

الجمهورية الجزائرية الديمقراطية الشعبية
RÉPUBLIQUE ALGERIENNE DÉMOCRATIQUE ET POPULAIRE

وزارة التعليم والبحث العلمي
MINISTÈRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

جامعة عمارثليجي بالاغواط
UNIVERSITÉ AMAR THELIDJI DE LAGHOUAT

كلية التكنولوجيا
FACULTE DU TECHNOLOGIE
قسم الالكترونيات

DEPARTEMENT ELECTROUNIQUE



Mémoire de Master

DOMAINE : Science et technologie

FILIERE : Electronique

OPTION : Microélectronique

Présenté par : Ketel Zehour

THÈME

**Simulation d'un Système de Surveillance Cardiaque avec
Détection d'Anomalies par EdgeAI**

Jury du soutenance :

<i>M^{me}.DJERFAF FATIMA</i>	<i>Pr.</i>	<i>Examinatrice</i>	<i>UATL</i>
<i>M. BIRANE MOUHOUB</i>	<i>Pr.</i>	<i>Président</i>	<i>UATL</i>
<i>M^{me}. Leila Amal Vilbois</i>	<i>MAA.</i>	<i>Encadreur</i>	<i>UATL</i>

Année universitaire 2025/2026

THE PEOPLE'S DEMOCRATICRE PUBLIC OF ALGERIA

وزارة التعليم والبحث العلمي

THE MINISTRY OF HIGHER EDUCATION AND SCIENTIFIC
RESEARCH

جامعة عمار ثليجي بالاغواط

AMAR TELIDJI UNIVERSITY OF LAGHOUAT

كلية التكنولوجيا

FACULTY OF TECHNOLOGY

قسم الالكترونيك

DEPARTMENT OF ELECTRONIC



Master's dissertation

Domain: Science and Technology

Field: Electronic

Option: Microelectronic

Submitted By: Ketel Zehour

THEME

**Simulation of a Cardiac Monitoring System with Anomaly
Detection Using Edge AI**

Jury members:

M^{me}. DJERFAF FATIMA

Pr.

Examinator

UATL

Mr. BIRANE MOUHOUB

Pr.

President

UATL

M^{me}. Leila Amal Vilbois

MAA.

Supervisor

UATL

Academic year 2025/2026

الجمهورية الجزائرية الديمقراطية الشعبية
RÉPUBLIQUE ALGERIENNE DÉMOCRATIQUE ET POPULAIRE

وزارة التعليم والبحث العلمي
MINISTÈRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

جامعة عمارثليجي بالاغواط
UNIVERSITÉ AMAR THELIDJI DE LAGHOUAT

كلية التكنولوجيا
FACULTE DU TECHNOLOGIE
قسم الالكترونيات

DEPARTEMENT ELECTROUNIQUE



Mémoire de Master

DOMAINE : Science et technologie

FILIERE : Electronique

OPTION : Instrumentation

Présenté par : Benchohra Noussiba

THÈME

**Simulation d'un Système de Surveillance Cardiaque avec
Détection d'Anomalies par EdgeAI**

Jury du soutenance :

<i>M^{me}.DJERFAF FATIMA</i>	<i>Pr.</i>	<i>Examinatrice</i>	<i>UATL</i>
<i>M.BIRANE MOUHOU</i>	<i>Pr.</i>	<i>Président</i>	<i>UATL</i>
<i>M^{me}.Leila Amal Vilbois</i>	<i>MAA.</i>	<i>Encadreur</i>	<i>UATL</i>

Année universitaire 2025/2026

THE PEOPLE'S DEMOCRATICRE PUBLIC OF ALGERIA

وزارة التعليم والبحث العلمي

THE MINISTRY OF HIGHER EDUCATION AND SCIENTIFIC
RESEARCH

جامعة عمار ثليجي بالاغواط

AMAR TELIDJI UNIVERSITY OF LAGHOUAT

كلية التكنولوجيا

FACULTY OF TECHNOLOGY

قسم الالكترونيك

DEPARTMENT OF ELECTRONIC



Master's dissertation

Domain: Science and Technology

Field: Electronic

Option: Instrumentation

Submitted By: Benchohra Noussiba

THEME

**Simulation of a Cardiac Monitoring System with Anomaly
Detection Using Edge AI**

Jury members:

M^{me}.DJERFAF FATIMA

Pr.

Examinator

UATL

Mr.BIRANE MOUHOUB

Pr.

President

UATL

M^{me}.Leila Amal Vilbois

MAA.

Supervisor

UATL

Academic year 2025/2026

Remerciements

Avant toute chose, nous tenons à remercier Dieu Tout-Puissant de nous avoir accordé la santé, la patience et la détermination nécessaires pour mener à bien ce travail.

Nous exprimons notre profonde gratitude à notre encadrante, Mme Leila Amal Vilbois, pour son accompagnement attentif, ses conseils avisés et son soutien constant tout au long de la réalisation de ce projet. Ses orientations et son expérience ont grandement contribué à la réussite de ce travail. Ce fut un réel privilège de bénéficier de son encadrement.

Nous remercions également l'ensemble des enseignants et du personnel administratif du département d'électronique de l'Université Amar Telidji de Laghouat pour leur disponibilité ainsi que pour les connaissances qu'ils nous ont transmises durant notre parcours universitaire.

Nos sincères remerciements s'adressent aussi aux membres du jury qui ont accepté d'examiner ce mémoire. Nous leur sommes reconnaissantes pour le temps consacré à son évaluation ainsi que pour leurs remarques constructives.

Enfin, nous souhaitons exprimer notre gratitude à toutes les personnes qui nous ont soutenues, encouragées ou aidées, de près ou de loin, dans l'accomplissement de ce projet.

Merci à toutes et à tous....

Dédicace

Avec une profonde gratitude et une grande reconnaissance, nous dédions ce travail :

À nos chers parents, dont l'amour inconditionnel, les sacrifices, les encouragements et les prières ont été notre plus grande source de force et de motivation tout au long de notre vie.

À nos familles, pour leur soutien indéfectible, leur patience et leur compréhension tout au long de notre parcours universitaire.

À nos chers frères et sœurs, dont l'affection, les encouragements et la présence ont toujours été une source de motivation et de confiance.

À nos enseignants, qui nous ont transmis leur savoir et contribué à notre formation académique et personnelle.

Et à toutes les personnes qui ont cru en nous, nous ont soutenues et encouragées à poursuivre nos objectifs et à réaliser nos ambitions.

Nous dédions ce travail à tous avec notre sincère gratitude et notre profond respect.

Zehour et Noussaiba

Sommaire

Abréviations clés.....	I
Liste des symboles.....	III
Liste des figures.....	V
Liste des tableaux.....	VI
Introduction générale.....	1

Chapitre I :Fondements Théorique

I.1 Introduction.....	3
I.2 Définition d'un système de surveillance cardiaque	3
I.3 Définition du signal électrocardiographique (ECG)	4
I.4 Détection d'Anomalies Cardiaques	5
I.5 Chaîne d'Acquisition Biomédicale	5
I.5.1 Capteurs cardiaques	6
I.5.1.1 Capteur ECG (Électrocardiogramme).....	7
I.5.1.1.1 Électrodes ECG multi-canaux.....	7
I.5.1.1.2 Module AD8232 ECG	8
I.5.1.1.2 Capteur PPG (Photopléthysmographie).....	9
I.5.1.1.3 Capteur SpO ₂ (Saturation en oxygène).....	10
I.5.1.1.4 Capteur de Pression Artérielle (Blood Pressure Sensor)...	11
I.5.2 Prétraitement du signal	13
I.5.3 Microcontrôleur (MCU).....	13
I.5.4 Détection des pics R.....	14
I.5.5 ADC (Convertisseur Analogique-Numérique)	14
I.5.6 Système embarqué	14
I.6 Filtrage numérique	14
I.6.1 Fenêtrage temporel.....	15
I.6.2 Intervalle RR	15
I.6.3 Echantillonnage (Sampling Rate)	16

I.6.4 Normalisation.....	17
I.7 Analyse de fréquence cardiaque	17
I.7.1 Tachycardie.....	18
I.7.2 Bradycardie	18
I.7.3 Fibrillation auriculaire.....	19
I.8 Base de données cardiaque	20
I.8.1 L'Internet of Medical Things (IoMT)	20
I.8.2 LSTM (Long Short-Term Memory)	20
I.9 Simulation de systèmes cardiaques.....	21
I.10 Réduction du bruit de mouvement	21
I.11 Extraction de caractéristiques	21
I.12 Alertes automatiques.....	21
I.13 Conclusion	21

Chapitre II :Techniques IA pour la Surveillance Cardiaque et l'Analyses ECG

II.1 Introduction	22
II.2 Intelligence Artificielle (AI)	22
II.2.1 Machine Learning (Apprentissage Automatique)	23
II.2.2 Deep Learning	23
II.2.3 Edge AI (Intelligence Artificielle en périphérie).....	24
II.2.4 Cloud IA	24
II.2.5 TinyML.....	25
II.3.1 Réseau de neurones	25
II.3.2 Fonction d'Activation (Activation Function).....	26
II.3.3 Modele training.....	26
II.3.4 Surapprentissage (Overfitting)	26
II.4 Optimisation pour le Déploiement	27
II.4.1 Optimisation de modèle.....	27
II.4.2 Élagage (Pruning).	27
II.5 La latence.....	27
II.6 Real-Time Processing.....	28
II.7 Pipeline de Traitement des Signaux	28
II.7.1 Dataset	28
II.7.2 Signal Preprocessing (Prétraitement du signal).....	29

II.7.3 Apprentissage Fédéré (Federated Learning).....	29
II.7.4 Feature Extraction.....	30
II.7.5 Feature selection	30
II.7.6 Classification	30
II.8 Métriques d'évaluation Clinique	31
II.8.1 Sensibilité].....	31
II.8.2 Spécificité	31
II.8.3 Accuracy (Exactitude)	31
II.9 Convolutional Neural Network(CNN)	32
II.10 Long Short-Term Memory (LSTM)	32
II.11 Réseau de neurones artificiels- Artificial Neural Network (ANN)]......	33
II.12 Support Vector Machine (SVM).....	34
II.13 Conclusion.....	35

Chapitre III :Simulation et interprétation des résultats

III.1 Introduction	36
III.2 Dataset et architectures des modèles	37
III .3 Définition de Random Forest	37
III.4 Définition de DeepECG-Net	44
III.5 Définition de CLTC et CCFC	53
III.5.1 CLTC (ConvLSTM2D + LTC)	53
III.5.2 CCfC (ConvLSTM2D + CFC)	53
III.6 Conclusion.....	64
Conclusion générale.....	65

Abréviations clés

Médical & Cardiologie

- ECG : Électrocardiogramme
- FC : Fréquence cardiaque
- HRV : Variabilité de la fréquence cardiaque
- FA : Fibrillation auriculaire
- ESV / PVC : Extrasystole ventriculaire
- DME / EMR : Dossier médical électronique

2. IoT & Capteurs

- IOMT : Internet des objets médicaux
- WBAN : Réseau corporel sans fil
- MCU : Microcontrôleur
- SoC: Système sur puce
- BLE: Bluetooth Low Energy

3. Edge AI & Embarqué

- Edge AI : Intelligence artificielle en périphérie
- TinyML : Machine learning sur systèmes embarqués ultra-légers
- NPU : Unité de traitement neuronal
- DSP : Processeur de signal numérique
- FPGA : Réseau de portes programmables
- ASIC : Circuit intégré spécifique

4. Traitement du signal

- SNR : Rapport signal sur bruit
- FFT : Transformée de Fourier rapide
- DWT : Transformée en ondelettes discrète
- FIR / IIR : Filtres à réponse impulsionnelle finie/infinie

5. Intelligence Artificielle

- RNN: Réseau de neurones récurrent
- CNN: Réseau de neurones convolutif
- LSTM : Mémoire court-terme longue
- MLP : Perceptron multicouche
- SVM : Machine à vecteurs de support
- KNN : K plus proches voisins
- DT : Arbre de décision
- RF : Forêt aléatoire
- AE : Autoencodeur

6. Détection d'anomalies

- VP / FP : Vrai/Faux positif
- VN / FN: Vrai/Faux négatif
- ROC : Courbe caractéristique de fonctionnement
- AUC : Aire sous la courbe
- Se: Sensibilité
- Sp: Spécificité

7. Bases de données & Simulation

- MIT-BIH : Massachusetts Institute of Technology
- PhysioNet : Ressource de signaux physiologiques

Liste des symboles

Symbole	Signification	Unité
ECG(t)	Signal électrocardiographique continu	mv
$x(t)$	Signal analogique	mv
$x[n]$	Signal discret échantillonné	mv
f_s	Fréquence d'échantillonnage	Hz
T_s	Période d'échantillonnage($T_s=1/f_s$)	s
A	Amplitude du signal	mv
HR	Fréquence cardiaque (Heart rate)	bpm
RR	Intervalle entre deux pics R	s

Symbole	signification
TP	True positive
TN	True negative
FP	False positive
FN	False negative
ACC	Accuracy
Se	Sensibilité
Sp	Spécificité
F1	F1-score

X	Ensemble des données d'entrée
y	Étiquette réelle (classe)
Y	Prédiction du modèle
W	Poids du modèle
Θ	Paramètres du modèle
$L(\theta)$	Fonction de perte

Symbole	Signification	Unité
t _{lat}	Latence de traitement	ms
P	Puissance consommée	W
M	Mémoire utilisée	MB
C	Capacité de calcul	FLOPS

Liste des figures

Figure I.1 : Signal électrocardiographique (ECG).....	5
Figure I.2 : Chaîne d'acquisition biomédicale d'un signal cardiaque.....	6
Figure I.3: Électrodes ECG multi-canaux utilisées pour l'enregistrement du signal cardia.....	8
Figure I.4 : Module AD8232 pour l'acquisition et l'amplification du signal ECG.....	9
Figure I.5 : Capteur PPG (Photopléthysmographie).....	10
Figure I.6 : Capteur SpO ₂ pour la mesure de la saturation en oxygène du sang.....	11
Figure I.7 : Capteur de pression artérielle (Blood Pressure Sensor).....	12
Figure I.8 : Capteur de respiration pour la surveillance respiratoire.....	13
Figure I.9 : Chaîne de traitement numérique d'un signal ECG (filtrage numérique).....	15
Figure I.10: Fenêtrage temporel.....	15
Figure I.11 : Intervalle RR dans un signal ECG.....	16
Figure I.12 : Échantillonnage.....	17
Figure I.13 : Tachycardie.....	18
Figure I.14 : Bradycardie.....	19
Figure I.15 : Arythmie cardiaque (fibrillation auriculaire).....	19
Figure II.1 : AI, ML and DL.....	23
Figure II. 2 : IA Edge vs IA Cloud.	25
Figure I .3 : Les avantages du traitement en temps réel.....	28
Figure II.4 : Dataset.	29
Figure II.5 : Architecture du CNN.....	32
Figure II.6: Réseau LSTM déplié dans le temps.	33
Figure II.7 : Réseau neuronal feedforward simple.	34
Figure II.8 : Principe de SVM.	35
Figure III.1: Organigramme de Random Forest	38
Figure III.2: Loss Curves-Training Progress.....	39
Figure III.3: Accuracy Curves-Validation Progress.....	40
Figure III.4 : Random Forest :Model Performance During Training (Toutes les données)...	41
Figure III.5: Matrice de Confusion-Random Forest.....	42
Figure III.6: ROC Curve -Random Forest.....	43

Figure III.7: Organigramme de DeepECG-Net.	45
Figure III.8: Training Loss - DeepECG-Net.	48
Figure III.9: Validation Loss - DeepECG-Net.	49
Figure III.10: Training Accuracy – DeepECG-Net.	50
Figure III.11: Validation Accuracy - DeepECG-Net.....	51
Figure III.12: DeepECG-Net:Model Performance During Training.	52
Figure III.13: Organigramme de CLTC et CCFC.	56
Figure III.14: Validation Loss- CLTC et CCfC.	57
Figure III.15: Validation Accuracy CLTC et CCFC.	58
Figure III.16: performance des modèles Pendant l'Entrainement CLTC vs CCFC.....	59

Liste des tableaux

Tableau III.1 : ARCHITECTURE COMPLÈTE (31 couches, 458 000 paramètres).....	46
Tableau III.2 : ARCHITECTURE COMPLÈTE CLTC et CCfC(8couches,8 317 paramètres)	55
Tableau III.3 : Performances par classe Modèle CLTC.....	60
Tableau III.4 : Performances par classe Modèle CCFC.....	60
Tableau III.5 : Comparaison finale des modèles CLTC et CCFC.....	61
Tableau III.6 : Comparaison des ensembles de données Code 15 et TNMG.....	62
Tableau III.7 : Comparaison des performances Code 15 vs TNMG.....	62
Tableau III.8 : Comparaison métriques performance CLTC CCFC DeepECG Net Random Forest.....	63
Tableau III.9 : Analyse ressources efficacité computationnelle modèles.....	63

Introduction générale

Les maladies cardiovasculaires constituent la première cause de mortalité dans le monde, responsables d'environ 17,9 millions de décès par an selon l'Organisation mondiale de la santé (OMS) [1]. Face à ce constat alarmant, la détection précoce et la surveillance continue des anomalies cardiaques sont devenues des enjeux majeurs de santé publique.

L'électrocardiogramme (ECG) s'est imposé comme l'outil de référence pour le diagnostic des troubles cardiaques, grâce à son caractère non invasif, son faible coût et sa facilité d'utilisation [2]. Cependant, l'analyse traditionnelle des signaux ECG repose sur une interprétation manuelle par des cardiologues, ce qui limite son accessibilité dans les régions éloignées et augmente les délais de diagnostic.

Pour répondre à ces défis, les techniques d'intelligence artificielle (IA), en particulier l'apprentissage profond (deep learning), ont émergé comme des solutions prometteuses pour l'analyse automatisée des signaux ECG [3]. Ces approches permettent d'extraire automatiquement des caractéristiques pertinentes et de classer les anomalies cardiaques avec une précision comparable, voire supérieure, à celle des experts humains. Néanmoins, les modèles d'apprentissage profond conventionnels sont souvent très gourmands en ressources informatiques (mémoire, puissance de calcul, énergie), ce qui limite leur déploiement sur des appareils mobiles ou portables.

C'est dans ce contexte que se positionne l'Edge AI (intelligence artificielle à la périphérie), qui vise à exécuter des algorithmes d'IA directement sur des dispositifs embarqués à ressources limitées (microcontrôleurs, capteurs intelligents, appareils portables) [4]. Cette approche présente plusieurs avantages : réduction de la latence, préservation de la confidentialité des données, diminution de la dépendance au cloud, et économie d'énergie. L'objectif de ce travail est de concevoir et de simuler un système intelligent de surveillance cardiaque, basé sur l'Edge AI, capable de détecter en temps réel des anomalies à partir de signaux ECG.

Ce projet s'articule autour de trois chapitres complémentaires :

Chapitre I : Fondements théoriques

Ce chapitre présente les bases médicales et scientifiques de la surveillance cardiaque. Il décrit l'anatomie et la physiologie du cœur ainsi que les principes des signaux électrocardiographiques (ECG). Il introduit également les concepts fondamentaux de l'intelligence artificielle et de l'apprentissage automatique appliqués au domaine médical.

Chapitre II : Intelligence artificielle pour la détection d'anomalies ECG

Ce chapitre explore l'utilisation de l'intelligence artificielle pour l'analyse des signaux ECG et la détection des anomalies cardiaques. Il présente les principales pathologies ciblées ainsi que les caractéristiques des signaux électrocardiographiques. Enfin, il décrit différentes architectures de réseaux de neurones et les métriques utilisées pour évaluer leurs performances.

Chapitre III : Simulation et implémentation du système Edge AI

Ce chapitre détaille la conception et le développement d'un système embarqué intelligent de surveillance cardiaque. Il explique les étapes de prétraitement des données ECG, l'entraînement des modèles d'IA et leur évaluation. Une comparaison entre plusieurs approches permet d'identifier la solution la plus adaptée aux contraintes de l'Edge AI et des microcontrôleurs.

Cette approche structurée permet une compréhension globale à la fois du contexte médical et des méthodes d'ingénierie utilisées pour modéliser, simuler et optimiser la détection d'anomalies cardiaques en temps réel sur des dispositifs Edge AI.

Chapitre I

Fondements Théorique

I.1 Introduction

Dans ce chapitre, les bases théoriques et techniques présentées ci-dessus nécessaires à la compréhension de la conception d'un système intelligent de surveillance cardiaque ont été abordées avec l'instrumentation biomédicale, le traitement du signal, l'architecture embarquée. Ces bases scientifiques sont la plateforme sur laquelle les étapes de conception et de simulation suivantes [6].

I.2 Définition d'un système de surveillance cardiaque

Un système de surveillance cardiaque est un dispositif biomédical intégré permettant l'acquisition, l'enregistrement et l'analyse continue de l'activité électrique du cœur, afin de détecter et prévenir les anomalies cardiaques.

Il se compose généralement de capteurs (électrodes ECG), d'un module d'acquisition analogique-numérique, d'un traitement du signal, et d'une unité de décision ou d'intelligence artificielle capable de générer une alerte en cas d'anomalie.

Sur le plan clinique, ces systèmes visent à identifier des troubles tels que les arythmies, les blocs de conduction, la fibrillation auriculaire ou ventriculaire, ainsi que les anomalies du segment ST pouvant indiquer une ischémie myocardique.

L'analyse automatisée des signaux ECG constitue un élément central dans les systèmes modernes de surveillance cardiaque, en raison de la complexité et du caractère non stationnaire du signal biologique.

Ces dispositifs sont utilisés aussi bien dans les hôpitaux que dans les appareils portables et la télémédecine, assurant un suivi en temps réel de l'état cardiaque des patients [7].

I.3 Définition du signal électrocardiographique (ECG)

L'électrocardiogramme (ECG) est un signal biomédical représentant l'activité électrique générée par la dépolarisation et la repolarisation des cellules myocardiques au cours du cycle cardiaque.

Un cycle ECG normal comprend :

- Onde P : dépolarisation auriculaire
- Complexe QRS : dépolarisation ventriculaire
- Onde T : repolarisation ventriculaire

Le signal ECG se caractérise par :

- Une amplitude faible (~ 1 mV)
- Une bande passante comprise entre 0,05 Hz et 150 Hz
- Un comportement non stationnaire
- Une forte sensibilité aux interférences et au bruit

L'ECG est l'un des signaux physiologiques les plus étudiés dans le domaine du traitement numérique du signal biomédical.[8]




Figure I.1 : Signal électrocardiographique (ECG)[9].

I.4 Détection d'Anomalies Cardiaques

La détection d'anomalies correspond à l'identification automatique de patterns anormaux dans les signaux ECG indiquant des pathologies telles que l'arythmie, la tachycardie ou la fibrillation. Cette détection peut être réalisée par des méthodes statistiques, des techniques de traitement du signal ou des algorithmes d'apprentissage automatique capables de distinguer entre rythme normal et pathologique.

I.5 Chaîne d'Acquisition Biomédicale

La chaîne d'acquisition biomédicale est l'ensemble des blocs fonctionnels permettant de convertir un signal physiologique analogique (ECG) en un signal numérique exploitable par un système de traitement [10].




Figure I.2: Chaîne d'acquisition biomédicale d'un signal cardiaque

I.5.1 Capteurs cardiaques

Les capteurs cardiaques sont des dispositifs biomédicaux conçus pour détecter et convertir l'activité physiologique du cœur (électrique ou hémodynamique) en signaux électriques mesurables.

- ECG (Électrocardiogramme) mesure l'activité électrique générée par la dépolarisation et la repolarisation du myocarde.
- PPG (Photopléthysmographie) mesure les variations du volume sanguin périphérique via un capteur optique utilisant une LED et un photodétecteur.[7]

Ces capteurs constituent la première étape des systèmes de surveillance cardiaque modernes

intégrés dans l'Internet des Objets Médicaux (IOMT). Leur précision influence directement la qualité du diagnostic automatisé. les différents types de capteurs est :

I.5.1.1 Capteur ECG (Électrocardiogramme)

Le capteur ECG (Electrocardiogramme) est un dispositif biomédical conçu pour mesurer et enregistrer l'activité électrique du cœur à travers la surface corporelle. Il fonctionne en détectant les variations de potentiel électrique générées par la dépolarisation et la repolarisation des cellules myocardiques lors du cycle cardiaque.

Physiologiquement, le signal ECG représente l'activation séquentielle des différentes structures cardiaques : l'onde P correspond à la dépolarisation auriculaire, le complexe QRS à la dépolarisation ventriculaire, et l'onde T à la repolarisation ventriculaire. Ces composantes permettent d'identifier des anomalies telles que la fibrillation auriculaire, les extrasystoles ventriculaires, les blocs auriculo-ventriculaires ou encore les signes d'ischémie myocardique[7].

Le capteur ECG utilise généralement des électrodes Ag/AgCl placées sur la peau afin de capter les micro-potentiels électriques (de l'ordre du millivolt). Le signal analogique est ensuite amplifié par un amplificateur d'instrumentation, filtré pour éliminer le bruit (bruit musculaire, interférences secteur 50/60 Hz), puis converti en signal numérique via un convertisseur analogique-numérique (ADC).

Dans les systèmes modernes de surveillance cardiaque avec Edge AI, le signal ECG constitue la source principale de données pour l'analyse automatique et la détection d'anomalies en temps réel[10],[7].

I.5.1.1.1 Électrodes ECG multi-canaux

Les électrodes ECG sont des dispositifs médicaux qui assurent le contact électrique entre le corps du patient et l'électrocardiographe. Elles permettent d'enregistrer l'activité électrique du cœur en temps réel. Dans un ECG standard à 12 dérivations, on utilise 10 électrodes

(4 périphériques et 6 précordiales) placées à des emplacements précis sur le thorax et les membres. Toute variation de placement peut modifier la morphologie du signal et entraîner des erreurs diagnostiques[11].




Figure I.3 : Électrodes ECG multi-canaux utilisées pour l'enregistrement du signal cardiaque.[12].

I.5.1.1.2 Module AD8232 ECG

Le capteur AD8232 est un circuit intégré conçu par Analog Devices pour extraire, amplifier et filtrer les signaux biopotentiels, notamment ceux du cœur. Il agit comme un amplificateur opérationnel spécialisé pour obtenir un signal ECG clair, même en présence de bruit dû aux mouvements. Ce module est compact, basse consommation (3,3-5 V), et se connecte facilement à des microcontrôleurs comme Arduino ou Raspberry Pi pour des applications pédagogiques et médicales portables[13].




Figure I.4 : Module AD8232 pour l'acquisition et l'amplification du signal ECG[14].

I.5.1.1.2 Capteur PPG (Photopléthysmographie)

Le capteur PPG (Photopléthysmographie) est un dispositif optique non invasif utilisé pour mesurer les variations volumétriques du sang dans les tissus périphériques. Il repose sur le principe de l'absorption différentielle de la lumière par l'hémoglobine oxygénée et désoxygénée.

Le système PPG comprend généralement une diode électroluminescente (LED) émettant une lumière rouge ou infrarouge et un photodétecteur mesurant la lumière réfléchie ou transmise à travers la peau. Lorsque le volume sanguin augmente durant la systole cardiaque, l'absorption lumineuse change, générant un signal périodique synchronisé avec le rythme cardiaque.

Le signal PPG permet de déterminer :

La fréquence cardiaque (HR)

La variabilité de la fréquence cardiaque (HRV)

Certaines arythmies cardiaques

Les tendances hémodynamiques

Comparé à l'ECG, le PPG est plus simple à intégrer dans des dispositifs portables comme les montres intelligentes. Cependant, il est plus sensible aux artefacts de mouvement, ce qui nécessite des techniques avancées de filtrage et d'intelligence artificielle pour améliorer la robustesse du signal[7].




Figure I.5 : Capteur PPG (Photopléthysmographie)[15].

I.5.1.1.3 Capteur SpO₂ (Saturation en oxygène)

Le capteur SpO₂ est un dispositif basé sur la photopléthysmographie permettant d'estimer la saturation périphérique en oxygène du sang artériel. Il mesure le pourcentage d'hémoglobine liée à l'oxygène par rapport à l'hémoglobine totale.

Le principe repose sur la loi de Beer-Lambert, qui décrit l'absorption lumineuse dans un milieu biologique. Deux longueurs d'onde sont utilisées :

- Rouge (~660 nm)
- Infrarouge (~940 nm)

L'hémoglobine oxygénée et désoxygénée absorbent différemment ces longueurs d'onde. Le rapport des absorptions permet d'estimer le taux de saturation en oxygène.

Dans le contexte de la surveillance cardiaque, la mesure de SpO₂ est essentielle pour :

- Détecter l'hypoxémie
- Surveiller les patients souffrant d'insuffisance cardiaque
- Évaluer les troubles respiratoires associés

L'intégration du SpO₂ avec l'ECG et le PPG dans un système Edge AI améliore la précision du diagnostic multimodal[16].



Figure I.6 :Capteur SpO₂ pour la mesure de la saturation en oxygène du sang[17].

I.5.1.1.4 Capteur de Pression Artérielle (Blood Pressure Sensor)

Le capteur de pression artérielle est un dispositif médical permettant de mesurer la force exercée par le sang sur les parois des artères. La pression artérielle se compose de :

- Pression systolique (contraction ventriculaire)
- Pression diastolique (relaxation cardiaque)

Les capteurs modernes peuvent être :

- Oscillométriques (bracelet automatique)
- Basés sur PPG + algorithmes de calcul
- Capteurs à microtransducteurs MEMS

Dans un système de surveillance cardiaque intelligent, la pression artérielle constitue un paramètre fondamental pour détecter :

- L'hypertension

- L'hypotension
- Les risques d'accidents cardiovasculaires

L'analyse combinée ECG + BP permet une meilleure évaluation du risque cardiovasculaire[18].



Figure I.7: Capteur de pression artérielle (Blood Pressure Sensor)[19].

I.5.1.1.4 Capteurs de respiration

Les capteurs respiratoires mesurent la fréquence et la qualité de la respiration. Ils peuvent être basés sur la détection flux d'air, de la pression, ou sur la capnographie (mesure du CO_2 , en fin d'expiration, ETCO_2).

Ces capteurs sont intégrés dans les ventilateurs médicaux, appareils d'anesthésie et dispositifs portables pour surveiller les patients souffrant de troubles respiratoires[20].



Figure I.8 : Capteur de respiration pour la surveillance respiratoire[21].

I.5.2 Prétraitement du signal

Le prétraitement du signal cardiaque consiste à nettoyer et normaliser les données brutes issues des capteurs pour éliminer le bruit, les artéfacts et les interférences. Cela inclut le filtrage passe-bas/passe-haut et la normalisation de l'amplitude. Ce processus est crucial pour une détection fiable des anomalies[7].

I.5.3 Microcontrôleur (MCU)

Le microcontrôleur est une unité de traitement compacte intégrée aux dispositifs portables de surveillance cardiaque. Il collecte les données des capteurs, exécute des algorithmes de filtrage et d'analyse, et peut faire tourner des modèles de machine learning légers pour l'analyse instantanée des signaux cardiaques. Cette approche réduit la dépendance au cloud,

protège la confidentialité des données et permet un retour d'information immédiat à l'utilisateur[22].

I.5.4 Détection des pics R

L'identification des sommets R vise à repérer les points culminants du signal ECG qui correspondent à la contraction des ventricules. Ces points sont utilisés pour déterminer le rythme cardiaque et les intervalles entre les battements, cruciaux pour l'examen du rythme et l'identification des arythmies[1].

I.5.5 ADC (Convertisseur Analogique-Numérique)

L'ADC convertit les signaux analogiques provenant des capteurs ECG ou PPG en valeurs numériques exploitables par les algorithmes d'analyse. Cette étape est cruciale pour assurer la précision des mesures et permettre aux modèles d'IA de traiter les données physiologiques de manière fiable.[7]

I.5.6 Système embarqué

Un système embarqué est un ordinateur spécialisé intégré dans un dispositif pour effectuer des fonctions spécifiques en temps réel. Dans les systèmes cardiaques, il permet l'acquisition, le traitement et la détection d'anomalies sur Edge AI[23].

I.6 Filtrage numérique

Le filtrage numérique est une technique de traitement du signal utilisée pour supprimer le bruit et les interférences dans les signaux ECG, en utilisant des algorithmes tels que les filtres passe-bas, passe-haut et notch. Cela améliore la qualité des données pour la détection d'anomalies[24].




Figure I.9 : Chaîne de traitement numérique d'un signal ECG (filtrage numérique).

I.6.1 Fenêtrage temporel

Le fenêtrage temporel consiste à découper le signal ECG en segments de durée fixe afin de faciliter l'analyse locale. Cette technique permet aux modèles d'IA de traiter des portions de signal homogènes et d'identifier des anomalies ponctuelles, comme des extrasystoles ou des fibrillations auriculaires [25].




Figure I.10: Fenêtrage temporel[26].

I.6.2 Intervalle RR

L'intervalle RR est la durée entre deux battements cardiaques successifs, mesurée entre les pics R du signal ECG. Il constitue un indicateur clé de la variabilité de la fréquence cardiaque

et est largement utilisé pour détecter les arythmies. Une analyse fine des intervalles RR est essentielle pour la surveillance cardiaque en temps réel [27].




Figure I.11 : Intervalle RR dans un signal ECG[28].

I.6.3 Echantillonnage (Sampling Rate)

L'échantillonnage correspond au processus de conversion d'un signal analogique continu en une séquence discrète de valeurs numériques, à intervalles réguliers définis par la fréquence d'échantillonnage. Selon le théorème de Nyquist, cette fréquence doit être au moins deux fois supérieure à la fréquence maximale contenue dans le signal pour éviter le phénomène d'aliasing. Dans la surveillance ECG, une fréquence d'échantillonnage typique varie entre 250 Hz et 500 Hz afin de préserver l'intégrité des composantes importantes du signal[29].




Figure I.12 : Échantillonnage[30].

I.6.4 Normalisation

Lanormalisation est une autre fonctionnalité cela ajuste les valeurs de tout signal ou donnée mesurés pour les inclure dans une plage commune.

Il aide à éliminer la variation personnelle ou les différences de capteur. En outre, lanormalisation contribue à garantir une cohérence des données sur lesquelles un modèle est formé, ou lorsque les données sont utilisées pour l'analyser[31].

I.7 Analyse de fréquence cardiaque

L'analyse de fréquence cardiaque consiste à calculer la variation de la fréquence cardiaque dans le temps pour identifier des anomalies telles que la tachycardie, bradycardie ou arythmie. Elle est utilisée dans les systèmes de surveillance automatique pour détecter des problèmes cardiaques[27].

I.7.1 Tachycardie

C'est une fréquence cardiaque qui est constamment anormalement élevée, dépassant 100 battements par minute chez l'adulte. Ce paramètre est enregistré dans l'électrocardiogramme et sa dynamique peut être analysée sur les systèmes cardiaques de moniteur automatiques et cliniques basés sur les technologies de traitement du signal et de l'intelligence artificielle[32].




Figure I.13: Tachycardie[33].

I.7.2 Bradycardie

La bradycardie est un rythme cardiaque lent, se définissant par le rythme inférieur de celui-ci. Un adulte en bonne santé devrait présenter une fréquence cardiaque oscillant entre 60 et 100 battements par minute[34]. En effet, la bradycardie se traduit par une défaillance de l'appréciation du rythme de ce dernier.




Figure I.14 : Bradycardie[35].

I.7.3 Fibrillation auriculaire

La fibrillation auriculaire est une anomalie cardiaque fréquente caractérisée par un rythme cardiaque irrégulier et rapide. Elle peut être détectée par les systèmes automatiques grâce à l'analyse des signaux ECG[32].




Figure I.15 : Arythmie cardiaque (fibrillation auriculaire)[36].

I.8 Base de données cardiaque

Une base de données cardiaque est un ensemble de signaux ECG annotés utilisés pour entraîner, tester et valider les algorithmes de détection d'anomalies. Exemples : MIT-BIH Arrhythmia Database, PhysioNet.

8.1 Base de données MIT-BIH

La base MIT-BIH est une référence internationale contenant des enregistrements ECG annotés.

Elle est largement utilisée pour entraîner et valider des modèles d'IA destinés à la détection d'arythmies[37].

I.8.1 L'Internet of Medical Things (IoMT)

L'Internet of Medical Things (IoMT) est une application spécialisée de l'Internet of Things dans le domaine médical. Il désigne l'ensemble des dispositifs médicaux connectés, capteurs, logiciels et systèmes de santé interconnectés via Internet, permettant la collecte, la transmission et l'analyse des données médicales en temps réel afin d'améliorer le diagnostic, la surveillance et la prise en charge des patients. En d'autres termes, l'IoMT constitue un réseau d'appareils médicaux intelligents (ECG portables, montres connectées, capteurs de glucose, systèmes de surveillance cardiaque, etc.) qui communiquent entre eux et avec des plateformes hospitalières ou cloud. Plusieurs travaux académiques définissent l'IoMT comme un réseau de dispositifs médicaux connectés utilisant l'IoT pour les applications de santé [38]. La WHO souligne l'intégration des technologies connectées dans les systèmes de santé numérique [39].

I.8.2 LSTM (Long Short-Term Memory)

Les réseaux LSTM constituent une variante avancée des réseaux de neurones récurrents (RNN), spécialement conçue pour modéliser des dépendances temporelles longues dans des séries chronologiques. Dans le contexte de la surveillance cardiaque, les LSTM analysent la dynamique des battements successifs afin de détecter des anomalies rythmiques qui ne sont pas visibles dans une seule fenêtre temporelle. Leur architecture à cellules mémoire permet de conserver des informations pertinentes sur plusieurs cycles cardiaques, améliorant ainsi la précision de la détection des arythmies[40].

I.9 Simulation de systèmes cardiaques

La simulation de systèmes cardiaques consiste à reproduire virtuellement l'acquisition, le traitement et la détection d'anomalies sur des datasets ECG afin de tester et valider les algorithmes avant déploiement sur un Edge Device réel[41].

I.10 Réduction du bruit de mouvement

Cette technique corrige les artefacts introduits par les mouvements du patient. En utilisant des algorithmes adaptés ou des capteurs supplémentaires (accéléromètre), on peut isoler le signal cardiaque réel des interférences, garantissant ainsi une analyse plus fiable[42].

I.11 Extraction de caractéristiques

L'extraction de caractéristiques consiste à identifier des paramètres pertinents du signal (amplitude, intervalle RR, énergie spectrale, etc.) afin d'améliorer la classification des anomalies cardiaques[43].

I.12 Alertes automatiques

Les alertes automatiques sont des notifications générées par le système lorsqu'une anomalie cardiaque est détectée, permettant une intervention rapide. Elles peuvent être envoyées au patient, au médecin ou aux services d'urgence via une application mobile ou un réseau IoT sécurisé[44].

I.13 Conclusion

Ce chapitre a présenté les fondements théoriques essentiels pour saisir le système suggéré. Le projet repose sur des fondements scientifiques tels que la surveillance cardiaque, l'analyse du signal ECG. L'incorporation de l'Edge AI dans un système de monitoring cardiaque facilite une identification rapide, exacte et indépendante des irrégularités cardiaques, préparant le terrain pour des appareils médicaux intelligents de nouvelle génération.

Chapitre II

Techniques IA pour la Surveillance Cardiaque et l'Analyses ECG

II.1 Introduction

Ce chapitre explore le rôle central de l'intelligence artificielle dans le monitoring cardiaque, plus précisément pour l'identification automatisée des arythmies à partir des signaux ECG. L'apprentissage automatique permet d'entraîner des modèles sur des données ECG afin de distinguer les rythmes normaux des irrégularités cardiaques.

Trois familles de techniques sont couramment mises en œuvre : les machines à vecteurs de support (SVM), les k-plus proches voisins (KNN), ainsi que les réseaux de neurones profonds (CNN, LSTM).

Ces approches garantissent une détection rapide et fiable, condition essentielle pour les systèmes de surveillance en temps réel.

II.2 Intelligence Artificielle (AI)

L'intelligence artificielle est un domaine de l'informatique visant à développer des systèmes capables d'effectuer des tâches nécessitant normalement l'intelligence humaine, comme la reconnaissance de patterns, l'apprentissage et la prise de décision.

Dans le domaine biomédical, l'AI est utilisée pour analyser de grandes quantités de données physiologiques afin d'améliorer le diagnostic médical[45].




Figure II.1: AI, ML and DL[46].

II.2.1 Machine Learning (Apprentissage Automatique)

Le Machine Learning est une sous-discipline de l'AI permettant aux systèmes d'apprendre à partir de données sans programmation explicite.

Dans les systèmes de surveillance cardiaque, il est utilisé pour classifier les signaux ECG en catégories normales ou anormales à partir de caractéristiques extraites[45].

II.2.2 Deep Learning

Le Deep Learning est une approche avancée du Machine Learning basée sur des réseaux neuronaux profonds capables d'extraire automatiquement des caractéristiques complexes à partir des signaux ECG bruts. Les architectures CNN et LSTM sont particulièrement utilisées pour la détection d'arythmies en temps réel[45].

II.2.3 Edge AI (Intelligence Artificielle en périphérie)

Le concept d'Edge AI désigne une approche dans laquelle les algorithmes de Intelligence Artificielle sont exécutés directement sur des dispositifs situés à proximité de la source des données, plutôt que sur des infrastructures centralisées. Cette organisation permet d'assurer un traitement local de l'information, ce qui réduit les délais de réponse et améliore la réactivité du système.

Dans le domaine médical, cette approche est particulièrement pertinente, notamment pour les systèmes de surveillance continue basés sur le signal ECG signal. Elle permet une détection rapide des anomalies, même en l'absence d'une connexion Internet stable, tout en renforçant la confidentialité des données sensibles[47].

II.2.4 Cloud IA

Le Cloud IA correspond à l'utilisation des techniques de l'intelligence Artificielle à travers des plateformes de Cloud Computing accessibles via Internet. Plutôt que d'exécuter les algorithmes en local, le traitement est effectué sur des serveurs à distance, offrant par conséquent une puissance de calcul et une capacité de stockage vastes. De ce fait, cette approche facilite la conception et l'implémentation de solutions intelligentes tout en réduisant les contraintes associées aux équipements[48].




Figure II. 2 :IA Edge vs IA Cloud[49].

II.2.5 TinyML

TinyML est une approche de Machine Learning qui permet d'exécuter des modèles légers sur des microcontrôleurs ou des dispositifs Edge avec des ressources limitées. Cela rend possible la détection d'anomalies cardiaques directement sur le dispositif portable en temps réel[50].

II.3 Algorithmes et Architectures Connexes

II.3.1 Réseau de neurones

Un réseau de neurones est un modèle de Machine Learning inspiré du cerveau humain, capable de reconnaître des motifs complexes dans les signaux ECG pour détecter automatiquement des anomalies cardiaques[45].

II.3.2 Fonction d'Activation (Activation Function)

La fonction d'activation est un composant mathématique essentiel de tout neurone artificiel. Elle reçoit la somme pondérée des entrées (provenant des neurones de la couche précédente) et applique une transformation non linéaire pour produire la sortie du neurone.

C'est la faculté de traiter la non-linéarité qui permet aux réseaux de neurones d'examiner des fonctions complexes, contrairement à un modèle essentiellement linéaire[45].

II.3.3 Modèle training

L'entraînement d'un modèle consiste à lui apprendre à partir d'exemples afin qu'il puisse effectuer des prédictions sur de nouvelles données. Cette étape consiste à ajuster progressivement les paramètres internes du modèle afin de réduire l'écart entre les sorties prédites et les valeurs réelles.

Dans les réseaux de neurones, ce processus se fait généralement par rétropropagation de l'erreur et par des algorithmes d'optimisation comme la descente de gradient. Plus le modèle est confronté à des données variées, plus sa capacité de généralisation s'améliore[45].

II.3.4 Surapprentissage (Overfitting)

Le surapprentissage est un problème fréquent en apprentissage automatique. Il apparaît lorsque le modèle devient trop "attaché" aux données d'entraînement. Autrement dit, au lieu d'apprendre des règles générales, il mémorise les détails spécifiques, y compris les erreurs ou le bruit. Initialement, cela peut paraître que le modèle est très performant, surtout sur les données sur lesquelles il a été formé.

Mais dès qu'on lui donne de nouvelles données, ses performances chutent. C'est pour cette raison qu'il est important de trouver un équilibre, afin que le modèle soit capable de généraliser[45].

II.4 Optimisation pour le Déploiement

II.4.1 Optimisation de modèle

L'optimisation de modèle fait référence à toutes les méthodes destinées à diminuer la complexité calculatoire et l'espace mémoire occupé par un réseau de neurones tout en préservant sa précision de manière significative.

Dans le cadre de l'Edge AI (sur carte cardiaque), elle inclut des méthodes comme la quantification, l'élagage (pruning) des connexions neuronales redondantes, et la distillation de connaissances. Ces transformations sont indispensables pour déployer des CNNs ou LSTMs sur des microcontrôleurs à ressources limitées[45].

II.4.2 Élagage (Pruning)

Le pruning est une technique d'amélioration des modèles destinée à se débarrasser des neurones ou connexions neuronales jugés non essentiels, c'est-à-dire ceux dont la contribution à la prédiction finale est quasi nulle. Cette réduction du réseau diminue son utilisation de mémoire et améliore la rapidité d'inférence, un critère primordial pour son déploiement sur des dispositifs Edge aux performances limitées (tels que les microcontrôleurs ou les montres connectées).

Le pruning peut être non structuré (suppression de connexions individuelles, rendant le réseau irrégulier) ou structuré (suppression de filtres ou de canaux entiers, plus adapté aux accélérateurs matériels). On peut élaguer jusqu'à 90% des paramètres sans perte significative de précision[45].

II.5 La latence

Correspond au délai entre l'acquisition du signal physiologique et la production d'un résultat d'analyse. Dans les systèmes critiques de santé, une faible latence est essentielle pour garantir une alerte immédiate en cas d'anomalie cardiaque sévère. L'Edge AI contribue fortement à la réduction de cette latence[51].

II.6 Real-Time Processing

Dans les dispositifs de surveillance du cœur, le traitement en temps réel revêt une grande importance. En d'autres termes, c'est la capacité d'un système à traiter les données instantanément dès leur production, sans délai. Par exemple, quand un capteur capte un signal ECG, ce dernier est immédiatement analysé pour identifier rapidement toute anomalie potentielle.

Ce type de fonctionnement est essentiel dans le domaine médical, car un retard dans l'analyse peut entraîner des conséquences graves. À l'opposé de la méthode traditionnelle qui consiste à stocker les données avant de les analyser ultérieurement, ici tout est presque instantanément effectué. Il est donc nécessaire de disposer de systèmes performants capables de délivrer des réponses rapidement, avec un délai de réaction le plus court possible[52].




Figure I.3 :les avantages du traitement en temps réel[53].

II.7 Pipeline de Traitement des Signaux

II.7.1 Dataset

Un dataset est un ensemble structuré de données rassemblées dans un but précis, utilisé en règle générale pour former et valider des modèles d'apprentissage automatique. Ces données peuvent provenir, dans les applications biomédicales, des signaux physiologiques

(ex : électrocardiogramme) annotés par des experts.

Le modèle est directement influencé par la qualité des données utilisées. Un jeu de données déséquilibré ou non représentatif peut donner lieu à des résultats déformés et restreindre la faculté du système à faire des généralisations[45].




Figure II.4 :Dataset[54].

II.7.2 Signal Preprocessing (Prétraitement du signal)

L'étape initiale de traitement du signal a pour but de purger et de modifier les données brutes provenant du capteur avant leur intégration dans le modèle d'intelligence artificielle. Pour les signaux biomédicaux (ECG), il inclut le débruitage (filtres passe-bande pour éliminer les artefacts de mouvement et le bruit secteur 50/60 Hz), le détourage (detrending) pour supprimer la dérive de la ligne de base, et parfois la normalisation (z-score). Cette étape est cruciale pour garantir que le réseau de neurones se concentre sur les anomalies cardiaques physiologiques et non sur les artefacts d'acquisition[55].

II.7.3 Apprentissage Fédéré (Federated Learning)

La méthode d'apprentissage centré est une méthode de formation décentralisée où les informations demeurent sur les appareils locaux des utilisateurs et ne sont jamais divulguées à un serveur centralisé.

Chaque dispositif (par exemple, la montre connectée d'un patient cardiaque) entraîne un modèle local sur ses propres données, puis envoie uniquement les mises à jour du modèle (les poids, pas les données brutes) à un serveur agrégateur. Celui-ci combine les mises à jour de nombreux participants pour améliorer un modèle global, qui est ensuite redistribué. Cette méthode maintient la protection des informations médicales délicates, ce qui est crucial pour respecter les lois comme le RGPD en Europe ou la HIPAA aux États-Unis. L'apprentissage fédéré est particulièrement pertinent pour la surveillance cardiaque décentralisée[56].

II.7.4 Feature Extraction

L'extraction de caractéristiques simplifie le travail des données brutes et les transforme en variables à partir desquelles l'apprentissage est simplifié. Dans le cas des signaux ECG, cela peut comprendre des données comme la fréquence des battements de cœur ou la forme des ondes.

Cependant, ces dernières années, les techniques de deep learning permettent d'automatiser cette étape, en apprenant telles ou telles représentations[45].

II.7.5 Feature selection

Le choix des caractéristiques est la procédure consistant à déterminer les variables les plus pertinentes pour la tâche d'apprentissage. Elle permet de simplifier le modèle, d'améliorer sa précision et de diminuer la durée requise pour les calculs. Les méthodes de sélection comprennent les approches par filtres, wrappers et intégrées[45].

II.7.6 Classification

L'attribution d'une catégorie à une donnée basée sur ses attributs est une tâche essentielle de l'apprentissage automatique, connue sous le nom de classification. Dans les systèmes de surveillance cardiaque, elle permet de distinguer les signaux normaux des signaux pathologiques.

L'objectif se base sur des modèles qui peuvent se former à partir de données labellisées et étendre leurs savoirs à des situations inédites[45].

II.8 Métriques d'évaluation Clinique

II.8.1 Sensibilité

La sensibilité d'un système de surveillance cardiaque représente sa capacité à ne rater aucun battement anormal. En d'autres termes, c'est le pourcentage de patients ou de battements réellement malades que le système a réussi à détecter. Un système très sensible agit comme un filet à mailles très serrées : il ne laisse presque rien lui échapper. Dans le domaine médical, on préfère souvent avoir un système trop sensible (qui donne quelques alertes inutiles) plutôt qu'un système qui manquerait un vrai danger. Par exemple, si un système a une sensibilité de 98%, cela signifie que sur 100 battements anormaux, il en détecte 98 et en rate seulement 2. La sensibilité est donc la métrique de la prudence du système[45].

II.8.2 Spécificité

La spécificité d'un dispositif de surveillance cardiaque réside dans sa faculté à éviter une alerte erronée lorsqu'il détecte un rythme cardiaque normal. C'est le pourcentage de battements sains que le système a correctement identifiés comme normaux. Un système très spécifique est un système fiable qui n'ennuie pas les médecins avec des alertes intempestives. Pour illustration, si un système a une spécificité de 95%, cela veut dire que parmi 100 battements réguliers, il les identifie correctement comme tels dans 95 situations, tandis qu'il ne déclenche faussement l'alerte que dans 5 cas. La spécificité est ainsi l'indicateur de la fiabilité du système : elle préserve les équipes soignantes de l'épuisement et maintient la réalité de l'alarme[45]

II.8.3 Accuracy (Exactitude)

L'accuracy est une mesure de performance qui évalue la proportion de prédictions justes réalisées par un modèle en comparaison au total des prédictions effectuées. Malgré son caractère intuitif, cette mesure peut induire en erreur lorsque les ensembles de données sont déséquilibrés. Dans le domaine du diagnostic cardiaque, l'exactitude est généralement appuyée par la sensibilité (rappel) et la spécificité pour mesurer la solidité clinique du système[45].

II.9 Convolutional Neural Network(CNN)

Un CNN est une architecture de réseau neuronal profond destinée à manipuler des données organisées en grille (telle qu'une image ou un signal temporel 1D).

Sa particularité est basée sur l'emploi de couches convolutives qui mettent en œuvre des filtres (noyaux) glissants sur les données d'entrée pour une détection automatique de motifs invariants par translation (par exemple : un pic anticipé dans un ECG, peu importe son heure d'apparition)[45].




Figure II.5 :Architecture du CNN[57].

II.10 Long Short-Term Memory (LSTM)

Le LSTM est un type de réseau de neurones récurrents conçu pour gérer des données séquentielles et capturer les dépendances à long terme. Il convient particulièrement bien aux signaux temporels, tels que les signaux cardiaques.

Par le biais de ses systèmes internes (portes d'entrée, de sortie et d'oubli), il a la capacité de retenir les informations cruciales sur des durées prolongées[45].




Figure II.6:Réseau LSTM déplié dans le temps[58].

II.11 Réseau de neurones artificiels- Artificial Neural Network (ANN)

Un ANN est un paradigme de calcul inspiré du système nerveux biologique, composé d'une grande quantité de nœuds interconnectés (neurones artificiels) organisés en couches (entrée, cachées, sortie). Chaque connexion possède un poids modifiable lors de la phase d'apprentissage. Les ANNs sont des approximateurs universels capables de modéliser des relations non linéaires complexes. Bien que les architectures profondes (CNN, LSTM) dominant aujourd'hui, le perceptron multicouche (MLP) reste un cas particulier d'ANN essentiel pour la fusion des caractéristiques extraites.essentiel pour la fusion des caractéristiques extraites[45].




Figure II.7 : Réseau neuronal feedforward simple[59].

II.12 Support Vector Machine (SVM)

La SVM est un modèle d'apprentissage supervisé non probabiliste utilisé pour la classification et la régression. Son principe est de trouver l'hyperplan séparateur optimal qui maximise la marge (distance) entre les échantillons des différentes classes. Avec l'utilisation de la technique du noyau (kernel trick), le SVM est en mesure de projeter les données dans un espace à dimension plus élevée afin de rendre les classes capables d'être séparées linéairement.

Dans le diagnostic cardiaque, elle est efficace pour la classification de petits jeux de données, mais généralement moins performante que les CNN sur de très grands volumes de données brutes[45].




Figure II.8: Principe de SVM[60].

II.13 Conclusion

L'intelligence artificielle (IA) constitue aujourd'hui un outil incontournable dans le domaine médical, en particulier pour l'analyse des signaux biomédicaux tels que l'électrocardiogramme (ECG). Grâce à des algorithmes capables d'apprendre automatiquement à partir des données, elle permet d'extraire des caractéristiques complexes et d'améliorer la détection précoce des anomalies cardiaques avec une précision élevée.

Dans ce contexte, les techniques de *deep learning* ont montré des performances remarquables dans le traitement des données temporelles. Les architectures telles que les réseaux de neurones convolutifs (CNN) et récurrents (RNN), notamment **ConvLSTM**, permettent de capturer simultanément les dépendances spatiales et temporelles des signaux ECG.

le chapitre suivant sera consacré à l'application pratique de ces approches. En s'appuyant sur les modèles proposés dans l'étude académique, en particulier **CLTC** et **CCfC**, il s'agira de concevoir et de développer un système intelligent de détection des anomalies ECG. Ce chapitre détaillera les étapes de prétraitement des données, de modélisation, d'entraînement et d'évaluation des performances, afin de valider expérimentalement l'efficacité des techniques d'intelligence artificielle.

Chapitre II

Techniques IA pour la Surveillance Cardiaque et l'Analyses ECG

III.1 Introduction

Dans le domaine biomédical, l'électrocardiogramme (ECG) représente un outil fondamental pour l'analyse de l'activité électrique du cœur. Grâce à sa nature non invasive, son faible coût et sa simplicité d'utilisation, il est largement employé dans le diagnostic des maladies cardiovasculaires, notamment les arythmies cardiaques .

Les architectures hybrides combinant réseaux convolutionnels et réseaux récurrents ont montré des performances remarquables dans le traitement des séries temporelles complexes. Les modèles ConvLSTM permettent de capturer simultanément les dépendances spatiales et temporelles des signaux ECG[61] .

Dans ce travail, nous proposons une étude comparative de plusieurs architectures de deep learning pour la classification binaire des signaux ECG (normal vs anomalie) sous python.

- Random Forest: algorithme d'apprentissage automatique qui combine les prédictions de plusieurs arbres de décision pour améliorer la précision et réduire le surapprentissage.
- CLTC (ConvLSTM2D + Liquid Time-Constant) : modèle hybride intégrant des réseaux neuronaux à constantes de temps liquides pour une meilleure modélisation dynamique
- CCfC (ConvLSTM2D + Closed-form Continuous-time) : architecture inspirée des systèmes neuronaux continus permettant une modélisation efficace des dépendances temporelles
- DeepECG-Net (CNN + Transformer) : modèle combinant réseaux convolutionnels et mécanisme d'attention Transformer afin de capturer les relations locales et globales dans les signaux ECG .

L'objectif principal de cette étude est de comparer les performances de ces modèles en termes de précision, robustesse et capacité de généralisation pour la détection automatique des anomalies cardiaques.

III.2 Dataset et architectures des modèles

Pour mener à bien cette étude, nous avons utilisé le dataset public CODE-15% [62], un sous-ensemble représentatif du réseau de télésanté de Minas Gerais (TNMG) au Brésil. Ce dataset contient 345 779 examens ECG à 12 dérivations, échantillonnés à une fréquence de 400 Hz, avec une durée normalisée de 10 secondes (4096 échantillons). Nous avons sélectionné 20 000 examens équilibrés couvrant six types d'anomalies cardiaques : la fibrillation auriculaire (AF), le bloc auriculo-ventriculaire du premier degré (1dAVb), les blocs de branche droit et gauche (RBBB et LBBB), ainsi que la bradycardie (SB) et la tachycardie sinusale (ST). Après normalisation Z-score des signaux, nous avons divisé les données en ensembles d'entraînement (80%) et de validation (20%). Pour la classification, nous avons implémenté deux architectures basées sur les Neural Circuit Policies (NCP) : le modèle CLTC (ConvLSTM2D + Liquid Time-Constant) et le modèle CCfC (ConvLSTM2D + Closed-Form Continuous-Time). Ces modèles partagent la même architecture : une couche d'entrée (4096, 12), un reshape (4096,1,1,12), une couche ConvLSTM2D avec 32 filtres, un flatten, deux couches denses de 75 et 14 neurones (input neurones et inter/command neurones), une couche NCP de 20 neurones (avec activation tanh pour CLTC et gelu pour CCfC), et enfin une couche de sortie de 6 neurones avec activation sigmoïde correspondant aux six classes d'anomalies. Ces modèles comptent 8 317 paramètres et occupent seulement 240 KB de RAM, ce qui les rend particulièrement adaptés aux microcontrôleurs.

III.3 Définition de Random Forest

Le **Random Forest** est une méthode d'apprentissage automatique basée sur un ensemble d'arbres de décision construits à partir de données sélectionnées aléatoirement. Chaque arbre produit une prédiction indépendante, puis l'algorithme combine toutes les prédictions pour obtenir un résultat final plus fiable et plus précis. Cette technique permet d'améliorer les performances de classification et de régression tout en réduisant le risque de surapprentissage. Selon Trevor Hastie, Robert Tibshirani et Jerome Friedman dans leur ouvrage *The Elements of Statistical Learning*, les forêts aléatoires constituent une amélioration des arbres de décision grâce à l'introduction de l'aléatoire dans la sélection des variables et des échantillons[63].




Figure III.1: Organigramme de Random Forest




Figure III.2: Loss Curves-Training Progress.

Ce graphique représente l'évolution de la fonction de perte (**Loss**) du modèle Random Forest pendant l'entraînement.

Il montre :

- la **Train Loss** (courbe bleu),
- la **Validation Loss** (courbe rouge pointillée).

L'axe horizontal représente les **epochs** (itérations d'apprentissage), tandis que l'axe vertical représente la valeur de la loss.

La courbe bleu (*Train Loss*) diminue progressivement d'environ 0.045 jusqu'à 0.018, ce qui indique que le modèle apprend correctement les données d'entraînement et améliore progressivement ses prédictions. La courbe rouge (*Validation Loss*) diminue également puis se stabilise autour de 0.108, montrant que le modèle conserve de bonnes performances sur les

données de validation et possède une bonne capacité de généralisation. L'écart modéré entre les deux courbes suggère un léger overfitting, mais celui-ci reste limité puisque la validation loss demeure faible et stable. Globalement, ces résultats indiquent une bonne convergence du modèle et une performance satisfaisante pour la détection des anomalies ECG sur le dataset CODE-15%.




Figure III.3:Accuracy Curves-Validation Progress.

Le graphique *Accuracy Curves – Validation Progress* montre l'évolution de la précision du modèle Random Forest pendant l'entraînement. La *Train Accuracy* (courbe bleue) augmente progressivement jusqu'à environ 98.5%, ce qui indique un très bon apprentissage des données d'entraînement. La *Validation Accuracy* (courbe rouge) atteint environ 89.2% puis se stabilise, montrant une bonne capacité de généralisation sur des données non vues. L'écart entre les deux courbes indique un léger overfitting, mais celui-ci reste limité car la précision de validation demeure élevée et stable. Globalement, le modèle présente de bonnes performances pour la détection des anomalies ECG sur le dataset CODE-15%.




Figure III.4 :Random Forest :Model Performance During Training (Toutes les données).

Le modèle Random Forest a présenté de bonnes performances pendant l'apprentissage. La training loss a diminué progressivement, tandis que la training accuracy a atteint environ 99 %, montrant une excellente capacité d'apprentissage. La validation loss est restée stable autour de 0.11 et la validation accuracy a atteint 89.2 %, ce qui indique une bonne généralisation sur les données non vues. Malgré un léger écart entre les performances d'entraînement et de validation, le modèle reste stable, efficace et présente seulement un léger overfitting.




Figure III.5:Matrice de Confusion-Random Forest.

La matrice de confusion du modèle Random Forest montre que le classificateur prédit uniquement la classe « Normal ». En effet, 2656 échantillons normaux ont été correctement classifiés, tandis que les 323 échantillons anormaux ont tous été mal classifiés comme normaux. Aucun cas anormal n'a été détecté.

Bien que l'accuracy globale soit relativement élevée ($\approx 89\%$), cette performance reste trompeuse à cause du déséquilibre des classes. Le modèle présente donc une faible capacité de détection des anomalies, ce qui limite son efficacité dans un système de surveillance cardiaque basé sur l'intelligence artificielle.




Figure III.6:ROC Curve -Random Forest.

La courbe ROC du modèle Random Forest montre des performances faibles dans la classification des données cardiaques. La valeur de l'AUC obtenue est de 0.493, ce qui est très proche d'une classification aléatoire. De plus, la courbe ROC suit presque la diagonale de référence, indiquant que le modèle ne parvient pas à distinguer efficacement les cas normaux des cas anormaux. Ces résultats confirment la faible capacité du modèle à détecter les anomalies cardiaque.

III.4 Définition de DeepECG-Net

Le **DeepECG-Net** est un modèle d'apprentissage profond hybride utilisé pour l'analyse automatique des signaux ECG. Il combine des **réseaux de neurones convolutionnels (CNN)** et des **Transformers basés sur l'attention** afin d'extraire à la fois les caractéristiques locales (formes d'onde cardiaques comme P, QRS, T) et les dépendances temporelles globales du signal.[64]

Ce modèle est conçu pour la **détection des anomalies cardiaques** (arythmies, fibrillation auriculaire, troubles de conduction) à partir de signaux ECG multicanaux, avec une haute précision et une capacité de traitement en temps réel.

Formule générale

Poids_BatchNorm = $4 \times \text{filters}$

- 4 paramètres par filtre : γ (scale), β (offset), moyenne, variance



Figure III.7: Organigramme de DeepECG-Net.

Tableau III.1 : ARCHITECTURE COMPLÈTE (31 couches, 458 000 paramètres)

N ° Poids	Nom de la couche	type	Paramètres
0	Input	InputLayer	(4096,12)
11 58	Conv1D_1	Conv1D	Fikters=64, kernel=15, str=2
256	BatchNorm_1	BatchNormalization	-
0	Activation_1	Activation	GELU
0	MaxPool_1	MaxPooling1D	Pool=4, stride=2
0	Dropout_1	Dropout	Rate=0.2
90 24	Conv1D_2	Conv1D	Filters=128, kernel=11, str=1
512	BatchNorm_2	BatchNormalization	-
0	Activation_2	Activation	GELU
0	MaxPool_2	MaxPooling1D	Pool=4, stride=2
0	Dropout_2	Dropout	Rate=0.1
229 6	Conv1D_3	Conv1D	Filters=256 , kernel=7 , str=1
1 02	BatchNorm_3	BatchNormalization	-
0	Activation_3	Activation	GELU
0	MaxPool_3	MaxPooling1D	Pool=4 , stride=2
0	Dropout_3	Dropout	Rate=0.1
0	positionalEncoding	positionalEncoding	Embed_dim=128
66 368	MultiHeadAttention	MultiHeadAttention	Num_heads=8, key_dim=128
0	Add_1	Add	-
256	LayerNorm_1	LayerNormalization	-
32 896	FeedForward	Dense	256=128 neurones
0	Add_2	Add	-
256	LayerNorm_2	LayerNormalization	-
0	GlobalAvgpool	GlobalAvgpooling1D	-

16 51	Dense_1	Dense	128 neurons(GELU)
512	BatchNorm_4	BatchNormalization	-
0	Dropout_4	Dropout	Rate=0.1
8 256	Dense_2	Dense	64 neurons(GELU)
256	BatchNorm_5	BatchNormalization	-
0	Dropout_5	Dropout	Rate=0.1
65	Output	Dense	1neurone (sigmoid)




Figure III.8: Training Loss - DeepECG-Net.

La training loss diminue progressivement de 0.67 à 0.055 au fil des epochs, ce qui indique une bonne convergence et une réduction des erreurs d'apprentissage.




Figure III.9: Validation Loss - DeepECG-Net.

Le graphique de validation loss du modèle DeepECG-Net montre une diminution progressive de la perte au cours des epochs, passant d'environ 0.70 à 0.071. Cette évolution indique une bonne convergence du modèle ainsi qu'une amélioration des performances sur les données de validation, traduisant une bonne capacité d'apprentissage et de généralisation.




Figure III.10: Training Accuracy – DeepECG-Net.

La training accuracy augmente progressivement jusqu'à 98.5 %, montrant que le modèle apprend efficacement et améliore ses performances de classification des signaux ECG.




Figure III.11: Validation Accuracy - DeepECG-Net.

La précision de validation du modèle DeepECG-Net augmente progressivement avec le nombre d'epochs et atteint une valeur finale de 96,5 %, ce qui indique une excellente capacité de généralisation et de classification.




Figure III.12:DeepECG-Net:Model Performance During Training.

Les courbes d'apprentissage montrent une diminution progressive des pertes d'entraînement et de validation ainsi qu'une augmentation continue de la précision. Le modèle DeepECG-Net atteint une précision de validation maximale de 96,5 %, démontrant ainsi une excellente capacité de classification et de généralisation.

III.5 Définition de CLTC et CCFC

III.5.1 CLTC (ConvLSTM2D + LTC)

Le **CLTC (ConvLSTM2D + Liquid Time-Constant network)** est une architecture hybride qui combine :

- un **ConvLSTM2D** pour extraire les caractéristiques spatio-temporelles des signaux ECG multileads,
- et des **Liquid Time-Constant networks (LTC)** pour modéliser l'évolution continue et dynamique du signal dans le temps.

Les **LTC** sont des réseaux neuronaux inspirés des systèmes biologiques, où les neurones ont une dynamique continue décrite par des équations différentielles. Cela permet au modèle de traiter des signaux non réguliers, bruités et fortement dynamiques comme l'ECG[65].

Le CLTC fonctionne en 3 étapes principales :

- . Extraction locale (ConvLSTM2D)
- . Dynamique continue (LTC)
- . Classification finale

III.5.2 CCfC (ConvLSTM2D + CFC)

Le **CCfC (ConvLSTM2D + Closed-form Continuous networks)** est une évolution des modèles continus. Il remplace les LTC par des **CFC cells (Closed-form Continuous-time networks)**.

Les CFC sont des réseaux neuronaux continus optimisés qui permettent une formulation mathématique plus simple et plus stable des dynamiques temporelles[66].

Le CCfC suit une logique similaire mais plus optimisée :

- . ConvLSTM2D
- . CFC layer
- . Classification finale

Formule générale

$$\text{Poids_Dense} = \text{input_neurons} \times \text{output_neurons} + \text{output_neurons}$$

Avec :

- input_neurons = nombre de neurones dans la couche précédente
- output_neurons = nombre de neurones dans la couche actuelle
- $\text{input_neurons} \times \text{output_neurons}$ = nombre de poids (connexions)
- $+ \text{output_neurons}$ = nombre de biais (un par neurone de sortie)

Tableau III . 2 : ARCHITECTURE COMPLÈTE CLTC et CCfC (8 couches, 8 317 paramètres)

N ° poids	Nom de la couche	type	Neurones / Filters
0	Input	InputLayer	(4096, 12)
0	Reshape	Reshape	(4096, 1, 1, 12)
4,352	ConvLSTM2D	ConvLSTM2D $4 \times 32 \times (1 \times 1 \times 12 + 1) = 4 \times 32 \times 13 = 4\,352$	32 filters, kernel=(1,1)
0	Flatten	Flatten	32 $\rightarrow$ 32
2,475	Dense (Input neurons)	Dense $32 \times 75 + 75 = 2\,400 + 75 = 2\,475$	75 neurones (ReLU)
1.064	Dense (Inter/Command)	Dense	14 neurones (ReLU)
300	CLTC : LTC Cells CCfC : CFC Cells	Dense (LTC) $14 \times 20 + 20 = 280 + 20 = 300$ Dense (CFC) $14 \times 20 + 20 = 280 + 20 = 300$	20 neurones (tanh) 20 neurones (gelu)
126	Output	Dense $20 \times 6 + 6 = 120 + 6 = 126$	6 neurones (sigmoid)




Figure III.13: Organigramme de CLTC et CCFC.




Figure III.14: Validation Loss- CLTC et CCfC.

Ce graphe compare la perte de validation (**Validation Loss**) des modèles **CLTC** et **CCfC** durant l'entraînement.

- La loss diminue progressivement avec l'augmentation des epochs, ce qui montre que les deux modèles apprennent correctement.
- Après environ 200 epochs, les courbes deviennent stables, indiquant une bonne convergence.
- Le modèle **CCfC** (courbe rouge) conserve une loss légèrement plus faible que **CLTC**.

Résultats finaux

- **CLTC : 0.181**
- **CCfC : 0.172**

La différence de loss est $0.181 - 0.172 = 0.0090$




Figure III.15: Validation Accuracy CLTC et CCfC.

Ce graphe compare la précision de validation des modèles **CLTC** et **CCfC** au cours de l'entraînement.

- Les deux modèles améliorent progressivement leurs performances avec l'augmentation des epochs.
- Le modèle **CCfC** (courbe rouge) reste légèrement supérieur au modèle **CLTC** (courbe bleue).
- Les performances se stabilisent après environ 200 epochs, montrant une bonne convergence.

Résultats finaux

- **CLTC : 97.5 %**
- **CCfC : 98.0 %**

Le modèle **CCfC** obtient donc la meilleure précision avec un gain d'environ :

$$98.0\% - 97.5\% = 0.5\%$$




Figure III.16:performance des modèles Pendant l'Entrainement CLTC vs CCFC.

Les graphiques présentent la performance des modèles CLTC et CCFC pendant l'entraînement.

La perte (loss) diminue progressivement tandis que la précision (accuracy) augmente, ce qui montre que les deux modèles apprennent efficacement sans surapprentissage important. Le modèle CCFC obtient les meilleurs résultats avec une précision de validation de 98.0 %, contre 97.5 % pour CLTC.

Tableau III.3 : Performances par classe Modèle CLTC

Classe	Precision	Recall	F1 Score	AUROC
1dAVb	98.0%	97.0%	0.975	0.99
RBBB	98.5%	97.5%	0.980	0.99
LBBB	99.0%	98.0%	0.985	0.99
SB	97.5%	96.5%	0.970	0.98
AF	97.0%	96.0%	0.965	0.98
ST	98.0%	97.0%	0.975	0.99
MOYENNE	98.0%	97.0%	0.975	0.99

Tableau III.4 : Performances par classe Modèle CCFC

Classe	Precision	Recall	F1 Score	AUROC
1dAVb	97.5%	96.5%	0.970	0.99
RBBB	98.0%	97.0%	0.975	0.98
LBBB	98.5%	97.5%	0.980	0.99
SB	97.0%	96.0%	0.965	0.98
AF	96.5%	95.5%	0.960	0.98
ST	97.5%	96.5%	0.970	0.98
MOYENNE	97.5%	96.5%	0.970	0.98

Tableau III.5 : Comparaison finale des modèles CLTC et CCFC

Métrique	CLTC (LTC)	CCfC (CFC)
Precision moyenne	98.0%	97.5%
Recall moyenne	97.0%	96.5%
F1 Score moyen	0.975	0.970
AUROC moyen	0.99	0.98
Meilleure classe	LBBB	L BBB
Moins bonne classe	AF	AF

Analyse et interprétation des résultats

Les deux modèles de classification ECG, CLTC (LTC) et CCFC (CFC), affichent des performances élevées avec des précisions et rappels supérieurs à 96%. Le modèle CLTC obtient des scores légèrement meilleurs (Précision moyenne 98%, Rappel 97%, F1-Score 0.975, AUROC 0.99) comparé au modèle CCFC (Précision 97.5%, Rappel 96.5%, F1-Score 0.970, AUROC 0.98). Les courbes d'entraînement et de validation montrent une convergence stable et une précision finale proche de 98% pour les deux modèles. La classe LBBB est la mieux reconnue, tandis que la classe AF reste la plus difficile à classifier. Globalement, les deux approches sont fiables, avec un léger avantage pour CLTC en cohérence globale.

Tableau III.6 : Comparaison des ensembles de données Code 15 et TNMG

	Code-15%[62]	Article(TNMG) [67]	Différence
Dataset	Code-15% (public)	TNMG (privé)	Différent
Source	Zenodo	TNMG Brésil	Différent
Taille originale	345,779 examens	2,322,513 examens	-85%
Echantillons utilisés	20 ,000	21,000	-5%
Normalisation	Z-score ajouté	Standard (zero-padding)	Différent
RAM	240 KB	240 KB	Identique
Flash	96 KB	96 KB	Identique
Power	137.4mW	137.4mW	Identique
Temps	15 min	30min	Différent

Tableau III.7 : Comparaison des performances Code 15 vs TNMG

Critère	Code -15%[62]		Article (TNMG)[67]		Différence	
	CLTC	CCFC	CLTC	CCFC	CLTC	CCFC
Validation	97 .5%	98.0%	85.7%	85.9%	+11.8%	+12.1%
Accuracy	0.17	0.16	0.18	0.17	-0.01	-0.01
Validation Loss	0.96	0.97	0.827	0.828	+0.133	+0.142
F1 Score	0.98	0.99	0.961	0.963	+0.019	+0.027
AUROC						
Meilleur modèle	–	CCFC	–	CCFC	=	=

Analyse et interprétation des résultats

Les résultats montrent que les deux modèles CLTC et CCFC atteignent une précision élevée proche de 98% avec l'ensemble Code-15%, tandis que les performances chutent à environ 85% avec l'ensemble TNMG. Le modèle CCFC reste légèrement meilleur que CLTC sur toutes les métriques (Accuracy, F1-Score, AUROC). Les courbes d'entraînement confirment une convergence stable et une bonne généralisation. En conclusion, les deux modèles sont fiables, mais CCFC présente un petit avantage en robustesse et précision.

Tableau III.8 : Comparaison métriques performance CLTC CCFC DeepECG Net Random Forest

Métrique	CLTC/CCFC	DeepECG-Net	Random Forest
Accuracy(Validation)	98.0%(CCFC)/97.5%(CLTC)	96.5%	89.2%
Loss(Validation)	0.16 (CCFC) / 0.17 (CLTC)	~0.08	~0.09
Best Validation Accuracy	98.0%	96.5%	89.2%
Convergence	Rapide (~150 epochs)	Très rapide (~20 epochs)	Rapide
Surapprentissage	Faible (écart 1-2%)	Modéré(écart ~ 5%)	Faible

Tableau III.9 : Analyse ressources efficacité computationnelle modèles

Modèle	Couches	RAM	Power	Taille	Accuracy	Adapté Edge AI
CCFC(CFC)	8	240KB	137.4 mW	~340 KB	98.0%	Oui
CLTC(LTC)	8	240KB	137.4 mW	~340 KB	97.5%	Oui
DeepECG-Net	31	30MB	~500 mW	~30 MB	96.2%	Non
Random Forest	200arbres décision	~500MB	~500 mW	~500MB	89.2%	Non

Analyse et interprétation des résultats

Les modèles CLTC/CCFC se distinguent par une précision élevée (~98%) et une faible consommation de ressources (RAM 240 KB, puissance 137 mW), tout en gardant une architecture compacte (8 couches). Ils convergent rapidement et montrent peu de surapprentissage, ce qui les rend efficaces et stables. En comparaison, DeepECG-Net atteint une bonne précision (~96%) mais au prix d'une taille et d'une consommation beaucoup plus importantes (30 MB, 500 mW, 21 couches). Enfin, le Random Forest reste le moins performant (89%), avec une charge mémoire et énergétique très élevée (~500 MB, 500 mW). Globalement, CLTC/ CCFC offrent le meilleur compromis entre performance et efficacité computationnelle, ce qui les rend adaptés aux environnements contraints.

III.6 Conclusion

Ce chapitre a évalué quatre modèles de deep learning pour la détection d'anomalies ECG sur le dataset public[62]: CLTC (ConvLSTM2D+LTC), CCfC (ConvLSTM2D+CFC), DeepECG-Net (CNN+Transformer), Random Forest. Les résultats démontrent clairement la supériorité des modèles à base de NCP (CLTC et CCfC) pour les applications Edge AI, avec une mémoire extrêmement faible (240 KB RAM, 96 KB Flash) et une consommation énergétique réduite (137.4 mW). Le modèle CCfC surpasse légèrement CLTC avec une précision de 98.0% contre 97.5%, tout en offrant une convergence plus rapide. DeepECG-Net, malgré son architecture avancée, n'atteint que 96.5% de précision avec l'inconvénient majeur d'une consommation mémoire 125 fois plus élevée (30 MB). Le Random Forest obtiennent des résultats modestes (89.2% et 83.0%) avec une empreinte mémoire importante (~500 MB). La comparaison avec l'article [67] les résultats sont presque proches du cote architecture pour CLTC et CCfC, avec des performances supérieures (98.0% vs 85.7%) attribuables à un dataset mieux équilibré et une normalisation Z-score. En conclusion, CCfC (CFC) représente le meilleur compromis précision/mémoire/puissance (98.0% accuracy, 240 KB RAM, 137.4 mW), ce qui en fait le modèle idéal pour le déploiement sur microcontrôleurs dans des applications de surveillance cardiaque en temps réel. DeepECG-Net, malgré sa récence, n'est pas recommandé pour les appareils Edge AI en raison de sa lourdeur mémoire et de sa précision inférieur.

Conclusion Générale

Ce mémoire a été consacré à la conception et à la simulation d'un système intelligent de surveillance cardiaque basé sur l'Edge AI, capable de détecter des anomalies à partir de signaux électrocardiogrammes (ECG) en temps réel sur des microcontrôleurs à ressources limitées. L'objectif principal était de développer un modèle léger, précis et économe en énergie, tout en maintenant des performances de diagnostic élevées.

Le premier chapitre a présenté les fondements théoriques essentiels pour saisir le système suggéré. Le projet repose sur des bases scientifiques solides telles que la surveillance cardiaque et l'analyse du signal ECG. L'incorporation de l'Edge AI dans un système de monitoring cardiaque facilite une identification rapide, exacte et indépendante des irrégularités cardiaques, préparant ainsi le terrain pour des appareils médicaux intelligents de nouvelle génération.

Le deuxième chapitre a exploré le rôle central de l'intelligence artificielle dans le monitoring cardiaque, plus précisément pour l'identification automatisée des arythmies à partir des signaux ECG. L'apprentissage automatique permet d'entraîner des modèles sur des données ECG afin de distinguer les rythmes normaux des irrégularités cardiaques. Trois familles de techniques sont couramment mises en œuvre : les machines à vecteurs de support (SVM), les k-plus proches voisins (KNN), ainsi que les réseaux de neurones profonds (CNN, LSTM). Ces approches garantissent une détection rapide et fiable, condition essentielle pour les systèmes de surveillance en temps réel.

Le troisième chapitre a évalué cinq modèles de deep learning pour la détection d'anomalies ECG sur le dataset public CODE-15% : CLTC (ConvLSTM2D+LTC), CCfC (ConvLSTM2D+CFC), DeepECG-Net (CNN+Transformer) et Random Forest. Les résultats démontrent clairement la supériorité des modèles à base de NCP (CLTC et CCfC) pour les applications Edge AI, avec une mémoire extrêmement faible (240 KB RAM, 96 KB Flash) et une consommation énergétique réduite (137,4 mW). Le modèle CCfC surpasse légèrement CLTC avec une précision de 98,0 % contre 97,5 %, tout en offrant une convergence plus

rapide. DeepECG-Net, malgré son architecture avancée, atteint 96,5 % de précision avec l'inconvénient majeur d'une consommation mémoire 125 fois plus élevée (30 MB). Le Random Forest obtiennent des résultats modestes (89,2 % et 83,0 %) avec une empreinte mémoire importante (~500 MB). La comparaison avec l'article de Huang et al. (2024) montre que les résultats sont presque proches d'un point de vue architectural pour CLTC et CCfC, avec des performances supérieures (98,0 % contre 85,7 %) attribuables à un dataset mieux équilibré et à une normalisation Z-score.

Les résultats de cette étude permettent de tirer plusieurs conclusions importantes. Premièrement, les modèles à base de NCP (CLTC et CCfC) sont les plus adaptés aux contraintes des dispositifs Edge AI, offrant le meilleur compromis entre précision, mémoire et consommation énergétique. Deuxièmement, CCfC représente le meilleur choix pour ce projet, avec une précision de 98,0 %, une mémoire de 240 KB et une puissance de 137,4 mW.

Ce travail ouvre plusieurs perspectives pour des recherches futures. Il serait intéressant de déployer physiquement le modèle CCfC sur un microcontrôleur réel (STM32F746G) pour valider les performances en conditions réelles. L'utilisation de techniques d'optimisation comme la quantification des poids ou l'élagage (pruning) pourrait réduire encore davantage l'empreinte mémoire. Enfin, l'extension à un plus grand nombre de classes d'anomalies et la validation sur d'autres bases de données (CPSC, PTB-XL, MIT-BIH) permettraient d'évaluer la généralisation du modèle.

En conclusion, ce mémoire a démontré qu'il est possible de concevoir un système de surveillance cardiaque intelligent, précis et économique, fonctionnant en temps réel sur des microcontrôleurs à ressources limitées. Le modèle CCfC (ConvLSTM2D + Closed-Form Continuous-Time) représente la solution optimale, avec 98,0 % de précision, 240 KB de RAM et 137,4 mW de consommation. Ce travail contribue ainsi à l'avancement de l'Edge AI pour les applications de santé connectée, ouvrant la voie à des dispositifs médicaux portables accessibles, fiables et respectueux de la vie privée des patients.

Références bibliographiques

- [1] Pan, J.; Tompkins, W. J., « A Real-Time QRS Detection Algorithm », *IEEE Transactions on Biomedical Engineering*, vol. BME-32, n° 3, p. 230-236, 1985.
- [2] Yann LeCun, Yoshua Bengio, Geoffrey Hinton, « Deep Learning », vol. 521, n° 7553, p. 436-444, 2015. doi: 10.1038/nature14539.
- [3] Xingjian Shi, « Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting », *Advances in Neural Information Processing Systems 28 (NeurIPS 2015)*, p. 802-810, 2015.
- [4] Ramin Hasani, « Closed-form Continuous-time Neural Networks », *Nature Machine Intelligence*, vol. 4, p. 992-1003, 2022. doi: 10.1038/s42256-022-00556-7.
- [5] Ashish Vaswani, « Attention Is All You Need », *Advances in Neural Information Processing Systems 30 (NeurIPS 2017)*, p. 5998-6008, 2017.
- [6] M. A. Serhani, H. T. El Kassabi, H. Ismail, A. N. et Navaz, « ECG Monitoring Systems: Review, Architecture, Processes, and Key Challenges », *Sensors*, vol. 20, n° 6, p. 1796, 2020. doi: 10.3390.
- [7] Clifford, G. D.; Azuaje, F.; McSharry, P.E., *Advanced Methodes and tools for ECG Data Analysis*. Norwood, Massachusetts, USA: Artech House, 2006.
- [8] Goldberger, A. L. et al., « PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals », *Circulation*, vol. Vol.101, n° no.23, p. e215-e220, 2000.
- [9] Peter Yan Cardiology Clinic, « Electrocardiogram (ECG) waveform diagram », Peter Yan Cardiology Clinic. [En ligne]. Disponible sur: <https://cardiology.com.sg/12-lead-ecg/>
- [10] Charu C. Aggarwal, *Outlier Analysis*. Cham, Suisse (Springer International Publishing): Springer, 2017.
- [11] Webster, J. G., *Medical Instrumentation: Application and Design*, 4th ed. New York, NY, USA: Wiley, 2009.
- [12]
- [13] Analog Devices Inc., *Signal-Lead, Heart Rate Monitor Front End*, Analog Devices. Norwood, Massachusetts, USA, 2018.
- [14] [En ligne]. Disponible sur: <https://mhtronic.com/produit/kit-ecg-pour-la-surveillance-des-impulsions-ad8232/>

- [15] [En ligne]. Disponible sur: https://grobotronics.com/images/detailed/123/3517882-40_grobo.jpg
- [16] A. Jubran, « Pulse oximetry », *Critical Care/WHO Guidelines*, 2015.
- [17] Medicaaffaires, « xymètre de pouls - SpO2 Monitor », Medicaaffaires. [En ligne]. Disponible sur: <https://www.medicaaffaires.com/33-oxymetres-de-pouls>
- [18] T. G. Pickering et al., « Recommendations for Blood Pressure Measurement », WHO Hypertension Reports.
- [19] [En ligne]. Disponible sur: <https://circuit.rocks/products/blood-pressure-sensor-serial-output-html?srsltid=AfmBOoqVnEsfGX6r9Ydm6hOo72Rq81EopWXoF2aVOS2S9Dv5ekekfishy>
- [20] A.Sabil,N.Meslier,F.Gagnadoux,S.Launois, « Revue des Capteurs et signaux utilisés en polygraphie respiratoire », *Médecine du sommeil*,2020, doi: 10.1016/j.msom.2020.10.003.
- [21] [En ligne].
Disponible sur:
<https://www.medicaleexpo.fr/prod/thought-technology/product-70321-1154135.html>
- [22] Banerjee, T. et al., « Edge Computing for IoT- enabled Healthcare Applications », *IEEE Access*, vol. 8, p. 123-135, 2020.
- [23] Wolf, W., *Computers as Components: Principles of Embedded Computing System Design*, 2nd ed. San Francisco,CA,USA: Morgan Kaufmann, 2012.
- [24] Proakis, J. G.; Manolakis, et D. G., *Digital Signal Processing: Principles, Algorithms, and Applications*, 4th ed. Upper Saddle River,NJ,USA: Prentice Hall, 2007.
- [25] Clifford,G.D., *Signal Processing Methods for ECG Analysis*. Springer, 2012.
- [26] [En ligne]. Disponible sur: <https://fr.wikipedia.org/wiki/Fen%C3%AAtrage>
- [27] Task Force of the ESC et NASPE, « Heart rate variability: standards of measurement, physiological interpretation and clinical use », *European Heart Journal*, vol. 17, n° 3, p. 354-381, 1996.
- [28] [En ligne]. Disponible sur: https://www.researchgate.net/figure/Electro-cardiogramme-ECG-et-intervalle-RR_fig3_280525259
- [29] Oppenheim,A.V.,Singals and Systems, Prentice Hall.

- [30] [En ligne]. Disponible sur: https://www.siloged.fr/cours/html/ssi_echantillonnage/Echantillonnage.html?Restitutiondelinformation.html
- [31] Goodfellow, I., Bengio, Y., & Courville, A., *Deep Learning*. MIT Press, 2016.
- [32] A.L. Goldberger, Z.D. Goldberger, A. Shvilkina, *Goldberger's Clinical Electrocardiography: A Simplified Approach*, 9th edition. 2017.
- [33] [En ligne]. Disponible sur: <https://my.clevelandclinic.org/health/diseases/22108-tachycardia>
- [34] J. G. Webster, *Medical Instrumentation: Application and Design*. John Wiley and Sons, 2010.
- [35] [En ligne]. Disponible sur: <https://my.clevelandclinic.org/health/diseases/22473-sinus-bradycardia>
- [36] [En ligne]. Disponible sur: <https://www.capretraite.fr/prevenir-dependance/sante-grand-age/tout-sur-larythmie-cardiaque-symptomes-cause-et-traitement/>
- [37] Moody, G., Mark, R., « The MIT-BIH Arrhythmia Database », *IEEE Transactions on Biomedical Engineering*, vol. 38, n° 6, IEEE, p. 791-794, 2001.
- [38] S. M. Riazul Islam, Daehan Kwak, Md Humayun Kabir, Mahmud Hossain, Kyung-Sup Kwak, « The Internet of Things for Health Care: A Comprehensive Survey », *IEEE Access*, vol. 3, p. 678-708, 2015.
- [39] World Health Organization, « Global Observatory for eHealth Reports », World Health Organization, Geneva, Switzerland, 2010.
- [40] Hochreiter, Sepp; Schmidhuber, Jürgen, « Long Short-Term Memory », vol. 9, n° 8, p. 1735-1780, 1997.
- [41] Laguna, P.; Mark, R.G.; Moody, G.B.; Goldberger, A.L., « A database for evaluation of algorithms for measurement of QT and other waveform intervals in the ECG », in *Computers in Cardiology*, 1997.
- [42] Temko, A., *Robust heart rate estimation from wrist PPG signals*. Physiological Measurement, 2017.
- [43] Bishop, Christopher M., *Pattern Recognition and Machine Learning*. Springer, 2006.
- [44] Chavan, R.R., « Smart health Monitoring System using IoT and Edge Computing », 2020.
- [45] Chloé-Agathe Azencott, *Introduction au Machine Learning*. Paris: Dunod, 2019.

- [46] [En ligne]. Disponible sur: <https://devopedia.org/images/article/74/4291.1523678973.png>
- [47] W.Shi, J.Cao, Q.Zhang, Y.Li, et L.Xu, « Edge Computing: Vision and Challenges », IEEE Internet of Things Journal, vol. 3, n o 5, p. 637-646, 2016.
- [48] National Institute of Standards and Technology, « The NIST Definition of Cloud Computing », National Institute of Standards and Technology (NIST), 2011.
- [49] [En ligne]. Disponible sur: <https://fr.linkedin.com/pulse/edge-ai-vs-cloud-optimizing-data-processing-healthcare-wearables-ymmoftl=fr>
- [50] Warden, Pete et Situnayake, Daniel, TinyML: Machine Learning with Tensorflow Lite on Arduino and Ultra-Low-Power Microcontrollers. Sebastopol, California: O'Reilly Media, 2019.
- [51] Satyanarayanan, Mahadev, « The Emergence of Edge Computing », Computer, vol. 50, n o 1, IEEE, 2017.
- [52] Liu, Jane W.S., Real-Time Systems. Upper Saddle River, New Jersey: Prentice Hall, 2000.
- [53] [En ligne]. Disponible sur: <https://estuary.dev/blog/what-is-real-time-processing/>
- [54] MathWorks, « Signal Generation, Analysis, and Preprocessing », MathWorks, 2026.
- [55] Lataief, Khaled B., Shi, Yuchen, Lu, Jian, et Zhang, Junshan, « Large Language Models Empowered Autonomous Edge AI for Connected Intelligence », IEEE Communications Magazine, vol. 62, n o 10, p. 140-146, 2024.

[56] [En ligne]. Disponible sur:

<https://www.analyticsvidhya.com/blog/2021/05/understanding-column-transformer-and-machine-learning-pipelines/>

[57] [En ligne]. Disponible sur: <https://www.mdpi.com/2076-3417/9/21/4500?utm>

[58] [En ligne]. Disponible sur: <https://medium.com/@shivambansal36/language-modelling-text-generation-using-lstms-deep-learning-for-nlp-ed36b224b275>

[59] [En ligne]. Disponible sur: <https://dzone.com/articles/neural-networks-and-mathematical-models-examples-d>

[60] [En ligne]. Disponible sur: <https://medium.com/low-code-for-advanced-data-science/support-vector-machines-svm-an-intuitive-explanation-b084d6238106>

[61] Xingjian Shi, Zhourong Chen, Hao Wang, Dit-Yan Yeung, Wai-Kin Wong, et Wang-Chun Woo, « Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting », *NeurIPS 2015 (Neural Information Processing Systems)*, 2015.

[62] Antônio H. Ribeiro, Gabriela M. M. Paixão, Emilly M. Lima, et Marcelo M. Pinto Filho et al., « CODE-15%: A Large Scale Annotated Dataset of 12-Lead ECGs », 2021. doi: 10.5281/zenodo.4916206.

[63] Trevor Hastie, Robert Tibshirani, et Jerome Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2^e éd. New York, NY: Springer, 2009. [En ligne]. Disponible sur: <https://hastie.su.domains/ElemStatLearn/>

[64] Manal Algheith, « DeepECG-Net: a hybrid transformer-based deep learning model for real-time ECG anomaly detection », *Springer Nature*, p. Article number 20714, 2025. doi: 10.1038/s41598-025-07781-1.

[65] *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 35, n° 9, p. 7657-7666, 2021. doi: 10.1609/aaai.v35i9.16936.

[66] Ramin Hasani, Mathias Lechner, Alexander Amini, Daniela Rus, Lucas Liebenwein, et Aron Ray, « Closed-form Continuous-time Neural Networks », *Springer Nature*, vol. 4, n° 11, Nature Machine Intelligence, p. 992-1003, 2022. doi: 10.1038/s42256-022-0556-7.

- [67] Zhaojing Huang *et al.*, «Efficient Edge-AI Models for Robust ECG Abnormality Detection on Resource-Constrained Hardware », *Springer Nature*, vol. 17, p. 879-892, 2024.

الملخص

تهدف هذه المذكرة إلى محاكاة نظام مراقبة قلبية ذكي يعتمد على تقنيات Edge AI للكشف المبكر عن الشذوذات القلبية في الزمن الحقيقي. تم استخدام ثلاث مقاربات للتصنيف والكشف عن الحالات غير الطبيعية وهي: Random Forest و Deep ECGNet و CCFC-CLTC. تمت مقارنة أداء هذه النماذج من حيث الدقة والكفاءة وسرعة التنفيذ على الأجهزة الطرفية. أظهرت النتائج إمكانية دمج الذكاء الاصطناعي الطرفي في أنظمة المراقبة القلبية لتحسين الكشف المبكر وتقليل زمن الاستجابة.

الكلمات المفتاحية : Random Forest , DeepECG-Net , CLTC et CCFC

Résumé

Ce mémoire a pour objectif de simuler un système de surveillance cardiaque intelligent basé sur les technologies d'Edge AI afin de détecter précocement les anomalies cardiaques en temps réel. Trois approches de classification et de détection des cas anormaux ont été utilisées : Random Forest, Deep ECGNet et CCFC-CLTC. Une comparaison de leurs performances a été réalisée en termes de précision, d'efficacité et de rapidité d'exécution sur des dispositifs embarqués. Les résultats obtenus montrent la possibilité d'intégrer l'intelligence artificielle en périphérie (Edge AI) dans les systèmes de surveillance cardiaque pour améliorer la détection précoce et réduire le temps de réponse.

Mots-clés : Random Forest , DeepECG-Net , CLTC et CCFC

Abstract

This memoir aims to simulate an intelligent cardiac monitoring system based on Edge AI technologies for the early detection of cardiac anomalies in real time. Three approaches were used for the classification and detection of abnormal cases: Random Forest, Deep ECGNet, and CCFC-CLTC. Their performance was compared in terms of accuracy, efficiency, and execution speed on edge devices. The obtained results demonstrate the potential of integrating Edge AI into cardiac monitoring systems to improve early anomaly detection and reduce response time.

Keywords: Random Forest , DeepECG-Net , CLTC et CCFC