussi appelée taux de vrais négatifs. Elle mesure la capacité d'un modèle à correctement identifier les instances négatives parmi toutes les instances qui sont réellement négatives.

$$Spécificité = \frac{TN}{TN + FP} \quad (2.10)$$

— Coefficient de corrélation de Matthews (MCC) : Il est utilisé pour mesurer la corrélation entre les classes réelles et les classes prédites. Il prend en compte tous les résultats de la classification et fournit une évaluation globale de la précision du modèle. Le MCC varie entre -1 et 1 : une valeur de 1 indique une parfaite corrélation (tous les résultats sont corrects), une valeur de 0 indique aucune corrélation (les prédictions sont aléatoires), et la valeur -1 indique une corrélation négative parfaite (tous les résultats sont incorrects).

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TP + FP)(TN + FN)}} \quad (2.11)$$

— Aire sous la courbe ROC: Elle quantifie la capacité du modèle à distinguer entre les classes positives et négatives. La courbe ROC est une représentation graphique du taux de vrais positifs (rappel) par rapport au taux de faux positifs à différents seuils de décision.

Une valeur AUC = 1 indique que le modèle classifie parfaitement toutes les instances, une valeur AUC = 0.5 indique que le modèle ne fait pas mieux qu'un choix aléatoire, une valeur AUC < 0.5 indique que le modèle est mal spécifié.
L'AUC est insensible aux déséquilibres de classe, car elle évalue le modèle à tous les seuils possibles.

2.6. Conclusion

En conclusion, ce chapitre a exploré les étapes clés du traitement des signaux ECG. Nous avons souligné l'importance du prétraitement, qui prépare les données pour la classification, ainsi que les méthodes d'extraction des caractéristiques, qui permettent de tirer des informations essentielles des signaux.

La génération de signaux synthétiques, notamment par des approches mathématiques et des modèles génératifs, a également été discutée comme un moyen d'augmenter la quantité des données pour l'entraînement des modèles de classification. Enfin, nous avons présenté les méthodes de classification des signaux ECG ; l'utilisation des méthodes de Deep Learning a conduit à des avancées significatives. Ces méthodes peuvent automatiquement apprendre à reconnaître des motifs complexes dans les signaux ECG, ce qui améliore la précision du diagnostic par rapport aux approches traditionnelles. Cependant, les méthodes classiques restent utiles, en particulier lorsqu'il existe des données limitées ou lorsque des interprétations plus explicites des caractéristiques sont nécessaires.

Dans les chapitres suivants, nous présenterons nos contributions de thèse : le chapitre 3 sera dédié à l'augmentation des données afin de résoudre le problème de déséquilibre des bases de données ECG, tandis que les chapitres 4 et 5 traiteront la classification des battements cardiaques à l'aide d'une nouvelle architecture basée sur la modulation focale, améliorant ainsi la précision de la détection des battements cardiaques par rapport aux travaux de la littérature.

3. Développement de la variante DTW-SMOTE pour l'augmentation des données

Sommaire

3.1. Introduction 83
3.2. Méthodologie proposée 83
3.3. Description des bases de données ECG 84
3.4. Prétraitement des données ECG 86
3.4.1. Réduction de bruit 86
3.4.2. Normalisation du signal ECG 91
3.4.3. Segmentation des battements cardiaques 91
3.5. Augmentation des battements cardiaques 95
3.5.1. Principe de la méthode SMOTE classique 95
3.5.2. La distance de similarité DTW 95
3.5.3. Implémentation de la méthode DTW-SMOTE 96
3.6. Evaluation de la performance de la variante DTW-SMOTE 99
3.7. Conclusion 100

3.1. Introduction

La génération de données synthétiques est devenue une pratique essentielle dans le domaine de l'analyse des signaux ECG, notamment pour pallier les déséquilibres et les insuffisances des ensembles de données utilisés pour entraîner des modèles d'apprentissage automatique. Plusieurs approches ont été explorées dans la littérature. Les méthodes paramétriques, basées sur des modèles mathématiques ou stochastiques, offrent un contrôle précis des caractéristiques du signal, mais peinent à capturer les variations réalistes observées dans des conditions réelles. À l'inverse, les approches basées sur des modèles génératifs comme les GANs ou les auto-encodeurs variationnels permettent de générer des signaux synthétiques très proches des données réelles, mais leur efficacité dépend de la disponibilité de larges volumes de données d'entraînement et de ressources de calcul conséquentes.

Une autre classe de méthodes, les techniques d'augmentation des données, comme le SMOTE (Synthetic Minority Over-sampling Technique), a été largement adoptée pour traiter les ensembles de données déséquilibrés. Le SMOTE, en interpolant entre des exemples existants, génère des données synthétiques qui enrichissent les classes minoritaires et améliorent ainsi les performances des modèles de classification. Cependant, les variantes classiques du SMOTE présentent des limitations lorsqu'il s'agit de capturer les particularités des signaux ECG, notamment leur nature temporelle et quasi-périodique.

Dans ce contexte, nous avons développé une nouvelle variante, DTW-SMOTE, qui tire parti de la distance de similarité DTW (Dynamic Time Warping) pour mieux préserver les caractéristiques temporelles des signaux ECG. Ce chapitre présente les étapes préliminaires nécessaires, notamment le prétraitement des signaux ECG pour garantir leur qualité (réduction du bruit, normalisation et segmentation). Ensuite, nous décrivons en détail le développement et l'implémentation de notre variante DTW-SMOTE. Enfin, nous évaluons les performances de cette méthode, en mettant en avant ses apports pour améliorer la classification des arythmies, soulignant ainsi sa pertinence dans le cadre des travaux de cette thèse.

3.2. Méthodologie proposée

La méthodologie proposée de l'approche globale de classification des battements cardiaques pour le diagnostic de l'arythmie repose sur un processus structuré en trois phases principales. Tout d'abord, l'acquisition des signaux ECG constitue l'étape initiale, où les données brutes sont collectées pour être soumises aux étapes de traitement ultérieures. Ces données brutes subissent ensuite un prétraitement visant à améliorer leur qualité et leur fiabilité. Ce prétraitement inclut la réduction du bruit pour minimiser les interférences, la normalisation des signaux afin de les rendre comparables entre eux, ainsi que la segmentation des battements cardiaques pour isoler les cycles cardiaques. Une étape cruciale est l'augmentation des données, réalisée à l'aide de la variante DTW-SMOTE, pour enrichir l'ensemble des battements cardiaques minoritaires.

Dans une seconde phase, les caractéristiques pertinentes sont extraites et sélectionnées à partir des signaux prétraités. Ces caractéristiques, qui encapsulent les informations essentielles des battements cardiaques, servent d'entrées pour les modèles de classification.

Enfin, la troisième phase se concentre sur l'élaboration et l'évaluation du modèle de classification. Les données sont divisées en trois sous-ensembles : apprentissage, validation et test. Le modèle est entraîné sur les données d'apprentissage, ses hyper-paramètres sont ajustés grâce à la validation, et ses performances sont évaluées sur les données de test. Cette approche rigoureuse garantit la fiabilité et la généralisabilité du modèle final, conçu pour améliorer la classification des arythmies à partir des signaux ECG.
La Figure 3.1 illustre les étapes principales de la méthodologie proposée.

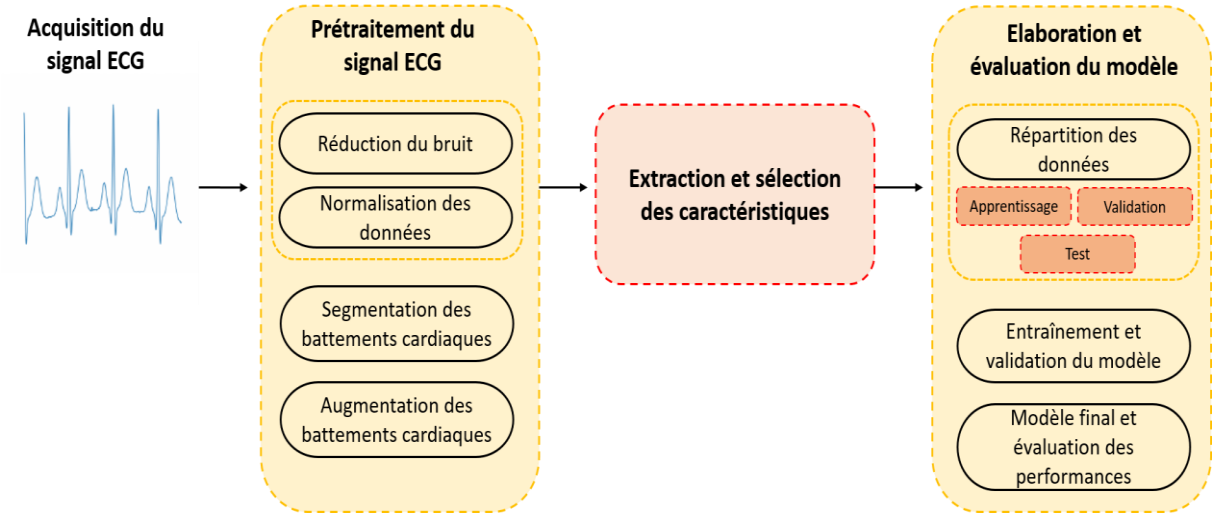

Figure 3.1. Diagramme synoptique de la méthodologie proposée.

L'objectif est de concevoir un modèle de classification dont l'entrée est un signal numérique et la sortie correspond à une classe de battement cardiaque. Les étapes de prétraitement et d'extraction des caractéristiques constituent le cœur de cette méthodologie, visant à convertir les données numériques temporelles en informations quantitatives exploitables. Les sections suivantes détaillent ces étapes, en mettant particulièrement l'accent dans ce chapitre sur la préparation des données et le développement de la variante DTW-SMOTE pour l'augmentation des données.

3.3. Description des bases de données ECG

Plusieurs bases de données publiques sont disponibles dans le Répertoire Physionet [11] pour évaluer les méthodes proposées dans les études ciblant l'analyse des signaux ECG. Les bases de données suivantes sont largement utilisées et ont été sélectionnées dans le cadre de ce travail pour la classification des arythmies :

- La base de données « MIT-BIH Arrhythmia » (MITDB) [249] : Elle comprend 48 enregistrements ECG à deux dérivations. Ces enregistrements ont été recueillis entre 1975 et 1979 à l'hôpital Beth Israel de Boston et proviennent de 47 sujets dont 25 hommes et 22 femmes. Les hommes ont entre 32 et 89 ans, tandis que les femmes ont entre 23 et 89 ans (deux enregistrements proviennent du même sujet masculin parmi tous les enregistrements). Chaque séquence a une durée d'une demi-heure.

La fréquence d'échantillonnage est de 360 échantillons par seconde, et la résolution de numérisation est de 11 bits sur une plage de 10 mV. La base de données englobe dix-sept types distincts de battements cardiaques, ils sont listés dans l'Annexe A.

- La base de données « MIT-BIH Normal Sinus Rhythm » (NSRDB) [11] : Elle contient 18 enregistrements ECG à long terme de sujets ne présentant pas d'arythmies significatives. Les sujets se composent de 5 hommes, âgés de 26 à 45 ans, et de 13 femmes, âgées de 20 à 50 ans. Les enregistrements ont été échantillonnés à un taux de 128 échantillons par seconde pour chacune des dérivations, avec une résolution de 12 bits. Cette base de données sert de référence pour la détection et la classification des battements cardiaques sinusaux normaux.

Le Tableau 3.1 reprend les informations des bases de données présentées ci-dessous : le nombre d'enregistrements, le nombre de sujets, la durée de chaque enregistrement, la fréquence d'échantillonnage, et le nombre de dérivations pour chaque base de données.

Tableau 3.1. Description des bases de données utilisées dans l'analyse du signal ECG.

Base de données	Sujets	Enregistre-ments	Dérivations	Durée	Fréquence (Hz)
MIT-BIH Arrhythmia	47	48	2	30 min	360
MIT-BIH Normal Sinus Rhythm	18	18	2	24 h	128

Les Figures 3.2 et 3.3 illustre deux séquences ECG, chacune d'une durée de 5 secondes, extraites des bases de données MITDB et NSRDB.

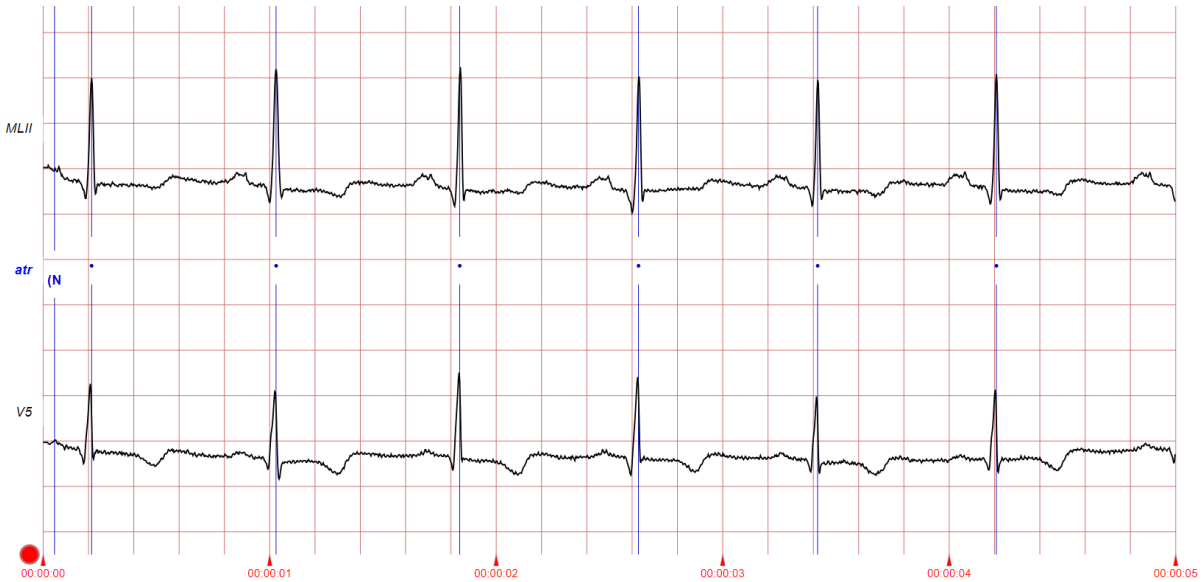

Figure 3.2. Signal ECG extrait de MITDB de l'enregistrement '100', représentant deux dérivations.



Figure 3.3. Signal ECG extrait de NSRDB de l'enregistrement '16539', représentant deux dérivations.

Dans cette étude, les signaux sont extraits des dérivations MLII et V5. La dérivation MLII est la version modifiée de la dérivation des membres II standard, qui ajuste légèrement les placements des électrodes. Elle est obtenue en plaçant une électrode négative au poignet droit, une électrode positive à la cheville gauche, et une électrode de référence au bras gauche. Cela donne une bonne visualisation des ondes P, des complexes QRS et des ondes T, ce qui est crucial pour la détection des arythmies. La dérivation V5 est une dérivation précordiale, placée sur le 5e espace intercostal gauche. Elle capture les signaux électriques au niveau de la paroi latérale gauche du cœur, qui est un point sensible pour l'analyse des anomalies ventriculaires. En utilisant les dérivations MLII et V5, on combine une vue générale du rythme cardiaque (via MLII) et une analyse régionale spécifique (via V5).
(Ces dérivations sont détaillées et illustrées dans la partie 1.3.1.1)

3.4. Prétraitement des données ECG

Après la préparation initiale des données, qui consiste à collecter et organiser les signaux ECG bruts, intervient l'étape cruciale de prétraitement. Cette phase a pour objectif de transformer les signaux bruts en données exploitables pour les étapes ultérieures d'analyse et de classification. Cette section détaille les processus de réduction de bruit, de normalisation du signal et de segmentation des battements cardiaques, indispensables pour améliorer la précision des méthodes de classification.

3.4.1. Réduction de bruit

L'objectif principal de la réduction du bruit est d'éliminer ou de minimiser les variations aléatoires du signal. Cette technique vise à améliorer la clarté de l'information tout en améliorant le rapport signal/bruit. Le signal ECG contient différents types de bruit, comme présenté dans la section 2.2.1, chacun devant être éliminé à l'aide d'un filtre spécial.

La dérive de la ligne de base est un artefact à basse fréquence (inférieures à 0,5 Hz) qui provient des électrodes chargées ou des mouvements et de la respiration du patient. Un filtre

passe-haut Butterworth d'ordre 5 [30] avec une fréquence de coupure de 0,5 Hz est utilisé, ce qui signifie que le filtre bloque toute composante de fréquence inférieure à 0,5 Hz (dérive).
Le gain G_n du filtre de Butterworth d'ordre n est donné par l'équation suivante :

$$G_n(\omega) = \frac{1}{\sqrt{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}}} \quad (3.1)$$

Où ω est la fréquence du filtre et ω_c est la fréquence de coupure.

Afin d'optimiser la réduction du bruit, différents ordres de filtre compris dans l'intervalle [2, 9] ont été testés. Les performances des ordres ont été évaluées quantitativement à l'aide des métriques SNR et MSE. Les résultats ont montré que les ordres 4 et 5 offraient les meilleurs compromis entre une atténuation efficace des composantes basse fréquence et une distorsion minimale du signal ECG. Pour la majorité des enregistrements ECG, l'ordre 5 a été retenu, offrant une bonne réduction de la dérive avec des valeurs de MSE comprises entre 0,01 et 0,09, tout en préservant l'intégrité du signal ECG, comme confirmé par des observations qualitatives.

L'interférence des lignes électriques est un artefact à haute fréquence causé par une mauvaise mise à masse de l'équipement ECG. Nous lissons le signal avec un noyau à moyenne glissante (Moving Average Kernel), qui est un filtre à réponse impulsionnelle finie (FIR) [36] privilégié lorsqu'il s'agit de données de séries temporelles, avec une largeur d'une période de 50 Hz. Le filtre consiste à remplacer chaque point du signal par la moyenne des points voisins dans une fenêtre de taille définie. Il est généralement conçu pour éliminer toutes les hautes fréquences. La sortie d'un filtre FIR d'ordre n est donnée par l'équation suivante :

$$y(k) = \sum_{i=0}^{n} b_i * x(k-i) \quad (3.2)$$

Où $x(k)$ est le signal d'entrée et b_i sont les poids du filtre.

La Figure 3.4 illustre le résultat de suppression des bruits basse fréquence et haute fréquence du signal ECG. On remarque que le filtre de Butterworth, grâce à sa réponse en fréquence lisse, minimise la distorsion du signal ECG d'origine tout en supprimant efficacement la dérive de la ligne de base. Il est aussi facile à concevoir et à implémenter numériquement.

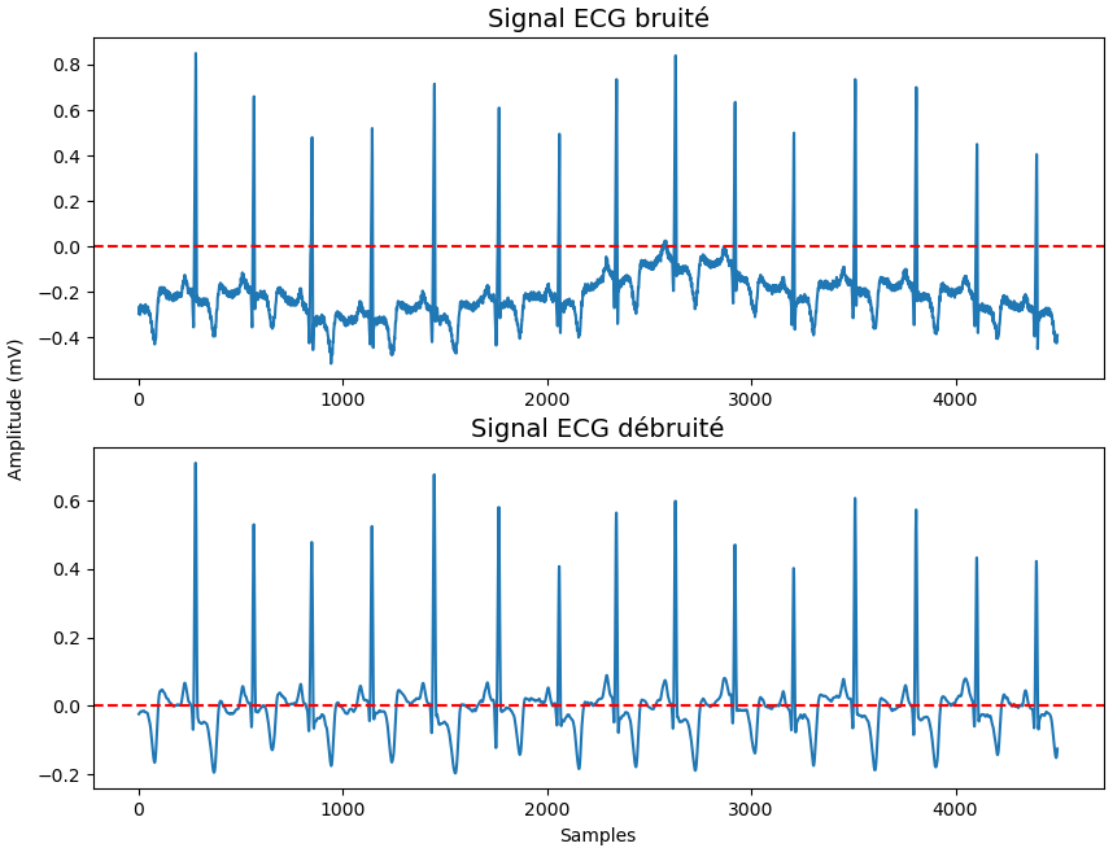

Figure 3.4. Signal ECG bruité Vs signal ECG débruité. La ligne rouge illustre la correction de la dérive de la ligne de base.

Pour comparer la qualité de réduction du bruit avec les méthodes appliquées ci-dessus « Butterworth et FIR », nous proposons d'appliquer une autre méthode de réduction du bruit basée sur la décomposition du signal : la méthode de transformée en ondelettes discrète DWT. Plusieurs fonctions ondelettes seront testées dans ce cadre, notamment les ondelettes 'Daubechies', 'Symlet' et 'Biorthogonal', avec différents ordres pour chacune.

L'évaluation des performances des méthodes appliquées sera effectuée pour chaque enregistrement ECG et chaque dérivation du signal, en utilisant les métriques suivantes : l'erreur quadratique moyenne (MSE), le pourcentage de différence quadratique moyenne (PRD), et le rapport signal sur bruit (SNR).

La méthode DWT a été évaluée à l'aide de plusieurs types d'ondelettes : 'db2', 'db4', 'db6', 'sym2', 'sym4', 'sym6', 'bior1.1', 'bior1.3' et 'bior2.2', ainsi qu'avec différents niveaux de décomposition allant de 3 à 9. Cette configuration génère ainsi 63 combinaisons de paramètres pour chaque enregistrement ECG. Le Tableau 3.2 illustre un extrait des résultats obtenus lors de la réduction du bruit par DWT pour l'enregistrement '100' de la base de données MITDB. Seul le meilleur résultat sera retenu pour une comparaison avec les performances du filtrage par les filtres « Butterworth et FIR ».

Tableau 3.2. Combinaison de 63 paramètres pour la réduction du bruit avec la méthode DWT.

	Ondelette	Niveau	MSE	PRD	SNR
1	db2	3	0.0003	4.6036	26.738
2	db2	4	0.0003	4.3721	27.1862
3	db2	5	0.0002	4.3243	27.2817
4	db2	6	0.0002	4.3211	27.2882
5	db2	7	0.0002	4.3154	27.2995
...	...	...	...	...	...
58	bior2.2	5	0.0001	3.2446	29.7769
59	bior2.2	6	0.0001	3.2397	29.79
60	bior2.2	7	0.0001	3.2281	29.821
61	bior2.2	8	0.0001	3.2198	29.8436
62	bior2.2	9	0.0001	3.2174	29.8499

Nous procédons à une comparaison des résultats obtenus pour chaque méthode appliquée à chaque patient, en évaluant les métriques MSE, PRD et SNR. Il est à noter que la suppression du bruit à l'aide de la méthode DWT surpasse les performances de la méthode « Butterworth et FIR », mais avec moins de qualité visuelle. Cela peut être expliqué par le fait que la première méthode parvient à éliminer une partie du bruit de manière globale, mais laisse subsister certains artefacts ou un bruit gênant, ce qui donne un SNR élevé sans pour autant améliorer la qualité du signal. En revanche, la deuxième méthode peut mieux préserver les détails du signal, mais avec un SNR plus faible.
De plus, nous envisageons de réaliser une augmentation des données ECG. Avec un SNR relativement faible, les caractéristiques cliniques essentielles sont bien préservées, permettent ainsi de générer des données synthétiques de qualité, qui reflètent mieux les variations réelles observées dans les ECG.

Les Figures 3.5 et 3.6 illustrent la suppression du bruit avec les méthodes « Butterworth + FIR » et DWT respectivement.

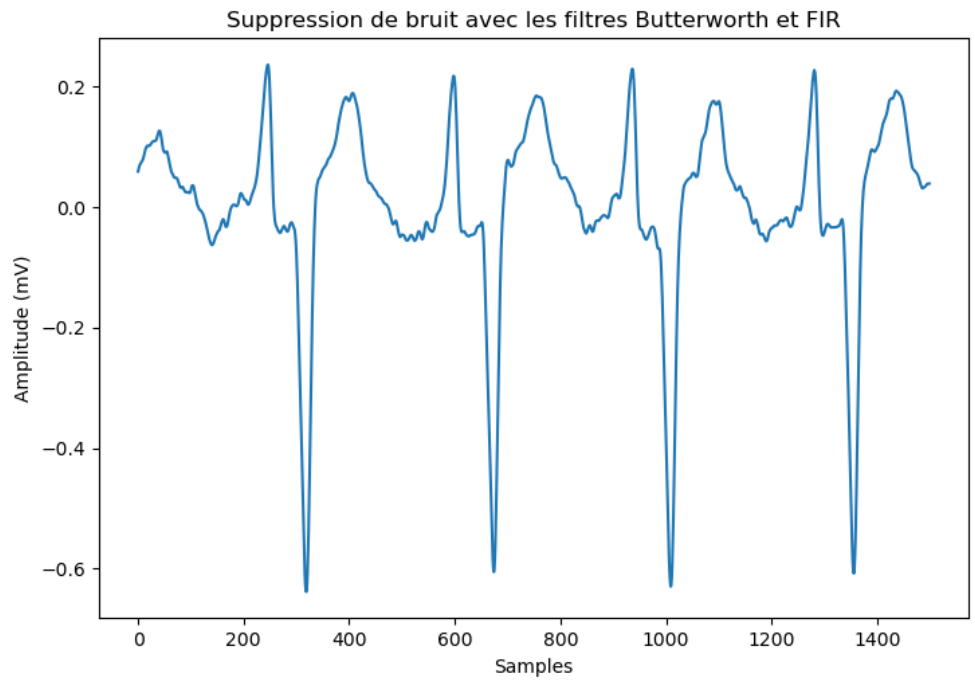

Figure 3.5. Application de la méthode "Butterworth et FIR" à l'enregistrement '102' de la base de données MITDB.

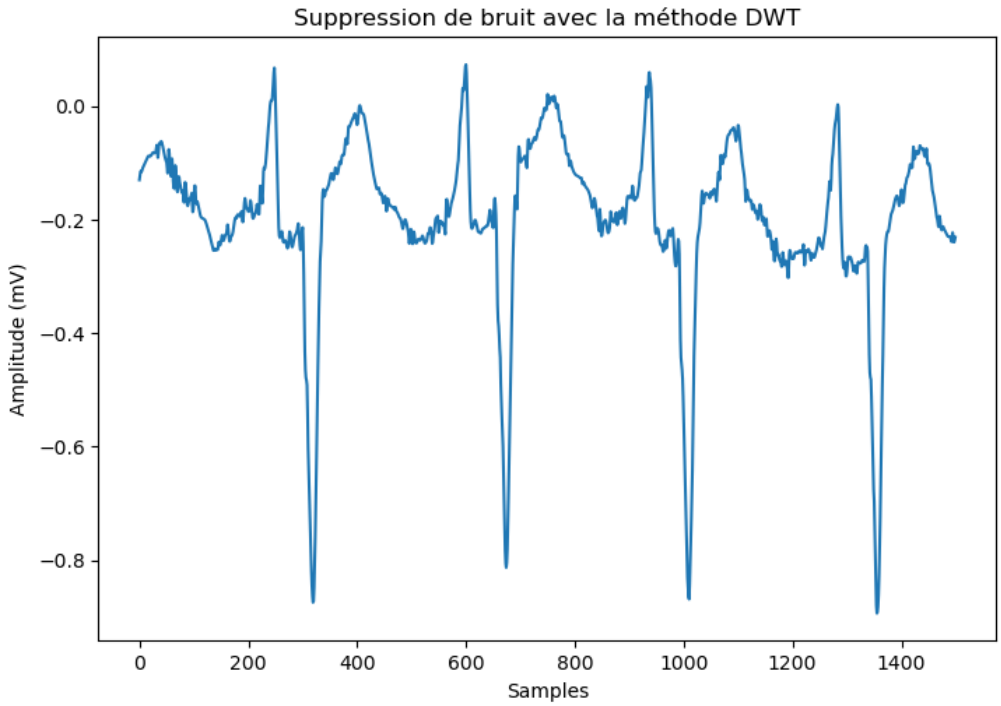

Figure 3.6. Application de la méthode DWT à l'enregistrement '102' de la base de données MITDB.

3.4.2. Normalisation du signal ECG

Après la réduction de bruit, la normalisation des données est une étape essentielle pour atténuer l'impact des valeurs aberrantes et assurer une représentation cohérente des signaux. La normalisation Min-Max est une technique de standardisation des données couramment utilisée pour remettre à l'échelle des données numériques dans une plage spécifique par le biais d'une transformation linéaire. En normalisant les valeurs d'amplitude dans la plage [0,1], la méthode Min-Max peut améliorer la comparabilité des signaux ECG entre différents enregistrements et patients, réduisant ainsi l'impact des écarts d'amplitude. De plus, lors de l'entraînement d'algorithmes d'apprentissage automatique, les données normalisées aident à stabiliser les gradients et à accélérer la convergence des modèles.

3.4.3. Segmentation des battements cardiaques

Dans cette approche, l'objectif est de classifier les battements cardiaques où chaque battement correspond à un cycle cardiaque. À partir d'un signal nettoyé de longue durée, de courts segments correspondants aux battements de cœur sont extraits en utilisant la méthode de la transformée en ondelettes discrète (DWT). Il n'est pas nécessaire d'appliquer une détection des pics R, car nous nous appuyons sur les annotations déjà fournies par la base de données MITDB. La Figure 3.7 illustre les positions des pics R dans un signal ECG extrait de la base de données MITDB.

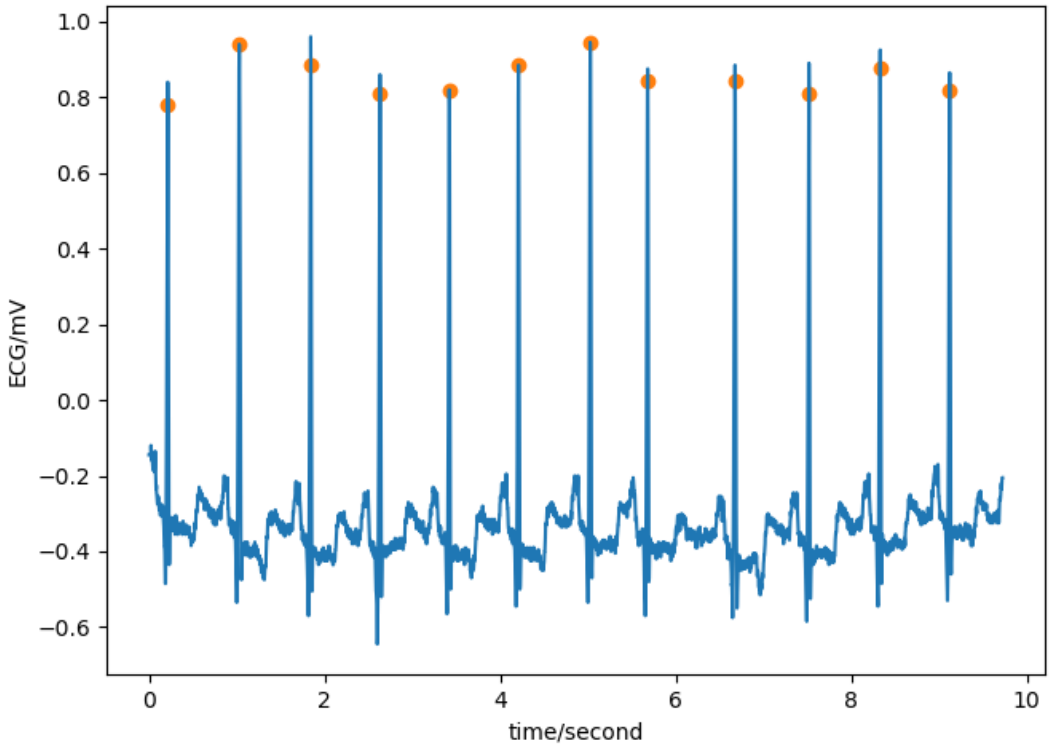

Figure 3.7. Positions des pics R.

La transformée en ondelettes discrète (DWT) est employée pour segmenter dynamiquement le signal ECG en détectant les débuts des ondes P et les fins des ondes T, en s'appuyant sur les annotations des pics R.

La DWT est une décomposition temps-fréquence qui analyse le signal ECG en différentes échelles de fréquence :

$$W_x(a,b) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) dt \quad (3.3)$$

Où :

— $\psi(t)$ est l'ondelette mère.
— a est le facteur d'échelle (contrôle la dilatation/compression).
— b est le facteur de translation (décalage temporel).

Dans cette étude, nous avons adopté l'approche DWT proposée par [105], où l'ondelette mère utilisée est une spline quadratique bi-orthogonale. Cette méthode a démontré son efficacité grâce à ses performances élevées, validées sur 980 000 battements cardiaques, avec une sensibilité de 99,66 % et une prédictivité positive de 99,56 % [105].

La DWT permet de décomposer le signal en le faisant passer à travers une série de filtres passe-bas et passe-haut :

- **Passe-bas** ($G[n]$) : extrait les approximations Aj (basses fréquences), au niveau j.
- **Passe-haut** ($H[n]$) : extrait les détails Dj (hautes fréquences), au niveau j.

$$A_j[n] = \sum_k A_{j-1}[k]\, G[2n-k] \quad (3.4)$$

$$D_j[n] = \sum_k A_{j-1}[k]\, H[2n-k] \quad (3.5)$$

La Figure 3.8 illustre l'application de la méthode DWT sur un signal ECG issu de la base de données MITDB. Les coefficients obtenus après décomposition en ondelettes sont représentés, comprenant le coefficient d'approximation A4 ainsi que les coefficients de détail D4, D3, D2 et D1.

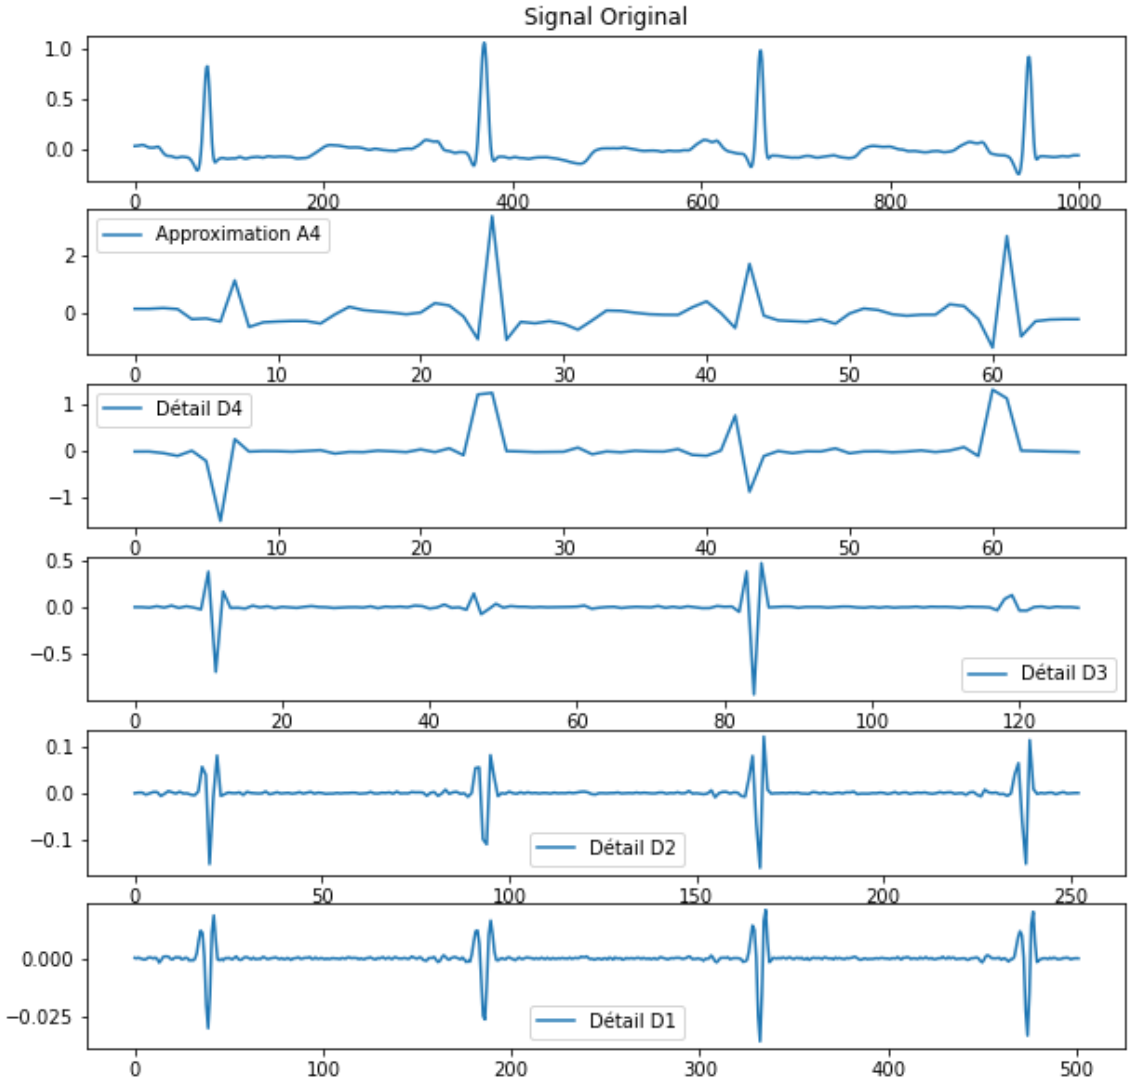

Figure 3.8. Calcul des coefficients d'approximation et de détail pour la délimitation des ondes P et T de l'ECG : Exemple avec un niveau de décomposition de 4.

Après la décomposition du signal, les coefficients DWT sont utilisés pour délimiter les ondes P et T. Prenons l'exemple de l'onde P :

- Utilisation des coefficients DWT : Les coefficients de détail D4 et d'approximation A4, extraits au niveau 4, sont les plus adaptés pour détecter l'onde P car cette onde a une faible amplitude et une fréquence basse.
- Détection du pic de l'onde P : On repère d'abord le maximum local des coefficients A4 avant le premier QRS.
- Détection du début de l'onde P :
    - On cherche la première montée significative des coefficients d'approximation A4.
    - On utilise un seuil adaptatif S_p basé sur l'énergie du signal pour détecter une croissance dans D4 et A4. L'amplitude doit chuter sous 50% du pic détecté tel que : $|D4[i]| < 0.5\, S_p$ et $S_p = \mu_{D4} + 1.0\, \sigma_{D4}$
- Détection de la fin de l'onde P :

- On recherche la première diminution significative des coefficients D4 après le pic détecté.
- On applique un seuil de descente similaire au seuil de montée : Nous cherchons après le pic où l'amplitude retombe sous 50% du pic détecté.

En analysant les composantes ainsi obtenues, notamment celles à basse fréquence associées aux débuts des ondes P et aux fins des ondes T, la DWT peut identifier efficacement ces points clés dans l'ECG. Cette approche facilite la capture des informations spatiales et temporelles du signal.

La Figure 3.9 illustre la segmentation dynamique du signal ECG à l'aide de la DWT, après nettoyage et normalisation du signal. Les régions ombrées indiquent les battements cardiaques délimités par les débuts des ondes P et les fins des ondes T.
Dans cette approche, huit types de battements cardiaques sont extraits et segmentés : le battement Normal (N), le battement auriculaire prématuré (A), le battement ventriculaire prématuré (V), le battement du bloc de branche gauche (L), le battement du bloc de branche droit (R), le battement stimulé (p), la fusion des battements ventriculaire et normal (F), et la fusion des battements stimulé et normal (f). Ces battements sont décrits en détails dans la section 1.5.1.
Les battements cardiaques segmentés varient en longueur, mais afin de répondre aux contraintes du modèle d'apprentissage automatique, nous appliquons soit un remplissage par des zéros, soit un ré-échantillonnage pour garantir une taille d'entrée uniforme.

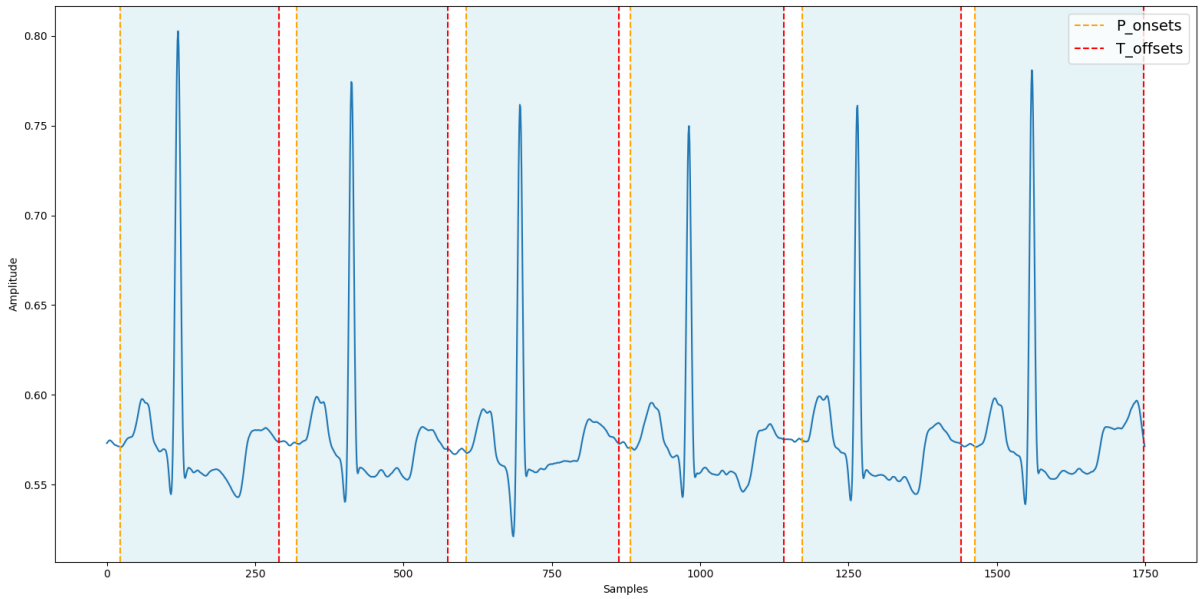

Figure 3.9. Segmentation des battements cardiaques par la transformée en ondelette discrète (DWT).

Pour évaluer la qualité de la segmentation, nous mesurons le taux de faux négatifs (FNR), également appelé taux d'échec. Ce taux reflète le nombre de battements cardiaques pertinents qui n'ont pas été détectés par la méthode de segmentation. Le FNR peut être exprimé par la formule suivante :

$$FNR = \frac{battements\ réels - \ battements\ segmentés}{battements\ réels} \quad (3.6)$$

Les « battements réels » correspondent aux annotations de référence.
L'objectif est de minimiser le FNR afin de garantir que la méthode DWT segmente avec précision la plupart des battements cardiaques, réduisant ainsi le risque de manquer des battements importantes, ce qui est essentiel pour le diagnostic des arythmies.

Les valeurs moyennes du FNR pour les bases de données MITDB et NSRDB sont respectivement de 9 % et 11 %. Ces résultats sont considérés comme acceptables, étant donné que la DWT n'a pas été en mesure de détecter les débuts et fins de toutes les ondes P et T. Par conséquent, la segmentation des battements correspondants n'a pas pu être réalisée, entraînant leur suppression. Ces limitations sont inhérentes à l'approche basée sur la DWT, mais la précision globale de la segmentation reste satisfaisante dans le contexte de l'application visée.

3.5. Augmentation des battements cardiaques

La dernière étape de prétraitement et de préparation des données ECG pour la classification consiste en l'augmentation des battements cardiaques. L'objectif est d'améliorer la diversité et la représentativité des données afin d'entraîner des modèles plus robustes et généralistes. Nous avons élaboré une nouvelle variante de la méthode d'augmentation SMOTE, basée sur la distance de similarité DTW.

3.5.1. Principe de la méthode SMOTE classique

Le SMOTE (Synthetic Minority Oversampling Technique) est une méthode d'augmentation de données utilisée pour équilibrer des ensembles déséquilibrés en générant de nouvelles instances de la classe minoritaire. Plutôt que de dupliquer des exemples, SMOTE crée des instances en interpolant entre des échantillons proches, identifiés via l'algorithme des k plus proches voisins (kNN) basé sur la **distance euclidienne**. Cela améliore la diversité de la classe minoritaire et favorise la généralisation des modèles de classification. (Voir la section 2.4.5)

3.5.2. La distance de similarité DTW

La Déformation Temporelle Dynamique DTW (Dynamic Time Warping) a été introduite pour la première fois dans le contexte de la reconnaissance vocale par Hiroaki Sakoe et Seibi Chiba en 1978 [252]. Ils l'ont développée comme une méthode pour mesurer la similarité entre deux séquences temporelles, même lorsqu'elles varient en vitesse ou en temps. La DTW est devenue populaire dans divers domaines tels que l'analyse de séries temporelles, y compris la reconnaissance vocale, les signaux ECG et le suivi des mouvements.

En comparant la DTW et la distance euclidienne, il est évident que la DTW excelle dans l'alignement de séquences de longueurs différentes ou de distorsions temporelles non linéaires. Elle trouve l'alignement optimal entre les séquences, ce qui lui permet de gérer les décalages, l'étirement ou la compression des données. Elle est donc particulièrement utile pour les données de séries temporelles où les événements peuvent ne pas se produire au même rythme. Quant à

la distance euclidienne, elle compare directement les séquences point par point, ce qui signifie que les deux séquences doivent être de même longueur et alignées dans le temps. Elle suppose que les points correspondants dans les deux séquences se produisent au même moment, ce qui la rend sensible aux décalages temporels, même minimes.
La DTW est plus coûteuse en termes de calcul que la distance euclidienne, mais elle est robuste pour les mesures de similarité. La Figure 3.10 offre une comparaison visuelle de la différence entre les distances euclidienne et DTW.

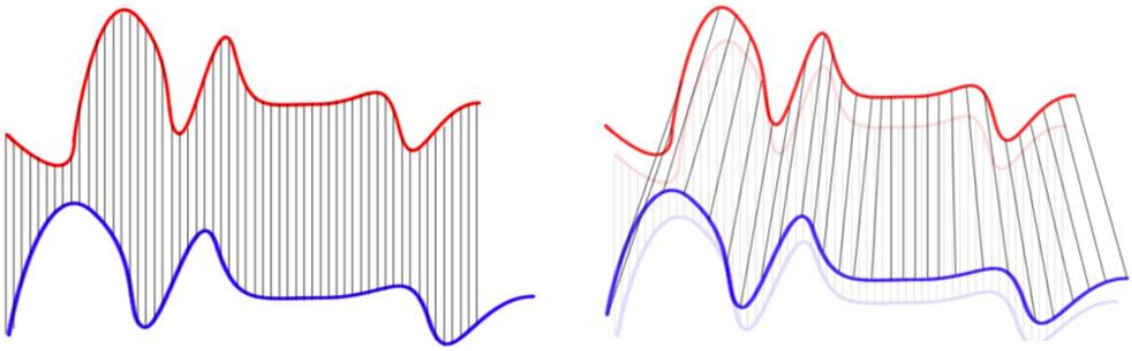

Figure 3.10. Correspondance euclidienne (à gauche) Vs correspondance DTW (à droite) entre deux séquences[18].

Dans le cas des signaux ECG, si un battement cardiaque est retardé dans un signal, la DTW trouvera la meilleure correspondance entre les battements, alors que la distance euclidienne traitera le décalage temporel comme une grande différence.

3.5.3. Implémentation de la méthode DTW-SMOTE

Ce travail présente une nouvelle variante de la méthode SMOTE qui utilise la déformation temporelle dynamique (DTW) pour identifier les K plus proches voisins. Étant donné que les données se composent de battements cardiaques de taille variable, la distance entre ces derniers ne peut pas être mesurée à l'aide de la formule euclidienne classique. Cependant, la DTW est capable de traiter des séries temporelles de longueurs différentes et pouvant être déformées dans le temps, permettant ainsi de trouver un alignement optimal où les caractéristiques telles que les creux et les pics peuvent être correctement mises en correspondance grâce à un mappage un-à-plusieurs.

L'algorithme DTW calcule le chemin d'alignement optimal de manière dynamique en considérant plusieurs alignements possibles et en sélectionnant celui qui minimise la distance cumulée. Cette approche améliore significativement la capacité de détection et de génération de nouveaux échantillons, ce qui est crucial pour le traitement des données déséquilibrées, notamment dans le domaine de la classification des battements cardiaques.

[18] Source: Wikimedia, 2011, Difference in matching between Euclidean and Dynamic Time Warping, https://commons.wikimedia.org/wiki/File:Euclidean_vs_DTW.jpg

Considérons deux séries temporelles présentant deux battements cardiaques, $X = (x_1, \ldots, x_N)$ et $Y = (y_1, \ldots, y_M)$ de longueurs $N \in \mathbb{N}$ et $M \in \mathbb{N}$ respectivement. La distance DTW est exprimée par l'Equation 3.7 où D est une matrice $N \times M$ qui définit la distance cumulée entre x_i et y_j. La matrice D est calculée dynamiquement comme indiqué dans l'Equation 3.8.

$$DTW(X,Y) = \sqrt{D[x_N, y_M]} \tag{3.7}$$

$$D[x_i, y_j] = d(x_i, y_j) + \min\left(D[x_{i-1}, y_{j-1}], D[x_{i-1}, y_j], D[x_i, y_{j-1}]\right) \tag{3.8}$$

Où $d(x_i, y_j)$ est la distance euclidienne entre les éléments x_i et y_j.

Le chemin d'alignement optimal est alors déterminé en retraçant le parcours de $D[x_N, y_M]$ à $D[x_1, y_1]$, tout en suivant la distance cumulée minimale. La Figure 3.11-(a) montre le chemin de déformation de deux battements cardiaques de longueur 234 et 208 échantillons respectivement, tandis que la Figure 3.11-(b) présente une comparaison point par point avec les lignes et les motifs correspondants entre les deux séries temporelles.

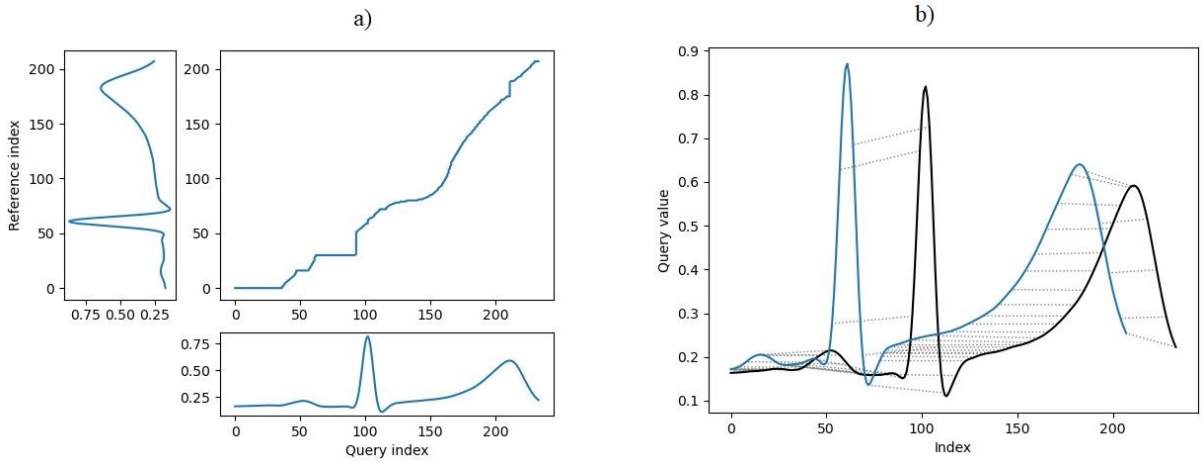

Figure 3.11. (a)-Trajectoire de déformation de deux battements cardiaques, (b)-comparaison DTW point par point.

En utilisant la distance DTW, nous appliquons la technique SMOTE pour ré-échantillonner toutes les classes des données d'entraînement, provenant des bases de données MITDB et NSRDB, à l'exception de la classe majoritaire correspondant aux battements normaux. Le Tableau 3.3 illustre la distribution des battements avant et après l'application de la variante DTW-SMOTE et la Figure 3.12 représente un battement auriculaire prématuré (A) réel et un battement synthétique généré par DTW-SMOTE.

Tableau 3.3. Distribution des battements cardiaques.

Type de battement cardiaque	Distribution des battements			
	Entraînement (avant SMOTE)	Entraînement (après SMOTE)	Validation	Test
Battement Normal (N)	37,665	37,665	16,142	23,061
Bloc de branche droit (R)	3522	37,665	1510	2156
Bloc de branche gauche (L)	3037	37,665	1301	1859
Battement stimulé (p)	2819	37,665	1208	1726
Battement ventriculaire prématuré (V)	1893	37,665	812	1159
Battement auriculaire prématuré (A)	1221	37,665	523	747
Fusion des battements stimulé et Normal (f)	316	37,665	135	194
Fusion des battements Ventriculaire et Normal (F)	302	37,665	130	185
Total	50, 775	301,320	21,761	31,087

Il est important de noter que les données de validation et de test ne sont pas soumises à une augmentation. Elles sont conservées afin de valider et d'évaluer la robustesse du modèle de classification automatique.

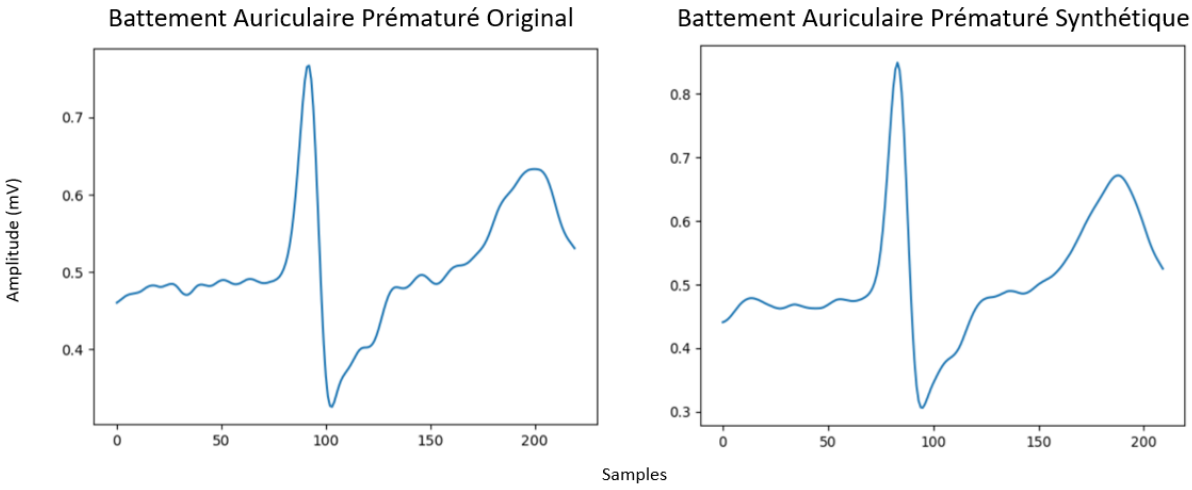

Figure 3.12. Battement Prématuré Auriculaire réel et Battement Prématuré Synthétique généré par DTW-SMOTE.

D’après la Figure 3.12, on pourra conclure que la méthode DTW-SMOTE a assuré :

- La conservation des propriétés morphologiques : Le signal synthétique reproduit avec précision la forme générale de l'onde, y compris la présence d’un pic proéminent R, les ondulations avant et après ce pic et les déformations. Cela montre que DTW-SMOTE a bien pris en compte les caractéristiques clés du signal original, conservant la morphologie typique d'un battement prématuré auriculaire.
- La conservation des propriétés temporelles : La méthode proposée a pu maintenir la structure temporelle du battement généré, sans altérer le nombre d'échantillons ou la fréquence des événements cardiaques. De plus, l'alignement des pics principaux dans les deux figures indique que DTW-SMOTE n'a pas modifié la position temporelle de l'onde R, ce qui est crucial pour la détection correcte des arythmies.

3.6. Evaluation de la performance de la variante DTW-SMOTE

Afin d'évaluer les performances de la variante DTW-SMOTE, deux techniques d'apprentissage automatique ont été appliquées à la classification des données augmentées par les méthodes SMOTE, ADASYN, et DTW-SMOTE. Les performances ont été mesurées à l'aide de deux modèles, l'arbre de décision et le SVM, sur les signaux ECG issus de la base de données MITDB.

Le modèle d'arbre de décision appliqué aux données augmentées avec la nouvelle variante DTW-SMOTE a démontré des performances supérieures à celles obtenues avec SMOTE et ADASYN. En particulier, DTW-SMOTE a permis d'atteindre une accuracy globale de 94,40 %, contre 93,95 % pour SMOTE et 93,41 % pour ADASYN. De plus, le F1-score et la précision sont également améliorés avec DTW-SMOTE, comme illustré dans le Tableau 3.4.
Ces résultats s'expliquent par l'utilisation de la distance DTW dans le processus de génération des échantillons synthétiques. La distance DTW, bien adaptée aux signaux temporels tels que les signaux ECG, permet de mesurer efficacement la similarité entre deux séquences en tenant compte des variations non linéaires dans le temps. Par conséquent, DTW-SMOTE est capable de générer des échantillons synthétiques plus proches des battements réels, ce qui améliore la qualité de l'ensemble de données augmentées et, par extension, les performances du modèle.

Pour le modèle SVM, les résultats obtenus avec DTW-SMOTE sont pratiquement équivalents à ceux de SMOTE classique, avec une accuracy globale de 88,53 % pour DTW-SMOTE contre 88,44 % pour SMOTE, et des F1-scores proches (70,59 % pour DTW-SMOTE contre 70,64 % pour SMOTE). Ces résultats reflètent le fait que le SVM, en tant que modèle moins flexible et fortement dépendant des frontières décisionnelles, est moins influencé par les variations introduites par des échantillons synthétiques plus réalistes. En revanche, la méthode ADASYN, bien qu'adaptée aux zones complexes des données, a montré des performances inférieures pour le SVM, notamment en termes de précision (55,49 %).

Tableau 3.4. Métriques d'évaluation (en %) des modèles d'Arbre de décision et du SVM sur les données augmentées par SMOTE, par ADASYN et par DTW-SMOTE.

	Arbre de décision			**SVM**		
	SMOTE	ADASYN	DTW-SMOTE	SMOTE	ADASYN	DTW-SMOTE
F1-score	79.94	78.61	81.78	70.64	63.24	70.59
Précision	75.47	73.64	78.40	63.80	55.49	63.75
Rappel	86.20	86.04	85.86	87.77	87.04	86.83
Accuracy	93.95	93.41	94.40	88.44	80.14	88.53

Les résultats de classification pour les classes très minoritaires F et f révèlent que la méthode DTW-SMOTE améliore de manière significative leurs performances par rapport à SMOTE et ADASYN, aussi bien avec l'arbre de décision qu'avec le SVM. Pour la classe F, l'arbre de décision atteint un F1-score de 57,63 % avec DTW-SMOTE, contre 48,31 % avec SMOTE et 43,69 % avec ADASYN, tandis que le SVM affiche un F1-score de 22,67 % avec DTW-SMOTE, dépassant SMOTE (20,28 %) et ADASYN (15,67 %). Pour la classe f, l'arbre de décision obtient un F1-score de 71,11 % avec DTW-SMOTE, contre 70,67 % avec SMOTE et 69,39 % avec ADASYN, et le SVM atteint un F1-score de 52,82 % avec DTW-SMOTE, supérieur à celui obtenu avec SMOTE (49,00 %) et ADASYN (47,91 %). Ces résultats montrent que l'utilisation de la distance DTW dans DTW-SMOTE permet de générer des échantillons synthétiques plus représentatifs des données réelles, offrant ainsi un avantage notable pour la classification des classes rares.

3.7. Conclusion

Ce chapitre a présenté les phases de préparation du signal ECG pour la classification des battements cardiaques, en mettant l'accent sur le développement de la **variante DTW-SMOTE** pour l'augmentation des données ECG, pour répondre au défi du déséquilibre des classes. Nous avons d'abord effectué un prétraitement rigoureux des signaux ECG, incluant la réduction du bruit, la normalisation et la segmentation des battements cardiaques.

L'intégration de la distance de similarité DTW dans le cadre de SMOTE a permis de générer des battements synthétiques qui conservent mieux la morphologie et les relations temporelles complexes des signaux ECG. Les évaluations de performance ont montré l'efficacité de cette approche pour améliorer la classification des battements cardiaques.

En conclusion, la méthode DTW-SMOTE offre une solution prometteuse pour le déséquilibre des classes dans les bases de données ECG, garantissant des données de haute qualité pour le développement d'algorithmes robustes. Dans les chapitres suivants, nous explorerons la classification des battements cardiaques avec une nouvelle architecture, tirant parti des données nettoyées et augmentées.

4. Classification des battements cardiaques : Approche basée sur l'extraction des caractéristiques spatiales

Sommaire

4.1. Introduction 102
4.2. Aperçu 103
4.3. Extraction des caractéristiques par un Réseau Résiduel profond (ResNet) 103
4.3.1. Réseau Convolutionnel classique (CNN) Vs Réseau Résiduel (ResNet) 104
4.3.2. Application aux battements cardiaques 105
4.4. Construction du modèle de classification 109
4.4.1. Classification par mécanisme d'Attention 109
4.4.2. Classification par Modulation Focale 110
4.4.3. Architecture globale du modèle de classification 111
4.5. Evaluation de la performance des modèles de classification 113
4.6. Conclusion 117

4.1. Introduction

La classification des battements cardiaques est une tâche essentielle pour le diagnostic automatisé des arythmies cardiaques, offrant un soutien précieux aux professionnels de santé dans la détection précoce des anomalies. Dans ce contexte, de nombreuses approches ont été explorées dans la littérature, utilisant des algorithmes de Machine Learning traditionnels tels que les SVM, kNN, ou encore les forêts aléatoires, pour analyser les signaux ECG. Ces méthodes, bien qu'efficaces dans certaines applications, se révèlent souvent limitées par leur dépendance à une extraction manuelle des caractéristiques et leur capacité à gérer la complexité croissante des données ECG.

L'émergence des techniques de Deep Learning a permis de surmonter certaines de ces limitations grâce à leur capacité à apprendre automatiquement des représentations complexes. Des architectures telles que les CNN, LSTM ou GRU se sont montrées particulièrement adaptées à l'analyse des signaux ECG en exploitant à la fois les relations locales et temporelles des données. De plus, le mécanisme d'attention, largement adopté dans ces architectures, a permis de réduire l'influence des informations moins significatives dans le signal. Cependant, ces méthodes présentent encore des défis, notamment des coûts computationnels élevés, une forte dépendance aux hyper-paramètres, et une sensibilité à la qualité des données. Par ailleurs, certaines approches, bien qu'efficaces dans d'autres domaines, n'ont pas encore été explorées ou adaptées aux spécificités des signaux ECG.

Dans ce chapitre, nous proposons une approche novatrice pour la classification des battements cardiaques basée sur des techniques avancées de Deep Learning. En premier lieu, nous exploitons les capacités des **Réseaux Résiduels (ResNet)** pour extraire automatiquement des caractéristiques représentatives des signaux ECG, une architecture reconnue pour sa robustesse face à la dégradation des performances dans les réseaux profonds. Ensuite, nous proposons deux stratégies distinctes pour la classification des battements cardiaques :

- Une approche basée sur la **Modulation Focale**, appliquée pour la première fois aux signaux ECG dans ce travail, permettant de mieux gérer le déséquilibre des classes en focalisant l'apprentissage sur les parties les plus importantes.
- Une approche utilisant le mécanisme d'Attention, afin d'identifier les relations entre différentes parties du signal. Ce modèle est employé comme référence comparative afin d'évaluer les performances de la Modulation Focale.

Les performances de ces modèles sont rigoureusement évaluées sur la base de données MITDB, une référence dans l'étude des arythmies, et comparées en termes de précision et de robustesse. Ce travail contribue à enrichir l'état de l'art en explorant des solutions innovantes et adaptées aux défis spécifiques de la classification des battements cardiaques.

4.2. Aperçu

Dans cette approche, la classification des battements cardiaques est formulée comme un problème d'apprentissage supervisé, avec pour objectif principal d'identifier les arythmies cardiaques au sein des signaux ECG. Le cadre proposé vise à développer une méthodologie robuste permettant de distinguer différents types de battements cardiaques (normal ou pathologique) en exploitant les capacités avancées des modèles de Deep Learning.

La Figure 4.1 présente une vue d'ensemble de la méthodologie adoptée, qui repose sur plusieurs étapes clés : la préparation et le prétraitement des données ECG, l'extraction automatique de caractéristiques représentatives et la classification via des modèles spécialisés. Le prétraitement des données ECG est composé des étapes de nettoyage des données, et de transformation de ces données temporelles en battements cardiaques individuelles. Les étapes du prétraitement ont été expliqués dans le chapitre précédant. L'étape suivante consiste à extraire des caractéristiques discriminantes à l'aide d'un modèle ResNet, qui apprend automatiquement des représentations complexes adaptées aux spécificités des données ECG. Ces caractéristiques alimentent ensuite un modèle de classification conçu pour distinguer les différentes classes de battements cardiaques.

Toutes ces étapes seront expliquées en détails dans les sous-sections suivantes.

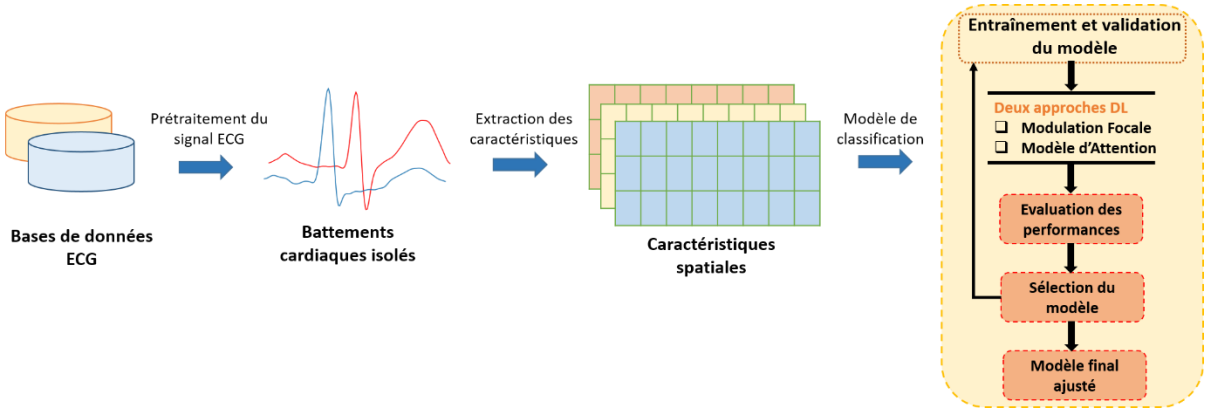

Figure 4.1. Schéma de la méthodologie adoptée pour la classification des battements cardiaques.

4.3. Extraction des caractéristiques par un Réseau Résiduel profond (ResNet)

Dans le domaine de la classification des battements cardiaques, l'extraction des caractéristiques joue un rôle central, car elle détermine la qualité des informations fournies au modèle d'apprentissage. Les approches traditionnelles reposent souvent sur une extraction manuelle des caractéristiques, ce qui peut limiter la capacité à capturer les subtilités des signaux ECG complexes. Grâce aux avancées en Deep Learning, des architectures comme les réseaux convolutifs (CNN) ont permis d'automatiser cette tâche, mais elles restent sensibles à des défis tels que la perte d'information dans les couches profondes.

Pour répondre à ces limites, cette section introduit l'utilisation des Réseaux Résiduels (ResNets), une architecture de Deep Learning reconnue pour sa capacité à apprendre des représentations complexes tout en atténuant le problème de dégradation des performances dans

les réseaux profonds. L'objectif est de tirer parti des ResNets pour extraire des caractéristiques représentatives des battements cardiaques, essentielles pour la classification précise des arythmies.

4.3.1. Réseau Convolutionnel classique (CNN) Vs Réseau Résiduel (ResNet)

Un **réseau neuronal convolutionnel** (CNN) est constitué de plusieurs couches, y compris des couches de convolution, des couches de Pooling pour réduire la dimensionnalité des cartes de caractéristiques (features maps), et des couches entièrement connectées pour mapper les caractéristiques extraites à des probabilités de classes dans les tâches de classification. Les couches de convolution appliquent des filtres sur les données d'entrée pour en extraire des caractéristiques importantes, telles que les contours, les formes ou les motifs, par le biais d'opérations successives.

Bien que les CNNs aient montré de grands succès dans de nombreuses applications, ils présentent des limites lorsqu'ils deviennent plus profondes :

- Problème de l'évanescence de gradient : Lorsque les CNNs deviennent plus profonds, pendant la rétro-propagation, les gradients deviennent de plus en plus petits lorsqu'ils sont renvoyés dans le réseau. Cela peut entraîner un arrêt de l'apprentissage des premières couches, car les mises à jour des poids deviennent insignifiantes, rendant l'entraînement des réseaux très profonds difficile.
- Problème de dégradation : Ajouter plus de couches dans un CNN peut parfois conduire à une dégradation des performances. Ce phénomène se produit car les réseaux plus profonds peuvent avoir du mal à apprendre des paramètres optimaux, entraînant une stagnation ou une dégradation des performances.
- Sur-apprentissage : Quand le réseau devient trop complexe (avec de nombreuses couches et paramètres), il peut sur-apprendre les données d'entraînement et perdre en capacité de généralisation pour de nouvelles données.

Des réseaux de **neurones résiduels (ResNets)** [253] ont été introduits pour résoudre les défis rencontrés par les CNNs simples. Les ResNets permettent l'entraînement de réseaux beaucoup plus profonds, tout en améliorant ou en maintenant les performances.
Le principe clé des ResNets réside dans l'introduction de **connexions de saut** (skip connexions). Ces connexions résiduelles permettent à la sortie d'une couche de contourner une ou plusieurs couches suivantes pour être ajoutée directement à la sortie d'une couche ultérieure. La couche apprend la différence résiduelle par rapport à l'entrée, plutôt que la transformation complète.

La Figure 4.2 compare un bloc de convolution classique à un bloc résiduel. Le bloc de convolution classique doit apprendre directement la représentation $f(x)$, tandis que le bloc résiduel doit apprendre la représentation résiduelle $g(x) = f(x) - x$.

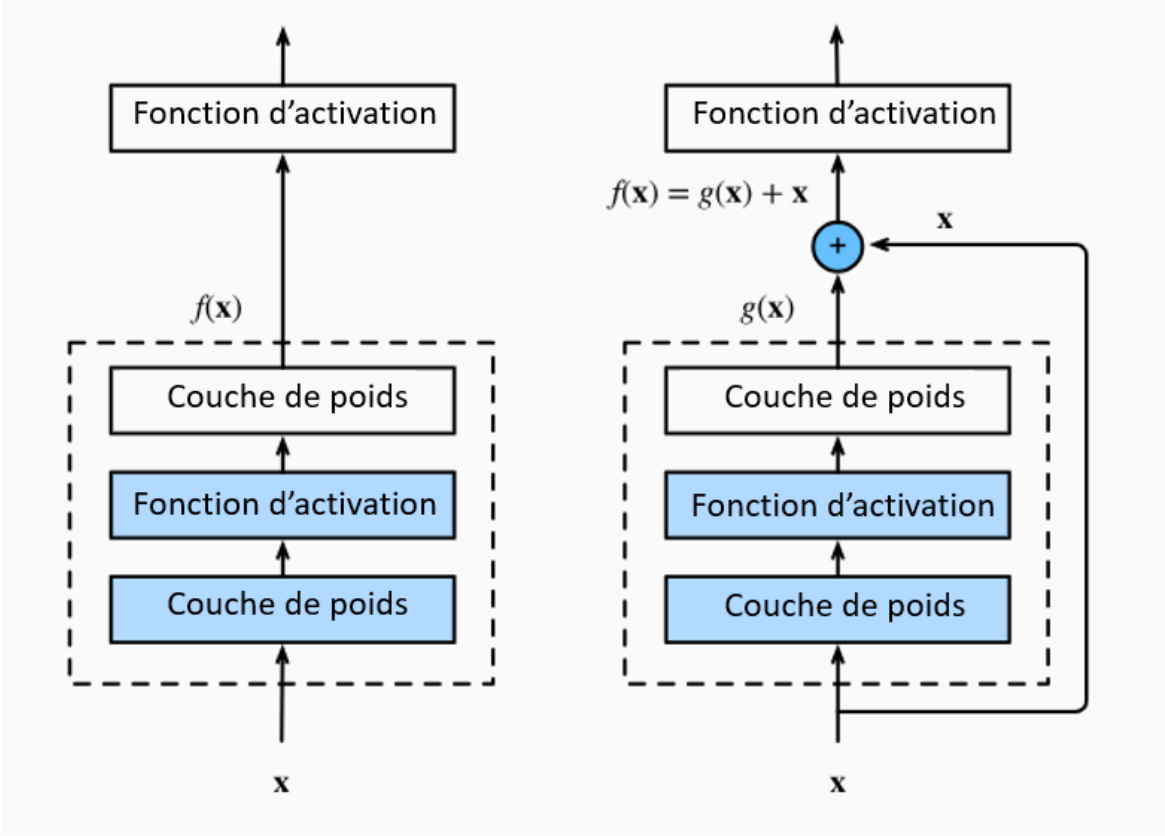

Figure 4.2. Comparaison entre le bloc de convolution classique et le bloc résiduel.

Les ResNets résolvent les limites des CNNs classiques :

- Faciliter l'entraînement des réseaux profonds : Les connexions résiduelles facilitent la propagation des gradients à travers le réseau, permettant d'entraîner efficacement des réseaux plus profonds. Cela aide à atténuer le problème de l'évanescence du gradient, car les gradients peuvent circuler directement à travers les connexions de saut.
- Améliorer la généralisation : Le mapping résiduel incite le réseau à se concentrer sur l'apprentissage de petites transformations plus gérables, ce qui peut améliorer la généralisation du modèle. Les ResNets peuvent ainsi apprendre des représentations plus profondes, menant souvent à de meilleures performances dans des tâches complexes, sans risque de sur-apprentissage.

4.3.2. Application aux battements cardiaques

Nous appliquons un réseau résiduel pour l'extraction des caractéristiques spatiales des battements cardiaques.

Le réseau résiduel employé pour ce problème est un réseau convolutionnel composé de 12 couches. Des couches de convolution, utilisant différentes tailles de noyaux, sont appliquées sur les battements cardiaques afin de générer des cartes de caractéristiques (feature maps), chacune extrayant diverses propriétés du signal ECG, telles que les pics, les creux, les ondes et les motifs locaux. A la fin du modèle, une couche de Pooling adaptif moyen est rajoutée pour

condenser l'ensemble des cartes de caractéristiques en une seule, intégrant toutes les informations pertinentes. Le résultat est un vecteur unidimensionnel de **512 caractéristiques**.

L'architecture détaillée du réseau résiduel est présentée dans le Tableau 4.1. Les filtres de convolution utilisés possèdent des paramètres tels que le stride qui dénote le nombre de pixels par lesquels la fenêtre se déplace après chaque opération, et le paddding qui consiste à ajouter des zéros à chaque côté des frontières de l'entrée, afin de mieux préserver les informations en bordure du signal.

Tableau 4.1. Principales couches du bloc résiduel utilisé pour l'extraction des caractéristiques ECG.

Couche	Taille du filtre	Nombre de filtres	Stride	Padding
Conv1	7	64	2	3
Max-Pooling	3	1	2	1
Conv2_block	$\begin{bmatrix}3\\3\end{bmatrix}$	$\begin{bmatrix}64\\64\end{bmatrix}$	$\begin{bmatrix}1\\1\end{bmatrix}$	$\begin{bmatrix}1\\1\end{bmatrix}$
Conv3_block	$\begin{bmatrix}3\\3\\1\end{bmatrix}$	$\begin{bmatrix}128\\128\\128\end{bmatrix}$	$\begin{bmatrix}2\\1\\2\end{bmatrix}$	$\begin{bmatrix}1\\1\\-\end{bmatrix}$
Conv4_block	$\begin{bmatrix}3\\3\\1\end{bmatrix}$	$\begin{bmatrix}256\\256\\256\end{bmatrix}$	$\begin{bmatrix}2\\1\\2\end{bmatrix}$	$\begin{bmatrix}1\\1\\-\end{bmatrix}$
Conv5_block	$\begin{bmatrix}3\\3\\1\end{bmatrix}$	$\begin{bmatrix}512\\512\\512\end{bmatrix}$	$\begin{bmatrix}2\\1\\2\end{bmatrix}$	$\begin{bmatrix}1\\1\\-\end{bmatrix}$

Chaque couche de cette architecture joue un rôle spécifique dans le traitement du signal d'entrée afin d'obtenir une représentation riche et discriminante des battements cardiaques :

- **Couche de convolution initiale (Conv1) :**
  - Taille du filtre 7×1 : Capture les structures globales du signal ECG.
  - Nombre de filtres 64 : Génère 64 cartes de caractéristiques pour détecter différentes morphologies des battements.
  - Stride 2 : Réduit la taille du signal en sautant 2 échantillons à chaque pas, permettant une extraction plus globale des caractéristiques et une meilleure efficacité computationnelle.
  - Padding 3 : Ajoute des zéros aux bords pour conserver la taille initiale du signal après convolution.
- **Couche de Pooling (Max-Pooling) :**
  - Taille du filtre 3×1 : Réduit la dimension du signal tout en conservant les informations clés.
  - Stride 2 : Diminue encore la résolution spatiale pour préparer l'entrée aux blocs résiduels.
  - Padding 1 : Ajoute un remplissage pour préserver les structures importantes.
- **Blocs Résiduels (Conv2_block à Conv5_block) :** Les blocs résiduels permettent une extraction progressive des caractéristiques en profondeur tout en atténuant la

perte d'information grâce aux connexions résiduelles. Chaque bloc résiduel est composé de deux/trois couches convolutionnelles successives, avec :

- Taille du filtre 3×1 : Capture les variations locales rapides du signal, notamment les pics et creux des ondes ECG
- Nombre de filtres : Augmentant progressivement de 64 à 512.
- Stride 1 ou 2 selon les couches : Pour une extraction fine des caractéristiques sans perte excessive d'informations spatiales.
- Padding : ajusté pour préserver la structure du signal ECG.

En résumé, les connexions résiduelles assurent une transmission fluide des gradients, facilitant ainsi l'apprentissage en profondeur. Par ailleurs, l'augmentation progressive du nombre de filtres permet de capturer des motifs ECG de plus en plus complexes.

Ajustement des hyper-paramètres :

L'optimisation bayésienne est utilisée pour ajuster les hyper-paramètres du réseau résiduel (ResNet). L'objectif est de trouver les valeurs des hyper-paramètres $x \in X$ du modèle qui maximisent le F1-score sur l'ensemble de validation :

$$x^* = \arg\max_{x \in X} F_1(x) \tag{4.1}$$

Où :

- x représente les hyper-paramètres à optimiser.
- $F_1(x)$ est la fonction objectif représentant le F1-score obtenu sur un échantillon de validation.
- X est l'espace de recherche des hyper-paramètres.

L'optimisation bayésienne suppose que la fonction (le F1-score) est inconnue, et utilise un Processus Gaussien (GP) pour l'approximer :

$$F_1(x) \sim GP\big(\mu(x), k(x, x')\big) \tag{4.2}$$

Où :

- $\mu(x)$est la fonction moyenne qui représente l'estimation du F1-score en x.
- $k(x, x')$ est une fonction de covariance qui définit la corrélation entre différentes valeurs d'hyper-paramètres.

Une observation y_i du F1-score après l'entraînement du modèle en x_i suit :

$$y_i = F_1(x_i) + \epsilon, \qquad \epsilon \sim \mathcal{N}(0, \sigma^2) \tag{4.3}$$

L'optimisation bayésienne utilise une fonction d'acquisition pour choisir le prochain ensemble x c'est-à-dire la nouvelle combinaison d'hyper-paramètres, équilibrant exploitation (tester des valeurs qui semblent bonnes) et exploration (explorer des zones incertaines). Une fonction courante est Expected Improvement (EI) :

$$a(x) = \mathbb{E}[\max(0, F_1(x) - F_1^+)] \tag{4.4}$$

Où F_1^+ est le meilleur F1-score observé jusqu'à présent.

Le prochain ensemble d'hyper-paramètres est choisi en maximisant : $x_{n+1} = arg \max_{x \in X} a(x)$

Expliquons les hyper-paramètres qui seront ajustés pour le réseau résiduel ResNet :

- **γ (focal loss parameter)** : paramètre de focalisation de la fonction de perte « focal loss ». Il réduit l'importance des échantillons bien classés et met davantage l'accent sur ceux qui sont mal classés. La fonction de perte est présentée comme suit :

$$L_{FL} = -\sum_{c=1}^{C} \alpha_c (1 - p_c)^{\gamma} \, y_c \log(p_c) \tag{4.5}$$

  Où :
  - c est le nombre de classes et p_c représente la probabilité prédite pour la classe c.
  - α est un facteur d'ajustement pour compenser le déséquilibre des classes, Toutefois, étant donné que notre jeu de données a déjà été équilibré, nous le fixons à $\alpha = 1$, assurant ainsi une importance égale pour toutes les classes.

- **lr (learning rate)** : Taux d'apprentissage de l'optimiseur AdamW. Cet optimiseur est choisi car il propose une correction en appliquant la régularisation $L2$ directement sur les mises à jour des poids, plutôt que de l'intégrer dans le calcul des gradients, comme c'est le cas dans Adam classique. Il permet aussi d'ajuster le taux d'apprentissage individuel de chaque paramètre en fonction de sa variance, contrairement au SGD (stochastic gradient descent) qui possède un taux d'apprentissage fixe.

- **λ (weight decay)** : Coefficient de pénalité $L2$ appliqué à la mise à jour des poids pour limiter le sur-ajustement. La mise à jour des poids avec AdamW est définie par :

$$\theta_{t+1} = \theta_t - lr \frac{\widehat{m}_t}{\sqrt{\widehat{v}_t} + \epsilon} - \lambda \theta_t \tag{4.6}$$

  Où :
  - $lr_t = \frac{lr}{\sqrt{\widehat{v}_t} + \epsilon}$ ajuste le poids de chaque paramètre, en fonction du taux d'apprentissage global lr.
  - $\widehat{m}_t$ et $\widehat{v}_t$ sont les versions corrigées du biais des moyennes mobiles des gradients et des gradients au carré.

- **dropout_prob** : Probabilité de dropout, utilisée pour la régularisation du modèle. Le Dropout est appliqué une fois par bloc résiduel ainsi qu'à la fin du réseau résiduel.

L'algorithme est initialisé avec 2 combinaisons aléatoires d'hyper-paramètres pour construire le modèle probabiliste. L'ajustement est réalisée pendant 100 itérations, en explorant les valeurs des hyper-paramètres dans les intervalles suivants : $\gamma \in [0.1\,, 5.0]$, $lr \in [10^{-5}\,, 0.1]$, $dropout_prob \in [0.1\,, 0.4]$ et $\lambda \in [10^{-5}, 0.1]$.

L'optimisation bayésienne sélectionne progressivement les meilleurs hyper-paramètres en fonction des performances observées, en s'appuyant sur le Processus Gaussien qui prédit l'effet des hyper-paramètres sur le F1-score. La fonction d'acquisition guide la recherche vers les hyper-paramètres optimaux.

L'algorithme converge lorsque le F1-score ne s'améliore plus. Les valeurs des hyper-paramètres qui maximisent la fonction objectif sur l'échantillon de validation sont : $\gamma = 2, lr = 0.001, dropout = 0.2, \lambda = 0.001$. Ces hyper-paramètres permettent un compromis optimal entre stabilité d'apprentissage et généralisation.

Parmi les hyper-paramètres non optimisés figure l'initialisation des poids. Nous optons pour des stratégies éprouvées et spécifiques à chaque type de couche afin d'éviter l'exploration d'un vaste espace de configurations. Notre approche se décompose comme suit :

- **Initialisation Kaiming normal pour les couches de convolutions :** Adaptée aux activations de type ReLU, cette méthode maintient la variance des activations tout au long du réseau, facilitant ainsi une convergence stable.
- **Initialisation par valeurs constantes pour les couches de batch normalisation :** L'initialisation avec des constantes (1 pour les poids et 0 pour les biais) permet de démarrer le processus de normalisation dans des conditions stables, évitant ainsi toute instabilité initiale.
- **Initialisation par distribution normale pour les couches entièrement connectées :** Cette approche standard assure une dispersion adéquate des poids dès le départ, optimisant la propagation de l'information et des gradients.

En adoptant ces stratégies d'initialisation, on réduit la complexité de l'optimisation des hyper-paramètres. Cela a permis de se concentrer sur d'autres aspects critiques du modèle, comme le taux d'apprentissage et les paramètres de régularisation.

4.4. Construction du modèle de classification

Après avoir extrait des caractéristiques représentatives des battements cardiaques à l'aide de l'architecture ResNet, ces caractéristiques servent d'entrée au modèle de classification. Dans cette section, nous abordons les modèles de classification utilisés pour l'analyse des battements cardiaques de la base de données MITDB. Nous explorons deux approches : la classification par mécanisme d'attention et la classification par Modulation Focale.

4.4.1. Classification par mécanisme d'Attention

Le mécanisme d'attention [254] est une technique utilisée dans les réseaux de neurones, pour permettre au modèle de se concentrer sur les parties les plus pertinentes de l'entrée lors de la prise de décision.

Dans le contexte de la classification des signaux ECG, le mécanisme d'attention permet au modèle de se concentrer sur les caractéristiques essentielles pour distinguer les différentes classes de battements cardiaques. Contrairement aux méthodes classiques où toutes les parties du signal sont traitées de manière équivalente, le mécanisme d'attention attribue un "poids" plus important aux caractéristiques qui contiennent des informations cruciales pour la classification. Cela permet au modèle de mieux saisir les variations spécifiques des battements cardiaques, en améliorant ainsi la précision du diagnostic des arythmies. Le modèle "apprend" à reconnaître les caractéristiques essentielles, tout en ignorant les informations moins pertinentes, ce qui optimise la classification des battements anormaux.

Les étapes de calcul d'Attention sont présentées comme suit :

- **Calcul des Scores d'Attention** : Pour une entrée donnée, on calcule un score d'attention e_i pour chaque élément de la séquence d'entrée x_i:

$$e_i = f(q, k_i) \tag{4.7}$$

Où q est le vecteur de requête (query), k_i est le vecteur de clé (key) correspondant à x_i, et f est une fonction qui calcule le produit scalaire (interaction entre la requête q et les clés k_i).

- **Normalisation avec Softmax**: Les scores d'attention sont ensuite normalisés pour obtenir des poids d'attention α_i :

$$\alpha_i = \frac{\exp(e_i)}{\sum_j \exp(e_j)} \tag{4.8}$$

- **Calcul de la Sortie Pondérée** : Enfin, la sortie finale est calculée comme une combinaison pondérée des valeurs d'entrée v_i :

$$z = \sum_i \alpha_i v_i \tag{4.9}$$

Où v_i est le vecteur de valeur (value) correspondant à chaque entrée.

4.4.2. Classification par Modulation Focale

Les réseaux FocalNets [255] sont développés par Microsoft en 2022, ou le mécanisme d'Attention est remplacé intégralement par un module de Modulation Focale afin de modéliser les interactions des jetons dans les tâches de vision. Ce module améliore la capacité de généralisation du réseau en recourant à des couches focales dynamiques plutôt qu'à des noyaux de convolution statiques.

Dans la présente approche, seul le bloc de Modulation Focale est mis en œuvre, car il constitue le noyau des FocalNets. Ce bloc permet aux différentes parties d'une entrée d'interagir de manière dépendante à cette entrée. Il débute par la collecte d'informations contextuelles à plusieurs niveaux autour de chaque segment de l'entrée appelé jeton de requête (query token). Par la suite, un mécanisme de porte (gate) est utilisé pour sélectionner les informations contextuelles les plus pertinentes, lesquelles sont ensuite combinées de manière simple mais efficace pour améliorer la qualité des interactions.

Tout d'abord, l'entrée H est projetée linéairement puis divisée en requête q, contexte Y^0, et portes G^l. Ces trois composants parcourent trois opérations majeures du bloc de Modulation Focale :

- Contextualisation hiérarchique : À cette étape, le contexte initial $Y^0 \in \mathbb{R}^{H*W*C}$ passe par une série de couches de convolution en profondeur (Depth-Wise) et de GeLU. Ces blocs sont désignés comme des niveaux focaux l, la sortie de chaque niveau étant un contexte Y^l. La carte de caractéristiques (feature map) finale Y^{L+1} passe par une couche de Pooling moyen global. Les équations correspondantes des étapes susmentionnées sont définies dans les équations suivantes :

$$q, Y^0, G = f(H) \tag{4.10}$$

$$Y^l = g^l(Y^{l-1}) \in \mathbb{R}^{H*W*C} \quad , l \in \{1, \ldots, L\} \tag{4.11}$$

$$Y^{L+1} = AvgPooling(Y^l) \in \mathbb{R}^C \tag{4.12}$$

Où f est la couche de projection linéaire et g^l est la couche focale où l représente le niveau focal, $l \in \{1, \ldots, L\}$.
(H, W, C) est la taille de sortie correspondant à la hauteur, la largeur et aux canaux.

- Agrégation par portes : Les portes $G^l \in \mathbb{R}^{H*W*(L+1)}$ sont utilisées pour effectuer une agrégation pondérée sur le contexte Y^l. Ensuite, la sortie Z est transmise à une couche de convolution pour obtenir le Modulateur M. Les équations sont décrites comme suit :

$$Z = \sum_{l=1}^{L+1} G^l \odot Y^l \tag{4.13}$$

$$M = h(Z) \tag{4.14}$$

Où h est l'opération de convolution, Z et $M \in \mathbb{R}^{H*W*C}$

- Interaction : La requête initiale q interagit avec l'agrégation contextuelle. Une autre fonction de projection post-linéaire est appliquée avec un Dropout pour fournir la sortie focale finale selon l'équation suivante :

$$F^{out} = linear(q \odot M) \tag{4.15}$$

La Modulation Focale permet au modèle de se concentrer de manière sélective sur des parties spécifiques de son entrée, tout en s'appuyant sur des opérations plus légères. Ce processus repose d'abord sur une agrégation des informations, suivie d'une interaction entre les différentes parties agrégées de l'entrée. Contrairement à l'Attention, qui privilégie l'interaction avant l'agrégation, la Modulation Focale inverse cette approche, optimisant ainsi l'efficacité du modèle tout en réduisant la complexité des calculs.

4.4.3. Architecture globale du modèle de classification

Nous présentons l'architecture globale du modèle de classification basée sur la Modulation Focale.
Le bloc de prédiction utilise en entrée les caractéristiques extraites par le réseau Résiduel (ResNet) et génère la classe des battements cardiaques de l'ECG. Cette architecture se compose de deux couches LSTM, particulièrement efficaces pour capturer les motifs et variations dans les séquences présentant des dépendances. Ces couches LSTM sont suivies d'une couche de Modulation Focale. La sortie de la Modulation Focale est ensuite soumise à une normalisation (batch normalization), qui agit comme une régularisation en ajoutant du bruit aux statistiques des mini-batchs, ce qui permet d'accélérer le processus d'apprentissage. Enfin, une couche

entièrement connectée (couche Dense) est intégrée pour produire les huit classes de battements cardiaques.
L'architecture globale du modèle de classification est illustrée sur la Figure 4.3. On appelle cette architecture par **le modèle LSTM-Focal**.

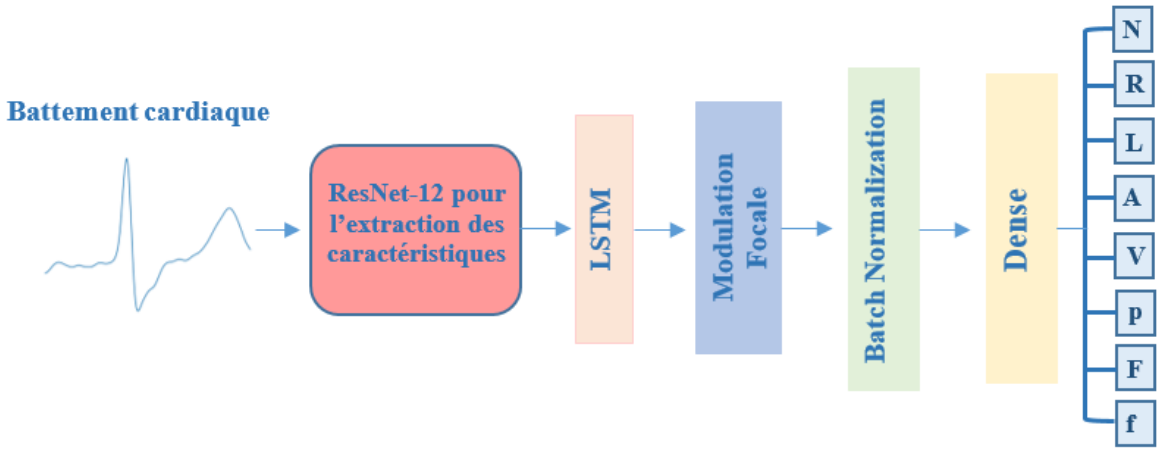

Figure 4.3. Le bloc de prédiction basé sur les couches LSTM-Focal.

Le choix de cette architecture ainsi que l'ordre de ses éléments sont justifiés par la manière dont chaque couche contribue au traitement et à la classification des signaux ECG :

- Le réseau résiduel de 12 couches : Il permet d'extraire des caractéristiques complexes des signaux ECG tout en évitant les problèmes de vanishing gradient, grâce aux couches résiduelles qui facilitent l'apprentissage dans les couches plus profondes.
- Les couches LSTM : Elles sont utilisées pour capturer les relations temporelles dans les battements cardiaques, ce qui est crucial pour les signaux séquentiels comme l'ECG.
- La Modulation Focale : Elle vient ensuite se concentrer sur les parties les plus pertinentes du signal, afin d'améliorer la précision en filtrant le bruit et les informations non pertinentes.
- La batch normalisation : Elle stabilise l'entraînement et accélère la convergence en normalisant les activations des couches, assurant ainsi une distribution cohérente des données.
- La couche dense : Elle regroupe les informations extraites et effectue la classification finale des battements cardiaques.

Ainsi, l'architecture est conçue pour d'abord extraire des caractéristiques complexes, capturer les dépendances temporelles, se concentrer sur les informations les plus importantes, stabiliser l'entraînement et, en dernier lieu, effectuer la classification des battements cardiaques.

La même architecture est adoptée lors de l'utilisation du mécanisme d'Attention ; le bloc de Modulation Focale est supprimé et est remplacé par l'opération d'Attention, tout en conservant le reste de l'architecture inchangé. On appelle ce modèle **LSTM-Attention**.

4.5. Evaluation de la performance des modèles de classification

Dans cette partie, nous présentons les résultats de classification par Modulation Focale en détails puis nous comparons ces résultats aux résultats de classification par mécanisme d'Attention. Les métriques d'évaluation utilisées pour calculer les performances de la classification sont les suivantes : l'accuracy, la précision, le rappel et le F1-score.

a. Distribution des données

Dans cette première approche, le modèle de classification est appliqué aux signaux de la base de données MITDB. Les données de test sont extraites avant l'augmentation des données par la méthode DTW-SMOTE, afin d'évaluer efficacement les performances du modèle avec des données déséquilibrées et non vues par le modèle durant la phase d'entraînement. Ces données de test forment 30 % de la base de données original, soit 33,442 battements de cœur au total.
Nous obtenons un ensemble de données de 475 248 fragments de battements au total après l'augmentation. Cet ensemble de données est ensuite stratifié de manière égale entre les classes et divisé en un ensemble d'entraînement (80 %) qui contient 380 198 battements et un ensemble de validation (20 %) qui contient 95 050 battements.

b. Ajustement des hyper-paramètres

L'objectif de l'ajustement des hyper-paramètres est de trouver ceux qui maximisent le F1-score sur l'ensemble de validation.
Dans ce travail, nous avons utilisé l'optimisation bayésienne, le même algorithme utilisé pour ajuster les hyper-paramètres su réseau ResNet utilisé précédemment pour l'extraction des caractéristiques, appliquée à un petit échantillon de l'ensemble de validation, en raison de la taille importante des données et du nombre élevé de combinaisons d'hyper-paramètres possibles. Cette approche est essentielle, car ajuster les hyper-paramètres directement sur l'ensemble complet des données serait trop coûteux en termes de temps et de calcul.
L'optimisation bayésienne offre une approche plus efficace car, contrairement à la recherche aléatoire ou par grille, elle garde la trace des résultats d'évaluation antérieurs qu'elle utilise pour former un modèle probabiliste associant les hyper-paramètres à la probabilité d'un score sur la fonction objective. Cela réduit le nombre d'évaluations nécessaires pour trouver un bon ensemble d'hyper-paramètres. De plus, l'optimisation bayésienne est adaptative : à chaque itération, elle ajuste sa stratégie d'exploration en fonction des résultats obtenus, ce qui améliore progressivement l'efficacité de la recherche.

Les hyper-paramètres ajustés sont :

- Taux d'apprentissage : plage de recherche $[10^{-5}, 10^{-1}]$.
- Paramètre de régularisation $L2$ dans l'optimiseur AdamW: plage de recherche $[10^{-5}, 10^{-1}]$.
- Probabilité de Dropout : Plage de recherche $[0.1,0.5]$
- Paramètre de focalisation de la fonction de perte γ : Plage de recherche $[0.1,5.0]$
- Nombre de couches LSTM : Plage de recherche [1,5]
- Taille des couches LSTM : [32, 64, 128]

- Niveau focal : Nombre de couches focales dans le bloc de Modulation Focale. Plage de recherche [1,2]
- Fenêtre focale : paramètre permettant de définir la taille du noyau des convolutions dans le bloc focal. Plage de recherche : [1,3]
- Facteur focal : Pondération des couches focales. Plage de recherche [1,2]

La relation entre la taille du kernel de la couche de convolution i et les paramètres de Modulation Focale est définie par :

$$Taille\ kernel_i = facteur\ focal * i + fenêtre\ focale\ et\ \ 0 < \ i < niveau\ focal \quad (4.16)$$

Puisque les caractéristiques du signal ECG sont déjà extraites par le réseau résiduel, nous ne prévoyons pas d'utiliser un grand nombre de couches focales dans le bloc de classification final. L'objectif est de maintenir un nombre réduit de couches ainsi qu'une taille de kernel restreinte (≤ 7) afin d'éviter des convolutions excessives qui augmenteraient la complexité computationnelle. De plus, il est essentiel que la taille du kernel soit toujours impaire afin de préserver la symétrie du filtrage et d'éviter tout décalage dans les cartes de caractéristiques. C'est dans cette optique que les paramètres de Modulation Focale présentés ci-dessus ont été définis dans des plages de recherche restreintes.

La même implémentation de l'algorithme d'optimisation bayésienne utilisée pour l'ajustement des hyper-paramètres du réseau ResNet, présentée dans la section 4.3.2, est également appliquée aux hyper-paramètres du modèle de classification.
L'algorithme converge lorsque le F1-score ne s'améliore plus. Les valeurs des hyper-paramètres qui maximisent la fonction objectif sur l'échantillon de validation sont présentées au Tableau 4.2.

Tableau 4.2. Résultats d'ajustement des hyper-paramètres par l'optimisation bayésienne.

Paramètre	Valeur optimale
Taux d'apprentissage	0.001
Paramètre de régularisation ***L2***	0.001
Dropout	0.1
Paramètre de focalisation de la fonction de perte	2
Nombre de couches LSTM	2
Taille des couches LSTM	64
Niveau focal	2
Fenêtre focale	3
Facteur focal	2

c. Résultats de classification

Pour la reconnaissance des battements cardiaques, les fragments PQRST sont envoyés par lots (batchs) à la couche d'entrée du réseau résiduel. Un vecteur de 512 caractéristiques est extrait de chaque série temporelle. Ces vecteurs de caractéristiques parcourent ensuite le modèle

de classification LSTM-Focal pour produire la classe correspondant à chaque battement cardiaque.
La Figure 4.4 présente l'évolution de l'accuracy durant les processus d'entraînement et de validation. Le modèle **LSTM-Focal** a été entraîné sur **50 epochs** (nombre total d'itérations pour l'entraînement de tout l'ensemble d'apprentissage), au cours desquelles l'apprentissage s'est stabilisé, atteignant une accuracy maximale de **99,94 %** pour l'entraînement et de **99,87 %** pour la validation, permettant ainsi de classifier correctement la majorité les battements cardiaques.

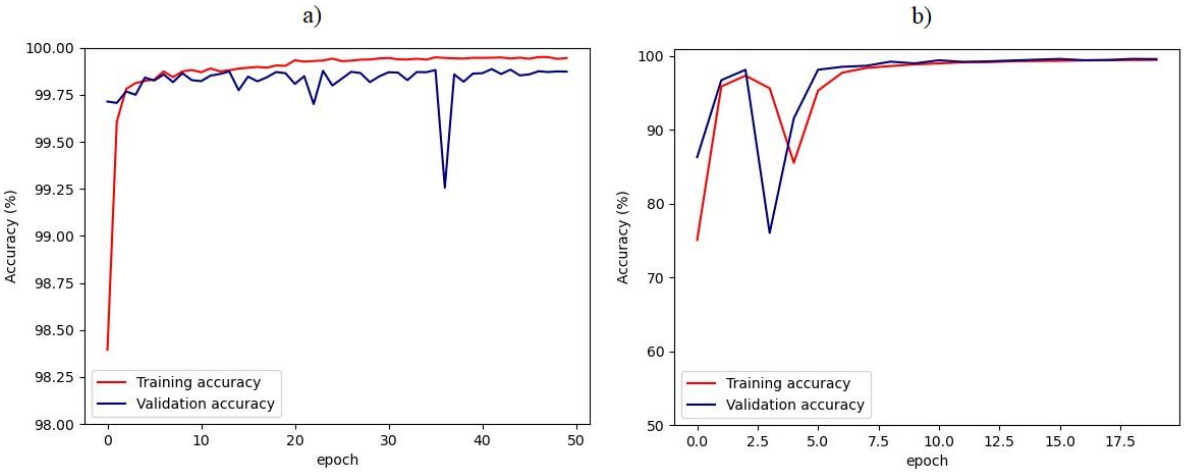

Figure 4.4. Accuracy d'entraînement et de validation du modèle LSTM-Focal (a) et du modèle LSTM-Attention (b).

Le modèle LSTM-Focal a ensuite été évalué sur les données de test déséquilibrées. La matrice de confusion, illustrée dans la Figure 4.5, montre que le modèle a correctement classé 32 977 battements sur 33 442, atteignant ainsi une accuracy globale de 98,61 %. Les résultats des métriques d'évaluation sur les données de test sont récapitulés dans le Tableau 4.3. Le modèle a obtenu des F1-scores élevés pour les classes N, L, R et p, qui représentent la majorité des données testées. En termes de performances globales, le modèle a atteint une précision de 94,53 %, un rappel de 93,68 % et un F1-score de 94,08 %.

La performance de reconnaissance la plus faible est observée pour la classe F, qui ne compte que 179 battements dans l'ensemble de test. De plus, il est noté que ces battements F, correspondant à la fusion des battements normaux et ventriculaires, sont souvent mal classés comme appartenant aux catégories Normal (N) ou Ventriculaire (V). De manière similaire, les battements de type f, correspondant à la fusion des battements normaux et stimulés, sont principalement confondus avec des battements normaux (N) ou stimulés (p). En conséquence, les classes f et F ont présenté les taux de classification correcte les plus faibles. Pour améliorer la précision, il serait pertinent d'extraire des caractéristiques supplémentaires permettant de mieux distinguer ces battements cardiaques.

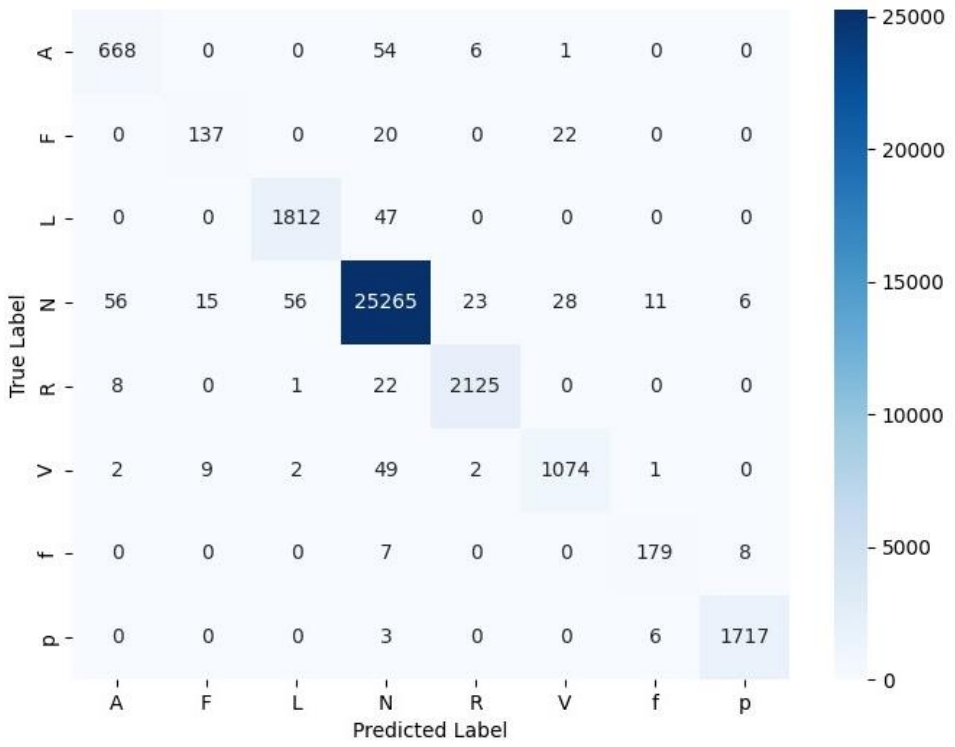

Figure 4.5. Matrice de confusion du modèle LSTM-Focal à partir des données de test.

Tableau 4.3. Métriques d'évaluation (en %) du modèle LSTM-Focal à partir des données de test.

Battements	Précision	Rappel	F1-score
Battement auriculaire prématuré (A)	91.01	91.63	91.32
Fusion des battements Ventriculaire et Normal (F)	85.09	76.54	80.59
Bloc de branche gauche (L)	96.85	97.47	97.16
Battement Normal (N)	99.21	99.23	99.22
Bloc de branche droit (R)	98.56	98.56	98.56
Battement ventriculaire prématuré (V)	95.47	94.29	94.88
Fusion des battements stimulé et Normal (f)	90.86	92.27	91.56
Battement stimulé (p)	99.19	99.48	99.33
Macro-moyenne	**94.53**	**93.68**	**94.08**
Moyenne pondérée	98.60	98.61	98.60
Accuracy globale	**98.61**		

Le modèle LSTM-Attention a été entraîné afin d'évaluer l'efficacité du bloc de Modulation Focale dans la tâche de classification des battements cardiaques. Comme illustré dans la Figure 4.4, le modèle atteint sa stabilité après 15 epochs, avec une accuracy globale en entraînement et en validation de 99,31 % et 99,5 % respectivement. Le Tableau 4.4, présente les métriques d'évaluation des deux modèles testés ; le modèle LSTM-Focal surpasse le modèle LSTM-Attention, atteignant une accuarcy globale de 98,61 %, contre 97,65 % pour ce dernier.

L'ajout du bloc de Modulation Focale a considérablement amélioré les performances du modèle, pour l'identification des battements cardiaques, avec une accuracy de 94,53 %, contre 89,94 % pour le modèle utilisant le mécanisme d'Attention.

Tableau 4.4. Métriques d'évaluation (en %) du modèle LSTM-Focal et du modèle LSTM-Attention.

Modèle	Précision	Rappel	F1-score	Accuracy
LSTM-Focal	94.53	93.68	94.08	98.61
LSTM-Attention	89.94	92.49	91.17	97.65

d. Temps de classification

Le temps requis par le modèle d'apprentissage profond pour tester un battement de cœur peut être évalué en calculant la moyenne des temps de prédiction sur l'ensemble des échantillons. Ce temps est exprimé dans l'équation ci-dessous, où e représente le temps d'exécution au pas t.

$$T = \sum_{t=0}^{n} \frac{e_t}{n} \tag{4.17}$$

Pour mesurer la variation du temps de classification, nous répétons ce processus à plusieurs reprises, puis nous calculons la moyenne ainsi que l'écart-type des temps de classification sur toutes les itérations. À chaque évaluation, nous obtenons un temps de classification moyen constant de **0,002 seconde**, avec un écart-type nul pour l'analyse d'un seul battement de cœur.

4.6. Conclusion

Ce chapitre a mis en lumière l'application de techniques avancées de classification des battements cardiaques en utilisant la base de données MITDB. Nous avons exploré l'extraction des caractéristiques ECG à l'aide d'un réseau résiduel profond, en soulignant les avantages de cette architecture par rapport aux réseaux convolutionnels classiques. Nous avons ensuite examiné les méthodes de classification basées sur le mécanisme d'attention et la Modulation Focale, ce dernier étant plus performant pour la classification des signaux ECG. Ce travail est le premier à appliquer les couches focales pour la classification des battements cardiaques, ce qui souligne l'originalité et la pertinence de notre approche. Les résultats obtenus démontrent l'efficacité de ces méthodes pour la classification des battements cardiaques, avec un taux de reconnaissance de 98,61%, ouvrant ainsi de nouvelles perspectives pour l'analyse des données ECG.

Dans le chapitre suivant, nous aborderons une autre approche pour l'extraction hybride des caractéristiques ECG puis nous présenterons l'application du modèle LSTM-Focal sur deux bases de données distinctes MITDB et NSRDB, dans le but d'évaluer la robustesse de la Modulation Focale lorsqu'elle est appliquée à des données inter-patients et multi-dérivations. Cette comparaison permet de mieux apprécier la capacité de généralisation du modèle dans des contextes variés.

5. Classification des battements cardiaques : Approche hybride par fusion de caractéristiques spatiales et temporelles

Sommaire

5.1. Introduction 120
5.2. Aperçu 120
5.3. Extraction hybride des caractéristiques ECG 121
5.3.1. Extraction des caractéristiques temporelles par le Matching Pursuit Orthogonal (OMP) 121
5.3.2. Extraction des caractéristiques spatiales profondes par le réseau Résiduel (ResNet) 123
5.3.3. Fusion des caractéristiques ResNet-OMP 123
5.4. Modèle de classification 124
5.5. Evaluation de la performance des modèles de classification 124
5.6. Discussion et comparaison 128
5.7. Conclusion 130

5.1. Introduction

La classification des battements cardiaques représente un défi majeur, tant en raison de la variabilité des données que de la complexité des anomalies cardiaques. Le chapitre précédent était consacré à la classification des battements de la base MITDB, en se concentrant exclusivement sur l'extraction des caractéristiques spatiales profondes. Bien que cette approche ait permis d'obtenir des résultats prometteurs, il est essentiel d'explorer des méthodes complémentaires pour améliorer la précision.

Dans ce chapitre, la classification des battements cardiaques est abordée sous un nouvel angle en intégrant une approche hybride. Ce travail s'appuie sur la fusion de caractéristiques issues à la fois d'extraction manuelle temporelle et de représentations profondes. Cette méthodologie vise à surmonter les limitations des approches précédentes en exploitant simultanément les forces des deux techniques.

Nous commencerons par une présentation de l'algorithme Matching Pursuit Orthogonal (OMP) pour l'extraction manuelle des caractéristiques temporelles. Cette méthode, reconnue pour sa capacité à décomposer les signaux en une base parcimonieuse, permet d'obtenir des caractéristiques significatives pour capturer la dynamique temporelle des battements cardiaques. En parallèle, les Réseaux Résiduels (ResNet) sont employés pour extraire des caractéristiques profondes spatiales. Une fois ces deux types de caractéristiques obtenus, leur fusion, appelée ResNet-OMP, constitue une étape essentielle de cette approche. Cette combinaison permet d'exploiter les complémentarités entre les informations temporelles et profondes, renforçant ainsi la capacité des modèles à différencier les différents types de battements cardiaques.

Nous aborderons également l'application du modèle basé sur la Modulation Focale à deux bases de données MITDB et NSRDB. Enfin, une évaluation rigoureuse de la performance du modèle sera réalisée, suivie d'une discussion approfondie des résultats obtenus, afin de contextualiser nos contributions dans le cadre de l'état de l'art actuel en matière de classification des battements cardiaques pour la détection de l'arythmie.

5.2. Aperçu

Dans ce chapitre, nous présentons une approche hybride pour la classification des battements cardiaques, en combinant des caractéristiques spatiales extraites par un réseau résiduel (ResNet) et des caractéristiques temporelles obtenues grâce à l'algorithme Matching Pursuit Orthogonal (OMP). L'objectif principal est d'améliorer la précision de la détection des arythmies en tirant parti des forces complémentaires de ces deux techniques.

La Figure 5.1 offre une vue d'ensemble de la méthodologie adoptée, qui repose sur l'extraction hybride des caractéristiques et la classification des battements cardiaques. Ces étapes sont précédées par la préparation et le prétraitement des données ECG, détaillées dans le chapitre 3, permettent de nettoyer et préparer les battements cardiaques pour l'extraction des caractéristiques.

L'étape suivante consiste à extraire les caractéristiques des signaux ECG, en fusionnant les informations temporelles et spatiales. L'algorithme OMP est utilisé pour capturer les dynamiques temporelles des battements cardiaques, tandis que le ResNet permet d'extraire des représentations profondes et spatiales. Cette approche hybride vise à combiner les avantages des deux méthodes, en offrant une meilleure compréhension des signaux ECG complexes.

Enfin, ces caractéristiques fusionnées sont utilisées pour entraîner le modèle de classification basé sur la Modulation Focale.

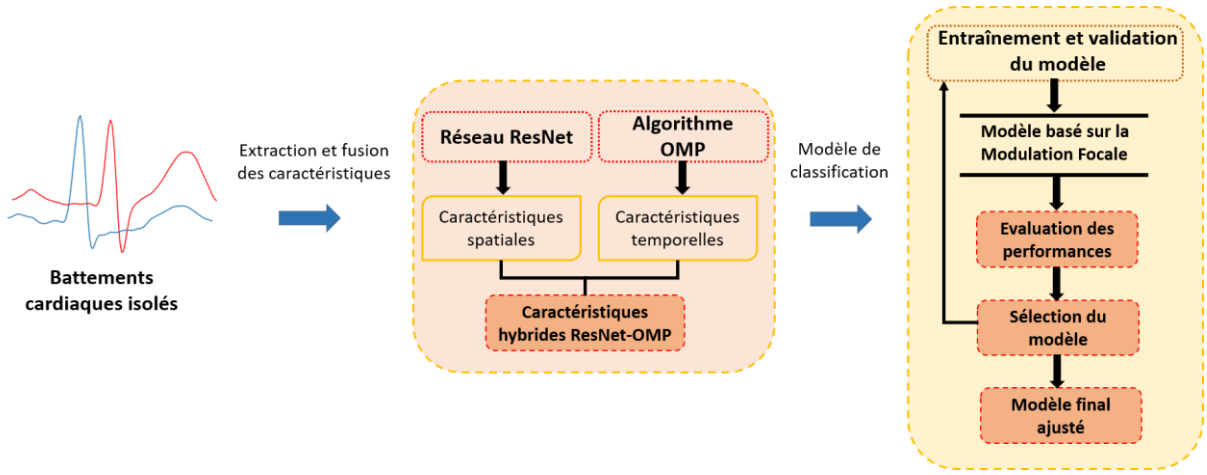

Figure 5.1. Schéma de la méthodologie adoptée pour la classification des battements cardiaques basée sur la fusion de caractéristiques hybrides.

5.3. Extraction hybride des caractéristiques ECG

Dans ce chapitre, nous adoptons une approche hybride, combinant des méthodes d'extraction temporelle et spatiale, afin d'exploiter au mieux les informations disponibles dans les signaux ECG.

5.3.1. Extraction des caractéristiques temporelles par le Matching Pursuit Orthogonal (OMP)

Le Matching Pursuit (MP) est un algorithme itératif qui utilise un dictionnaire d'atomes pour décomposer le signal en une représentation éparse. Il sélectionne de manière itérative les atomes du dictionnaire et calcule les coefficients pour reconstruire le signal d'entrée. Nous cherchons à trouver les coefficients qui forment la représentation éparse du signal.

Le Matching Pursuit Orthogonal est une variante de l'algorithme MP qui ajoute une contrainte pour renforcer l'orthogonalité entre les atomes sélectionnés. Grâce à cette contrainte, les atomes sélectionnés ne sont pas corrélés entre eux, ce qui permet une représentation plus précise et plus stable des signaux.

Pour le choix du dictionnaire d'atomes, plusieurs dictionnaires peuvent être utilisés avec l'algorithme OMP. Les dictionnaires de bases orthogonales comprennent généralement la transformée en ondelettes discrète et la transformée en cosinus discrète. Les dictionnaires sur-complets, qui offrent un niveau de parcimonie plus élevé, contiennent plus d'atomes que la dimensionnalité de l'espace du signal et peuvent être utilisés avec les fonctions de Gabor, les Curvelets ou les Shearlets. Quant aux dictionnaires dits « Learned », ils peuvent être appris directement à partir des données, ce qui permet une meilleure approximation des caractéristiques du signal.

L'objectif de l'OMP est de sélectionner itérativement les colonnes d'une matrice de dictionnaire qui donnent la meilleure approximation du signal d'entrée. L'algorithme OMP peut être formulé comme suit :
Soit $x \in R^n$ un signal et $D \in R^{(n \times m)}$ une matrice de dictionnaire avec m atomes. L'objectif est de trouver le vecteur de coefficient $\alpha \in R^m$ tel que $x \approx D\alpha$ avec un nombre minimal de coefficients non nuls dans α :

- Tout d'abord, nous initialisons le vecteur des atomes sélectionnés avec un ensemble vide et nous initialisons le résidu comme signal d'entrée.
- Pour chaque itération k, nous sélectionnons l'atome du dictionnaire qui présente la corrélation la plus élevée avec le résidu actuel. Nous ajoutons cet atome à l'ensemble des atomes sélectionnés.
- Soit S l'ensemble des indices correspondant aux atomes sélectionnés à chaque itération et D_s la sous-matrice de D formée par les colonnes indexées par S. L'OMP résout le problème d'optimisation suivant pour trouver le α optimal :

$$argmin_\alpha \|x - D_s\alpha\|_2^2 \quad (5.1)$$

- Une fois que α est trouvé, l'atome sélectionné est ajouté à l'ensemble S et le résidu est mis à jour conformément à ce qui suit :

$$R = x - D_s\alpha \quad (5.2)$$

Nous continuons à itérer sur le dictionnaire jusqu'à ce qu'à atteindre le nombre maximum d'itérations ou jusqu'à ce que le résidu devienne égal à 0.
La sortie α est la représentation éparse des séquences de battements cardiaques par rapport aux atomes sélectionnés, ce qui signifie que seules quelques-unes de ses mesures seront non zéros. Il en résulte un vecteur 1-D avec 5 caractéristiques non nulles.

Pour sélectionner la fonction d'ondelette la plus appropriée qui sera utilisée comme dictionnaire d'atomes avec l'OMP, les coefficients OMP sont mesurés pour différents types d'ondelettes comme Daubechies (db), Symlets (sym) et Coiflets (coif), et avec différents ordres N. Ensuite, le signal est reconstruit à l'aide du dictionnaire d'ondelettes et de ces coefficients. L'ondelette qui maximise la corrélation de Pearson sur l'ensemble des battements cardiaques est choisie. Les ondelettes « Symlet2 » et « Daubechies2 » produisent des résultats similaires, soit $\approx 0{,}3692$, et l'une d'entre elles est ainsi sélectionnée comme étant la plus appropriée pour cette étude de cas. Les résultats du calcul de la corrélation pour tous les types d'ondelettes sont présentés dans le Tableau 5.1.

Tableau 5.1. Comparaison de différents types d'ondelettes pour l'algorithme OMP.

Type d'ondelette	Corrélation de Pearson	Type d'ondelette	Corrélation de Pearson
"db2"	**0.3692**	"sym4"	0.2657
"db3"	0.3349	"sym5"	0.1816
"db4"	0.2236	"sym6"	0.1078
"db5"	0.2365	"sym7"	0.0598
"db6"	0.2478	"sym8"	0.1211

“db7”	0.2006	“coif2”	0.1343
“db8”	0.1539	“coif3”	0.1157
“sym2”	**0.3692**	“coif4”	0.0931
“sym3	0.3349	“coif5”	0.1117

5.3.2. Extraction des caractéristiques spatiales profondes par le réseau Résiduel (ResNet)

Le réseau résiduel utilisé dans cette approche contient 4 blocs résiduels, correspondant à 12 couches de convolution, ce qui permet d'extraire les motifs spatiaux et les variations d'amplitude des battements cardiaques. Quatre tailles différentes de feature maps (64, 128, 256 et 512) résultant des noyaux de convolution sont utilisées pour extraire les caractéristiques détaillées du signal ECG. Nous obtenons en sortie un vecteur 1-D contenant 512 caractéristiques. L'architecture du réseau ResNet utilisée dans cette approche est identique à celle présentée dans le quatrième chapitre, décrite dans le Tableau 4.1.

Pour vérifier que le réseau résiduel à 12 couches de convolution extrait les caractéristiques les plus pertinentes, un réseau résiduel à 34 couches de convolution est également testé, afin d’évaluer l'impact de la profondeur du modèle sur ses performances. Ce réseau à 34 couches comprend 15 blocs résiduels et adopte la même architecture de couches que le ResNet à 12 couches présenté dans le Tableau 4.1.
L'accuracy et le F1-score ont été mesurés lors des phases d'entraînement et de validation. Le réseau ResNet à 12 couches a montré de meilleures performances, atteignant sa convergence après 212 époques. Le Tableau 5.2 présente une comparaison entre le ResNet à 12 couches et celui à 34 couches. Les résultats indiquent que le modèle à 12 couches a légèrement surpassé celui à 34 couches, nécessitant également moins de temps d'entraînement et de ressources computationnelles. Ces résultats suggèrent que l'augmentation du nombre de couches dans un modèle d'apprentissage profond ne conduit pas nécessairement à une amélioration des performances globales.

Tableau 5.2. Comparaison entre les modèles 12-ResNet et 34-ResNet pour l'extraction des caractéristiques ECG.

Modèle	Epoch de convergence	Accuracy d’entraînement	Accuracy de validation	Temps d’entraînement
12-ResNet	212	99.82	98.73	17h - 46min
34-ResNet	211	99.76	98.63	47h - 56min

5.3.3. Fusion des caractéristiques ResNet-OMP

Le réseau Résiduel permet d'apprendre des caractéristiques hiérarchiques à partir de données brutes, tandis que l'algorithme du Matching Pursuit Orthogonal permet d'extraire des caractéristiques temporelles compactes et informatives, en particulier lorsqu'il utilise les ondelettes de Daubechies, qui sont pertinentes pour représenter des signaux avec des composantes lisses et oscillatoires.

Nous préconisons l'application d'une agrégation afin de regrouper l'ensemble des caractéristiques profondes résiduelles avec celles obtenues via l'OMP avant d'être introduites dans le modèle de classification. Plusieurs méthodes d'agrégation peuvent être appliquées :

- Pooling moyen global (GAP) : Calcule la moyenne de toutes les caractéristiques pour obtenir une seule valeur agrégée.
- Pooling maximal : Calcule la valeur maximale du vecteur de caractéristiques pour obtenir une seule valeur agrégée. Cette méthode met l'accent sur la caractéristique la plus saillante du vecteur.
- Sommation : Calcule la somme de toutes les caractéristiques pour obtenir une seule valeur agrégée.
- Réduction de la dimensionnalité basée sur la PCA : Applique l'analyse en composantes principales pour réduire la dimensionnalité du vecteur de caractéristiques tout en préservant les informations les plus importantes.

Or les caractéristiques profondes extraites présentent une meilleure interprétabilité si elles ne sont pas transformées d'où nous combinons simplement les caractéristiques ResNet et OMP dans un seul Data frame pour former un ensemble hybride de caractéristiques et l'introduire dans le modèle de classification des battements cardiaques. Le vecteur fusionné est un vecteur 1-D avec 517 caractéristiques hybrides.
Cette approche permet de combiner différentes sources d'information, optimisant ainsi les performances du modèle en tirant parti de la complémentarité des caractéristiques extraites.

5.4. Modèle de classification

Dans le cadre de la classification des battements cardiaques, le bloc de Modulation Focale, décrit au chapitre 4 , est utilisé sur l'ensemble des caractéristiques hybrides extraites des signaux ECG. Le schéma du bloc de classification est illustré sur la Figure 4.3. Le processus commence par l'application des couches LSTM, reconnues pour leur capacité à capturer les dépendances à long terme et à maintenir la stabilité des gradients. Ces couches sont appliquées aux caractéristiques hybrides, avant de passer à la couche de Modulation Focale. Cette dernière se distingue par sa capacité à se concentrer dynamiquement sur les parties essentielles des entrées, en utilisant des noyaux de tailles variables dans les couches focales. Une normalisation est ensuite effectuée, suivie de l'application d'une couche dense, qui génère les probabilités des différentes classes de battements cardiaques.

5.5. Evaluation de la performance des modèles de classification

Dans cette section, sont présentés les résultats de la classification obtenus par l'application de la Modulation Focale sur les caractéristiques hybrides issues de la fusion des caractéristiques ResNet et OMP. Ces résultats sont ensuite comparés à ceux obtenus en appliquant la Modulation Focale uniquement sur les caractéristiques ResNet, dans le but d'évaluer l'impact de l'intégration des caractéristiques temporelles OMP.

a. Distribution des données

Dans cette approche hybride, les battements cardiaques sont extraits de deux bases de données, MITDB et NSRDB. Afin de traiter le déséquilibre des classes, les battements cardiaques ont été répartis en trois ensembles : un ensemble d'entraînement (50 %), augmenté par la technique DTW-SMOTE, un ensemble de validation (20 %) et un ensemble de test (30 %), conservé pour l'évaluation finale. La distribution des battements est présentée dans le Tableau 3.3, comprenant un total de 301 320 fragments pour l'entraînement, 21 761 pour la validation, et 31 087 pour le test.

Bien que les données de la base NSRDB aient été intégrées dans cette approche, le nombre total de battements dans l'ensemble d'entraînement a diminué par rapport à la première approche, où l'entraînement comptait 380 198 battements. Cette réduction s'explique par l'élimination de plusieurs segments de battements lors de la phase de segmentation, notamment lorsque des segments chevauchés ont été détectés et supprimés.

b. Résultats de classification

Le modèle LSTM-Focal reçoit en entrée des caractéristiques hybrides résultant de la fusion des caractéristiques spatiales extraites par le réseau résiduel et des caractéristiques temporelles issues de l'algorithme Matching Pursuit Orthogonal, puis produit en sortie la classe de battement cardiaque.

Le modèle a obtenu un F1-score global de 99,99 % durant l'entraînement sur les données augmentées, et a convergé à l'epoch 45, atteignant une performance maximale sur l'ensemble de validation non équilibré avec une accuracy de 98,82 % et un F1-score de 93,92 %. Lors de l'évaluation sur les données de test déséquilibrées, comprenant 31 087 battements de cœur, le modèle a présenté des performances prometteuses, avec un temps de prédiction par échantillon de seulement **0,0002 seconde**. Il a atteint des métriques élevées, à savoir une accuracy globale de 98,99 %, un F1-score de 94,77 %, une précision de 95,55 %, et un rappel de 94,04 %. Les résultats détaillés pour chaque type de battement cardiaque sont présentés dans le Tableau 5.3.

Tableau 5.3. Métriques d'évaluation (en %) du modèle LSTM-Focal sur les données de test issues de l'extraction hybride des caractéristiques.

Battements	Précision	Rappel	F1-score
Battement auriculaire prématuré (A)	94.84	88.49	91.55
Fusion des battements Ventriculaire et Normal (F)	83.33	78.38	80.78
Bloc de branche gauche (L)	99.62	99.41	99.52
Battement Normal (N)	99.34	99.67	99.50
Bloc de branche droit (R)	99.63	99.30	99.47
Battement ventriculaire prématuré (V)	94.95	94.13	94.54
Fusion des battements stimulé et Normal (f)	93.30	93.30	93.30

Battement stimulé (p)	99.36	99.65	99.51
Macro-moyenne	**95.55**	**94.04**	**94.77**
Moyenne pondérée	98.97	98.99	98.98
Accuracy globale	**98.99**		

La matrice de confusion (Figure 5.2) illustre les performances du modèle sur les 31 087 battements cardiaques testés, dont 30 772 ont été correctement classés. Les meilleurs résultats ont été obtenus pour les battements de types N, L, R et p, avec un F1-score supérieur à 99 %, démontrant une haute précision. En revanche, pour la classe F (fusion des battements ventriculaires et normaux), le rappel est plus faible, à 78,38 %, indiquant un nombre relativement élevé de faux négatifs. Sur les 185 battements de type F, 21 ont été mal classés en battements N et 18 en battements V. De plus, la majorité des erreurs de classification, toutes catégories confondues, se retrouvent classées dans la catégorie des battements normaux (N).

La performance élevée des classes N, L, R et p pourrait s'expliquer par leurs caractéristiques distinctes, permettant au modèle d'apprendre et de prédire plus efficacement. L'utilisation de la technique DTW-SMOTE pour augmenter les données a également amélioré la capacité du modèle à discerner les caractéristiques des différents types de battements. Cependant, malgré un nombre suffisant de données d'apprentissage, certaines classes restent difficiles à classifier correctement. Par exemple, bien que les classes aient été équilibrées après l'augmentation, le modèle a mal classé 22 % des instances F et 12 % des instances A sur les données de test. Cela suggère que les données d'entraînement n'offrent peut-être pas une représentation complète des caractéristiques nécessaires pour ces classes spécifiques.

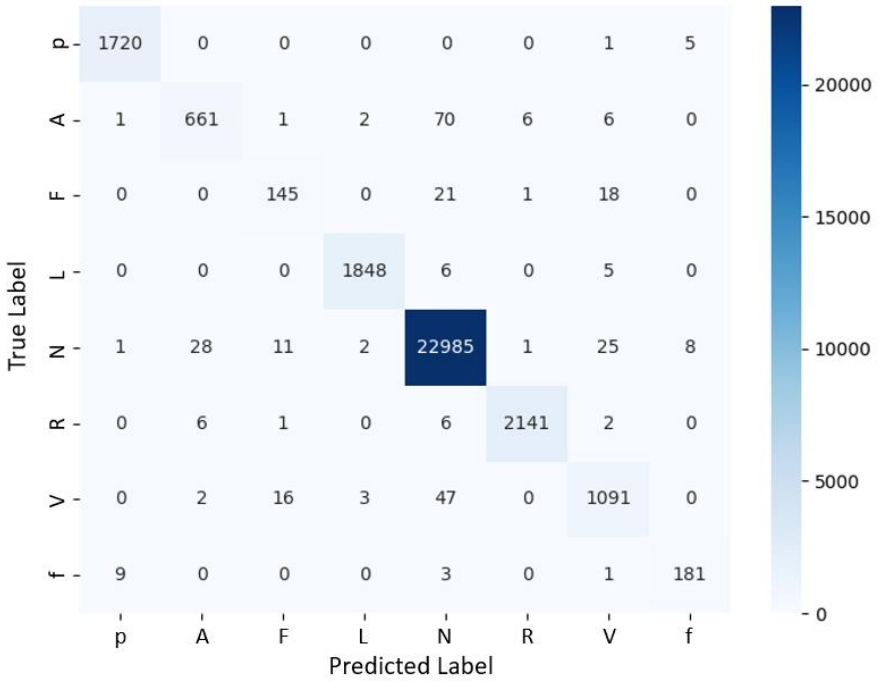

Figure 5.2. Matrice de confusion du modèle LSTM-Focal à partir des données de test.

Afin d'évaluer la capacité de discrimination du modèle LSTM-Focal, nous avons tracé la courbe ROC (Receiver Operating Characteristic) pour chaque classe de battement cardiaque. Cette courbe illustre le taux de vrais positifs (TPR) en fonction du taux de faux positifs (FPR). L'aire sous la courbe ROC (AUC) fournit une mesure globale des performances du modèle, une valeur proche de 1 indiquant une meilleure performance de classification.
Comme le montre la Figure 5.3, la plupart des courbes ROC s'approchent du coin supérieur gauche, suggérant une performance de classification élevée avec des valeurs d'AUC proches ou égales à 1,00. Cependant, les classes A et F présentent des valeurs d'AUC légèrement inférieures (0,98 et 0,97 respectivement), ce qui laisse suggéré que le modèle pourrait encore être amélioré pour ces classes. La courbe ROC micro-moyenne, qui synthétise les performances globales du modèle sur toutes les classes, témoigne d'une classification robuste, confirmant ainsi l'efficacité générale du modèle sur l'ensemble des données.

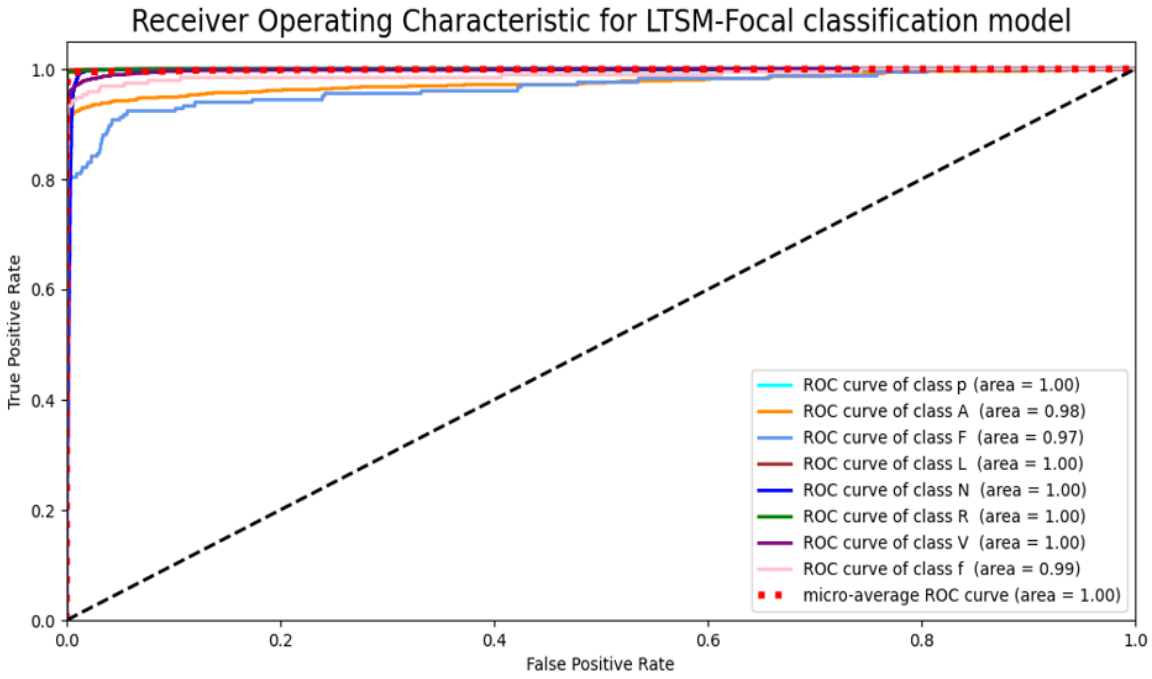

Figure 5.3. Courbe ROC micro-moyenne du modèle LSTM-Focal (ligne rouge en pointillés) et courbes ROC de toutes les classes de battements cardiaques.

c. L'impact des caractéristiques temporelles OMP sur la classification

Dans le cadre de cette approche, une expérience comparative a été réalisée en entraînant le modèle LSTM-Focal sur des caractéristiques extraites uniquement du réseau résiduel (ResNet). Cette comparaison vise à mettre en lumière l'impact des caractéristiques OMP sur les performances de classification. Les métriques d'évaluation globales, présentées dans le Tableau 5.4, montrent que l'entraînement du modèle avec des caractéristiques hybrides entraîne des résultats supérieurs à ceux obtenus avec uniquement les caractéristiques profondes ResNet. En effet, l'accuracy et le F1-score sont respectivement augmentés de 0,04 % et 0,11 %.
Plus particulièrement, le rappel pour la classe F a progressé, passant de 76,22 % à 78,38 % grâce à l'approche hybride, ce qui se traduit par une réduction du nombre de faux négatifs. Cette amélioration est encourageante dans le contexte du diagnostic des arythmies. Ainsi, les

caractéristiques OMP, qui capturent les schémas temps-fréquence des battements cardiaques, contribuent légèrement à l'amélioration de l'efficacité du modèle et renforcent sa capacité à distinguer les classes cardiaques.

Tableau 5.4. Les performances (%) du modèle LSTM-Focal appliqué aux caractéristiques hybrides Vs le modèle LSTM-Focal appliqué uniquement aux caractéristiques ResNet.

Modèle	Précision	Rappel	F1-score	Accuracy
LSTM-Focal pour les caractéristiques hybrides	95.55	94.04	94.77	98.99
LSTM-Focal pour les caractéristiques ResNet	95.43	93.84	94.61	98.95

5.6. Discussion et comparaison

Pour évaluer la robustesse de l'approche proposée, cette étude est confrontée à plusieurs travaux récents de la littérature, qui ont utilisé les bases de données de Physionet pour la classification multi-classes des battements cardiaques ECG. Comme l'indique le Tableau 5.5, une majorité d'articles s'appuie sur la base de données MIT-BIH Arrhythmia (MITDB), qui recense 17 types de battements cardiaques distincts. Par ailleurs, la base de données INCART est également exploitée dans l'application de modèles CNN [257] et CNN Siamois [264], permettant de détecter respectivement 5 et 7 classes. Notons que le CNN siamois, fondé sur un réseau jumeau et un mappage simple de l'espace caractéristique, atteint une accuracy de 95,6 %, tandis que notre modèle atteint une accuracy de 98,99 %. Les deux modèles réussissent à identifier cinq types courants de battements cardiaques (N, A, F, R, V).

Il est à relever que la majorité des travaux se concentre sur la classification de cinq classes de battements, en se basant soit sur le paradigme d'annotation des classes de la MITDB (Annexe A), soit sur celui de l'AAMI (Annexe B). Dans notre étude, chaque classe correspond à un type de battement cardiaque défini selon les annotations de la base de données MITDB. Les classes les plus fréquemment analysées incluent (N, V, L, R, S, A et F), étant donné leur prévalence dans les différentes bases de données de Physionet.

Pour comparer l'efficacité des modèles de classification, nous considérons uniquement les approches ayant utilisé le même paradigme d'annotation. Par exemple, l'étude [229] a obtenu un F1-score élevé de 97,2 % en employant des caractéristiques issues d'un auto-encodeur convolutif pour classer 5 battements, sans recourir à l'augmentation des données. En revanche, notre modèle a réalisé un F1-score de 94,77 % en utilisant une combinaison de caractéristiques hybrides de type ResNet et OMP. Un travail récent [265] a, quant à lui, utilisé une approche combinée de LSTM-GRU-CNN-Attention pour classifier 5 types de données augmentées grâce à un réseau GAN conditionnel, surpassant notre méthode avec un F1-score de 97,51 %. Toutefois, il convient de noter que cette étude n'a utilisé qu'une seule base de données avec 5 types de battements de cœur, alors que notre approche classifie 8 battements extraits de deux bases de données, permettant ainsi d'explorer différents motifs dans les données et d'améliorer la capacité de généralisation du modèle.

En confrontant notre méthode à certains articles ayant adopté le paradigme d'annotation de l'AAMI, nous avons observé des performances élevées. Des architectures complexes telles que AlexNet [259] appliquée aux images, et ResNet-101 [260] appliquée aux caractéristiques temps-fréquence, ont atteint respectivement des accuracy de 98,6 % et 94,57 %, par rapport à

une accuracy de 98,99 % obtenue par notre méthode sur des caractéristiques spatiales et temporelles fusionnées.

Des études détectant 13, 15 et 17 classes [112], ainsi que 14 classes [260], ont enregistré des F1-scores inférieurs sur la base de données MITDB, même en utilisant des techniques de sur-échantillonnage [260]. Ce phénomène peut être attribué à la nature fortement déséquilibrée de la MITDB, où les classes minoritaires sont sous-représentées, ce qui amène le modèle à se concentrer sur l'apprentissage des caractéristiques des classes majoritaires. Pour remédier à cette problématique, il est primordial de récupérer d'abord des données minoritaires supplémentaires, puis de les augmenter en recourant à des paradigmes d'augmentation des données robustes.

De nombreux modèles de Deep Learning peuvent atteindre une grande précision. Par exemple, l'étude [256] a obtenu un F1-score de 96,40 % en appliquant une combinaison de CNN et de Bi-LSTM directement sur des battements de cœur, sans recourir à une étape d'extraction de caractéristiques manuelle.

Notre approche se révèle compétitive, affichant des valeurs élevées d'accuracy et de F1-score en comparaison avec d'autres études ayant recours à des classes de battements cardiaques similaires.

Tableau 5.5. Tableau récapitulatif comparatif des approches de Deep Learning pour la classification des battements cardiaques.

Papier-Année	Base de données	Classe	Technique d'augmentation	Feature set	Classificateur	Performance	
						Accuracy	F1-score
[112] (2018)	MITDB	13 15 17	Aucune	Données brutes	CNN	95.2 92.51 91.33	92.45 89.28 85.38
[110] (2019)	MITDB	5	Aucune	Données brutes	U-Net modifié	97.32	94.56
[229] (2019)	MITDB	5	Aucune	CAE	LSTM	99.11	97.2
[256] (2020)	MITDB	4	Aucune	Données brutes	MF-CBRNN	99.56	96.40
[257] (2020)	MITDB INCART	5	Aucune	Données brutes	CNN	98.41 97.04	91.72 52.30
[258] (2021)	MITDB	4	Aucune	Données brutes	DenseNet-BiLSTM	99.44	95.89
[259] (2021)	MITDB	5	SMOTE	Fusion de GAF, RP et images MTF	AlexNet	98.6	92.49
[260] (2021)	MITDB	5 14	Sur-échantillonnage et sous-échantillonnage	HT-WVD	ResNET-101	94.57 99.75	95.95 90.16
[191] (2022)	MITDB	5	SMOTE	PCA	CNN+LSTM	99.35	98.38
[261] (2022)	MITDB	5	Aucune	Données brutes	CNN	99.81	92.12
[262] (2022)	MITDB	5	SMOTE	Données brutes	CNN+BiLSTM	98.36	91.67
[263] (2022)	MITDB	4	Aucune	Intervalles RR, coefficients	Adaboost	95.6	66.2

				HOS et DWT			
[264] (2023)	INCART	7	Aucune	Données brutes	CNN Siamois	95.6	95.54
[265] (2023)	MITDB	5	GAN conditionnel	Données brutes	BiLSTM-BiGRU+Dilated CNN + Attention	99.01	97.51
Approche proposée	MITDB et NSRDB	8	SMOTE	ResNet + OMP	LSTM-Focal	98.99	94.77

Les résultats de la présente approche dépassent ceux présentés au chapitre 4, où nous avions uniquement utilisé la base de données MITDB et avons employé un réseau résiduel pour l'extraction des caractéristiques, et un modèle LSTM-Focal, qui a atteint une accuracy globale de 98,61 %. Ainsi, la combinaison de caractéristiques hybrides avec le modèle basé sur la Modulation Focale constitue un élément clé pour un diagnostic efficace de l'arythmie.

Pour optimiser les performances de la méthode proposée, il est crucial d'extraire davantage de données originales correspondant aux classes minoritaires avant d'effectuer l'augmentation des données. Cette démarche permettra au modèle d'acquérir une compréhension approfondie des caractéristiques associées à chaque classe. De plus, l'extension du modèle à d'autres bases de données pourrait améliorer sa capacité à reconnaître divers types de battements cardiaques.

5.7. Conclusion

En conclusion, ce chapitre a mis en lumière l'importance cruciale de l'extraction hybride des caractéristiques ECG pour améliorer la classification des battements cardiaques. En combinant l'extraction des caractéristiques temporelles via la méthode du Matching Pursuit Orthogonal (OMP) avec l'extraction profonde à l'aide du réseau Résiduel (ResNet), cette approche a permis d'atteindre des résultats remarquables, avec un taux de détection de 98,99 %, une précision de 95.55 % et un F1-score de 94,77 %. Ces performances dépassent celles obtenues avec des méthodes classiques, illustrant ainsi l'efficacité de la complémentarité entre les représentations temporelles et spatiales des signaux ECG.

D'autre part, la classification des battements cardiaques à l'aide du modèle LSTM-Focal s'est révélée particulièrement rapide, nécessitant seulement 0,0002 seconde par battement. Ce temps de prédiction réduit est prometteur pour la mise en œuvre de la présente approche dans les applications de soins de santé en ligne en temps réel.

Ainsi, cette approche pave la voie à des applications futures dans le domaine de la cardiologie, où une détection précoce et précise des anomalies cardiaques est primordiale pour améliorer les soins aux patients et les résultats cliniques. Les travaux futurs pourraient se concentrer sur l’extraction de caractéristiques qui augmentent la différentiation entre les battements et l'exploration de nouvelles méthodes d'apprentissage afin de renforcer encore la performance des modèles de classification.

Conclusion générale et perspectives

Cette thèse a permis d'explorer l'utilisation des techniques d'intelligence artificielle (IA) pour la classification des battements cardiaques à partir des signaux électrocardiogrammes (ECG). Le travail mené s'inscrit dans un contexte médical où la détection précoce et précise des arythmies revêt une importance majeure pour la prise en charge des patients et la prévention des complications graves. L'IA, avec ses avancées récentes en matière d'apprentissage profond, s'est révélée être un outil puissant pour l'analyse des signaux ECG, permettant non seulement une meilleure classification des battements cardiaques, mais aussi une capacité accrue à traiter les données complexes et massives issues de la surveillance médicale.

Dans un premier temps, nous avons présenté une introduction détaillée du système cardiovasculaire et du signal ECG, ainsi qu'une discussion sur les arythmies cardiaques, leurs caractéristiques, leurs types et leur impact clinique. Ceci a également permis d'établir la problématique de recherche et les contributions principales de cette thèse, en soulignant les défis scientifiques et techniques liés à la classification des battements cardiaques dans un cadre médical.

Ensuite, nous avons présenté l'état de l'art des techniques de prétraitement, d'extraction des caractéristiques, de génération des données synthétiques et de classification des signaux ECG. Cette revue a mis en évidence les principales approches utilisées, notamment les méthodes classiques de Machine Learning et les approches de Deep Learning, ainsi que leurs limites en termes de performance et de généralisabilité. À partir de cette analyse, des contributions originales ont été proposées dans le cadre de cette thèse.

L'un des apports majeurs de ce travail réside dans le développement de la variante **DTW-SMOTE**, une méthode d'augmentation des données ECG. Cette approche a permis de surmonter le problème de déséquilibre des classes, fréquemment rencontré dans les bases de données ECG, tout en préservant la variabilité temporelle des battements cardiaques grâce à l'utilisation de la distance de similarité DTW. L'évaluation de la méthode a démontré son efficacité, notamment en augmentant la diversité des données d'entraînement et en améliorant les performances des modèles de classification.

Ensuite, nous avons conçu des modèles de classification des battements cardiaques basés sur des architectures profondes, notamment à travers l'utilisation des réseaux résiduels (ResNet) et du module de **Modulation Focale**. Ces modèles se sont distingués par leur capacité à extraire des caractéristiques complexes des signaux ECG, leur permettant de mieux différencier les battements normaux des battements anormaux, avec un taux de détection atteignant 98.61 % et un F1-score de 94.08 %. En outre, l'intégration d'une approche d'extraction hybride fusionnant les caractéristiques temporelles issues de l'OMP et des caractéristiques spatiales a produit des résultats encore plus prometteurs. Cette stratégie a permis d'atteindre un taux de détection de 98.99 %, un F1-score de 94.77 % et un temps de classification de 2.10^{-4} seconde, mettant en évidence l'intérêt de combiner plusieurs types de représentations complémentaires du signal.

Ces résultats expérimentaux sur des bases de données ECG de référence, telles que MITDB et NSRDB, ont confirmé la robustesse des approches proposées. Les modèles développés ont

surpassé plusieurs méthodes classiques, en termes de précision de classification et de temps de prédiction, ce qui représente un atout majeur dans les environnements cliniques.

Perspectives

Bien que les résultats obtenus soient encourageants, plusieurs pistes d'amélioration et de développement futures peuvent être envisagées :

- **Utilisation des modèles multimodaux** : Une des perspectives majeures consiste à exploiter des modèles de classification multimodaux, capables d'intégrer simultanément plusieurs types de données complémentaires pour améliorer la précision des prédictions. Par exemple :
    - Les signaux temporels (ECG brut) pourraient être combinés avec leurs représentations fréquentielles (par transformation de Fourier ou de Hilbert) pour capturer des caractéristiques globales et locales.
    - Les représentations visuelles du signal ECG, telles que les images de Gramian Angular Fields (GAF) ou les Markov Transition Fields (MTF), pourraient enrichir les modèles en exploitant des informations spatiales.

  Une telle approche permettrait de tirer parti de la complémentarité entre différentes représentations des signaux ECG pour améliorer la détection des arythmies complexes.

- **Généralisation des modèles** : Les modèles développés ont été principalement évalués sur des bases de données spécifiques, ce qui représente une étape essentielle dans leur validation initiale. Il serait essentiel, dans un cadre futur, de valider ces modèles sur des bases de données ECG plus diversifiées, issues de différents environnements cliniques et couvrant des populations variées (âge, sexe, comorbidités). Cette généralisation permettrait de :
    - Vérifier la robustesse des modèles face à des bruits spécifiques à l'acquisition clinique, comme les interférences des dispositifs ou les variations dues aux postures des patients.
    - Garantir une capacité d'adaptation des modèles à des populations de patients présentant des pathologies multiples, ce qui est crucial pour une application clinique à grande échelle.

- **Implémentation clinique et surveillance en temps réel** : L'intégration des modèles développés dans des systèmes de monitoring cardiaque en temps réel constitue une perspective à fort impact clinique. Une telle implémentation pourrait inclure :
    - La détection automatique des arythmies dans des dispositifs portables (smartwatches, patchs ECG connectés).
    - La transmission des alertes aux cliniciens en temps réel, permettant des interventions rapides et personnalisées.
    - L'intégration dans des systèmes hospitaliers de télémédecine pour surveiller les patients à distance, contribuant ainsi à réduire les coûts et les délais de prise en charge.

- **Explicabilité des modèles** : Un défi crucial à relever pour encourager l'adoption des modèles d'intelligence artificielle en médecine est leur explicabilité. Il serait pertinent

de développer des techniques qui permettent aux cliniciens de comprendre et d'interpréter les décisions des modèles. Ces techniques pourraient inclure :

- Des approches de visualisation (par exemple, les cartes de chaleur pour identifier les parties du signal influençant le plus les prédictions).
- Des méthodes d'interprétabilité globales, comme les algorithmes SHAP (SHapley Additive exPlanations) ou LIME (Local Interpretable Model-agnostic Explanations).

Cette explicabilité contribuerait à instaurer une confiance accrue dans les systèmes d'IA, en assurant leur transparence et leur fiabilité pour une prise de décision médicale critique.

En conclusion, cette thèse a montré que l'IA offre des perspectives prometteuses pour la détection des battements cardiaques. Les travaux réalisés ouvrent la voie à de nouvelles recherches, tant sur le plan théorique que pratique, pour améliorer encore les performances des systèmes d'IA appliqués à la cardiologie, avec pour objectif ultime d'améliorer les soins aux patients.

Bibliographie

[1] World Heart Federation. (2023). *World heart report 2023*. https://world-heart-federa-tion.org/wp-content/uploads/World-Heart-Report-2023.pdf

[2] Ministère des Solidarités et de la Santé. (2020). *Covid-19: Third leading cause of death in France in 2020*. https://drees.solidarites-sante.gouv.fr/sites/default/files/2023-07/ER1250EN.pdf

[3] Fédération Française de Cardiologie. (2021, May 21). *Les artères et les veines*. https://www.fedecardio.org/je-m-informe/les-arteres-et-les-veines/

[4] Betts, J. G., Young, K. A., Wise, J. A., Johnson, E., Poe, B., Kruse, D. H., Korol, O., Johnson, J. E., Womble, M. D., & DeSaix, P. (2019). Structure and function of blood vessels. In *The cardiovascular system: Blood vessels and circulation*. In *Anatomy and Physiology 2e*. OpenStax. https://openstax.org/books/anatomy-and-physiology-2e/pages/20-1-structure-and-function-of-blood-vessels

[5] Texas Heart Institute. (n.d.). *Heart anatomy*. Retrieved April 1, 2024, from https://www.texasheart.org/heart-health/heart-information-center/topics/heart-anatomy/

[6] Rehman, I., & Rehman, A. (2023). Anatomy, thorax, heart. In *StatPearls*. StatPearls Publishing. https://www.ncbi.nlm.nih.gov/books/NBK470256/

[7] Betts, J. G., Young, K. A., Wise, J. A., Johnson, E., Poe, B., Kruse, D. H., Korol, O., Johnson, J. E., Womble, M. D., & DeSaix, P. (2019). Heart anatomy. In *The cardiovascular system: The heart*. In *Anatomy and Physiology 2e*. OpenStax. https://openstax.org/books/anatomy-and-physiology-2e/pages/19-1-heart-anatomy

[8] Goldberger, A. L., Goldberger, Z. D., & Shvilkin, A. (2018). Essential concepts: What is an ECG? In A. L. Goldberger, Z. D. Goldberger, & A. Shvilkin (Eds.), *Goldberger's clinical electrocardiography* (9th ed., pp. 2-5). Elsevier. DOI: 10.1016/B978-0-323-40169-2.00001-9

[9] Betts, J. G., Young, K. A., Wise, J. A., Johnson, E., Poe, B., Kruse, D. H., Korol, O., Johnson, J. E., Womble, M. D., & DeSaix, P. (2019). Cardiac muscle and electrical activity. In *The cardiovascular system: The heart*. In *Anatomy and Physiology 2e*. https://openstax.org/books/anatomy-and-physiology-2e/pages/19-2-cardiac-muscle-and-electrical-activity

[10] Iaizzo, P. A. (Ed.). (2009*). Handbook of cardiac anatomy, physiology, and devices* (2nd ed.). Springer.

[11] Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. Ch., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., & Stanley, H. E. (2000). PhysioBank,

PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation, 101(23).* DOI: 10.1161/01.cir.101.23.e215

[12] Rawshani, A. (2008). *The clinical ECG interpretation* (e-book). ECGWaves. https://ecgwaves.com/course/the-ecg-book/

[13] Goldberger, A. L., Goldberger, Z. D., & Shvilkin, A. (2018). ECG basics: Waves, intervals, and segments. In A. L. Goldberger, Z. D. Goldberger, & A. Shvilkin (Eds.), *Goldberger's clinical electrocardiography* (9th ed., pp. 6-10). Elsevier. DOI: 10.1016/B978-0-323-40169-2.00002-0

[14] Goldberger, A. L., Goldberger, Z. D., & Shvilkin, A. (2018). How to make basic ECG measurements. In A. L. Goldberger, Z. D. Goldberger, & A. Shvilkin (Eds.), *Goldberger's clinical electrocardiography* (9th ed., pp. 11-20). Elsevier. DOI: 10.1016/B978-0-323-40169-2.00003-2

[15] Goldberger, A. L., Goldberger, Z. D., & Shvilkin, A. (2018). The normal ECG. In A. L. Goldberger, Z. D. Goldberger, & A. Shvilkin (Eds.), *Goldberger's clinical electrocardiography* (9th ed., pp. 32-40). Elsevier. DOI: 10.1016/B978-0-323-40169-2.00005-6

[16] Malik, M., et al. (1996). Heart rate variability: Standards of measurement, physiological interpretation, and clinical use. *European Heart Journal, 17*(3), 354-381. DOI: 10.1093/oxfordjournals.eurheartj.a014868

[17] Shaffer, F., & Ginsberg, J. P. (2017). An overview of heart rate variability metrics and norms. *Frontiers in Public Health, 5*, 258. DOI: 10.3389/fpubh.2017.00258

[18] American Heart Association. (2022, November). About arrhythmia. https://www.heart.org/en/health-topics/arrhythmia/about-arrhythmia

[19] Zipes, D. P., & Jalife, J. (Eds.). (2013). Cardiac electrophysiology: From cell to bedside (6th ed.). *Elsevier Health Sciences*.

[20] Lilly, L. S. (2012). Pathophysiology of heart disease: A collaborative project of medical students and faculty (5th ed.). Wolters Kluwer Health/Lippincott Williams & Wilkins.

[21] Yasuma, F., & Hayano, J. (2004). Respiratory sinus arrhythmia: Why does the heartbeat synchronize with respiratory rhythm? *Chest, 125*(2), 683-690. DOI: 10.1378/chest.125.2.683

[22] Boulif, A., Ananou, B., Ouladsine, M., & Delliaux, S. (2024). Focal-based deep learning model for automatic arrhythmia diagnosis. In L. Franco, C. de Mulatier, M. Paszynski, V. V. Krzhizhanovskaya, J. J. Dongarra, & P. M. A. Sloot (Eds.), *Computational science – ICCS 2024. Lecture notes in computer science* (Vol. 14835). Springer, Cham. DOI: 10.1007/978-3-031-63772-8_31

[23] Roukoz, H., Lü, F., & Sakaguchi, S. (2015). Catheter ablation of cardiac arrhythmias. In P. Iaizzo (Ed.), *Handbook of cardiac anatomy, physiology, and devices*. Springer. DOI: 10.1007/978-3-319-19464-6_28

[24] Goldberger, A. L., Goldberger, Z. D., & Shvilkin, A. (2018). Ventricular conduction disturbances: Bundle branch blocks and related abnormalities. In A. L. Goldberger, Z. D. Goldberger, & A. Shvilkin (Eds.), *Goldberger's clinical electrocardiography* (9th ed., pp. 61-72). Elsevier. DOI: 10.1016/B978-0-323-40169-2.00008-1

[25] Goldberger, A. L., Goldberger, Z. D., & Shvilkin, A. (2018). Pacemakers and implantable cardioverter–defibrillators: Essentials for clinicians. In A. L. Goldberger, Z. D. Goldberger, & A. Shvilkin (Eds.), *Goldberger's clinical electrocardiography* (9th ed., pp. 226-239). Elsevier. DOI: 10.1016/B978-0-323-40169-2.00022-6

[26] Goldberger, A. L., Goldberger, Z. D., & Shvilkin, A. (2018). Ventricular arrhythmias. In A. L. Goldberger, Z. D. Goldberger, & A. Shvilkin (Eds.), *Goldberger's clinical electrocardiography* (9th ed., pp. 156-171). Elsevier. DOI: 10.1016/B978-0-323-40169-2.00016-0

[27] Conover, M. B. (2002). *Understanding electrocardiography* (8th ed.). Elsevier Health Sciences.

[28] M. Sugadev, M. Kaushik, V. Vijaykumar, & T. Ravi. (2021). Survey on Various noise sources in ECG signal and its Filtering Methods. *2021 10th International Conference on Internet of Everything, Microwave Engineering, Communication and Networks (IEMECON)*, Jaipur, India, pp. 01-06. DOI: 10.1109/IEMECON53809.2021.9689132

[29] Satija, U., Ramkumar, B., & Manikandan, M. S. (2018). A review of signal processing techniques for electrocardiogram signal quality assessment. *IEEE Reviews in Biomedical Engineering, 11*, 36-52. DOI: 10.1109/RBME.2018.2810957

[30] Gacek, A. (2012). An introduction to ECG signal processing and analysis. In A. Gacek & W. Pedrycz (Eds.), *ECG signal processing, classification and interpretation* (pp. 1-28). Springer. DOI: 10.1007/978-0-85729-868-3_2

[31] Clifford, G. D. (2006). ECG statistics, noise, artifacts, and missing data. *Advanced Methods and Tools for ECG Data Analysis*, 6, 55–99

[32] Widrow, B., & Stearns, S. D. (1985). *Adaptive signal processing*. Englewood Cliffs, NJ: Prentice-Hall.

[33] Pan, J., & Tompkins, W. J. (1985). A real-time QRS detection algorithm. *IEEE Transactions on Biomedical Engineering*, 32(3), 230–236. DOI: 10.1109/TBME.1985.325532

[34] Murthy, I. S. N., & Niranjan, U. C. (1992). Decomposition of ECG by linear filtering. *Computers in Biology and Medicine, 22*(1–2), 13-22. DOI: 10.1016/0010-4825(92)90048-R

[35] Sörnmo, L., & Laguna, P. (2005). *Bioelectrical signal processing in cardiac and neurological applications*. Elsevier.

[36] Donoho, D. L. (1995). De-noising by soft-thresholding. *IEEE Transactions on Information Theory, 41(3),* 613–627. DOI: 10.1109/18.382009

[37] Addison, P. S. (2005). Wavelet transforms and the ECG: A review. *Physiological Measurement, 26(5),* R155–R199. DOI: 10.1088/0967-3334/26/5/R01

[38] Huang, N., Shen, Z., Long, S., Wu, M. L. C., Shih, H., Zheng, Q., Yen, N. C., Tung, C. C., & Liu, H. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, *454*(1971), 903–995. DOI: 10.1098/rspa.1998.0193

[39] Blanco-Velasco, M., Weng, B., & Barner, K. E. (2008). ECG signal denoising and baseline wander correction based on the empirical mode decomposition. *Computers in Biology and Medicine*, *38*(1), 1–13. DOI: 10.1016/j.compbiomed.2007.06.003

[40] Suchetha, M., Kumaravel, N., Jagannath, M., & Jaganathan, S. K. (2017). A comparative analysis of EMD based filtering methods for 50Hz noise cancellation in ECG signal. *Informatics in Medicine Unlocked*, *8*, 54–59. DOI: 10.1016/j.imu.2017.01.003

[41] Wu, Z., & Huang, N. E. (2009). Ensemble empirical mode decomposition: A noise-assisted data analysis method. *Advances in Adaptive Data Analysis*, *1*(1), 1–41. DOI: 10.1142/S1793536909000047

[42] Yeh, J.-R., Shieh, J.-S., & Huang, N. (2010). Complementary ensemble empirical mode decomposition: A novel noise enhanced data analysis method. *Advances in Adaptive Data Analysis*, *2*(2), 135–156. DOI: 10.1142/S1793536910000422

[43] Jung, T. P., Makeig, S., Humphries, C., Lee, T. W., McKeown, M. J., Iragui, V., & Sejnowski, T. J. (2000). Removing electroencephalographic artifacts by blind source separation. *Psychophysiology*, *37*(2), 163–178. DOI: 10.1111/1469-8986.3720163

[44] Clifford, G., & Tarassenko, L. (2005). Application of ICA in removing artefacts from the ECG. *Neural Computing and Applications*, *15*, 105–116. DOI: 10.1007/s00521-005-0466-1

[45] Sweeney, K., Ward, T., & McLoone, S. (2012). Artifact removal in physiological signals-practices and possibilities. *IEEE Transactions on Information Technology in Biomedicine*, *16*(3), 488–500. DOI: 10.1109/TITB.2012.2188536

[46] Barhatte, A. S., Ghongade, R., & Tekale, S. V. (2016). Noise analysis of ECG signal using fast ICA. *In 2016 Conference on Advances in Signal Processing (CASP)* (pp. 118-122). IEEE. DOI: 10.1109/CASP.2016.7746149

[47] Castaño Usuga, F. A., Gissel, C., & Hernández, A. M. (2022). Motion artifact reduction in electrocardiogram signals through a redundant denoising independent component analysis method for wearable health care monitoring systems: Algorithm development and validation. *JMIR Medical Informatics, 10*(11), e40826. DOI: 10.2196/40826

[48] Thakor, N. V., & Zhu, Y. S. (1991). Applications of adaptive filtering to ECG analysis: noise cancellation and arrhythmia detection. *IEEE Transactions on Biomedical Engineering*, *38*(8), 785–794. DOI: 10.1109/10.83591

[49] Shaddeli, R., Yazdanjue, N., Ebadollahi, S., Saberi, M. M., & Gill, B. (2021). Noise removal from ECG signals by adaptive filter based on variable step size LMS using evolutionary algorithms. *2021 IEEE Canadian Conference on Electrical and Computer Engineering (CCECE)*, 1–7. DOI: 10.1109/CCECE53047.2021.9569149

[50] He, X., Goubran, R. A., & Liu, X. P. (2012). Ensemble Empirical Mode Decomposition and adaptive filtering for ECG signal enhancement. *2012 IEEE International Symposium on Medical Measurements and Applications Proceedings*, 1–5. DOI: 10.1109/MeMeA.2012.6226649

[51] Chen, M., Zhong, Y., Zhu, H., & Pan, Y. (2018). Kalman Filter Based Electromyographic Signal Suppression of Real-Time ECG Signal. *2018 Computing in Cardiology Conference (CinC)*, 1–4. DOI: 10.22489/CinC.2018.198

[52] Sameni, R., Shamsollahi, M. B., Jutten, C., & Babaie-Zade, M. (2005). Filtering noisy ECG signals using the extended Kalman filter based on a modified dynamic ECG model. *Computers in Cardiology 2005*, Lyon, France, 1017-1020. DOI: 10.1109/CIC.2005.1588283.

[53] Sarafan, S., et al. (2022). A Novel ECG Denoising Scheme Using the Ensemble Kalman Filter. *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Glasgow, Scotland, United Kingdom, 2005-2008. DOI: 10.1109/EMBC48229.2022.9871884.

[54] Moradi, M. H., Ashoori Rad, M., & Baghbani Khezerloo, R. (2014). ECG signal enhancement using adaptive Kalman filter and signal averaging. *International Journal of Cardiology, 173*(3), 553–555. DOI: 10.1016/j.ijcard.2014.03.128

[55] Romero, I. (2010). PCA-based noise reduction in ambulatory ECGs. *2010 Computing in Cardiology*, Belfast, UK, 677-680.

[56] Romero, I. (2011). PCA and ICA applied to noise reduction in multi-lead ECG. *2011 Computing in Cardiology*, Hangzhou, China, 613-616.

[57] Saladi, S., Yepuganti, K., & Gudheti, R. (2019). Denoising of ECG Signals Using Wavelet Transform and Principal Component Analysis. *SSRN Electronic Journal*. DOI: 10.2139/ssrn.3356368.

[58] K. Sharmila, E. H. Krishna, K. N. Reddy, & K. A. Reddy. (2011). Application of multiscale principal component analysis (MSPCA) for enhancement of ECG signals. *2011 IEEE International Instrumentation and Measurement Technology Conference*, Hangzhou, China, pp. 1-5. DOI: 10.1109/IMTC.2011.5944301.

[59] Liu, B., & Li, Y. (2021). ECG signal denoising based on similar segments cooperative filtering. *Biomedical Signal Processing and Control, 68*, 102751. DOI: 10.1016/j.bspc.2021.102751

[60] Raheja, N., & Manoacha, A.K. (2023). Wavelet and Savitzky–Golay Filter-Based Denoising of Electrocardiogram Signal: An Improved Approach. In Jain, S., Marriwala, N., Tripathi, C.C., & Kumar, D. (Eds.), *Emergent Converging Technologies and Biomedical*

Systems. ETBS 2022 (Vol. 1040). Springer, Singapore. DOI: 10.1007/978-981-99-2271-0_27.

[61] Samann, F., & Schanze, T. (2019). An efficient ECG denoising method using discrete wavelet with Savitzky-Golay filter. *Current Directions in Biomedical Engineering, 5*(1), 385-387. DOI: 10.1515/cdbme-2019-0097

[62] Jin, Y., Qin, C., Liu, J., Liu, Y., Li, Z., & Liu, C. (2024). A novel deep wavelet convolutional neural network for actual ECG signal denoising. *Biomedical Signal Processing and Control, 87*(Part A), 105480. DOI: 10.1016/j.bspc.2023.105480

[63] Arsene, C. T. C., Hankins, R., & Yin, H. (2019). Deep learning models for denoising ECG signals. In *Proceedings of the 27th European Signal Processing Conference (EUSIPCO)* (pp. 1–5). DOI: 10.23919/EUSIPCO.2019.8902833

[64] Samann, F., & Schanze, T. (2023). RunDAE model: Running denoising autoencoder models for denoising ECG signals. *Computers in Biology and Medicine, 166*, 107553. DOI: 10.1016/j.compbiomed.2023.107553

[65] Antczak, K. (2018). Deep recurrent neural networks for ECG signal denoising (ArXiv:1807.11551). https://arxiv.org/abs/1807.11551

[66] Mvuh, F. L., Ebode Ko'a, C. O. V., & Bodo, B. (2024). Multichannel high noise level ECG denoising based on adversarial deep learning. *Scientific Reports, 14*, 801. DOI: 10.1038/s41598-023-50334-7

[67] Hou, Y., Liu, R., Shu, M., & Chen, C. (2023). An ECG denoising method based on adversarial denoising convolutional neural network. *Biomedical Signal Processing and Control, 84*, 104964. DOI: 10.1016/j.bspc.2023.104964

[68] Singh, P., & Pradhan, G. (2021). A new ECG denoising framework using generative adversarial network. *IEEE/ACM Transactions on Computational Biology and Bioinformatics, 18*(2), 759–764. DOI: 10.1109/TCBB.2020.2976981

[69] Tracey, B. H., & Miller, E. L. (2012). Nonlocal means denoising of ECG signals. *IEEE Transactions on Biomedical Engineering, 59*(9), 2383–2386. DOI: 10.1109/TBME.2012.2208964

[70] Madan, P., Singh, V., Singh, D. P., Diwakar, M., & Kishor, A. (2022). Denoising of ECG signals using weighted stationary wavelet total variation. *Biomedical Signal Processing and Control, 73*, 103478. DOI: 10.1016/j.bspc.2021.103478

[71] Dogan, H., & Dogan, R. O. (2023). A comprehensive review of computer-based techniques for R-peaks/QRS complex detection in ECG signal. *Archives of Computational Methods in Engineering, 30*(3703–3721). DOI: 10.1007/s11831-023-09916-x

[72] Li, C., Zheng, C., & Tai, C. (1995). Detection of ECG characteristic points using wavelet transforms. *IEEE Transactions on Biomedical Engineering, 42*(1), 21-28. DOI: 10.1109/10.362922

[73] Ghaffari, A., Homaeinezhad, M. R., Akraminia, M., Atarod, M., & Daevaeiha, M. (2009). A robust wavelet-based multi-lead electrocardiogram delineation algorithm. *Medical Engineering & Physics, 31*(10), 1219–1227. DOI: 10.1016/j.medengphy.2009.07.017

[74] Xu, X., & Liu, Y. (2005). Adaptive threshold for QRS complex detection based on wavelet transform. In *Proceedings of the 27th Annual Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 7281–7284). DOI: 10.1109/IEMBS.2005.1616192

[75] Sharma, N., Sunkaria, R. K., & Sharma, L. D. (2022). QRS complex detection using stationary wavelet transform and adaptive thresholding. *Biomedical Physics & Engineering Express, 8*(6). DOI: 10.1088/2057-1976/ac8e70

[76] Yochum, M., Renaud, C., & Jacquir, S. (2016). Automatic detection of P, QRS, and T patterns in 12-lead ECG signals based on CWT. *Biomedical Signal Processing and Control, 25*, 46–52. DOI: 10.1016/j.bspc.2015.10.011

[77] Chouakri, S., Bereksi-Reguig, F., & Taleb-Ahmed, A. (2011). QRS complex detection based on multi-wavelet packet decomposition. *Applied Mathematics and Computation, 217*(23), 9508–9525. DOI: 10.1016/j.amc.2011.05.015

[78] Pan, J., & Tompkins, W. J. (1985). A real-time QRS detection algorithm. *IEEE Transactions on Biomedical Engineering, 32*(3), 230-236. DOI: 10.1109/TBME.1985.325532

[79] Hamilton, P. S., & Tompkins, W. J. (1986). Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmia database. *IEEE Transactions on Biomedical Engineering, 33*(12), 1157–1165. DOI: 10.1109/tbme.1986.325695

[80] Nasar, H., & Jabber, J. (2020). An efficient technique of QRS complex detection of electrocardiography signal based on optimized median filter and efficient signal reshaping. *International Journal of Signal System Control and Engineering Application, 12*, 13–20. DOI: 10.36478/ijssceapp.2019.13.20

[81] Phukpattaranont, P. (2015). QRS detection algorithm based on the quadratic filter. *Expert Systems with Applications, 42*(11), 4867–4877. DOI: 10.1016/j.eswa.2015.02.012

[82] Castells-Rufas, D., & Carrabina, J. (2015). Simple real-time QRS detector with the MaMeMi filter. *Biomedical Signal Processing and Control, 21*, 137–145. DOI: 10.1016/j.bspc.2015.06.001

[83] Kim, J., & Shin, H. (2016). Simple and robust realtime QRS detection algorithm based on spatiotemporal characteristic of the QRS complex. *PLoS ONE, 11*(3), e0150144. DOI: 10.1371/journal.pone.0150144

[84] Trahanias, P. E. (1993). An approach to QRS complex detection using mathematical morphology. *IEEE Transactions on Biomedical Engineering, 40*(2), 201–205. DOI: 10.1109/10.212060

[85] Chen, Y., & Duan, H. (2005). A QRS complex detection algorithm based on mathematical morphology and envelope. In *Proceedings of the 2005 IEEE Engineering in Medicine and Biology Society* (pp. 4654–4657). DOI: 10.1109/IEMBS.2005.1615508

[86] Yazdani, S., & Vesin, J.-M. (2016). Extraction of QRS fiducial points from the ECG using adaptive mathematical morphology. *Digital Signal Processing, 56*, 100–109. DOI: 10.1016/j.dsp.2016.06.010

[87] Benitez, D., Gaydecki, P. A., Zaidi, A., & Fitzpatrick, A. P. (2001). The use of the Hilbert transform in ECG signal analysis. *Computers in Biology and Medicine, 31*(5), 399–406. DOI: 10.1016/S0010-4825(01)00009-9

[88] Manikandan, M. S., & Soman, K. (2012). A novel method for detecting R-peaks in electrocardiogram (ECG) signal. *Biomedical Signal Processing and Control, 7*(2), 118–128. DOI: 10.1016/j.bspc.2011.03.004

[89] Zhu, H., & Dong, J. (2013). An R-peak detection method based on peaks of Shannon energy envelope. *Biomedical Signal Processing and Control, 8*, 466–474. DOI: 10.1016/j.bspc.2013.01.001

[90] Sahoo, S., Biswal, P., Das, T., & Sabut, S. (2016). De-noising of ECG signal and QRS detection using Hilbert transform and adaptive thresholding. *Procedia Technology, 25*, 68–75. DOI: 10.1016/j.protcy.2016.08.084

[91] Sabherwal, P., Aggarwal, M., & Singh, L. (2017). Automatic detection of the R peaks in single-lead ECG signal. *Circuits, Systems, and Signal Processing, 36*. DOI: 10.1007/s00034-017-0537-2

[92] Xiang, Y., Lin, Z., & Meng, J. (2018). Automatic QRS complex detection using two-level convolutional neural network. *BioMedical Engineering OnLine, 17*(13). DOI: 10.1186/s12938-018-0441-4

[93] Mehta, S. S., & Lingayat, N. S. (2008). Combined entropy-based method for detection of QRS complexes in 12-lead electrocardiogram using SVM. *Computers in Biology and Medicine, 38*(1), 138–145. DOI: 10.1016/j.compbiomed.2007.08.003

[94] Belkadi, M. A., Daamouche, A., & Melgani, F. (2021). A deep neural network approach to QRS detection using autoencoders. *Expert Systems with Applications, 184*, 115528. DOI: 10.1016/j.eswa.2021.115528

[95] Vijayarangan, S., Vignesh, R., Murugesan, B., Preejith, S. P., Joseph, J., & Sivaprakasam, M. (2020). RPnet: A deep learning approach for robust R peak detection in noisy ECG. In *Proceedings of the 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 345–348). IEEE. DOI: 10.1109/EMBC44109.2020.9176084

[96] Madeiro, J. P., Cortez, P. C., Marques, J. A., Seisdedos, C. R., & Sobrinho, C. R. (2012). An innovative approach of QRS segmentation based on first-derivative, Hilbert, and Wavelet Transforms. *Medical Engineering & Physics, 34*(9), 1236–1246. DOI: 10.1016/j.medengphy.2011.12.011

[97] Bajaj, A., & Kumar, S. (2019). QRS complex detection using fractional Stockwell transform and fractional Stockwell Shannon energy. *Biomedical Signal Processing and Control, 54*, 101628. DOI: 10.1016/j.bspc.2019.101628

[98] Guendouzi, F., & Attari, M. (2022). QRS complex detection in ECG signals using empirical wavelet transform and flower pollination algorithm. *Periodica Polytechnica Electrical Engineering and Computer Science, 66*(4), 380–390. DOI: 10.3311/PPee.20535

[99] Rodríguez, R., Mexicano, A., Bila, J., Cervantes, S., & Ponce, R. (2015). Feature extraction of electrocardiogram signals by applying adaptive threshold and principal component analysis. *Journal of Applied Research and Technology, 13*(2), 261–269. DOI: 10.1016/j.jart.2015.06.008

[100] Yun, D., Lee, H. C., Jung, C. W., Kwon, S., Lee, S. R., Kim, K., Kim, Y. S., & Han, S. S. (2022). Robust R-peak detection in an electrocardiogram with stationary wavelet transformation and separable convolution. *Scientific Reports, 12*(1), 19638. DOI: 10.1038/s41598-022-19495-9

[101] Martis, R. J., Acharya, U. R., Lim, C. M., Mandana, K. M., Ray, A. K., & Chakraborty, C. (2013). Application of higher order cumulant features for cardiac health diagnosis using ecg signals. *International Journal of Neural Systems, 23*(04), 1350014.

[102] Gao, J., Zhang, H., Lu, P., & Wang, Z. (2019). An Effective LSTM Recurrent Network to Detect Arrhythmia on Imbalanced ECG Dataset. *Journal of Healthcare Engineering, 2019*, 1–10. DOI: 10.1155/2019/6320651

[103] Yang, W., Si, Y., Wang, D., & Zhang, G. (2019). A Novel Approach for Multi-Lead ECG Classification Using DL-CCANet and TL-CCANet. *Sensors, 19*(14), 3214. DOI: 10.3390/s19143214

[104] Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adam, M., Gertych, A., & Tan, R. S. (2017). A deep convolutional neural network model to classify heartbeats. *Computers in Biology and Medicine, 89*, 389–396. DOI: 10.1016/j.compbiomed.2017.08.022

[105] Martínez, J. P., Almeida, R., Olmos, S., Rocha, A. P., & Laguna, P. (2004). A wavelet-based ECG delineator: Evaluation on standard databases. *IEEE Transactions on Biomedical Engineering, 51*(4), 570–581. DOI: 10.1109/TBME.2003.821031

[106] Al-Shrouf, A. (2020). ECG beat classification using a sliding window and correlation of the three-bit linear prediction error signal. *WSEAS Transactions on Signal Processing, 16*, 12–18. DOI: 10.37394/232014.2020.16.2

[107] Niroshana, S. M. I., Kuroda, S., Tanaka, K., & et al. (2023). Beat-wise segmentation of electrocardiogram using adaptive windowing and deep neural network. *Scientific Reports, 13*, 11039. DOI: 10.1038/s41598-023-37773-y

[108] Yang, W., Si, Y., Wang, D., & Guo, B. (2018). Automatic recognition of arrhythmia based on principal component analysis network and linear support vector machine. *Computers in Biology and Medicine, 101*, 22–32. DOI: 10.1016/j.compbiomed.2018.08.003

[109] Dai, H., Hwang, H. G., & Tseng, V. S. (2021). Convolutional neural network-based automatic screening tool for cardiovascular diseases using different intervals of ECG signals. *Computer Methods and Programs in Biomedicine, 203*, 106035. DOI: 10.1016/j.cmpb.2021.106035

[110] Oh, S. L., Ng, E. Y. K., Tan, R. S., & Acharya, U. R. (2019). Automated beat-wise arrhythmia diagnosis using modified U-net on extended electrocardiographic recordings with heterogeneous arrhythmia types. *Computers in Biology and Medicine, 105*, 92–101.

[111] Liu, S. H., Cheng, D. C., & Lin, C. M. (2013). Arrhythmia identification with two-lead electrocardiograms using artificial neural networks and support vector machines for a portable ECG monitor system. *Sensors (Basel), 13*(1), 813–828. DOI: 10.3390/s130100813

[112] Yıldırım, Ö., Pławiak, P., Tan, R. S., & Acharya, U. R. (2018). Arrhythmia detection using deep convolutional neural network with long duration ECG signals. *Computers in Biology and Medicine, 102*, 411–420. DOI: 10.1016/j.compbiomed.2018.09.009

[113] Tiwari, A., & Falk, T. H. (2019). Lossless electrocardiogram signal compression: A review of existing methods. *Biomedical Signal Processing and Control, 51*, 338–346. DOI: 10.1016/j.bspc.2019.03.004

[114] Ajankar, S. O., & Talbar, S. N. (2019). An electrocardiogram signal compression technique: A comprehensive review. *Analog Integrated Circuits and Signal Processing, 98*, 59–74. DOI: 10.1007/s10470-018-1323-1

[115] David, S. (1998). *Data compression—The complete reference*. New York: Springer. DOI: 10.1007/978-1-84628-603-2

[116] Agulhari, C. M., Bonatti, I. S., & Peres, P. L. D. (2013). An adaptive run length encoding method for the compression of electrocardiograms. *Medical Engineering & Physics, 35*(2), 145–153. DOI: 10.1016/j.medengphy.2010.03.003

[117] Martinez-Alajarin, J., Martinez-Rosso, J., & Merino, R. (2008). Encoding technique for binary sequences using vector tree partitioning applied to compression of phonocardiographic signals. *Electronics Letters, 44*, 84–85. DOI: 10.1049/el:20082533

[118] Rajankar, S., & Talbar, S. (2017). Adaptive vector K-tree partitioning and an entropy coder: Application to ECG compression. *International Journal of Telemedicine and Clinical Practices, 2*, 215. DOI: 10.1504/IJTMCP.2017.087873

[119] Jalaleddine, S. M. S., Hutchens, C. G., Strattan, R. D., & Coberly, W. A. (1990). ECG data compression techniques: A unified approach. *IEEE Transactions on Biomedical Engineering, 37*(4), 329-343. DOI: 10.1109/10.52340

[120] Cox, J. R., Nolle, F. M., Fozzard, H. A., & Oliver, G. C. (1968). AZTEC, a preprocessing program for real-time ECG rhythm analysis. *IEEE Transactions on Biomedical Engineering, 15*(2), 128-129. DOI: 10.1109/TBME.1968.4502549

[121] Hargittai, S. (2013). Enhanced turning point algorithm for the visualization and printing of long term ECG curves. *Proceedings*, 963-966. DOI: 10.13140/2.1.2521.6966

[122] Ishijima, M., Shin, S.-B., Hostetter, G. H., & Sklansky, J. (1983). Scan-along polygonal approximation for data compression of electrocardiograms. *IEEE Transactions on Biomedical Engineering*, *30*(11), 723-729. DOI: 10.1109/TBME.1983.325186

[123] Alam, S., & Gupta, R. (2014). A DPCM-based electrocardiogram coder with thresholding for real-time telemonitoring applications. In *2014 International Conference on Communication and Signal Processing* (pp. 176-180). Melmaruvathur, India. DOI: 10.1109/ICCSP.2014.6949823

[124] Hamza, R. K., Rijab, K. S., & Hussien, M. A. (2021). The ECG data compression by discrete wavelet transform and Huffman encoding. In *2021 7th International Conference on Contemporary Information Technology and Mathematics (ICCITM)* (pp. 75-81). DOI: 10.1109/ICCITM53167.2021.9677704

[125] Kumar, R., & Saini, I. (2014). Empirical wavelet transform based ECG signal compression. *IETE Journal of Research, 60*(6), 423–431. DOI: 10.1080/03772063.2014.963173

[126] Batista, L. V., Melcher, E. U. K., & Carvalho, L. C. (2001). Compression of ECG signals by optimized quantization of discrete cosine transform coefficients. *Medical Engineering & Physics, 23*(2), 127-134. DOI: 10.1016/S1350-4533(01)00030-3

[127] Benzid, R., Messaoudi, A., & Boussaad, A. (2008). Constrained ECG compression algorithm using the block-based discrete cosine transform. *Digital Signal Processing, 18*(1), 56-64. DOI: 10.1016/j.dsp.2007.08.003

[128] Khorrami, H., & Moavenian, M. (2010). A comparative study of DWT, CWT, and DCT transformations in ECG arrhythmias classification. *Expert Systems with Applications, 37*(8), 5751-5757. DOI: 10.1016/j.eswa.2010.02.033

[129] Olmos, S., Millan, M., Garcia, J., & Laguna, P. (1996). ECG data compression with the Karhunen-Loeve transform. In *Computers in Cardiology 1996* (pp. 253-256). IEEE. DOI: 10.1109/CIC.1996.542521

[130] Blanchett, T., Kember, G. C., & Fenton, G. A. (1998). KLT-based quality controlled compression of single-lead ECG. *IEEE Transactions on Biomedical Engineering*, 45(7), 942-945. DOI: 10.1109/10.686803

[131] GholamHosseini, H., Nazeran, H., & Moran, B. (1998). ECG compression: Evaluation of FFT, DCT, and WT performance. *Australasian Physical & Engineering Sciences in Medicine*, 21(4), 186-192

[132] Shinde, A. A., & Kanjalkar, P. (2011). The comparison of different transform-based methods for ECG data compression. In *2011 International Conference on Signal Processing, Communication, Computing and Networking Technologies* (pp. 332-335). IEEE. DOI: 10.1109/ICSCCN.2011.6024570

[133] Sandryhaila, A., Saba, S., Puschel, M., & Kovacevic, J. (2012). Efficient compression of QRS complexes using Hermite expansion. *IEEE Transactions on Signal Processing, 60*(2), 947-955. DOI: 10.1109/TSP.2011.2173336

[134] Dózsa, T., & Kovács, P. (2016). ECG signal compression using adaptive Hermite functions. In S. Loshkovska & S. Koceski (Eds.), *ICT Innovations 2015* (Vol. 399, pp. 249-257). Springer. DOI: 10.1007/978-3-319-25733-4_25

[135] Tai, S. C. (1992). Six-band sub-band coder on ECG waveforms. *Medical & Biological Engineering & Computing, 30*(2), 187–192. DOI: 10.1007/BF02446129

[136] Husøy, J. H., & Gjerde, T. (1996). Computationally efficient sub-band coding of ECG signals. *Medical Engineering & Physics, 18*(2), 132–142. DOI: 10.1016/1350-4533(95)00028-3

[137] Pham, T., Lau, Z. J., Chen, S. H. A., & Makowski, D. (2021). Heart rate variability in psychology: A review of HRV indices and an analysis tutorial. *Sensors, 21*(12), 3998. DOI: 10.3390/s21123998

[138] Chen, G., Hong, Z., Guo, Y., & Pang, C. (2019). A cascaded classifier for multi-lead ECG based on feature fusion. *Computer Methods and Programs in Biomedicine, 178*, 135-143. DOI: 10.1016/j.cmpb.2019.06.021

[139] Anwar, S. M., Gul, M., Majid, M., & Alnowami, M. (2018). Arrhythmia classification of ECG signals using hybrid features. *Computational and Mathematical Methods in Medicine, 2018*, 8 pages. DOI: 10.1155/2018/1380348

[140] Raj, S., & Ray, K. C. (2018). Automated recognition of cardiac arrhythmias using sparse decomposition over composite dictionary. *Computer Methods and Programs in Biomedicine, 165*, 175-186. DOI: 10.1016/j.cmpb.2018.08.008

[141] Park, J., & Kang, K. (2014). PcHD: Personalized classification of heartbeat types using a decision tree. *Computers in Biology and Medicine, 54*, 79-88. DOI: 10.1016/j.compbiomed.2014.08.013

[142] Martis, R., Mexicano, A., Bila, J., Ponce, R., & Cervantes Alvarez, S. (2014). Feature extraction of electrocardiogram signals by applying adaptive threshold and principal component analysis. *Journal of Applied Research and Technology, 46,* 1253-1258. DOI: 10.1109/IS3C.2014.324

[143] Li, D., Huang, K., Zhang, H., & Zhang, L. (2013). UMPCA based feature extraction for ECG. In C. Guo, Z. G. Hou, & Z. Zeng (Eds.), *Advances in neural networks – ISNN 2013* (Vol. 7951, pp. 404–411). Springer. DOI: 10.1007/978-3-642-39065-4_47

[144] Kallas, M., Clovis, F., Kanaan, L., Merheb, D., Honeine, P., & Amoud, H. (2012). Multi-class SVM classification combined with kernel PCA feature extraction of ECG signals. In *2012 19th International Conference on Telecommunications (ICT 2012)* (pp. 1–6). IEEE. DOI: 10.1109/ICTEL.2012.6221261

[145] Martis, R. J., Acharya, U. R., & Lim, C. M. (2013). ECG beat classification using PCA, LDA, ICA and discrete wavelet transform. *Biomedical Signal Processing and Control, 8*(5), 437-448. DOI: 10.1016/j.bspc.2013.01.005

[146] Sarfraz, M., Khan, A. A., & Li, F. F. (2014). Using independent component analysis to obtain feature space for reliable ECG arrhythmia classification. In *2014 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)* (pp. 62–67). IEEE. DOI: 10.1109/BIBM.2014.6999249

[147] Alexakis, C., Nyongesa, H., Saatchi, R., Harris, N., Davies, C., Emery, C., Ireland, R. H., & Heller, S. (2003). Feature extraction and classification of electrocardiogram (ECG) signals related to hypoglycaemia. *Computers in Cardiology*, *30*, 537–540. DOI: 10.1109/CIC.2003.1291211

[148] Yang, C., Ku, G. W., Lee, J.-G., & Lee, S.-H. (2020). Interval-based LDA algorithm for electrocardiograms for individual verification. *Applied Sciences, 10*(17), 6025. DOI: 10.3390/app10176025

[149] Vaneghi, F. M., Oladazimi, M., Shiman, F., Kordi, A., Safari, M. J., & Ibrahim, F. (2012). A comparative approach to ECG feature extraction methods. In *Proceedings of the 2012 Third International Conference on Intelligent Systems Modelling and Simulation* (pp. 252–256). IEEE. DOI: 10.1109/ISMS.2012.35

[150] Ge, D.-F., Hou, B.-P., & Xiang, X.-J. (2007). Study of feature extraction based on autoregressive modeling in EGG automatic diagnosis. *Acta Automatica Sinica, 33*(5), 462–466. DOI: 10.1360/aas-007-0462

[151] Coast, D. A., Stern, R. M., Cano, G. G., & Briller, S. A. (1990). An approach to cardiac arrhythmia analysis using hidden Markov models. *IEEE Transactions on Biomedical Engineering, 37*(9), 826–836. DOI: 10.1109/10.58593

[152] Young, B., Brodnick, D., & Spaulding, R. (1999). A comparative study of a hidden Markov model detector for atrial fibrillation. In *Neural Networks for Signal Processing IX: Proceedings of the 1999 IEEE Signal Processing Society Workshop* (pp. 468-476). IEEE. DOI: 10.1109/NNSP.1999.788166

[153] Akhbari, M., Shamsollahi, M. B., Sayadi, O., Armoundas, A. A., & Jutten, C. (2016). ECG segmentation and fiducial point extraction using multi hidden Markov model. *Computers in Biology and Medicine*, *79*, 21-29. DOI: 10.1016/j.compbiomed.2016.09.004

[154] F. M. Nolle et al., "Evaluation of a frequency-domain algorithm to detect ventricular fibrillation in the surface electrocardiogram," *Proceedings. Computers in Cardiology 1988*, Washington, DC, USA, 1988, pp. 337-340, DOI: 10.1109/CIC.1988.72630.

[155] J. J. Rieta et al., "Atrial fibrillation, atrial flutter and normal sinus rhythm discrimination by means of blind source separation and spectral parameters extraction," *Computers in Cardiology*, Memphis, TN, USA, 2002, pp. 25-28, DOI: 10.1109/CIC.2002.1166698.

[156] Mrochek, A., Frolov, A., Vaikhanskaya, T., Voitovich, A., Voitikova, M., & Melnikova, O. (2011). Identification and Spectrum Analysis of the Atrial Electrical Activity for Differential Diagnostics of the Atrial Fibrillation. *1*, 124-127.

[157] Hayes, M. H. (1996). *Statistical digital signal processing and modeling* (pp. 408-412). John Wiley & Sons.

[158] Cherifi, D., Adjerid, C., Boukerma, B., Zebbiche, B., & Nait-Ali, A. (2017). ECG features extraction using AC/DCT for biometric. In *2017 2nd International Conference on Bio-engineering for Smart Technologies (BioSMART)* (pp. 1-6). IEEE. DOI: 10.1109/BIOSMART.2017.8095342

[159] Gupta, V., & Mittal, M. (2019). QRS complex detection using STFT, chaos analysis, and PCA in standard and real-time ECG databases. *Journal of the Institution of Engineers (India): Series B, 100*, 489–497. DOI: 10.1007/s40031-019-00398-9

[160] Li, H., Yuan, D., Wang, Y., Cui, D., & Cao, L. (2016). Arrhythmia classification based on multidomain feature extraction for an ECG recognition system. *Sensors, 16*(10), 1744. DOI: 10.3390/s16101744

[161] Abeysekera, S. S., & Boashash, B. (1991). Methods of signal classification using the images produced by the Wigner-Ville distribution. *Pattern Recognition Letters, 12*(11), 717-729. DOI : 10.1016/0167-8655(91)90010-J

[162] Chouvarda, I., Maglaveras, N., Boufidou, A., Mohlas, S., & Louridas, G. (2003). Wigner-Ville analysis and classification of electrocardiograms during thrombolysis. *Medical & Biological Engineering & Computing, 41*(6), 609-617. DOI: 10.1007/BF02349967

[163] Afonso, V. X., & Tompkins, W. J. (1995). Detecting ventricular fibrillation. *IEEE Engineering in Medicine and Biology Magazine, 14*(2), 152–159. DOI: 10.1109/51.376752

[164] Akdeniz, F., & Kayikçioğlu, T. (2017). Detection of ECG arrhythmia using large Choi-Williams time-frequency feature set. In *2017 Medical Technologies National Congress (TIPTEKNO)* (pp. 1–4). Trabzon, Turkey. DOI: 10.1109/TIPTEKNO.2017.8238090

[165] Izci, E., Ozdemir, M. A., Sadighzadeh, R., & Akan, A. (2018). Arrhythmia detection on ECG signals by using empirical mode decomposition. *2018 Medical Technologies National Congress (TIPTEKNO)*, 1-4. DOI: 10.1109/TIPTEKNO.2018.8597094

[166] Kanjilal, P. P., Palit, S., & Saha, G. (1997). Fetal ECG extraction from single-channel maternal ECG using singular value decomposition. *IEEE Transactions on Biomedical Engineering, 44*(1), 51-59. DOI: 10.1109/10.553712

[167] Ziani, S., Farhaoui, Y., & Moutaib, M. (2023). Extraction of fetal electrocardiogram by combining deep learning and SVD-ICA-NMF methods. *Big Data Mining and Analytics, 6*(3), 301-310. DOI: 10.26599/BDMA.2022.9020035

[168] Frei, M. G., & Osorio, I. (2007). Intrinsic time-scale decomposition: Time–frequency–energy analysis and real-time filtering of non-stationary signals. *Proceedings of the*

Royal Society A: Mathematical, Physical and Engineering Sciences, 463(2089), 321–342. DOI: 10.1098/rspa.2006.1761

[169] Pantelopoulos, A., & Bourbakis, N. (2010). Efficient single-lead ECG beat classification using matching pursuit based features and an artificial neural network. In *Proceedings of the 10th IEEE International Conference on Information Technology and Applications in Biomedicine* (pp. 1-4). Corfu, Greece. DOI: 10.1109/ITAB.2010.5687731

[170] Śmigiel, S. (2022). ECG classification using orthogonal matching pursuit and machine learning. *Sensors (Basel)*, *22*(13), 4960. DOI: 10.3390/s22134960

[171] Tan, J. H., Hagiwara, Y., Pang, W., Lim, I., Oh, S. L., Adam, M., Tan, R. S., Chen, M., & Acharya, U. R. (2018). Application of stacked convolutional and long short-term memory network for accurate identification of CAD ECG signals. *Computers in Biology and Medicine*, *94*, 19-26. DOI: 10.1016/j.compbiomed.2017.12.023

[172] Limam, M., & Precioso, F. (2017). Atrial fibrillation detection and ECG classification based on convolutional recurrent neural network. *2017 Computing in Cardiology (CinC)*, Rennes, France, 1-4. DOI: 10.22489/CinC.2017.171-325

[173] Salem, M., Taheri, S., & Yuan, J. (2018). ECG arrhythmia classification using transfer learning from 2-dimensional deep CNN features. *2018 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, Cleveland, OH, USA, 1-4. DOI: 10.1109/BIOCAS.2018.8584808

[174] Cao, M., Zhao, T., Li, Y., Zhang, W., Benharash, P., & Ramezani, R. (2023, July). ECG heartbeat classification using deep transfer learning with convolutional neural network and STFT technique. *Journal of Physics: Conference Series*, *2547*(1), 012031. IOP Publishing. DOI: 10.1088/1742-6596/2547/1/012031

[175] Güney, E., Ekşi, Z., & Çakıroğlu, M. (2012). WebECG: A novel ECG simulator based on MATLAB Web Figure. *Advances in Engineering Software*, *45*(1), 167-174. DOI: 10.1016/j.advengsoft.2011.09.005

[176] Praveen, P., Samartha, B., Pai, V. R., Namith Rao, M., Shivaprakasha, K. S., & Bhandarkar, R. (2021). Generation of ECG arrhythmias using Fourier analysis. In S. Kalya, M. Kulkarni, & K. S. Shivaprakasha (Eds.), *Advances in VLSI, signal processing, power electronics, IoT, communication and embedded systems* (Vol. 752, pp. 367-376). Springer. DOI: 10.1007/978-981-16-0443-0_29

[177] McSharry, P. E., Clifford, G. D., Tarassenko, L., & Smith, L. A. (2003). A dynamical model for generating synthetic electrocardiogram signals. *IEEE Transactions on Biomedical Engineering*, *50*(3), 289-294. DOI: 10.1109/TBME.2003.808805

[178] George, R. A., & Periyasamy, R. (2021). Modelling of electrocardiogram using autoregressive moving average model and linear predictive coefficient: A comparative study. *2021 Seventh International Conference on Bio Signals, Images, and Instrumentation (ICBSII)*, 1–4. DOI: 10.1109/ICBSII51839.2021.9445142

[179] Raach, O., Pillai, T. R., & Abdullah, A. (2018). Garma modeling of ECG and classification of arrhythmia. In *Proceedings of the 2018 8th International Conference on Intelligent Systems, Modelling and Simulation (ISMS)* (pp. 26–31). Kuala Lumpur, Malaysia.

[180] Faal, M., & Almasganj, F. (2021). ECG signal modeling using volatility properties: Its application in sleep apnea syndrome. *Journal of Healthcare Engineering*, 2021, 4894501. DOI: 10.1155/2021/4894501

[181] El Khansa, L., & Naït-Ali, A. (2007). Parametrical modelling of a premature ventricular contraction ECG beat: Comparison with the normal case. *Computers in Biology and Medicine, 37*(1), 1-7. DOI: 10.1016/j.compbiomed.2005.07.006

[182] Guevara, M. R. (1991). Mathematical modeling of the electrical activity of cardiac cells. In L. Glass, P. Hunter, & A. McCulloch (Eds.), *Theory of Heart* (pp. 133-162). Springer. DOI: 10.1007/978-1-4612-3118-9_10

[183] Quiroz-Juárez, M. A., Jiménez-Ramírez, O., Vázquez-Medina, R., & others. (2019). Generation of ECG signals from a reaction-diffusion model spatially discretized. *Scientific Reports, 9*(1), 19000. DOI: 10.1038/s41598-019-55448-5

[184] Golany, T., & Radinsky, K. (2019). PGANs: Personalized generative adversarial networks for ECG synthesis to improve patient-specific deep ECG classification. *Proceedings of the AAAI Conference on Artificial Intelligence, 33*(01), 557-564. DOI: 10.1609/aaai.v33i01.3301557

[185] Berger, L., Haberbusch, M., & Moscato, F. (2023). Generative adversarial networks in electrocardiogram synthesis: Recent developments and challenges. *Artificial Intelligence in Medicine, 143*, 102632. DOI: 10.1016/j.artmed.2023.102632

[186] Kuznetsov, V. V., Moskalenko, V. A., Gribanov, D. V., & Zolotykh, N. Y. (2021). Interpretable feature generation in ECG using a variational autoencoder. *Frontiers in Genetics, 12*, Article 638191. DOI: 10.3389/fgene.2021.638191

[187] Nademi, Y., Zhang, Y., Sadiq, F., Khan, A., & Moubayed, N. (2023). Generative data by β-variational autoencoders help build stronger classifiers: ECG use case. In *2023 19th International Symposium on Medical Information Processing and Analysis (SIPAIM)* (pp. 1-7). IEEE. DOI: 10.1109/SIPAIM56729.2023.10373478

[188] Shahin, M., Oo, E., & Ahmed, B. (2020). Adversarial multi-task learning for robust end-to-end ECG-based heartbeat classification. In *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. 341-344). IEEE. DOI: 10.1109/EMBC44109.2020.9175640

[189] Chawla, N., Bowyer, K., Hall, L., & Kegelmeyer, W. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, *16*(1), 321-357.

[190] Luo, X., Yang, L., Cai, H., Tang, R., Chen, Y., & Li, W. (2021). Multi-classification of arrhythmias using a HCRNet on imbalanced ECG datasets. *Computer Methods and Programs in Biomedicine, 208,* 106258. DOI: 10.1016/j.cmpb.2021.106258

[191] Irfan, S., Anjum, N., Althobaiti, T., Alotaibi, A. A., Siddiqui, A. B., & Ramzan, N. (2022). Heartbeat classification and arrhythmia detection using a multi-model deep-learning technique. *Sensors, 22*(15), 5606. DOI: 10.3390/s22155606

[192] Elreedy, D., & Atiya, A. F. (2019). A comprehensive analysis of synthetic minority oversampling technique (SMOTE) for handling class imbalance. *Information Sciences*, *505*, 32-64. DOI: 10.1016/j.ins.2019.07.070

[193] Kaplan Berkaya, S., Uysal, A. K., Gunal, E. S., Ergin, S., Gunal, S., & Gulmezoglu, M. B. (2018). A survey on ECG analysis. *Biomedical Signal Processing and Control, 43,* 216-235. DOI: 10.1016/j.bspc.2018.03.003

[194] Xie, L., Li, Z., Zhou, Y., He, Y., & Zhu, J. (2020). Computational diagnostic techniques for electrocardiogram signal analysis. *Sensors*, *20*(21), 6318. DOI: 10.3390/s20216318

[195] Kutlu, Y., & Kuntalp, D. (2011). A multi-stage automatic arrhythmia recognition and classification system. *Computers in Biology and Medicine, 41*(1), 37-45. DOI: 10.1016/j.compbiomed.2010.11.003

[196] Kutlu, Y., & Kuntalp, D. (2012). Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients. *Computer Methods and Programs in Biomedicine, 105*(3), 257-267. DOI: 10.1016/j.cmpb.2011.10.002

[197] Martis, R. J., Acharya, U. R., Prasad, H. P., Chua, C. K., Lim, C. M., & Suri, J. S. (2013). Application of higher order statistics for atrial arrhythmia classification. *Biomedical Signal Processing and Control, 8*(6), 888-900. DOI: 10.1016/j.bspc.2013.08.008

[198] Latif, G., Al Anezi, F. Y., Zikria, M., & Alghazo, J. (2020). EEG-ECG signals classification for arrhythmia detection using decision trees. In *2020 Fourth International Conference on Inventive Systems and Control (ICISC)* (pp. 192-196). IEEE. DOI: 10.1109/ICISC47916.2020.9171084

[199] Sahoo, S., Subudhi, A., Dash, M., & Panda, G. (2020). Automatic classification of cardiac arrhythmias based on hybrid features and decision tree algorithm. *International Journal of Automation and Computing, 17*(5), 551–561. DOI: 10.1007/s11633-019-1219-2

[200] Jovic, A., & Bogunovic, N. (2011). Electrocardiogram analysis using a combination of statistical, geometric, and nonlinear heart rate variability features. *Artificial Intelligence in Medicine, 51*(3), 175-186. DOI: 10.1016/j.artmed.2010.09.005

[201] Nejadgholi, I., Moradi, M. H., & Abdolali, F. (2011). Using phase space reconstruction for patient-independent heartbeat classification in comparison with some benchmark methods. *Computers in Biology and Medicine, 41*(6), 411-419. DOI: 10.1016/j.compbiomed.2011.04.003

[202] Abawajy, J. H., Kelarev, A. V., & Chowdhury, M. (2013). Multistage approach for clustering and classification of ECG data. *Computer Methods and Programs in Biomedicine, 112*(3), 720-730. DOI: 10.1016/j.cmpb.2013.08.002

[203] Vafaie, M. H., Ataei, M., & Koofigar, H. R. (2014). Heart diseases prediction based on ECG signals' classification using a genetic-fuzzy system and dynamical model of ECG signals. *Biomedical Signal Processing and Control, 14*, 291-296. DOI: 10.1016/j.bspc.2014.01.001

[204] Martis, R. J., Chakraborty, C., & Ray, A. K. (2009). A two-stage mechanism for registration and classification of ECG using Gaussian mixture model. *Pattern Recognition, 42*(11), 2979-2988. DOI: 10.1016/j.patcog.2009.03.008

[205] Martis, R. J., Acharya, U. R., Prasad, H., Chua, C. K., & Lim, C. M. (2013). Automated detection of atrial fibrillation using Bayesian paradigm. *Knowledge-Based Systems, 54*, 269-275. DOI: 10.1016/j.knosys.2013.10.015

[206] Orhan, U. (2013). Real-time CHF detection from ECG signals using a novel discretization method. *Computers in Biology and Medicine, 43*, 1556-1562. DOI: 10.1016/j.compbiomed.2013.07.004

[207] Seera, M., Lim, C. P., Liew, W. S., Lim, E., & Loo, C. K. (2015). Classification of electrocardiogram and auscultatory blood pressure signals using machine learning models. *Expert Systems with Applications, 42*, 3643-3652. DOI: 10.1016/j.eswa.2015.01.025

[208] Behadada, O., Trovati, M., Chikh, M. A., Bessis, N., & Korkontzelos, Y. (2016). Logistic regression multinomial for arrhythmia detection. In *2016 IEEE 1st International Workshops on Foundations and Applications of Self* Systems (FAS*W)* (pp. 133-137). IEEE. DOI: 10.1109/FAS-W.2016.39

[209] Dilmac, S., & Korurek, M. (2015). ECG heart beat classification method based on modified ABC algorithm. *Applied Soft Computing*, *36*, 641–655. DOI: 10.1016/j.asoc.2015.07.015

[210] Afkhami, R. G., Azarnia, G., & Tinati, M. A. (2016). Cardiac arrhythmia classification using statistical and mixture modeling features of ECG signals. *Pattern Recognition Letters*, *70*, 45–51. DOI : 10.1016/j.patrec.2015.10.021

[211] Song, C. Y., Liu, K. B., Zhang, X., Chen, L. L., & Xian, X. C. (2016). An obstructive sleep apnea detection approach using a discriminative hidden Markov model from ECG signals. *IEEE Transactions on Biomedical Engineering*, *63*(7), 1532–1542. DOI: 10.1109/TBME.2015.2503009

[212] Hassan, A. R., & Haque, M. A. (2017). An expert system for automated identification of obstructive sleep apnea from single-lead ECG using random under sampling boosting. *Neurocomputing*, *235*, 122–130. DOI: 10.1016/j.neucom.2017.01.025

[213] Yeh, Y. C., Wang, W. J., & Chiou, C. W. (2010). A novel fuzzy c-means method for classifying heartbeat cases from ECG signals. *Measurement*, *43*(10), 1542–1555. DOI: 10.1016/j.measurement.2010.05.001

[214] De Carvalho, H. H., Moreno, R. L., Pimenta, T. C., Crepaldi, P. C., & Cintra, E. (2013). A heart disease recognition embedded system with fuzzy cluster algorithm. *Computer*

Methods and Programs in Biomedicine, *110*(3), 447–454. DOI: 10.1016/j.cmpb.2012.12.001

[215] Kiranyaz, S., Ince, T., Pulkkinen, J., & Gabbouj, M. (2011). Personalized long-term ECG classification: A systematic approach. *Expert Systems with Applications*, *38*(3), 3220–3226. DOI: 10.1016/j.eswa.2010.09.045

[216] Liu, X., Wang, H., Li, Z., & Qin, L. (2021). Deep learning in ECG diagnosis: A review. *Knowledge-Based Systems*, *227*, 107187. DOI: 10.1016/j.knosys.2021.107187

[217] Ansari, Y., Mourad, O., Qaraqe, K., & Serpedin, E. (2023). Deep learning for ECG arrhythmia detection and classification: An overview of progress for the period 2017-2023. *Frontiers in Physiology*, *14*, 1246746. DOI: 10.3389/fphys.2023.1246746

[218] Ali, M. S. A. M., AlFuqaha, A., Thabtah, F., & Alqudah, A. (2013). Robust arrhythmia classifier using hybrid multilayered perceptron network. In *2013 IEEE 9th International Colloquium on Signal Processing and its Applications* (pp. 304-309). IEEE. DOI: 10.1109/CSPA.2013.6530061

[219] Savalia, S., & Emamian, V. (2018). Cardiac arrhythmia classification by multi-layer perceptron and convolution neural networks. *Bioengineering (Basel)*, *5*(2), 35. DOI: 10.3390/bioengineering5020035

[220] Borghi, P. H., Borges, R. C., & Teixeira, J. P. (2021). Atrial fibrillation classification based on MLP networks by extracting jitter and shimmer parameters. *Procedia Computer Science*, *181*, 931-939. DOI: 10.1016/j.procs.2021.01.249

[221] Nurmaini, S., Tondas, A. E., Darmawahyuni, A., Rachmatullah, M. N., Partan, R. U., Firdaus, F., & et al. (2020). Robust detection of atrial fibrillation from short-term electrocardiogram using convolutional neural networks. *Future Generation Computer Systems*, *113*, 304–317. DOI: 10.1016/j.future.2020.07.021

[222] Iftene, A., Burlacu, A., & Gifu, D. (2022). Atrial fibrillation detection based on deep learning models. *Procedia Computer Science*, *207*, 3752–3760. DOI: 10.1016/j.procs.2022.09.436

[223] Jun, T. J., Nguyen, H. M., Kang, D., Kim, D., Kim, D., & Kim, Y. (2018). ECG arrhythmia classification using a 2-D convolutional neural network. *ArXiv*, *abs/1804.06812*.

[224] Degirmenci, M., Ozdemir, M. A., Izci, E., & Akan, A. (2022). Arrhythmic heartbeat classification using 2D convolutional neural networks. *IRBM*, *43*(5), 422-433. DOI: 10.1016/j.irbm.2021.04.002

[225] Elyamani, H. A., Salem, M. A., Melgani, F., & others. (2024). Deep residual 2D convolutional neural network for cardiovascular disease classification. *Scientific Reports, 14*, 22040. DOI: 10.1038/s41598-024-72382-3

[226] Singh, S., Pandey, S. K., Pawar, U., & Janghel, R. R. (2018). Classification of ECG arrhythmia using recurrent neural networks. *Procedia Computer Science, 132*, 1290–1297. DOI: 10.1016/j.procs.2018.05.045

[227] Wang, M., Rahardja, S., Fränti, P., & Rahardja, S. (2022). Single-lead ECG recordings modeling for end-to-end recognition of atrial fibrillation with dual-path RNN. *Biomedical Signal Processing and Control, 79*, 104067. DOI: 10.1016/j.bspc.2022.104067

[228] Yildirim, Ö. (2018). A novel wavelet sequence based on deep bidirectional LSTM network model for ECG signal classification. *Computers in Biology and Medicine, 96*, 189–202. DOI: 10.1016/j.compbiomed.2018.03.016

[229] Yildirim, O., Baloglu, U. B., Tan, R. S., Ciaccio, E. J., & Acharya, U. R. (2019). A new approach for arrhythmia classification using deep coded features and LSTM networks. *Computer Methods and Programs in Biomedicine, 176*, 121–133. DOI: 10.1016/j.cmpb.2019.05.004

[230] Swapna, G., Soman, K. P., & Vinayakumar, R. (2018). Automated detection of cardiac arrhythmia using deep learning techniques. *Procedia Computer Science*, *132*, 1192-1201. DOI: 10.1016/j.procs.2018.05.034

[231] Mohebbanaaz, Y. P. S., & Kumari, L. V. R. (2021). Automated detection of cardiac arrhythmia using recurrent neural network. In *2021 6th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE)* (pp. 1-6). IEEE. DOI : 10.1109/ICRAIE52900.2021.9703995

[232] Ojha, M. K., Wadhwani, S., Wadhwani, A. K., & et al. (2022). Automatic detection of arrhythmias from an ECG signal using an auto-encoder and SVM classifier. *Phys Eng Sci Med*, *45*(665-674). DOI: 10.1007/s13246-022-01119-1

[233] Ochiai, K., Takahashi, S., & Fukazawa, Y. (2018). Arrhythmia detection from 2-lead ECG using convolutional denoising autoencoders. In *Proceedings of the KDD Conference* (pp. 1-7).

[234] Nithya, S., & Rani, M. M. S. (2022). Stacked variational autoencoder in the classification of cardiac arrhythmia using ECG signals with 2D-ECG images. In *2022 International Conference on Intelligent Innovations in Engineering and Technology (ICIIET)* (pp. 222-226). Coimbatore, India. DOI: 10.1109/ICIIET55458.2022.9967575

[235] Wu, Z., Ding, X., & Zhang, G. (2016). A novel method for classification of ECG arrhythmias using deep belief networks. *International Journal of Computational Intelligence and Applications*, *15*, 1650021:1–1650021:14.

[236] G, S., T, K. P., & V, K. K. (2018). Classification of ECG beats using deep belief network and active learning. *Medical & Biological Engineering & Computing*, *56*, 1887–1898. DOI: 10.1007/s11517-018-1815-2

[237] P, S., & Sofana Reka, S. (2023). A deep belief network model for automatic atrial fibrillation detection. *IETE Journal of Research*, *70*(2), 1303–1315. DOI: 10.1080/03772063.2023.2167739

[238] Yan, G., Liang, S., Zhang, Y., & Liu, F. (2019). Fusing Transformer model with temporal features for ECG heartbeat classification. *2019 IEEE International Conference*

on Bioinformatics and Biomedicine (BIBM), 898-905. DOI: 10.1109/BIBM47256.2019.8983326

[239] Wang, B., Liu, C., Hu, C., Liu, X., & Cao, J. (2021). Arrhythmia classification with heartbeat-aware transformer. In *ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1025-1029). IEEE. DOI: 10.1109/ICASSP39728.2021.9413938

[240] Hu, R., Chen, J., & Zhou, L. (2022). A transformer-based deep neural network for arrhythmia detection using continuous ECG signals. *Computers in Biology and Medicine, 144*, 105325. DOI: 10.1016/j.compbiomed.2022.105325

[241] Dong, Y., Zhang, M., Qiu, L., Wang, L., & Yu, Y. (2023). An arrhythmia classification model based on vision transformer with deformable attention. *Micromachines*, *14*(6), 1155. DOI: 10.3390/mi14061155

[242] Oh, S. L., Ng, E. Y. K., Tan, R. S., & Acharya, U. R. (2018). Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats. *Computers in Biology and Medicine*, *102*, 278-287. DOI: 10.1016/j.compbiomed.2018.06.002

[243] Ullah, W., Siddique, I., Zulqarnain, R. M., Alam, M. M., Ahmad, I., & Raza, U. A. (2021). Classification of arrhythmia in heartbeat detection using deep learning. *Computational Intelligence and Neuroscience*, *2021*, Article 2195922. DOI : 10.1155/2021/2195922

[244] Anbarasi, A., Ravi, T., Manjula, V. S., & et al. (2022). A modified deep learning framework for arrhythmia disease analysis in medical imaging using electrocardiogram signal. *Biomedical Research International*, *2022*, Article 5203401. DOI: 10.1155/2022/5203401

[245] Sumathi, S., Beaulah, H. L., & Vanithamani, R. (2014). A wavelet transform based feature extraction and classification of cardiac disorder. *Journal of Medical Systems, 38*(98). DOI: 10.1007/s10916-014-0098-x

[246] Wang, J. (2021). Automated detection of premature ventricular contraction based on the improved gated recurrent unit network. *Computers in Biology and Medicine, 208,* 106284. DOI: 10.1016/j.cmpb.2021.106284

[247] Kim, J. H., Seo, S. Y., Song, C. G., & Kim, K. S. (2019). Assessment of electrocardiogram rhythms by GoogLeNet deep neural network architecture. *Journal of Healthcare Engineering, 2019,* 2826901. DOI: 10.1155/2019/2826901

[248] Ribeiro, A. H., Ribeiro, M. H., Paixão, G. M. M., et al. (2020). Automatic diagnosis of the 12-lead ECG using a deep neural network. *Nature Communications, 11,* 1760. DOI: 10.1038/s41467-020-15432-4

[249] Moody, G. B., & Mark, R. G. (2001). The impact of the MIT-BIH Arrhythmia Database. *IEEE Engineering in Medicine and Biology Magazine, 20(3),* 45–50. DOI: 10.1109/51.932724

[250] Butterworth, S. (1930). On the Theory of Filter Amplifiers. *Experimental Wireless and the Wireless Engineer, 7*, 536–541.

[251] Oppenheim, A.V., Willsky, A. S., & Young, I.T. (1983). Signals and Systems.

[252] Sakoe, H., & Chiba, S. (1978). Dynamic programming algorithm optimization for spoken word recognition. *IEEE transactions on acoustics, speech, and signal processing, 26(1)*, 43-49. DOI: 10.1109/tassp.1978.1163055

[253] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition*. IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. DOI: 10.1109/CVPR.2016.90

[254] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). *Attention Is All You Need. Advances in Neural Information Processing Systems 30 (NeurIPS 2017)*. DOI : 10.48550/arXiv.1706.03762

[255] Yang, J., Li, C., Dai, X., Yuan, L., & Gao, J. (2022). *Focal Modulation Networks. Advances in Neural Information Processing Systems 35 (NeurIPS 2022)*. DOI:10.48550/arXiv.2203.11926

[256] Chen, A., Wang, F., Liu, W., Chang, S., Wang, H., He, J., & Huang, Q. (2020). Multi-information fusion neural networks for arrhythmia automatic detection. *Computer Methods and Programs in Biomedicine, 193*, 105479.

[257] Romdhane, T. F., Alhichri, H., Ouni, R., & Atri, M. (2020). Electrocardiogram heartbeat classification based on a deep convolutional neural network and focal loss. *Computers in Biology and Medicine, 123*, 103866. DOI: 10.1016/j.compbiomed.2020.103866

[258] Gan, Y., Shi, J.-C., He, W.-M., & Sun, F.-J. (2021). Parallel classification model of arrhythmia based on DenseNet-BiLSTM. *Biocybernetics and Biomedical Engineering, 41(5)*, 1548–1560.

[259] Ahmad, Z., Tabassum, A., Guan, L., & Khan, N. (2021). ECG heart-beat classification using multimodal image fusion*. In ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) (pp. 1330-1334).* Toronto, ON, Canada: IEEE. DOI: 10.1109/ICASSP39728.2021.9414709

[260] Zhang, Y., Li, J., Wei, S., Zhou, F., & Li, D. (2021). Heartbeats classification using hybrid time-frequency analysis and transfer learning based on ResNet. *IEEE Journal of Biomedical and Health Informatics, 25(11),* 4175-4184. DOI: 10.1109/JBHI.2021.3085318

[261] Zubair, M., & Yoon, C. (2022). Cost-Sensitive Learning for Anomaly Detection in Imbalanced ECG Data Using Convolutional Neural Networks. *Sensors, 22(11),* 4075. DOI: 10.3390/s22114075

[262] Bhatia, S., Pandey, S. K., Kumar, A., & Alshuhail, A. (2022). Classification of electrocardiogram signals based on hybrid deep learning models. *Sustainability, 14*(16572). DOI: 10.3390/su142416572

[263] Wang, T., Lu, C., Ju, W., & Liu, C. (2022). Imbalanced heartbeat classification using Easy Ensemble technique and global heartbeat information. *Biomedical Signal Processing and Control, 71(Part A)*, 103105. DOI: 10.1016/j.bspc.2021.103105

[264] Eduardo Vasconcellos, M. M., et al. (2023). Siamese convolutional neural network for heartbeat classification using limited 12-lead ECG datasets. *IEEE Access, 11*, 5365-5376. DOI: 10.1109/ACCESS.2023.3236189

[265] Islam, M. S., Hasan, K. F., Sultana, S., Uddin, S., Lio', P., Quinn, J. M. W., & Moni, M. A. (2023). HARDC: A novel ECG-based heartbeat classification method to detect arrhythmia using hierarchical attention based dual structured RNN with dilated CNN. *Neural Networks, 162*, 271-287. DOI: 10.1016/j.neunet.2023.03.004

Liste des acronymes

AC
Courant alternatif, 57, 135
ADASYN
Adaptive Synthetic Sampling, 77
ANC
Adaptive Noise Cancellation, 60
ApEn
Approximate Entropy, 37, 71
AR
Autoregressive models, 70, 75
ARIMA
Autoregressive Integrated Moving Average, 75
ARMA
AutoRegressive Moving Average, 75
AV
Atrio-ventricular node, 21, 22, 23, 29, 30, 32, 38, 41, 42, 43, 44, 45, 47, 50
AVC
Accidents vasculaires cérébraux, 4
CEEMDAN
Ensemble Empirical Mode Decomposition with Adaptive Noise, 60
CKR
Cone Kernel representation, 72
CNN
Convolutional Neural Network, 61, 65, 73, 74, 78, 79, 97, 98, 99, 117, 118, 136, 142, 144
CSI
Cardiac Sympathetic Index, 70
CVI
Cardiac Vagal Index, 70
CWD
Choi-Williams Distribution, 72
CWT
Continuous Wavelet Transform, 64, 128, 132
DAE
Denoising Auto-Encoder, 61
DBN
Deep Belief Network, 73, 79
DCT
Discrete Cosine Transform, 69, 71, 132, 135
DDC
Direct Data Compression, 69
DFA
Detrended Fluctuation Analysis, 71
DFT
Discrete Fourier Transform, 71

DNN
Deep Neural Networks, 73
DPCM
Differential Pulse Code Modulation, 69, 132
DTW
Dynamic Time Warping, 4, 5, 6, 7, 82, 83, 91, 92, 93, 94, 95, 103, 113, 114, 120
DWT
Discrete Wavelet Transform, 59, 61, 62, 64, 69, 86, 87, 88, 89, 90, 91, 118, 132
ECG
Electrocardiogramme, 3, 4, 5, 6, 7, 14, 15, 17, 25, 26, 27, 28, 29, 30, 31, 32, 33, 35, 38, 41, 42, 43, 44, 45, 47, 48, 49, 50, 51, 52, 53, 54, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 66, 67, 68, 69, 70, 71, 72, 73, 74, 75, 76, 77, 81, 83, 84, 85, 86, 87, 89, 90, 91, 92, 95,97, 99, 100, 102, 106, 107, 109, 111, 112, 117, 119, 120, 121, 122, 123, 124, 125, 126, 127, 128, 129, 130, 131, 132, 133, 134, 135, 136, 137, 138, 139, 140, 141, 142, 143, 144, 150, 151
EEMD
Ensemble Empirical Mode Decomposition, 60
EGARCH
Exponential Generalized Autoregressive Conditional Heteroskedasticity, 75
EMD
Empirical Mode Decomposition, 59, 60, 62, 72, 73, 125
EMG
Electromyogramme, 57
FA
Fibrillation auriculaire, 42
FFT
Fast Fourier Transform, 69, 71, 132
FIR
Finite Impulse Response, 64, 85, 86, 87, 88
FNR
False Negative Rate, 90
FSD
Full scale deflection, 57, 58
FuzzyEn
Fuzzy Entropy, 71
GAN
Generative Adversarial Network, 61, 76, 117, 118
GARMA
Generalized Autoregressive Moving Average, 75
GRU
Gated Recurrent Unit, 73, 78, 79, 117
HMM
Hidden Markov Models, 71
HRV
Heart Rate Variability, 36, 37, 133
IALS
Inverse of the average length of the acceleration/deceleration segments, 70

ICA
Independent Component Analysis, 60, 62, 70, 125, 126, 134, 135
IDM
Infarctus du myocarde, 4
IMF
Intrinsic Mode Functions, 59, 72
ITD
Intrinsic Time-Scale Decomposition, 72
kNN
k-nearest neighbors, 14, 77, 91
LBBB
Left Bundle Branch Block, 49
LDA
Linear Discriminant Analysis, 70, 134
LMS
Least Mean Squares algorithm, 60, 62, 126
LSTM
Long-Short Term Memory, 61, 73, 74, 78, 79, 102, 103, 104, 105, 106, 107, 113, 115, 116, 117, 118, 119, 130, 141, 142
LZC
Lempel–Ziv complexity, 71
MA
Moving average, 75
MAR
Multivariate Autoregressive models, 70
MCV
Maladies cardiovasculaires, 4
MITDB
MIT-BIH Arrhythmia database, 83, 84, 87, 88, 89, 90, 93, 95, 96, 97, 100, 103, 106, 107, 108, 109, 113, 117, 118, 119, 120, 150
ML
Machine Learning, 4, 6, 14
MLP
Multi-layer Perceptron, 65, 78, 140
MP
Matching Pursuit, 72, 109
MSEn
Multiscale Entropy, 71
MSSD
Mean Square Successive Differences, 70
NLM
Non-Local Means algorithm, 61
NSRDB
MIT-BIH Normal Sinus Rhythm database, 84, 85, 90, 93, 107, 108, 109, 113, 118, 120
OMP
Orthogonal Matching Pursuit, 72, 74, 109, 110, 111, 112, 116, 117, 118, 119, 120
PAC
Premature Atrial Contraction, 46, 47

PAS
Percentage of intervals in alternation segments, 70
PCA
Principal Component Analysis, 60, 62, 70, 118, 126, 133, 134, 135
PIP
Percentage of inflection points, 70
PSNR
Peak Signal-to-Noise Ratio, 63
PSS
Percentage of short segments, 70
PVC
Premature Ventricular Contraction, 48, 51, 52, 67, 151
RBBB
Right Bundle Branch Block, 49, 50
RBM
Restricted Boltzmann Machine, 79
ResNet
Residual Network, 73, 97, 102, 109, 111, 112, 116, 117, 118, 119, 120, 143
RLS
Recursive Least Squares algorithm, 60, 62
RMSE
Root Mean Square Error, 63
RNN
Recurrent Neural Network, 61, 67, 73, 78, 141, 144
ROC
Receiver Operating Characteristic, 79, 80, 115, 116
SA
Sino-atrial node, 21, 22, 23, 32, 38, 39, 44
SampEn
Sample Entropy, 37, 71
ShanEn
Shannon Entropy, 71
SMOTE
Synthetic Minority Oversampling Technique, 4, 5, 6, 15, 54, 76, 77, 82, 83, 91, 92, 93, 94, 95, 103, 113, 114, 118, 120, 137, 138
SMOTE-ENC
SMOTE-Encoded Nominal and Continuous, 77
SMOTE-ENN
SMOTE-Edited Nearest Neighbors, 77
SNA
Système nerveux autonome, 35, 36, 37
SNP
Système nerveux parasympathique, 35
SNR
Signal-to-Noise Ratio, 63, 65, 87
SNS
Système nerveux sympathique, 35

SPWVD
Smoothed Pseudo Wigner–Ville Distribution, 72
STFT
Short Term Fourier Transform, 71, 72, 73, 135, 136
SVD
Singular Value Decomposition, 72, 73, 135
SVM
Support Vector Machines, 14, 65, 77, 95, 129, 133, 141
SWT
Stationary Wavelet Transform, 64
TPSV
Tachycardie paroxystique supraventriculaire, 42
TV
Tachycardie ventriculaire, 43
TVD
Total Variation Denoising, 61
VAE
Variational Auto-encoder, 76
VFC
Variabilité de la fréquence cardiaque, 35, 36
VGG
Visual Geometry Group, 73
WPW
Syndrome de Wolff-Parkinson-White, 43
WT
Wavelet Transform, 59, 64, 72, 132
WVD
Wigner-Ville Distribution, 72, 118

Annexes

A. Annotations des battements ECG selon PhysionetBank-MITDB.

CODE	DESCRIPTION
N	Normal beat (displayed as "·" by the PhysioBank ATM, LightWAVE, pschart, and psfd)
L	Left bundle branch block beat
R	Right bundle branch block beat
A	Atrial premature beat
a	Aberrated atrial premature beat
J	Nodal (junctional) premature beat
S	Supraventricular premature or ectopic beat (atrial or nodal)
V	Premature ventricular contraction
r	R-on-T premature ventricular contraction
F	Fusion of ventricular and normal beat
e	Atrial escape beat
j	Nodal (junctional) escape beat
n	Supraventricular escape beat (atrial or nodal)
E	Ventricular escape beat
/	Paced beat
f	Fusion of paced and normal beat
Q	Unclassifiable beat

B. Annotations des battements ECG selon la norme ANSI/AAMI EC57 ; 2012.

N	S	V	F	Q
• Normal • Left bundle branch block • Right bundle branch block • Atrial escape • Nodal (junctional) escape	• Atrial premature • Aberrant atrial premature • Nodal (junctional) premature • Supraventricular premature	• Premature Ventricular Contraction • Ventricular escape	• Fusion of ventricular and normal	• Paced • Fusion of paced and normal • Unclassifiable