REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITEYAHIA FARES DE MEDEA

Faculté de **T**echnologie

Départementdu **G**énie **E**lectrique

Mémoire de fin d'études de Master

Filière : Télécommunications

Spécialité : Système de Télécommunications

Etude d'un Système Intelligent pour la Détections des Maladies Cardiaques basé sur des signaux ECG

Présentés par :

FEKIRNourHouria

MOKHBAT Farah

Proposés et Dirigés par :

Mr. REBIAI Mohamed

Mr. BERKANI Mohamed RafikAymene

Promotion 2024

Remerciement

Nous débutons en exprimant notre gratitude à Allah le Tout-Puissant pour nous avoir accordé la volonté, la santé, la patience et le courage nécessaires pour atteindre notre objectif.

Nous tenons à exprimer notre profonde reconnaissance envers notre encadrant, **M. Berkani Mohamed RafikAymene**, dont l'expertise, la disponibilité et les conseils éclairés ont été d'une aide inestimable tout au long de ce projet. Sa présence attentive et son soutien constant ont été des piliers essentiels de notre réussite.

Nous souhaitons également adresser nos sincères remerciements à **M. Rebai Mohamed** pour sa contribution précieuse à ce travail. Sa perspective éclairée et ses suggestions judicieuses ont enrichi notre réflexion et ont contribué à la qualité finale du projet.

Nous adressons également nos remerciements chaleureux aux membres du jury, **M. BengherbiaBillel** et **M. LachenaniSidahmed**, pour leur contribution et leur évaluation attentive de notre travail. Leur expertise et leur implication ont enrichi notre projet et nous ont permis de progresser.

Nous n'oublions pas de mentionner toutes les personnes qui, de près ou de loin, ont contribué à la réalisation de ce projet. Leur collaboration et leur soutien ont été précieux et ont véritablement fait la différence.

Enfin, nous exprimons notre gratitude envers nos familles pour leur soutien indéfectible et leur compréhension tout au long de ce processus. Leur amour et leur encouragement ont été notre moteur dans les moments difficiles.

Merci à tous pour votre précieuse contribution à ce travail, et que la grâce d'Allah soit avec nous tous.

Dédicace

بسم الله الرحمن الرحيم

الحمد لله الذي ما نجحنا ولا علونا ولا تفوقنا ولا تخطينا جهدًا إلا برضاه، وإليه يُنسب الفضل والكمال والإكمال

أهدي هذا النجاح لنفسي، تهانينا، جزاك الله عني كل خير

إلى المرأة التي صنعت مني ما أنا عليه اليوم، والتي ظلت دعواتها تضم اسمي، إلى التي ألهمتني بنجاحاتها وإنجازاتها، وعرفتني على الثقة والقوة بالنفس، أمي، رزقك الله الفردوس الأعلى خير جزاء عني

إلى الذي لا ينفصل اسمي عن اسمه، إلى من كلل العرق جبينه، إلى من بذل الغالي والنفيس، إلى مأمني الوحيد، والدي الحبيب، لا حنى الله ظهرك ولا عظم عليك أمرًا، وأسعد قلبك وأطال عمرك ورزقك الجنة بدون حساب

إلى من شد الله بهم أزري، أختي وأخوي

إلى شريكتي، فرح مخباط، شكرًا لتعاونك ودعمك المتواصل وصداقتك الثمينة

. إلى عائلتي، فَقِير وخَثِيرِي

. الى جدتي حورية وخالتي حياة

وأخيرًا، لصديقاتي إلهام، سمية، ريم، وصبرين، شكرًا لصداقتكن، وتفهمكن، ودعمكن. ضحكاتكن وإيجابيتكن جعلت هذه الرحلة أكثر متعة وتحملًا

FEKIRNourHouria

À moi-même, louange à Allah qui m'a guidé et soutenu dans mes efforts.

À la femme dont les prières m'ont accompagné et qui m'a inspiré par ses réussites et sa confiance en soi, ma mère, que Dieu la récompense du meilleur.

À mon père, mon roc et mon soutien, que Dieu le protège et prolonge sa vie avec bonheur et le paradis sans compter.

À mes frères et sœurs. Vous êtes une source constante de soutien et de réconfort

À ma partenaire, Farah Mokhbat, pour son soutien continu, sa coopération précieuse et son amitié sincère.

À ma famille, fekir et khatiri.

À ma grand-mère Houria et ma tante Hayat.

Enfin, à mes amies Ilham, Samia, Rym, et Sabrine, merci pour votre amitié, votre compréhension, et votre soutien.

FEKIRNourHouria

Dédicace

Toutes les lettres ne sauraient trouver les mots qu'il faut... Tous les mots ne sauraient exprimer la gratitude, l'amour, le respect, la reconnaissance...

Je dédie cette thèse...

À ma mère aimante, Djahida, tu as été l'étoile brillante dans ma vie, mon guide et une source inépuisable d'amour et de soutien. Merci pour chaque moment partagé, tes mots encourageants et ton rôle irremplaçable.

À mon cher père, Elhoucin, mon roc et mon modèle, je te suis reconnaissant pour ton soutien inconditionnel et ta bienveillance. Tu es un exemple de persévérance et de dévouement. Tu as été un père exceptionnel.

À ma grand-mère, Hamida, pour son amour incommensurable et son inspiration constante.

À mes très chères sœurs, Amina, Houria, Sadjia, et Hamida, et à mon frère, Mohamed Ali, et sa femme, vous êtes les piliers de ma vie et ma source constante de bonheur. Votre soutien inconditionnel, votre amour et votre présence ont été des bénédictions que je chéris chaque jour.

À mes nièces, pour leur joie et leur inspiration.

À mon fiancé, pour son amour et son soutien sans faille.

À toute la famille Mokhbat, pour leur encouragement et leur appui tout au long de ce parcours.

À mon binôme, FekirNourHouria, pour son travail acharné, sa coopération et son soutien tout au long de cette aventure. Ta contribution a été essentielle à la réussite de ce projet.

À mes collègues, Soumia, Ilhem, et Youcef, pour leur soutien, leur amitié et leur collaboration tout au long de ce projet. Votre présence et vos encouragements ont été d'une grande aide et une source de motivation continue.

C'est avec une profonde reconnaissance envers tous ceux qui ont été présents à chaque étape de ce projet que je présente ce mémoire. Leur soutien et leur collaboration ont été essentiels à sa réalisation.

MOKHBAT FARAH

ملخص

تقدم هذه الدراسة مقارنة بين طريقتين لتصنيف إشارات تخطيط القلب ECG، وهما MFCC وGAF، باستخدام الشبكات العصبية الالتفافية CNN.تظهر النتائج أن طريقة MFCC توفر أداءً متفوقًا بمعدلات تصنيف عالية جدًا ودرجة منخفضة من الالتباس بين الفئات. يجمع النظام المطور مكونات مثل مستشعر ECG AD8232 والمتحكم الدقيقArduino، مما يضمن دقة وموثوقية عالية في جمع بيانات القلب، مما يفتح المجال لتطبيقات محتملة في المراقبة والتشخيص الطبي.

الكلمات المفتاحية: إشارات تخطيط القلب ECG، الشبكات العصبية الالتفافية CNN، MFCC، GAF، مستشعر AD8232، Arduino، التشخيص الطبي.

Résumé

Cette étude compare deux méthodes de classification des signaux ECG, à savoir les MFCC et les GAF, en utilisant des réseaux de neurones convolutifs (CNN). Les résultats montrent que la méthode MFCC offre des performances supérieures, avec des taux de classification très élevés et une faible confusion entre les classes. La simplicité et l'efficacité du prétraitement MFCC, combinées à des performances exceptionnelles, font de cette méthode le choix préféré pour la classification des signaux ECG. Le système développé, intégrant des composants tels que le capteur ECG AD8232 et le microcontrôleur Arduino, assure une acquisition précise et fiable des données cardiaques, ouvrant la voie à des applications potentielles dans la surveillance et le diagnostic médical.

Mots-clés: Signaux ECG, réseaux de neurones convolutifs CNN, MFCC, GAF, capteur AD8232, Arduino, diagnostic médical.

Abstract

This study compares two methods for classifying ECG signals, namely MFCC and GAF, using convolutional neural networks (CNN). The results show that the MFCC method offers superior performance, with very high classification rates and low confusion between classes. The simplicity and efficiency of MFCC preprocessing, combined with exceptional performance, make this method the preferred choice for ECG signal classification. The developed system, integrating components such as the AD8232 ECG sensor and Arduino microcontroller, ensures accurate and reliable cardiac data acquisition, paving the way for potential applications in medical monitoring and diagnosis.

Key words : ECG signals, CNN, MFCC, GAF, AD8232 Sensor, Arduino, medical diagnosis

Sommaire

Remerciement ..... **I**
Dédicace ..... **II**
Dédicace ..... **IV**
ملخص ..... **V**
Résumé ..... **V**
Abstract ..... **VI**
Sommaire ..... **VI**
Liste des Figures ..... **IX**
Liste des Tableaux ..... **XIV**
Liste des abréviations ..... **XV**
Introduction Générale **1**
Chapitre I : ECG & IA & IoT **2**
I.1-Introduction 2
I.2-Le cœur 2
I.2.1- Anatomie de La pompe vitale 3
I.2.2-La Mécanique du Cœur 3
I.2.3-L'activité électrique du cœur 4

I.3-L'électrocardiogramme 5
I.4-Les phases d'ECG 6
I.4.1-Le standard de l'ECG 6
I.5-L'acquisition du signal ECG 7
I.5.1-Les dérivations d'ECG 8
I.6-Les maladies cardiaques 9
I.6.1- Les maladies étudiées 10
I.6.2-Causes des maladies cardiaques 11
I.7-Intelligence Artificielle 11
I.8-IA dans le domaine médical 11
I.8.1-IA dans le domaine d'ECG 11
I.9-Internet d'objet 12
I.9.1- L'utilisation de l'IoT pour la surveillance des maladies cardiaque 13
I.10-Travaux connexes 13
I.11-Conclusion 16
Chapitre II : Traitement de Signal et IA 17
II.1-Introduction 21
II.2-Prétraitement du signal ECG 21
II.2.1-Coefficients cepstraux sur l'échelle Mel 21
II.2.2- Champ Angulaire Gramien 23
II.3-Intelligence artificielle 24
II.3.1-L'histoire d'IA 25
II.3.2-Domaines de l'IA 27
II.3.3-Types de l'IA 28
II.4-Apprentissage automatique (Machine Learning) 28
II.4.1-L'apprentissage supervisé 30
II.4.2-L'apprentissage non supervisé 30
II.4.3-L'apprentissage par renforcement 30
II.4.4-Algorithmes de ML 31
II.5-Apprentissage en profondeur (Deep Learning) 35
II.5.1-L'apprentissage supervisé 36
II.5.2-L'apprentissage non supervisé 37
II.6-Réseaux Neurones 37
II.6.1-Neurone Biologique 37
II.6.2-Neurone Artificiel 38

II.6.3-Architecteur des réseaux de neurones 39
II.6.4-Réseaux de neurones non bouclés 39
II.6.5-Réseaux de neurones bouclés 39
II.6.4-Réseaux de neurones convolutifs 40
II.6.5-Modèles d'apprentissage profond 40
II.7-IA Générative 46
II.7.1-Architectures couramment utilisées en AI Générative 46
II.8-Fonctions d'activation 47
II.9-Aggrégation des modèles 48
II.9.1-Techniques d'agrégation de modèles 48
II.10-Internet d'objet 48
II.10.1-Architecture d'IoT 48
II.11-Conclusion 49
Chapitre III : Résultats du Système 50
III.1-Introduction 46
III.2-Matériels utilisées 46
III.2.1-Software 46
III.2.2- Hardware 47
III.3-Bibliothèques utilisés 49
III.4-Méthodologie proposée 51
III.5-Système proposé 51
III.5.1-Description de Base de données 52
III.5.2-Prétraitement 54
III.5.3-Redimensionnement 55
III.5.4-Décomposition du signal 55
III.5.5-Modèle CNN 55
III.6-Discussion des résultats 58
III.6.1-Graphe des pertes et de précision 58
III.6.2-Caractéristique de fonctionnement du récepteur (courbe ROC) 59
III.6.3-Rapport de classification 60
III.6.4-Matrice de Confusion 61
III.7-Réalisation du nœud d'acquisition 65
III.8-Adaptation des Données 67
III.9-Prédiction et test des signaux récolté 68
III.10-Comparaison avec des travaux précédentes 69

III.11-Conclusion 70
Conclusion Générale 71
Bibliographie 72

Liste des Figures

Figure I-1 : Localisation du cœur ---------- 05

Figure I-2 : Les cavités cardiaques---------- 06

Figure I-3 : Localisation des Valves Cardiaques ---------- 06

Figure I-4 : L'activité électrique du cœur humain ---------- 07

Figure I-5 : Placement des électrodes d'électrocardiogramme sur le corps ---------- 08

Figure I-6 : Les ondes d'ECG ---------- 09

Figure I-7 : Signal ECG normal ---------- 10

Figure I-8 : L'électrocardiographie ---------- 10

Figure I-9 : Les douze dérivations---------- 11

Figure I-10 : Les types d'Apprentissage Automatique ---------- 16

Figure I-11: La relation entre IA, ML et DL---------- 16

Figure I-12 : Les types d'Apprentissage en profondeur---------- 17

Figure I-13: Le rôle principal d'IOT----------17

Figure I-14: Processus Intégré et Analysé les Signaux ECG----------18

Figure II-1 : Diagramme de MFCC ---------- 39

Figure II-2 : L'image résultant de MFCC ---------- 40

Figure II-3 : L'Organigramme du GAF ---------- 41

Figure II-4 : Transformation du Champ Angulaire de Gramien ---------- 41

Figure II-5 : Les dates clés de l'IA---------- 43

Figure II-6 : Les types d'Apprentissage Automatique---------- 47

Figure II-7 : Synoptique des Approches d'apprentissage Automatique ---------- 48

Figure II-8 : Algorithme KNN ---------- 49

Figure II-9 : Les SVM et la Continuité Linéaire (1) et Non Linéaire(2) ---------- 50

Figure II-10 : Un modèle de marge ----------
50

Figure II-11 : Arbre de décision ----------
51

Figure II-12 : Forêts aléatoires ----------52

Figure II-13: La relation entre IA, ML et DL----------52

Figure II-14 : Les types d'Apprentissage en profondeur----------53

Figure II-15 : Apprentissage supervisé ----------
53

Figure II-16 : Apprentissage non supervisé des données ----------
54

Figure II-17 : Neurone Biologique----------55

Figure II-18 : Structure d'un Réseau Neurone Artificiel ANN----------
56

Figure II-19 : Architecture de base de CNN ----------
57

Figure II-20 : L'opération de convolution----------
58

Figure II-21 : Opération de mise en commun (Pooling) ----------
58

Figure II-22 : La couche d'aplatissement ----------
59

Figure II-23 : Couche entièrement connecté (fullyconnected) ----------
59

Figure II-24 : Un Réseau Neuronaux Récurrents (RNN) ----------
60

Figure II-25 : Architecture de RNN ----------
61

Figure II-26 : LSTM ---------- 61

Figure II-27 : La génération de visages via les GAN ---------- 63

Figure III-1 : Capteur ECG AD8232---------- 70

Figure III-2: Les électrodes utilisées---------- 70

Figure III-3: Carte ArduinoUno ----------71

Figure III-4: Système de modèle proposé----------74

Figure III-5 : Visualisation de la distribution des données ---------- 75

Figure III-6 : Représentation des MFCC ---------- 76

Figure III-7: GAF des signaux ECG----------76

Figure III-8: Décomposition des fichiers---------- 77

Figure III-9: Schéma synoptique de processus d'entraînement de CNN----------78

Figure III-10 : Architecture CNN Utiliser en 3D ---------- 80

Figure III-11: Reconnaissance d'images étape par étape----------80

Figure III-12: Graphe de la perte (A) et des précisions (B) de validation et d'entraînement---81

Figure III-13: courbe ROC----------81

Figure III-14 : Matrice de Confusion de prétraitement MFCC---------- 84

Figure III-15 : Matrice de Confusion du Modèle CNN après le prétraitement GAF---------- 85

Figure III-16 : Matrice de Confusion du test---------- 86

Figure III-17 : montage du nœud d'acquisition---------- 87

Figure III-18 : Les zones de placement des électrodes---------- 88

Figure III-19 : Signal récolté----------88

Figure III-20: signal ECG émané d'AD83232 ---------- 89

Figure III-21 : signal ECG de la base de données---------- 89

Figure III-22 : signal ECG après l'adaptation par masquages de données---------- 89

Figure III-23 : Probabilités prédites pour chaque classe---------- 90

Figure III-24 : Matrice de confusion pour le test des signaux collectée---------- 90

Liste des Tableaux

Tableau I-1 : Résultats des travaux connexes ----------35

Tableau II-1 : Les fonctions d'activation ----------64

Tableau III-1 : Les bibliothèques utilisées----------71

Tableau III-2: Une Analyse selon la Classification AAMI ----------75

Tableau III-3 : Exploration des Couches ----------79

Tableau III-4 : Rapport de Classification la méthode MFCC ----------82

Tableau III-5 : comparaison entre les métriques de MFCC et GAF----------85

Tableau III-6 : tableau d'évaluation des performances ----------87

Tableau III-7 : L'interconnexion entre ECG AD8232 et ArduinoUno----------87

Tableau III-8 : Tableau Comparaison des travaux ----------91

Liste des abréviations

AI : Artificial Intelligence**.**

ANN : Artificial Neural Network**.**

AV : Auriculo Ventriculaire.

ASI : La super intelligence artificielle

CNN : Convolutional Neural Network

CSV : comma-separated values.

DI, DII, DIII : Dérivations Standard (d'EINTHOVEN) de l'EC

DL : Deep Learning

ECG : Electrocardiogramme

FA : la fibrillation atriale

GND : Ground

GAF : GRAMAIN ANGULAR FIELD TRASFORMATION

IOT : Internet of things.

IAE : L'intelligence artificielle étroite

IAG: L'intelligence artificielle générale

LReLu : Leaky Rectified Linear Unit

LSTM : Long Short-Term Memory

ML : Machine Learning.

MFCC : Mel-frequency Cepstral coefficients

PC : Personal Computer.

RNN : Réseau de Neurones Récurrents

RNA : les réseaux de neurones non récursifs**,**

RNG : Réseaux Neuronaux Génératifs

SA : nœud senusal

SVEB : Battement ectopique supraventriculaire

Sklearn: Scikit-learn

VEB : Battement ectopique ventriculaire

Introduction Générale

Les maladies cardiovasculaires (MCV) sont parmi les principales causes de décès dans le monde, entraînant chaque année des millions de morts. Le diagnostic précis de ces maladies est essentiel, surtout dans les services de cardiologie des hôpitaux. L'électrocardiogramme (ECG) est un outil crucial pour le diagnostic et l'analyse des arythmies cardiaques.

L'analyse de l'ECG est une méthode non invasive qui permet aux médecins de surveiller l'activité électrique du cœur en temps réel grâce à des électrodes placées sur la peau. Cependant, des erreurs de diagnostic peuvent survenir, surtout lorsque des médecins généralistes non spécialisés interprètent ces signaux. Ce constat a motivé notre projet de fin d'études, visant à développer un système intelligent pour la détection des maladies cardiovasculaires par l'analyse automatisée des signaux ECG.

Le premier chapitre de ce projet explore l'anatomie du cœur humain, les cycles cardiaques, l'activité électrique, ainsi que les différentes ondes et intervalles d'un signal ECG. Il aborde également les méthodes d'acquisition et de traitement de ces signaux, ainsi que les diverses maladies cardiovasculaires et leurs causes.

Le second chapitre examine le domaine de l'intelligence artificielle (IA) et ses sous-domaines, notamment l'apprentissage automatique (ML) et l'apprentissage en profondeur (DL). Nous discutons des concepts des réseaux de neurones artificiels (ANN) et des réseaux de neurones convolutifs (CNN), en mettant l'accent sur leurs applications pour l'analyse des signaux biologiques. Nous présentons également les bases de l'Internet des objets (IoT) et ses applications en santé.

Le dernier chapitre se concentre sur le prétraitement des signaux ECG, la création de la base de données, et l'élaboration d'un modèle CNN capable de détecter et classer automatiquement les différentes maladies cardiovasculaires avec une grande précision. Cette étude compare deux méthodes de classification des signaux ECG : les coefficients cepstraux en fréquence de Mel (MFCC) et les grammes d'adjacence par fréquence (GAF), en utilisant des réseaux de neurones convolutifs. Les résultats montrent que la méthode MFCC offre des performances supérieures avec des taux de classification élevés et une faible confusion entre les classes. La simplicité et l'efficacité du prétraitement MFCC, combinées à des performances exceptionnelles, en font la méthode préférée pour la classification des signaux ECG. Le système développé, intégrant des composants tels que le capteur ECG AD8232 et le microcontrôleur Arduino, assure une acquisition précise et fiable des données cardiaques, ouvrant la voie à des applications potentielles dans la surveillance et le diagnostic médical.

Chapitre I : ECG & IA &IoT

I.1-Introduction

Ce chapitre explore deux aspects clés : d'une part, l'anatomie et le fonctionnement du cœur humain, y compris son activité électrique analysée via l'ECG, et d'autre part, les avancées d'IA dans le domaine médical, notamment l'apprentissage automatique et l'apprentissage en profondeur.Dans la première partie, nous examinons l'anatomie cardiaque, la mécanique cardiaque et l'activité électrique du cœur, ainsi que l'acquisition des signaux ECG.Dans la seconde partie, nous explorons le rôle croissant de l'IA en médecine, en mettant en lumière les applications de l'apprentissage automatique et de l'apprentissage en profondeur dans l'analyse des signaux ECG et la prévention des maladies cardiovasculaires. Nous abordons également quelques travaux connexes dans ce domaine, soulignant les avancées récentes qui contribuent à améliorer les diagnostics et les traitements des affections cardiaques.

I.2-Le cœur

Le cœur, véritable moteur de notre corps, joue un rôle crucial dans la circulation sanguine. Niché entre nos poumons, il se trouve sous le sternum, plus ou moins au milieu de la cage thoracique. Il oscille généreusement entre 14 et 16 centimètres, pesant aux alentours de 300 grammes. Incroyablement actif, il bat environ 100 000 fois par jour, assurant ainsi un flux incessant de vie à travers notre organisme[1]. La figure I-1 exprime le placement du cœur.



Figure I-1 : L'endroit du cœur

I.2.1- Anatomie de La pompe vitale

À l'intérieur du cœur, il y a une paroi épaisse qui le divise en deux parties : gauche et droite. Chacune de ces parties a deux cavités, une oreillette et un ventricule, reliées par une valve. Il agit comme une pompe qui fait circuler le sang dans tout le corps grâce à ses battements réguliers. C'est ce mouvement qui permet à tout notre corps d'obtenir l'oxygène dont il a besoin pour fonctionner. Chaque jour, le cœur réussit à pomper environ 8000 litres de sang[2].La figure I-2 représente le cœur humain et ses quatre chambres de cavités cardiaques.

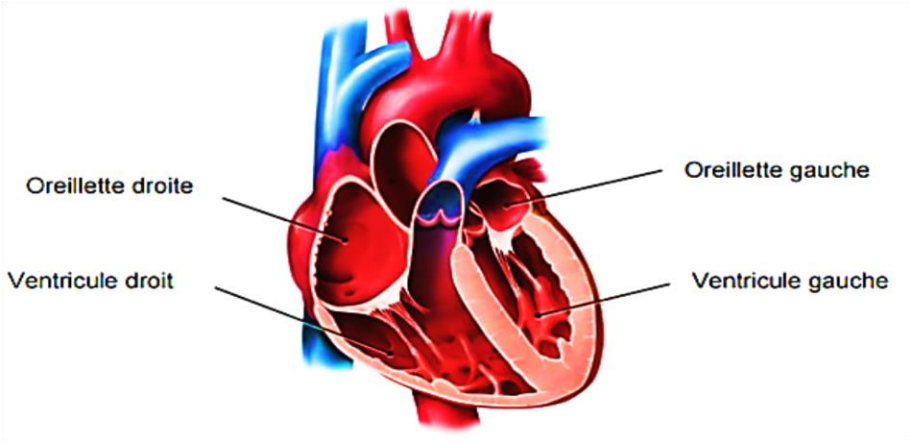


Figure I-2 : Les cavités cardiaques

I.2.2-La Mécanique du Cœur

Au centre de notre être, le cœur bat au rythme de 60 à 70 pulsations par seconde, propulsant un flux vital de 4,5 à 5 litres de sang par minute. Chaque battement orchestre une séquence d'événements précis, communément appelée la révolution cardiaque, qui se décompose en trois phases principales, La première phase, la systole auriculaire, voit les oreillettes se contracter pour expulser le sang vers les ventricules. Les valves tricuspide et mitrale se ferment alors pour empêcher le sang de refluer vers les oreillettes, produisant ainsi le son caractéristique des battements cardiaques.Ensuite, lors de la systole ventriculaire, les ventricules se contractent pour propulser le sang dans le système circulatoire. Une fois le sang expulsé, les valves pulmonaire et aortique se ferment pour éviter le reflux sanguin vers les ventricules, générant ainsi un deuxième son cardiaque plus aigu. Pendant cette phase, les oreillettes se remplissent de sang.Enfin, pendant la diastole, toutes les parties du cœur se relâchent, permettant aux ventricules de se remplir passivement de sang pour préparer le prochain cycle de battements [3]. La figure I-3 dis-vous où se situent les valves cardiaques.

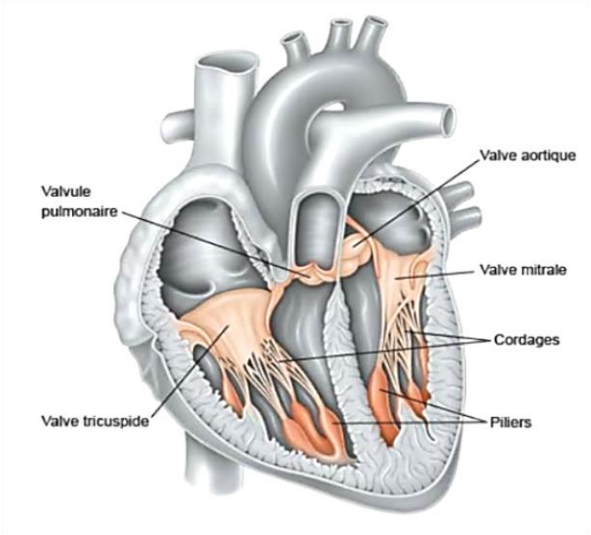


Figure I-3 : Localisation des Valves Cardiaques

I.2.3-L'activité électrique du cœur

Le cœur humain est une merveille de complexité, et son rythme vital est orchestré par un processus électrique sophistiqué. Au cœur de ce système se trouve le nœud sinusal (SA), souvent décrit comme le "pacemaker" naturel du cœur. Il émet régulièrement des signaux électriques qui parcourent les oreillettes, déclenchant leur contraction et favorisant le flux sanguin vers les ventricules, les cavités inférieures du cœur.Le signal électrique poursuit ensuite son chemin vers le nœud auriculo-ventriculaire (AV), situé entre les oreillettes et les ventricules. Ce nœud joue un rôle crucial en ralentissant brièvement le signal, permettant ainsi aux ventricules de se remplir complètement de sang avant de se contracter.Une fois que les ventricules sont remplis et prêts à se contracter, le signal électrique se propage à travers un réseau de fibres musculaires spécialisées présentes dans le cœur. Parmi ces fibres, deux structures clés se distinguent : le faisceau atrio-ventriculaire, également connu sous le nom de faisceau de His, et les fibres de Purkinje. Le faisceau atrio-ventriculaire (faisceau de His) agit comme un pont conducteur entre les oreillettes et les ventricules. Il transmet le signal électrique du nœud auriculo-ventriculaire aux ventricules avec une précision chronométrée. Cette transmission est cruciale pour assurer une contraction ventriculaire synchronisée et efficace. Les fibres de Purkinje, quant à elles, sont des extensions de ce faisceau, qui se répartissent dans les tissus musculaires des ventricules. Elles agissent comme des messagers diligents, véhiculant le signal électrique de manière rapide et coordonnée à travers les ventricules. Cette coordination précise des signaux électriques le long du faisceau atrio-ventriculaire et des fibres de Purkinje entraîne une contraction ventriculaire synchronisée. Ce processus est essentiel pour l'expulsion efficace du sang des ventricules vers les poumons et le reste du corps. Cette synchronisation garantit un fonctionnement optimal du système

circulatoire, assurant ainsi un apport adéquat d'oxygène et de nutriments à tous les tissus et organes du corps.la figure I-4 illustre tout le parcourt du courant électrique du cœur humain.

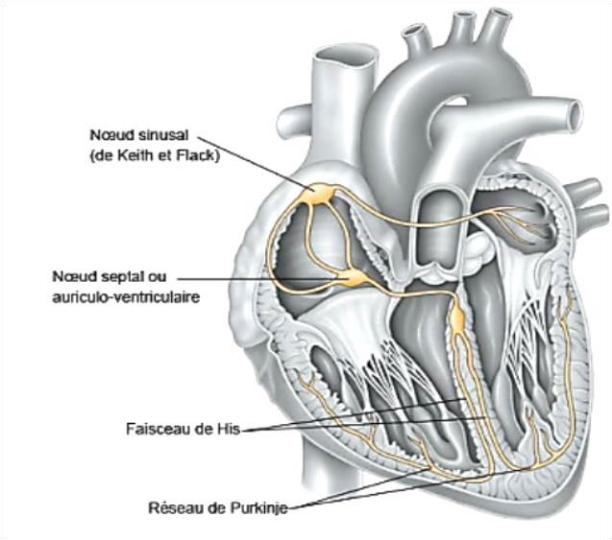


Figure I-4 : L'activité électrique du cœur humain

I.3-L'électrocardiogramme

Electrocardiogramme(ECG), est un test médical qui permet de voir comment le cœur fonctionne sur le plan électrique. Pour le réaliser, on place de petites électrodes (voir la figure I-5) sur la peau de la poitrine, des bras et des jambes. Ces électrodes détectent les impulsions électriques que le cœur émet lorsqu'il bat. Ces impulsions sont ensuite traduites en tracés graphiques, qu'on peut voir sur une feuille de papier ou sur un écran d'ordinateur. L'ECG est très utile pour repérer les problèmes cardiaques comme les battements irréguliers, les maladies des artères coronaires ou même les soucis structurels du cœur [4].

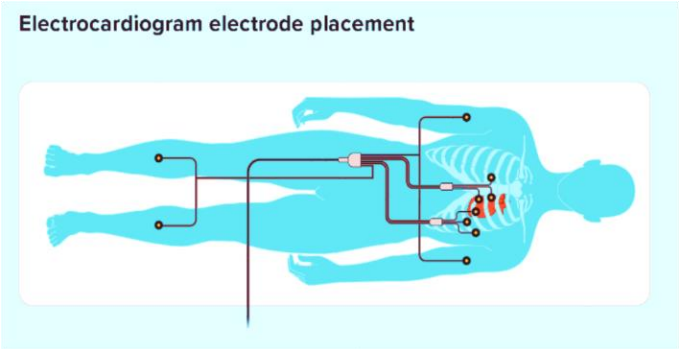


Figure I-5: Placement des électrodes d'électrocardiogramme sur le corps

I.4-Les phases d'ECG

Lorsqu'on observe un ECG, on voit plusieurs ondes et intervalles qui donnent des informations importantes sur le fonctionnement cardiaque. Les médecins examinent notamment l'onde P, l'intervalle PR, le complexe QRS, le segment ST, et l'ondeT, comme les montres dans la figure I-6.

- **Onde P :** Cette composante représente l'activation des oreillettes, amorçant ainsi le cycle cardiaque en démontrant l'initiation du rythme cardiaque.
- **Intervalle PR :** Il marque la transition entre l'activation des oreillettes et celle des ventricules, reflétant ainsi la synchronisation des différentes phases du cœur.
- **Complexe QRS :** Cette phase symbolise l'activation ventriculaire, indiquant le début de la contraction cardiaque destinée à propulser le sang dans la circulation systémique.
- **Segment ST :** Ce segment correspond à la période de repos post-contraction, offrant une évaluation de la santé myocardique après l'effort contractile.
- **Onde T :** Elle représente la repolarisation ventriculaire, marquant le repos électrique des ventricules en préparation à la prochaine phase de contraction cardiaque.
- **Onde U :** L'onde U, moins fréquemment observée, signale la phase finale de la repolarisation ventriculaire, illustrant ainsi la complétion du cycle électrique cardiaque. La présence de parasites ou d'irrégularités à la fin de l'enregistrement de l'ECG peut suggérer un déséquilibre en potassium, un élément crucial à considérer lors de l'évaluation de la santé cardiaque globale.

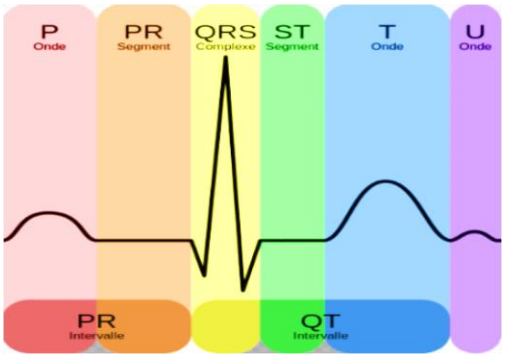


Figure I-6 : Les ondes d'ECG

I.4.1-Le standard de l'ECG

L'ECG est essentiel pour évaluer la santé cardiaque en fournissant des détails sur l'activité électrique du cœur. Pour une interprétation précise, il est crucial de connaître les normes des différentes phases du tracé, y compris la durée, l'amplitude et le rythme cardiaque.

I.4.1.1- La durés des ondes

- **Onde P:** La durée normale de l'onde P est généralement inférieure à 0,12 seconde. Elle représente la dépolarisation des oreillettes.
- **Complexe QRS**: La durée normale du complexe QRS varie généralement entre 0,06 et 0,10 seconde. Il représente la dépolarisation des ventricules.
- **Intervalle P-R:** Cet intervalle, qui mesure le temps de conduction de l'onde électrique des oreillettes aux ventricules, a une durée normale comprise entre 0,12 et 0,20 seconde.
- **Intervalle Q-T**: Cet intervalle, qui mesure le temps de dépolarisation et de repolarisation ventriculaire, a une durée normale de 0,35 à 0,44 seconde.
- **Segment ST:** La durée normale de ce segment est généralement considérée comme étant entre 0,08 et 0,12 seconde. Il représente la phase de repolarisation ventriculaire [5].

I.4.1.2-L'amplitude

- **Onde P**: L'amplitude normale de l'onde P est généralement inférieure à 0,25 mV (2,5 mm). Cette ondereprésente la dépolarisation des oreillettes.
- **Complexe QRS**: L'amplitude normale du complexe QRS varie généralement entre 0,5 et 2 mV (5 à 20 mm). Cela représente la dépolarisation des ventricules.
- **Onde T:** L'amplitude normale de l'onde T varie généralement entre 0,1 et 0,5 mV (1 à 5 mm). Cette onde représente la repolarisation des ventricules [5].

I.4.1.3-Le rythme cardiaque

- **Rythme Sinusal:** Le rythme cardiaque normal est généralement compris entre 60 et 100 BPM au repos chez les adultes.
- **Bradycardie:** Une fréquence cardiaque inférieure à 60 BPM est considérée comme une bradycardie. Cela peut être physiologique chez les athlètes ou être associé à des conditions médicales telles que l'hypothyroïdie ou des troubles du nœud sino-auriculaire.
- **Tachycardie:** Une fréquence cardiaque supérieure à 100 BPM est considérée comme une tachycardie. Cela peut être dû à l'exercice, au stress, à l'anxiété ou à des conditions médicales telles que la fièvre, l'anémie ou des troubles cardiaques [5].

I.5-L'acquisition du signal ECG

L'acquisition du signal ECG, c'est comme ouvrir une fenêtre sur l'activité électrique du cœur.La figure I-7 présente un exemple classique d'un ECG normal.



Figure I-7 : Signal ECG normal

C'est un peu comme installer des petites antennes sur notre peau pour capter les messages électriques que notre cœur envoie constamment. Ces "antennes", ce sont les électrodes, que l'on place sur notre poitrine et nos membres. Ensuite, on relie ces électrodes à un appareil spécial appelé électrocardiographe (voir la figure I-8). C'est comme brancher notre cœur à une machine qui peut lire et enregistrer ses messages électriques. Une fois que tout est connecté, c'est comme si on entrait dans un laboratoire secret où les mystères du cœur sont révélés. L'électrocardiographe amplifie les signaux électriques captés par les électrodes et élimine tous les bruits indésirables qui pourraient interférer. C'est comme si la machine mettait en évidence la musique secrète que notre cœur joue en permanence. Et puis vient le moment fascinant où les résultats apparaissent sur l'écran. C'est comme regarder une carte dessinée par notre propre cœur. Chaque bosse, chaque creux, chaque ligne est une histoire que les médecins savent lire comme un livre. Ces résultats peuvent révéler des secrets cachés sur la santé de notre cœur : s'il bat trop vite, trop lentement, ou s'il y a quelque chose qui ne va pas[référence].



Figure I-8 : L'électrocardiographie

I.5.1-Les dérivations d'ECG

L'ECG à 12 dérivations est une méthode standardisée internationalement pour obtenir une représentation tridimensionnelle de l'activité électrique du cœur. Ces dérivations se répartissent en deux groupes : les dérivations frontales et les dérivations précordiales.

Les six dérivations frontales sont :

- DI : mesure bipolaire entre le bras droit (-) et le bras gauche (+).
- DII : mesure bipolaire entre le bras droit (-) et la jambe gauche (+).

- DIII : mesure bipolaire entre le bras gauche (-) et la jambe gauche (+).
- AVR : mesure unipolaire sur le bras droit.
- AVL : mesure unipolaire sur le bras gauche.
- AVF : mesure unipolaire sur la jambe gauche.

La lettre "A" dans AVR, AVL et AVF signifie "augmentée". Il convient de noter que dans les pays anglo-saxons, ces dérivations sont souvent désignées simplement par I, II et III. Les six dérivations précordiales sont utilisées pour obtenir une vue plus précise de l'activité électrique du cœur dans la région précordiale. Elles comprennent V1 à V6, qui sont positionnées de manière spécifique autour de la poitrine selon des repères anatomiques. En outre, il existe d'autres dérivations telles que V7 à V9, V3R, V4R et VE, qui peuvent être utilisées dans certains cas pour affiner le diagnostic de certaines conditions cardiaques, comme l'infarctus du myocarde. L'ensemble de ces dérivations permet une analyse approfondie de l'activité électrique cardiaque et joue un rôle crucial dans le diagnostic et la gestion des troubles cardiaques [6].la figure I-9 vous montre les deuze dérivations.

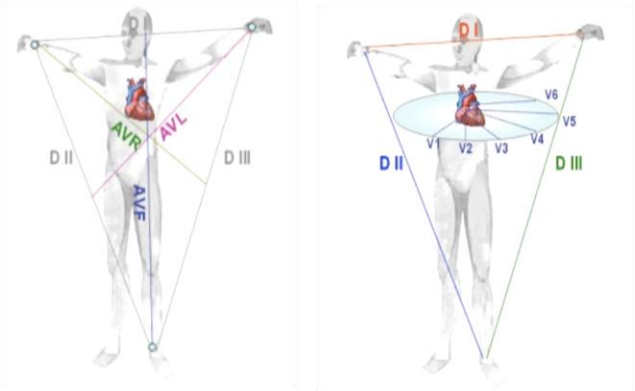


Figure I-9: Les douze dérivations

I.6-Les maladies cardiaques

Les maladies cardiaques, elles touchent tellement de gens à travers le monde. C'est comme une grande famille de problèmes, vous savez, qui affectent le cœur de différentes façons. Il y différents types de troubles touchant le système circulatoire [7], tels que :

- **Maladie coronarienne:** une affection des vaisseaux sanguins qui alimentent le muscle cardiaque.
- **Maladie cérébrovasculaire:** une pathologie des vaisseaux sanguins qui alimentent le cerveau.

- **Maladie artérielle périphérique:** un trouble des vaisseaux sanguins qui alimentent les bras et les jambes. 4
- **Cardiopathie rhumatismale:** des dommages au muscle cardiaque et aux valves cardiaques dus au rhumatisme articulaire aigu, provoquée par des bactéries streptococciques.
- **Cardiopathie congénitale:** des malformations congénitales qui affectent le développement et le fonctionnement normaux du cœur en raison d'anomalies structurelles.
- **Thrombose veineuse profonde et embolie pulmonaire:** des caillots sanguins se forment dans les veines des jambes, qui peuvent se déloger et se déplacer vers le cœur et les poumons, entraînant ainsi une embolie pulmonaire.

I.6.1-Les maladies étudiées

- **Battement Normal (N) :** Cette catégorie fait référence aux battements cardiaques qui suivent un rythme régulier et typique, en accord avec le fonctionnement normal du cœur. Ils ne présentent pas d'anomalies significatives dans leur séquence ou leur fréquence.
- **Battement Ectopique Ventriculaire (VEB) :** Les battements ventriculaires ectopiques sont caractérisés par des contractions cardiaques qui débutent dans les ventricules plutôt que dans le nœud sinusal, qui est le stimulateur cardiaque normal. Ces battements peuvent se produire prématurément ou retardés dans le cycle cardiaque, souvent associés à des sensations telles que des palpitations ou des battements irréguliers.
- **Battement Ectopique Supraventriculaire (SVEB) :** Ce type de battement se produit lorsque des impulsions électriques anormales émanent des parties supérieures du cœur, généralement les oreillettes. Ces battements peuvent résulter en des rythmes cardiaques irréguliers et peuvent être accompagnés de symptômes tels que des palpitations ou une sensation de saut dans la poitrine.
- **Battement de Fusion (F) :** Les battements de fusion se manifestent lorsque des signaux électriques normaux et anormaux se combinent pour produire un battement cardiaque unique. Cela peut se produire lorsque les impulsions électriques provenant du nœud sinusal et d'autres régions cardiaques se chevauchent, créant un battement fusionné aux caractéristiques mixtes.
- **Battement Inconnu (Q) :** Cette classification est réservée aux battements cardiaques qui ne peuvent être catégorisés selon les classifications précédentes. Ils peuvent

résulter de conditions spécifiques non identifiées ou de facteurs autres que les arythmies cardiaques, nécessitant une évaluation plus approfondie pour déterminer leur origine et leur nature [8].

I.6.2-Causes des maladies cardiaques

Les facteurs congénitaux, les principaux déclencheurs des maladies cardiovasculaires comprennent :

- L'hypertension artérielle.
- Le diabète.
- Les dyslipidémies.
- Le tabagisme.
- Une alimentation déséquilibrée.
- Le manque d'activité physique et le surpoids [9].

I.7-Intelligence Artificielle

L'IA est un domaine étendu de l'informatique qui se concentre sur la création de machines intelligentes capables de penser et d'agir comme des êtres humains. Le concept d'IA englobe la conception des machines capables de simuler des fonctions cognitives humaines telles que l'apprentissage, la résolution de problèmes, et la reconnaissance de modèles. Malgré les avancées significatives dans le traitement informatique et la capacité de stockage, il reste encore des défis à relever pour égaler la souplesse et la polyvalence de l'intelligence humaine, notamment dans des contextes nécessitant une compréhension approfondie et une adaptation à des situations nouvelles.Cependant, des progrès notables ont été réalisés dans des domaines spécifiques où des systèmes d'IA ont démontré des performances comparables à celles des experts humains. Ces applications incluent le diagnostic médical, les moteurs de recherche, ainsi que la reconnaissance vocale ou écrite. L'IA est un domaine multidisciplinaire en constante évolution, et les récentes avancées en apprentissage automatique et en apprentissage profond révolutionnent de nombreux secteurs industriels, ouvrant de nouvelles perspectives et opportunités [10].

I.8-IA dans le domaine médical

I.8.1-IA dans le domaine d'ECG

L'IA révolutionne l'analyse des ECG en médecine. Tout d'abord, l'IA est utilisée pour le diagnostic de la fibrillation atriale (FA), un trouble du rythme cardiaque courant. En exploitant des techniques avancées telles que les réseaux neuronaux profonds, l'IA permettent

une détection précise de la FA à partir des enregistrements ECG, dépassant ainsi les méthodes traditionnelles. Cette capacité à diagnostiquer précisément la FA ouvre la voie à des interventions précoces et à une meilleure gestion de cette condition. De plus, l'IA est également utilisée pour prédire les troubles du rythme cardiaque à partir des données ECG, identifiant ainsi les patients à risque accru, permettant une stratégie de prévention proactive. Cette capacité de prédiction peut aider à orienter les interventions cliniques et à améliorer les résultats pour les patients. Enfin, l'utilisation de l'IA permet une analyse approfondie de l'ECG en rythme sinusal, offrant des perspectives précieuses sur la santé cardiovasculaire globale des individus et permettant une prise en charge personnalisée et proactive[11]. L'IA révolutionne l'analyse des ECG en médecine :

- **Diagnostic Précis**: Elle détecte les anomalies subtiles pour des diagnostics plus précis.
- **Détection Précoce:** Elle repère les signaux de risque des maladies cardiovasculaires, permettant une intervention précoce.
- **Aide à la Décision:** Elle fournit des recommandations pour des plans de traitement adaptés.
- **Efficacité :** Elle automatise l'analyse, libérant du temps pour les médecins.
- **Surveillance Continue:** Elle alerte en temps réel en cas d'anomalies cardiaques.
- **Personnalisation des Soins :** Elle adapte les traitements aux besoins spécifiques de chaque patient.
- **Recherche Avancée:** Elle ouvre de nouvelles voies pour comprendre et traiter les maladies cardiaques.

I.9-Internet d’objet

L'Internet des objets (IoT) est une technologie récente qui crée un réseau mondial de machines et d'appareils capables de communiquer et d'échanger des données entre eux via Internet. Contrairement à Internet classique, l'IoT va au-delà de la simple connectivité en permettant aux objets connectés de générer des informations, facilitant ainsi l'analyse et la prise de décision. En d'autres termes, l'IoT représente une forme d'Internet plus intelligente. Des exemples d'applications incluent les caméras de sécurité, les capteurs, les véhicules, les bâtiments et les logiciels, tous capables d'échanger des données entre eux [12].la Figure I-10 vous exprime le rôle principal d’IOT.

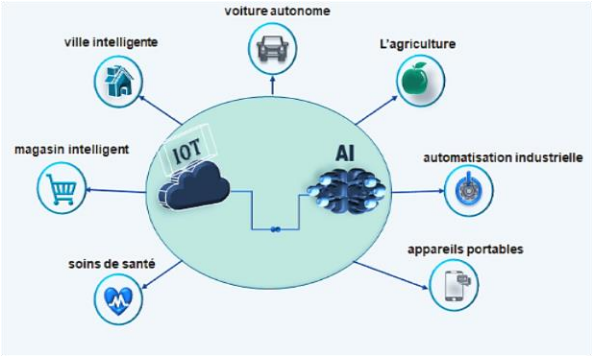


Figure I-10:Le rôleprincipal d'IOT

I.9.1- L'utilisation de l'IoT pour la surveillance des maladies cardiaque

L'utilisation de l'IoT pour surveiller les maladies cardiaques, c'est un vrai coup de génie, avec cette technologie, des petits appareils connectés peuvent garder un œil sur notre cœur en permanence, même quand on est chez nous ou qu'on est en train de faire nos trucs quotidiens. C'est comme avoir un médecin personnel toujours avec nous. Ce qui est vraiment cool, c'est que ces appareils peuvent détecter les soucis cardiaques avant même qu'on s'en rende compte. Ça peut permettre aux médecins d'agir vite pour nous soigner. Ça peut vraiment sauver des vies [12].

I.10-Travaux connexes

Dans le domaine de la santé numérique, l'analyse des signaux ECG représente un pilier essentiel pour le diagnostic précoce des affections cardiaques. Cette étude met en lumière plusieurs approches innovantes développées par divers chercheurs, visant à améliorer la précision et l'efficacité de cette analyse critique. Nous examinons en détail les étapes méthodologiques utilisées par différents chercheurs sur Figure I-11.

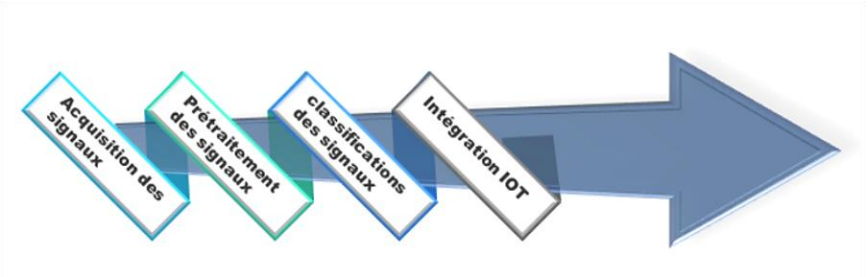


Figure I-11: Processus Intégré et Analyséles Signaux ECG

M R A. BERKANI et al[13], ont développé un système de surveillance des signaux ECG utilisant un réseau de neurones convolutif unidimensionnel (1D-CNN). Avec une précision de classification de 97 % et une erreur de seulement 0,11 %, le système intègre un nœud

d'acquisition basé sur ArduinoUno et un capteur AD8232, ainsi qu'un traitement sur une carte Raspberry Pi. Le modèle CNN est implémenté selon l'approche TinyML, offrant ainsi une détection rapide et précise des maladies cardiovasculaires.

M. Imran A et ses collègues[14], ont développé un système intégrant des réseaux neuronaux CNN et LSTM pour la classification des signaux ECG. Grâce à l'utilisation d'un dispositif AD8232 pour l'acquisition des signaux et à un prétraitement dans MATLAB/Simulink, leur système a atteint une remarquable précision de classification de 90,73 %, facilitant ainsi une gestion améliorée des conditions cardiaques grâce à une intégration dans des dispositifs IoT.

H. Sigurthorsdottir et al[15], ont utilisé un réseau neuronal CRNN pour classifier les signaux cardiaques. La précision de la classification était de 57,3 % sur l'ensemble de validation local et de 51,1 % sur l'ensemble de test caché.

VandithSreenivas K et al[16], ont proposé une méthode novatrice pour l'analyse des signaux ECG. Leur approche combine l'utilisation de réseaux neuronaux convolutionnels (CNN) avec la transformation des signaux ECG en images 2D à l'aide à la fois de GramianAngular Fields (GAF) et de Markov Transition Fields (MTF). Cette méthodologie a conduit à une précision de classification remarquable de 97 % sur l'ensemble d'entraînement et de test.

Yu-Jin Lin et ses collègues[17], ont exploré une méthode innovante exploitant un dispositif IoT pour l'acquisition des données ECG. Leur système, fondé sur des réseaux neuronaux CNN, a démontré une précision de classification des signaux ECG atteignant 94,96 %, ouvrant ainsi la voie à une gestion efficace des conditions cardiaques en temps réel.

Y. Elmir et al[18], ont mené une étude novatrice dans le domaine de l'analyse des signaux ECG. Leur approche, basée sur l'utilisation de réseaux neuronaux convolutionnels (CNN) et des ensembles de données MIT-BIH Arrhythmia et PTB Diagnostic ECG, a surpassé les résultats précédemment rapportés, avec une précision de détection d'anomalies atteignant respectivement 97,47 % et 98,65 %.

A. Amrouche et al[19], ont mené une étude sur la classification des battements de cœur dans les signaux ECG. Deux modèles sont comparés : les réseaux neuronaux profonds (DNN) et les machines à vecteurs de support (SVM). Les données sont prétraitées pour équilibrer les classes, puis les modèles sont formés. Le DNN obtient une précision de 97,45 % contre 90,33 % pour le SVM. Le DNN surpasse le SVM dans la plupart des classes, montrant son efficacité supérieure dans cette tâche.

A. Diker et ses collègues [20], proposent une approche novatrice pour la classification des signaux électrocardiographiques (ECG) en utilisant des spectrogrammes et des réseaux de neurones convolutionnels (CNN). Les chercheurs ont utilisé la base de données publique PTBDB, qui contient des enregistrements ECG étiquetés, pour entraîner et évaluer trois architectures de CNN : AlexNet, VGG-16 et ResNet-18. Le prétraitement des données implique la génération de spectrogrammes à partir des signaux ECG pour représenter les informations temporelles et fréquentielles. Les modèles sont entraînés à l'aide d'une approche de transfert d'apprentissage et évalués sur un ensemble de validation distinct. Les résultats montrent qu'AlexNet a fourni les performances les plus élevées avec une précision de 83,82 %, démontrant ainsi que cette approche peut être efficace pour la classification des signaux ECG.

Tableau I-1 :Résultats des travaux connexes

Travail	L'année	Prétraitement	Modèle IA	Processus	Base des Données	Précision
M R A. Berkani et Al [13]	2022	Segmentation sur 1024 échantillons	CNN-1D	Apprentissage profond classification	MIT-BIH Arrhythmia	97%
M. A. Imran et Al [14]	2023	CWT	CNN- 1D	Apprentissage profond classification	MIT-BIH Arrhythmia	90.78%
H.Sigurthor-sdottir et Al [15]	2020	Filtrage passe haut Fc=0.5Hz	CRNN	Apprentissage profond classification	Physionet / computing in cardiology 2020	57.3%
V K. Sreeniva et Al [16]	2021	GAF MTF	CNN- 2D	Apprentissage profond classification	MIT-BIH Arrhythmia	97%
Yu-Jin Lin et Al [17]	2019	Dé bruitage Transformer en image	CNN- 1D	Apprentissage profond classification n	Base des données interne d'hôpital réel	94.96%
Y. Elmir et Al [18]	2023	GAF	CNN	Apprentissage profond et par transfert classification	MIT-BIH Arrhythmia PTB Diagnostic ECG	98.65%
A. Amrouche et Al [19]	2023	Segmentation Spectrogramme	DNN CNN- 1D	Apprentissage automatique et profond classification	MIT-BIH Arrhythmia	97.45%

A. Diker et Al [20]	2019	Filtrage. Normalisation. Segmentation. Caractéristiques. Spectrogramme.	CNN- 1D Alexnet VGG16 Resnet18	Apprentissage profond classification	PTBDB (PTB Diagnostic ECG)	83.82%

I.11-Conclusion

En conclusion, l'intégration d'IA dans l'analyse des ECG révolutionnent la manière dont nous diagnostiquons et traitons les maladies cardiaques. Grâce à des algorithmes sophistiqués d'apprentissage automatique et d'apprentissage en profondeur, l'IA permet une détection précoce des anomalies cardiaques, une personnalisation des traitements et une surveillance continue des patients. Cette combinaison de technologie et de médecine ouvre de nouvelles perspectives pour la santé cardiovasculaire, offrant des solutions plus rapides, plus précises et plus accessibles pour les patients du monde entier.

Chapitre II : Traitement de Signal et IA

II.1-Introduction

Ce chapitre explore deux aspects clés : d'une part, le prétraitement des données à l'aide des coefficients cepstraux de Mel-fréquence (MFCC) et du champ angulaire de Gramian (GAF), et d'autre part, le domaine fascinant des algorithmes d'IA et de ML, incluant notamment l'apprentissage automatique et l'apprentissage en profondeur.Dans la première partie de ce chapitre, nous nous concentrons sur l'importance du prétraitement des données à travers les techniques MFCC et GAF, examinant comment ces méthodes transforment les données brutes en représentations plus significatives.Dans la seconde partie, nous explorons le domaine des algorithmes d'IA et de ML, en passant en revue les principaux algorithmes tels que les k plus proches voisins (KNN), les machines à vecteurs de support (SVM), les arbres de décision et les forêts aléatoires. Nous examinons également les modèles d'apprentissage en profondeur (DL), tels que les réseaux de neurones convolutifs (CNN).De plus, nous abordons les mécanismes neuronaux biologiques et les réseaux de neurones artificiels, mettant particulièrement l'accent sur l'impact des fonctions d'activation.Enfin, nous explorons l'impact de l'intelligence artificielle sur l'Internet des objets (IoT), analysant l'architecture sous-jacente de l'IoT et mettant en lumière les différentes couches impliquées dans la collecte et le traitement des données.

II.2-Prétraitement du signal ECG

Le prétraitement du signal ECG est une étape cruciale dans l'analyse des données électrocardiographiques. Son objectif est d'améliorer la qualité du signal en éliminant les artefacts et le bruit, et en extrayant des caractéristiques pertinentes pour diverses applications telles que la détection des battements cardiaques et l'analyse de la variabilité de la fréquence cardiaque. Ce processus préliminaire est essentiel pour garantir la fiabilité et l'exactitude des analyses ultérieures. Afin d'atteindre ces objectifs, plusieurs techniques de traitement du signal sont couramment utilisées. Parmi celles-ci, certaines méthodes avancées telles que le MFCC, les ondelettes et le GAF peuvent également être explorées pour compléter les approches traditionnelles de prétraitement. Bien que ces techniques soient initialement développées pour d'autres domaines, leur adaptation au traitement du signal ECG pourrait offrir de nouvelles perspectives et approches innovantes dans l'analyse des données cardiaques [21].

II.2.1-Coefficients cepstraux sur l'échelle Mel

Coefficients cepstraux sur l'échelle Mel (MFCC) a été intensivement utilisés comme vecteur de paramètres acoustiques dans les systèmes de reconnaissance des paroles et des locuteurs. L’extraction des coefficients MFCC est motivée par les deux propriétés suivantes:

- **Déconvolution :** Les MFCC séparent les caractéristiques des voies vocales des caractéristiques excitatrices.
- **Décorrélation :** La transformée en cosinus discrète possède un effet de décorrélation entre les éléments du vecteur de paramètres. Les MFCC sont obtenus par la transformée cosinus inverse du logarithme du spectre de l'énergie du segment de la parole [21].

Pour comprendre comment les MFCC (voir la figure II-1) sont calculés, il est utile d'adopter une approche méthodique. Tout d'abord, le signal audio est divisé en segments distincts. Ensuite, chaque segment est analysé en termes de sa composition fréquentielle à l'aide de la transformation de Fourier, fournissant ainsi une représentation fréquentielle du segment. Ensuite, les filtres de Mel sont appliqués pour identifier les fréquences pertinentes, ce qui permet d'obtenir une représentation plus précise de l'énergie dans différentes parties du spectre sonore. Ensuite, une transformation logarithmique est appliquée à cette énergie pour accentuer les différences entre les parties du spectre. Enfin, une sélection des filtres les plus informatifs est effectuée pour obtenir une représentation plus significative du signal audio.

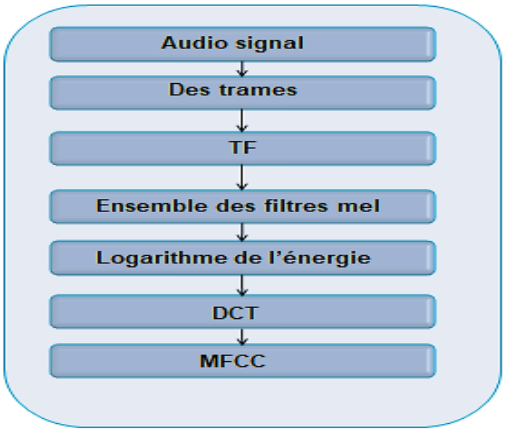


Figure II-1 : Diagramme de MFCC

En gros, les MFCC, c'est comme un condensé des caractéristiques les plus importantes de notre son, présenté d'une manière que notre cerveau peut facilement comprendre. C'est un peu comme si on prenait une photo (voir la figure II-2) de notre son et qu'on zoomait sur les détails les plus intéressants.

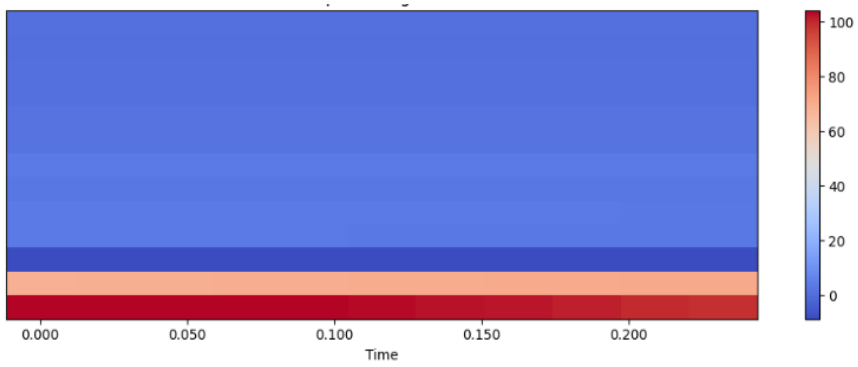


Figure II-2 : L'image résultant de MFCC

II.2.2- Champ Angulaire Gramien

Champ Angulaire Gramien (GAF) représente une approche novatrice et prometteuse dans le domaine de l'analyse des séries chronologiques. En transformant les données temporelles en images basées sur les coordonnées polaires, le GAF offre la possibilité de capturerefficacement les corrélations temporelles tout en préservant les relations absolues de temporalité. Cette représentation permet de visualiser les tendances et les motifs présents dans les données au fil du temps, offrant ainsi un moyen puissant d'analyser et de classifier les séries chronologiques. L'une des principales forces du GAF réside dans sa capacité à préserver les dépendances temporelles, ce qui en fait un outil précieux pour étudier les dynamiques temporelles complexes. Chaque pixel de l'image GAF représente une corrélation entre deux points de la série chronologique, ce qui permet une analyse détaillée des interactions temporelles entre les données. Cependant, il convient de noter que l'utilisation du GAF peut présenter certains défis, notamment en termes de taille des images générées, ce qui peut nécessiter des stratégies de gestion et de traitement efficaces pour les séries chronologiques de grande taille. De plus, il est crucial de sélectionner judicieusement les paramètres de mise à l'échelleet de régularisation lors de la création des images GAF (voir la figure II-4) afin d'obtenir des résultats optimaux. La figureII-3 expose de manière détaillée les étapes du GAF [22].

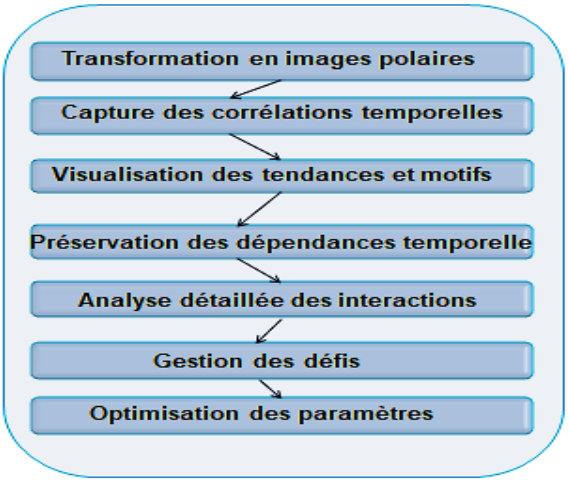


Figure II-3 :L'Organigramme du GAF

La méthode GAF représente une approche prometteuse pour la représentation et d'analyse des séries chronologiques, offrant un moyen innovant de visualiser et de comprendre les dynamiques temporelles des données. Son utilisation peut ouvrir de nouvelles perspectives dans divers domaines de recherche, notamment en matière de prévision, de détection classification des séries chronologiques [22].

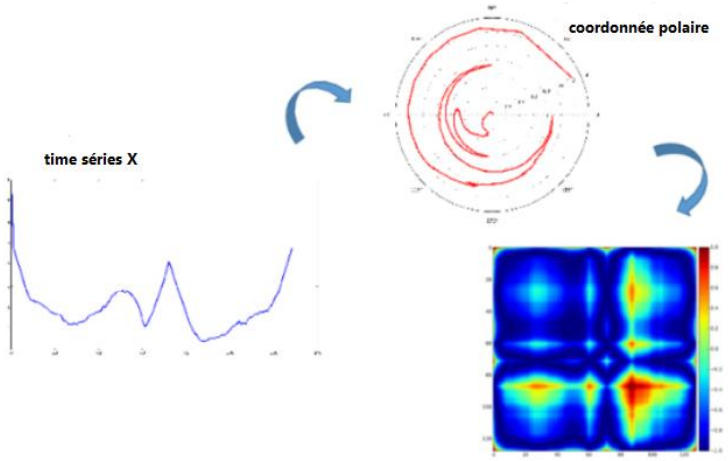


Figure II-4 : Transformation du Champ Angulaire de Gramien

II.3-Intelligence artificielle

Le domaine d'IA pose un défi conceptuel important en raison de la complexité à définir précisément ce qu'est l'IA et ce qui la distingue de l'intelligence naturelle. L'IA implique généralement la création de systèmes informatiques capables d'imiter ou de reproduire des fonctions cognitives humaines telles que l'apprentissage, le raisonnement, la résolution de problèmes et la compréhension du langage.La nature "artificielle" de l'IA réside dans le fait qu'elle est produite par l'ingéniosité humaine plutôt que par des processus naturels,

tels que l'évolution biologique. Cela soulève des questions sur la façon dont l'IA est conçue, créée et utilisée, ainsi que sur les implications éthiques et sociétales de son développement.La difficulté à définir l'IA découle en partie de la complexité de définir l'intelligence elle-même. La définition traditionnelle de l'intelligence inclut des éléments tels que la capacité à apprendre de l'expérience, à résoudre des problèmes de manière efficace et à s'adapter à de nouvelles situations. Cependant, ces caractéristiques ne sont pas toujours facilement transférables aux machines.La distinction entre les machines animées et inanimées est également pertinente pour la compréhension de l'IA. Les machines sont généralement considérées comme des artefacts créés par l'homme, tandis que les êtres humains ont une origine biologique. Cette distinction soulève des questions sur la capacité des machines à posséder une forme d'intelligence similaire à celle des êtres humains.La recherche d'une définition précise de l'IA nécessite donc une réflexion approfondie sur la nature de l'intelligence, ainsi que sur les implications philosophiques, éthiques et sociales de l'utilisation de machines intelligentes dans notre société. Ce défi conceptuel souligne l'importance d'une approche multidisciplinaire pour aborder les questions complexes soulevées par l'IA [23].

II.3.1-L'histoire d'IA

- **Les débuts (années 1950) :** L'IA trouve ses racines dans les travaux de chercheurs comme Alan Turing, qui a posé les fondations théoriques en proposant le célèbre test de Turing pour évaluer l'intelligence des machines. D'autres pionniers, comme John McCarthy, Marvin Minsky, Allen Newell et Herbert Simon, ont également contribué aux premiers développements de l'IA.
- **L'âge de l'optimisme (années 1950-1960) :** Cette période a été marquée par un grand optimisme quant aux possibilités de l'IA. Des premiers programmes ont été créés pour résoudre des problèmes de logique symbolique et de jeux comme le jeu d'échecs et les dames.
- **L'hiver de l'IA (années 1970-1980) :** Après une période d'enthousiasme initial, l'IA a connu une phase de stagnation connue sous le nom « hiver de l'IA ». Les progrès étaient plus lents que prévu, ce qui a conduit à une baisse du financement et de l'intérêt pour le domaine.
- **La renaissance (années 1980-1990) :** Cette période a vu l'émergence de nouvelles approches en IA, notamment les réseaux neuronaux artificiels et les systèmes experts. Des progrès significatifs ont été réalisés dans des domaines tels que la vision par ordinateur, le traitement du langage naturel et la robotique.

- **L'ère de l'apprentissage machine (années 2000 à aujourd'hui) :** Avec l'avènement de grandes quantités de données et de puissance de calcul accrue, l'apprentissage machine est devenu le moteur principal de l'IA moderne. Des techniques telles que les réseaux de neurones profonds ont permis des avancées majeures dans des domaines tels que la reconnaissance d'images, la traduction automatique et les véhicules autonomes.
- **L'IA aujourd'hui et demain :** L'IA est omniprésente dans notre vie quotidienne, des recommandations de produits en ligne aux assistants vocaux comme Siri et Alexa. Les chercheurs explorent également des domaines émergents tels que l'IA éthique, la compréhension de la causalité et la création de systèmes capables de raisonnement plus avancé [23].la figure II-5 fournit une représentation visuelle détaillée.

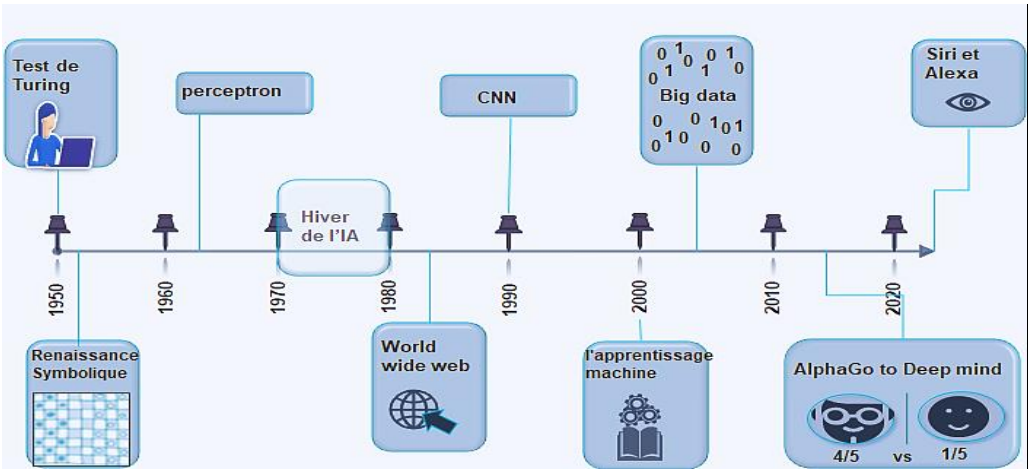


Figure II-5 : Les dates clés de l'IA

Il existe trois principaux types d'intelligence artificielle :

- L'IA étroite (IAE), aussi appelée IA faible, est celle que nous utilisons couramment aujourd'hui. Elle est conçue pour des tâches spécifiques et précises, telles que la reconnaissance faciale ou les moteurs de recherche sur Internet. Cependant, elle reste limitée à son domaine d'application spécifique.
- L'IA générale (IAG) vise à reproduire la pensée et les comportements humains. Actuellement, ce concept demeure théorique car les scientifiques n'ont pas encore réussi à créer une machine dotée de cette capacité. Développer une IAG nécessiterait des logiciels complexes permettant à la machine d'acquérir une conscience autonome par l'expérience.
- La super IA (ASI) est un concept utopique, plus proche de la science-fiction que de la réalité. Elle implique que les machines surpasseraient non seulement les connaissances

et les compétences humaines, mais aussi les capacités physiques. Bien que cela puisse sembler fascinant pour certains, d'autres s'inquiètent des risques potentiels que cela pourrait représenter pour l'humanité.

II.3.2-Domaines de l'IA

- **Systèmes Experts :** Logiciels imitant le comportement humain pour des tâches spécifiques, avec une précision remarquable.
- **Réseaux Neuronaux :**Modèles inspirés du cerveau humain, utilisant des cellules neuronales interconnectées pour le traitement de l'information.
- **Calcul Formel :** Manipulation symbolique des expressions mathématiques, distinguant du calcul numérique.
- **Représentation des Connaissances :** Structuration et utilisation symbolique des connaissances pour leur manipulation.
- **Simulation du Raisonnement Humain :**Modèles logiques visant à formaliser les modes de raisonnement humain, tels que les logiques modales ou temporelles.
- **Traitement du Langage Naturel :**Compréhension et analyse du langage humain, incluant la traduction et la synthèse de texte.
- **Résolution de Problèmes :**Analyse et résolution de problèmes concrets, notamment dans les jeux de réflexion.
- **Reconnaissance de la Parole et de l'Écriture :** Interprétation automatique de la parole et de l'écriture manuscrite ou dactylographiée.
- **Reconnaissance des Visages :**Identification et analyse automatique des visages, utilisée en sécurité et en surveillance.
- **Robotique :**Utilisation de robots pour diverses tâches, depuis des mouvements prédéfinis jusqu'à une autonomie de décision.
- **Systèmes Complexes Adaptatifs :**Étude des convergences vers des formes organisées de populations sous l'influence de lois simples et naturelles, combinant algorithmes génétiques et modèles de vie artificielle [24]**.**
- **Domaine médical :** L'intelligence artificielle révolutionne le diagnostic et le traitement des maladies, améliorant ainsi les soins de santé.
- **Domaine d'ingénierie :** L'intégration de l'IA permet aux ingénieurs de concevoir des solutions plus efficaces et innovantes pour relever les défis technologiques**.**
- **Automatisation :** Les systèmes autonomes, alimentés par l'IA, libèrent les travailleurs des tâches répétitives, favorisant ainsi la productivité.

- **Maisons intelligentes :** Les maisons équipées d'IA ajustent automatiquement leur environnement pour améliorer le confort et la sécurité des occupants.
- **Villes intelligentes :** L'IA optimise les services urbains pour créer des villes plus durables et agréables à vivre [24].

II.3.3-Types de l'IA

L'IA, c'est comme le grand domaine où on essaie de donner aux ordinateurs la capacité de faire des trucs qui ressemblent à ce que fait notre cerveau. Et pour ça, on a deux super outils dans notre boîte à outils : l'apprentissage automatique et l'apprentissage profond.

- **L'apprentissage automatique** : c'est un peu comme si on donnait à un ordinateur une tonne de données et qu'on lui demandait de deviner des trucs à partir de ces données. Par exemple, on lui montre plein de photos de chats et de chiens, et à force de voir ces images, il apprend à reconnaître la différence entre les deux sans qu'on lui dise explicitement ce qu'est un chat ou un chien.
- **L'apprentissage profond :** c'est comme un niveau au-dessus. On utilise des trucs qu'on appelle des réseaux de neurones (rien à voir avec nos neurones, mais bon, c'est le nom qu'on leur donne). Ces réseaux sont super complexes et peuvent apprendre des trucs vraiment compliqués, comme reconnaître des visages dans une foule ou traduire des langues étrangères.

L'apprentissage automatique et l'apprentissage profond sont comme des outils magiques qui permettent à nos ordinateurs de devenir de plus en plus intelligents et de faire des trucs incroyables, comme vous aider à trouver la bonne réponse à un problème de maths ou à recommander un film sur Netflix.

II.4-Apprentissage automatique(Machine Learning)

L'apprentissage automatisé, une branche fondamentale de l'IA, se définit par la capacité des systèmes informatiques à assimiler des connaissances et à résoudre des problèmes de manière autonome. Au cœur de ce processus réside la capacité des machines à extraire des informations significatives à partir de vastes ensembles de données, en identifiant des schémas et des tendances, pour ensuite construire des modèles mathématiques nommés "modèles d'apprentissage". Ces modèles sont construits à partir de données d'entraînement, représentant des exemples concrets ou simulés du problème à résoudre. Ils sont ensuite utilisés pour anticiper des résultats, prendre des décisions ou réaliser des tâches spécifiques sans nécessiter une programmation explicite pour chaque cas. Cependant, pour que le système puisse apprendre efficacement et produire des résultats pertinents, une intervention humaine

est souvent nécessaire en amont. Cela comprend la conception d'algorithmes appropriés, la collecte et la préparation des données requises, ainsi que l'évaluation et l'interprétation des résultats obtenus. Il est également essentiel de mettre en place des mécanismes de supervision et de rétroaction pour garantir que le système s'adapte de manière adéquate aux changements dans son environnement. Une fois ces étapes franchies, l'apprentissage automatisé permet d'accomplir une multitude de tâches, notamment l'identification et l'extraction de données pertinentes, la réalisation de prédictions ou d'estimations basées sur l'analyse des données, l'évaluation des probabilités associées à des événements spécifiques, l'adaptation autonome aux changements et aux évolutions, ainsi que l'optimisation des processus en fonction des modèles identifiés. En somme, l'apprentissage automatisé représente un outil puissant pour la résolution de problèmes complexes et l'amélioration des performances des systèmes informatiques dans une variété de domaines d'application [25].Le processus d'apprentissage nécessite la disponibilité de deux ensembles de données distincts :

- **Ensemble de données d'entraînement :** Ce corpus de connaissances est utilisé pour former notre algorithme d'apprentissage. Pendant cette phase, les paramètres du modèle peuvent être ajustés en fonction des performances obtenues.
- **Ensemble de données de test :** Ce jeu de données est utilisé exclusivement pour évaluer les performances du modèle sur des données qui n'ont pas été vues auparavant.

La théorie de l'apprentissage s'appuie sur des concepts mathématiques issus de la théorie des probabilités et de la théorie de l'information. Cela permet d'évaluer l'efficacité de différentes méthodes par rapport à d'autres, en termes d'optimalité et de performance.

On peut distinguer trois principaux types d'algorithmes d'apprentissage automatique (voir la figure I-10) :

- **Apprentissage supervisé.**
- **Apprentissage non supervisé.**
- **Apprentissage par renforcement.**

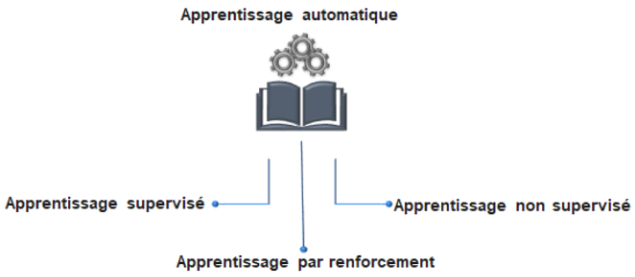


Figure II-6: Les types d'Apprentissage Automatique

II.4.1-L'apprentissage supervisé

L'apprentissage supervisé est une méthode fondamentale en machine Learning où un algorithme apprend à partir de données annotées. Ces données sont structurées sous forme de paires, où chaque exemple d'entrée est associé à une sortie correspondante, permettant ainsi au modèle de généraliser des schémas et de faire des prédictions précises. Au cours de l'entraînement, l'algorithme ajuste ses paramètres pour minimiser les écarts entre les sorties prédites et les sorties réelles, optimisant ainsi sa capacité à généraliser à de nouvelles données. Une fois entraîné, le modèle peut être utilisé pour prédire des résultats pour de nouvelles entrées. Cette approche est largement utilisée dans divers domaines, allant de la reconnaissance d'images à la prédiction de valeurs financières, contribuant ainsi à résoudre une gamme de problèmes complexes dans de nombreux secteurs [26].

II.4.2-L'apprentissage non supervisé

L'apprentissage non supervisé, c'est un peu comme explorer un territoire inconnu sans carte ni indications. Contrairement à l'apprentissage supervisé où l'on nous donne des balises pour nous guider, ici, on doit découvrir les schémas et les structures cachées par nous-mêmes. C'est comme si on explorait une forêt dense, cherchant des pistes et des indices pour comprendre comment les choses sont liées entre elles. Cette méthode est souvent utilisée pour regrouper des données similaires ou pour détecter des comportements inhabituels [26].

II.4.3-L'apprentissage par renforcement

La méthode d'apprentissage par renforcement vise à exploiter les données générées par l'interaction avec l'environnement pour guider les actions de manière à maximiser les récompenses ou à minimiser les risques. Pour créer des programmes intelligents, connus sous le nom d'agents, l'apprentissage par renforcement suit un processus itératif comprenant les étapes suivantes :

- Observation de l'état initial par l'agent.
- Utilisation d'une fonction de prise de décision pour déterminer l'action à entreprendre.
- Réception d'une récompense ou d'un renforcement de l'environnement suite à l'action réalisée.
- Stockage des informations sur la paire état-action associées à la récompense [27].Figure II -7offre une Vue d'Ensemble des Approches en Apprentissage Automatique.

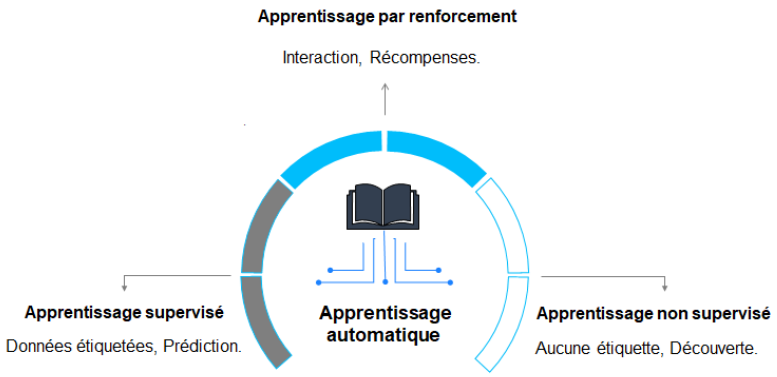


Figure II-7: Synoptique des Approches d'apprentissage Automatique

II.4.4-Algorithmes de ML

L'apprentissage automatique repose sur une variété d'algorithmes, chacun adapté à des types spécifiques de tâches et de données. Voici une liste de quelques-uns des algorithmes d'apprentissage automatique les plus couramment utilisés :

II.4.4.1-K plus proches voisins (KNN)

Le K plus proches voisins (KNN), également connu sous le nom de k-nearestneighbor, est une méthode d'apprentissage supervisée qui a été largement étudiée dans le domaine de l'estimation statistique et de la reconnaissance de motifs. Il est considéré comme une technique non paramétrique, ce qui signifie qu'il ne repose pas sur des hypothèses spécifiques concernant la distribution des données. Cette caractéristique le distingue des méthodes paramétriques telles que la régression linéaire.L'algorithme KNN est réputé pour sa simplicité. Il appartient à la catégorie de l'apprentissage paresseux (lazylearning), où la phase d'entraînement est minime voire inexistante. En effet, contrairement à de nombreux autres algorithmes d'apprentissage automatique, KNN n'implique pas de processus d'ajustement de paramètres basé sur des données d'entraînement massives. Cette particularité rend la phase d'entraînement relativement rapide et simple.L'approche KNN suppose que les données résident dans un espace de caractéristiques, où les points de données sont représentés par des

vecteurs. Ces vecteurs peuvent être unidimensionnels ou multidimensionnels, en fonction de la nature des données analysées. Cette méthode est couramment utilisée pour les tâches de classification et de régression[28].

Le processus de classification avec KNN consiste à identifier les k voisins les plus proches d'un nouvel exemple dans l'espace de caractéristiques, puis à attribuer à cet exemple la classe majoritaire parmi ces k voisins. De manière similaire, dans le contexte de la régression, les valeurs ciblent des k voisins les plus proches peuvent être utilisées pour prédire la valeur cible d'un nouvel exemple.KNN repose sur deux paramètres principaux : la fonction de similarité, qui mesure la proximité entre les exemples dans l'espace de caractéristiques, et le paramètre k, qui détermine le nombre de voisins à prendre en compte lors de la classification ou de la prédiction [29].À travers la figure II-8, nous pouvons discerne le rôle de KNN.

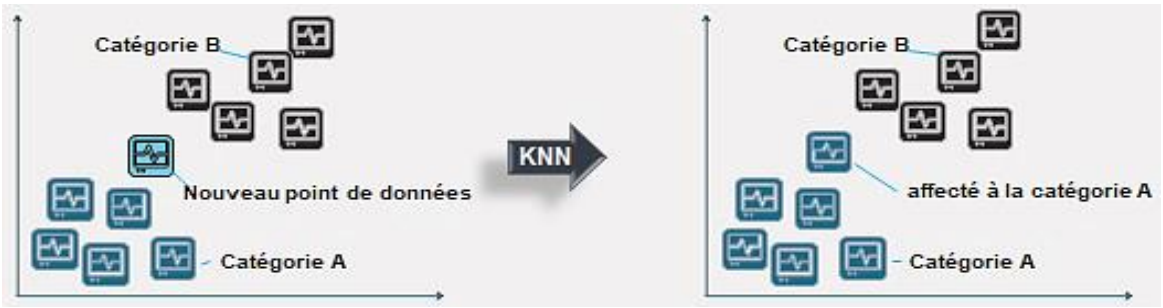


Figure II-8: Algorithme KNN

Cependant, malgré ses avantages évidents, la méthode KNN présente également des inconvénients. Parmi eux, on peut citer la nécessité de déterminer la valeur optimale de k, qui peut avoir un impact significatif sur les performances de l'algorithme. De plus, le temps de prédiction peut être relativement long, surtout lorsque le nombre de points de données est important, car il nécessite le calcul des distances entre le nouvel exemple et tous les exemples existants dans l'ensemble de données. Enfin, l'algorithme KNN peut être exigeant en termes de ressources mémoire, en particulier lorsqu'il est appliqué à des ensembles de données volumineux.

II.4.4.2-Les machines à support de vecteurs

La méthode des machines à vecteurs de support (SVM), introduite par Vapnik en 1990, est une approche de l'apprentissage supervisé utilisée pour résoudre des problèmes de classification et de régression. Elle repose sur deux concepts clés : la marge maximale et les fonctions noyau.Les SVM sont polyvalentes et peuvent être appliquées à divers domaines tels que la bio-informatique, la recherche d'information et la vision par ordinateur.Le principe fondamental des SVM est de trouver un séparateur entre deux classes qui soit le plus éloigné

possible de tous les points de données d'entraînement. Si les données peuvent être séparées par un hyperplan, le problème est dit linéairement séparable ; sinon, il est considéré comme non linéairement séparable.

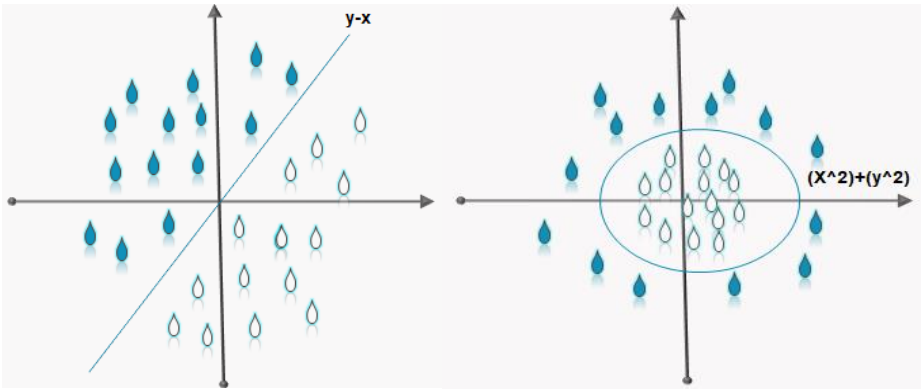


Figure II-9: Les SVM et la Continuité Linéaire (1) et Non Linéaire (2)

Lorsque les données sont linéairement séparables, il existe de nombreux séparateurs linéaires potentiels. Les SVM sélectionnent celui qui optimise la marge, c'est-à-dire la distance entre la surface de décision et les points de données les plus proches. Maximiser cette marge permet de déterminer un hyperplan optimal, assurant une séparation efficace entre les classes [29].La figureII-8et la figureII-10 offre un panorama détaillé de SVM.

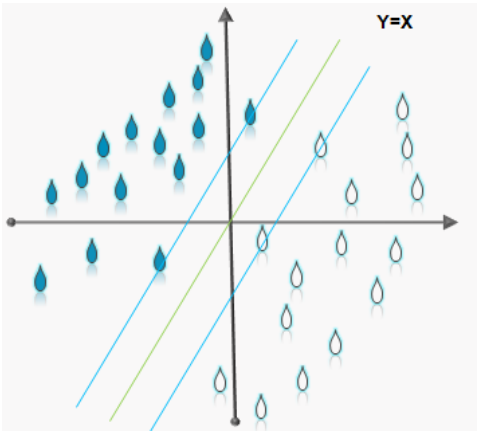


Figure II-10: Un modèle de marge

II.4.4.3-Arbres de décision

Fonctionnement des arbres de décision (voir la figure II-11) dans le cadre de l'apprentissage automatique supervisé. Cette méthode consiste à diviser l'espace des caractéristiques à l'aide de classificateurs faibles, organisés de manière hiérarchique sous forme d'arbre. Pour entraîner ces arbres, il est nécessaire de disposer d'un ensemble de données d'entraînement annotées, sur lesquelles les classificateurs faibles sont appliqués séquentiellement pour effectuer des divisions successives. L'objectif est de minimiser le taux

d'erreur de classification en identifiant des segments rectangulaires appropriés dans l'espace des caractéristiques. Étant donné la complexité de calculer toutes les partitions possibles, une approche séquentielle comme la division récursive binaire est adoptée. Chaque nœud de l'arbre représente un classificateur faible spécifique, et le processus d'ajustement est itératif jusqu'à ce que des régions disjointes soient obtenues, contenant soit des données de même classe, soit un nombre minimal de données. Afin de prévenir le surajustement des données d'entraînement, une régularisation est introduite dans la fonction objective, limitant ainsi le nombre de nœuds terminaux dans l'arbre. La détermination optimale du paramètre de régularisation peut être réalisée par validation croisée, permettant ainsi d'obtenir un arbre de décision efficace pour la généralisation aux nouvelles données [30].

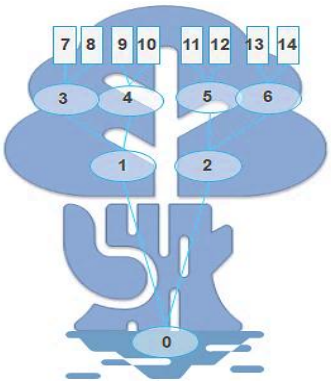


Figure II-11 : Arbre de décision

II.4.4.4-Les forêts aléatoires

Les forêts aléatoires (voir la figure II-12) offrent une solution à l'un des principaux inconvénients des arbres de décision. Une forêt aléatoire est essentiellement une collection d'arbres de décision, chacun étant légèrement différents desautres. L'idée derrière les forêts aléatoires est que chaque arbre peut offrir des prévisions assez précises, mais qu'il a tendance à surapprendre une partie des données. En construisant plusieurs arbres, tous performants mais se surajustant de manière différente, il est possible de réduire les effets du surajustement en moyennant leurs résultats. Cette réduction du surajustement, tout en conservant la capacité prédictive des arbres, peut être démontrée par des calculs mathématiques rigoureux.Pour mettre en œuvre cette stratégie, il est nécessaire de construire de nombreux arbres de décision. Chaque arbre doit être capable de prédire l'objectif de manière acceptable et doit également être différent des autres arbres. Les forêts aléatoires tirent leur nom de l'injection d'aléatoire dans la construction des arbres pour garantir leur diversité. Les arbres dans une forêt aléatoire sont randomisés de deux manières : en sélectionnant aléatoirement les points de données utilisés pour construire chaque arbre, et en sélectionnant aléatoirement les caractéristiques

pour chaque test de division.Les forêts aléatoires représentent l'algorithme le plus connu de la technique d'apprentissage ensembliste "bagging" ou "bootstrapaggregating". Cette technique implique la création de plusieurs instances d'un même modèle (plusieurs arbres de décision), chacune étant entraînée sur une portion aléatoire de l'ensemble des données. Après l'entraînement de chaque arbre, les résultats de chacun peuvent être agrégés pour effectuer la prédiction [31].

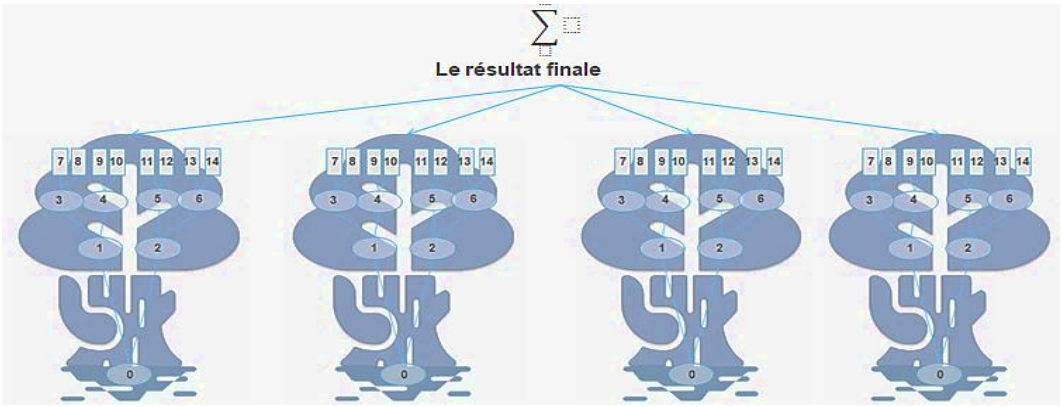


Figure II-12:Forêts aléatoires

II.5-Apprentissage en profondeur (DeepLearning)

L'apprentissage en profondeurest classé comme une branche d'apprentissage automatique, lequel est lui-même considéré comme une subdivision de l'IA (voir FigureII-13). L'objectif fondamental d'IA est de fournir un éventail d'algorithmes et de techniques destinés à résoudre les problèmes que les humains traitent instinctivement et presque sans effort [32].

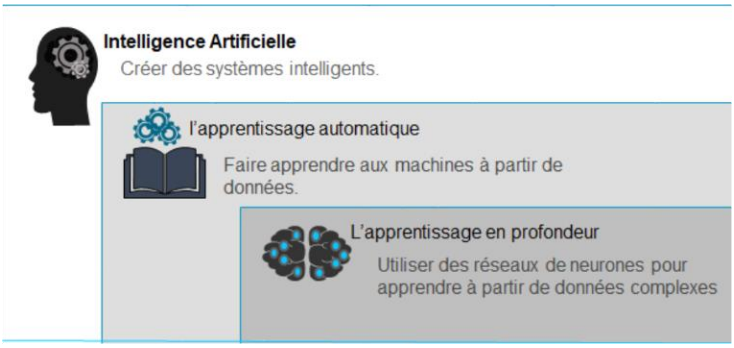


Figure II-13: La relation entre IA, ML et DL

C'est une méthode qui se base sur des algorithmes capables de reproduire les actions du cerveau humain en utilisant des réseaux de neurones artificiels. Ces réseaux se constituent de plusieurs couches de neurones interconnectés, ce qui permet de générer des modèles

complexes Non linéaires. L'apprentissage profond est couramment employé dans des secteurs tels que la reconnaissance d'images, la reconnaissance vocale, la conduite de véhicules autonomes, la recherche médicale, la détection de fraudes, et de nombreuses autres applications où la capacité d'apprentissage profond des machines est cruciale pour des tâches complexes [33]. On peut distinguer deux principaux types d'algorithmes d'apprentissage en profondeur (voir la figure II-14) :

- **Apprentissage supervisé.**
- **Apprentissage non supervisé.**

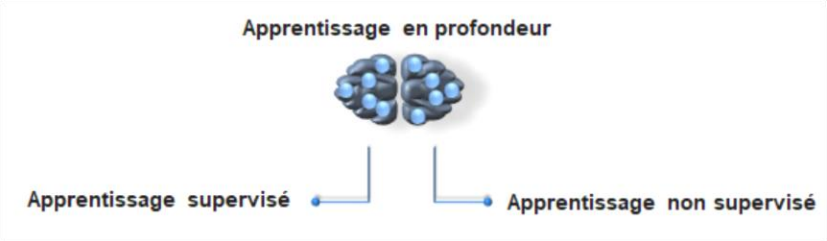


Figure II-14: Les types d'Apprentissage en profondeur

II.5.1-L'apprentissage supervisé

Cet axe d'étude implique d'entraîner un modèle à partir d'un ensemble de données où chaque exemple est associé à une étiquette. Ces étiquettes servent de référence pour guider le modèle vers la bonne prédiction. Par exemple, dans le contexte de la classification d'images, chaque image est accompagnée d'une étiquette définissant sa catégorie. Le modèle apprend à partir de cette correspondance entre les entrées et les étiquettes, visant à généraliser cette relation pour prédire avec précision les étiquettes pour de nouvelles données [34].La figureII-15 nous donne un exemple illustratif :

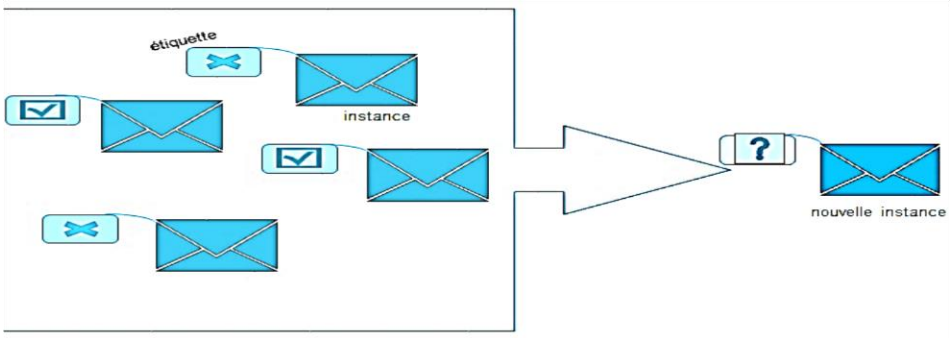
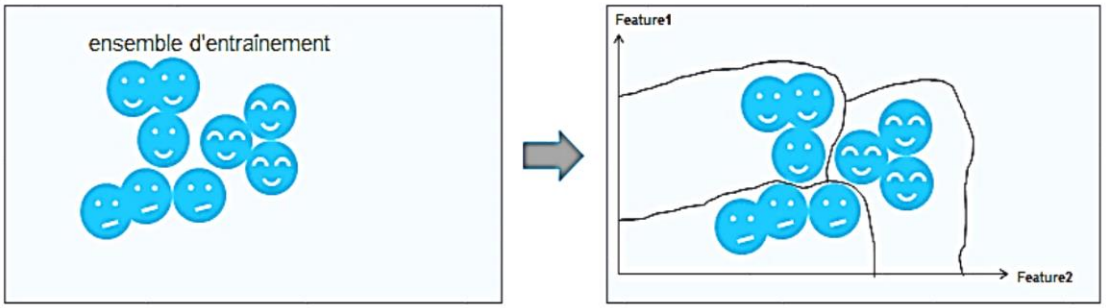


Figure II-15: Apprentissage supervisé

II.5.2-L'apprentissage non supervisé

Contrairement à l'apprentissage supervisé, cette approche n'utilise pas d'étiquettes pour guider l'apprentissage du modèle. Au lieu de cela, le modèle est exposé à un ensemble de données non étiquetées et doit trouver des structures ou des schémas intéressants au sein de ces données. Par exemple, dans la tâche de segmentation d'images, le modèle identifie les regroupements naturels de pixels similaires sans aucune information préalable sur les catégories. Cette méthode permet d'explorer les données de manière autonome, souvent utilisée pour la découverte de connaissances et l'analyse exploratoire des données. La figureII-16 nous donne un exemple illustratif



FigureII-16: Apprentissage non supervisé des données

II.6-Réseaux Neurones

II.6.1-Neurone Biologique

Le cerveau humain est composé d'une immense population de plus de 10 milliards deneurones, tous étroitement liés les uns aux autres, chaque neurone étant connecté àenviron 10 000 autres. Le corps cellulaire d'un neurone, appelé « soma » est le point central où convergent les entrées (les dendrites) et les sorties (les axones), assurant ainsi la liaison avec d'autres neurones. Ces neurones agissent comme des centres detraitement où se produisent des réactions biochimiques essentielles pour recevoir, traiteret transmettre les informations. Les dendrites, qui forment des réseaux arborescents defibres nerveuses, sont reliées au soma où réside le noyau cellulaire. L'axone, une longue fibre unique, s'étend à partir du soma, se ramifie en multiples branches et se connecte à d'autres neurones par des synapses.La transmission des signaux d'un neurone à un autre au niveau des synapses est unprocessus chimique complexe, impliquant la libération de substances chimiques spécifiques à partir de l'extrémité émettrice de la jonction. Cette interaction modifie le potentiel électrique à l'intérieur de la cellule réceptrice, ce qui peut entraîner soit uneaugmentation, soit une diminution de ce potentiel. Lorsque le potentiel atteint un seuilcritique, une impulsion est

générée dans l'axone, ce qui conduit à l'activation du celle [35].Les subtilités sont clairement exposées dans la figure II-17.

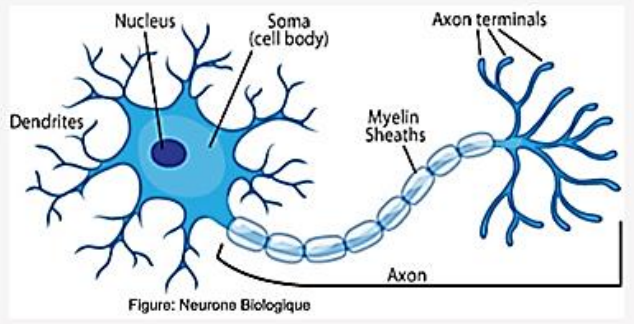


Figure II-17:Neurone Biologique

II.6.2-Neurone Artificiel

Les réseaux neuronaux artificiels (ANN), s'inspirant des réseaux neuronaux biologiques, sont des systèmes informatiques massivement parallèles. Ils se composent d'un grand nombre de processeurs simples reliés entre eux par de multiples interconnexions. Les modèles d'ANN cherchent à reproduire certains principes d'organisation observés dans le fonctionnement du cerveau humain. Dans cette perspective, un type particulier de réseau considère les nœuds comme des « neurones artificiels », formant ainsi les ANNs. Ces neurones artificiels sont des modèles informatiques inspirés des neurones naturels. Etant donné que la fonction des ANN est de traiter l'information, ils sont principalement utilisésdans les domaines qui y sont liés. Il existe une grande variété d'ANN qui sont utilisés pourmodéliser de vrais réseaux neurones et d'étudier le comportement et le contrôle chez les animaux et les machines, mais il existe des ANN qui sont utilisées à des fins d'ingénierie, tellela reconnaissance de formes, la prévision et la compression de données. Ceux-ci se composentessentiellement d'intrants (comme les synapses), qui sont multipliés par des poids. Lespoidsattribués avec chaque flèche représentent le flux d'information. Ces poids sont ensuitecalculéspar une fonction mathématique qui détermine l'activation des neurones. Une autrefonctioncalcule la sortie des neurones artificiels (parfois en fonction d'un certain seuil). Lesneuronesde ce réseau additionnent simplement leurs entrées seules entrées, leur sortie sera l'entrée qu'ils ont reçue multipliée par un poids. Dans la figure II-18on peut l'observer en détail[36].

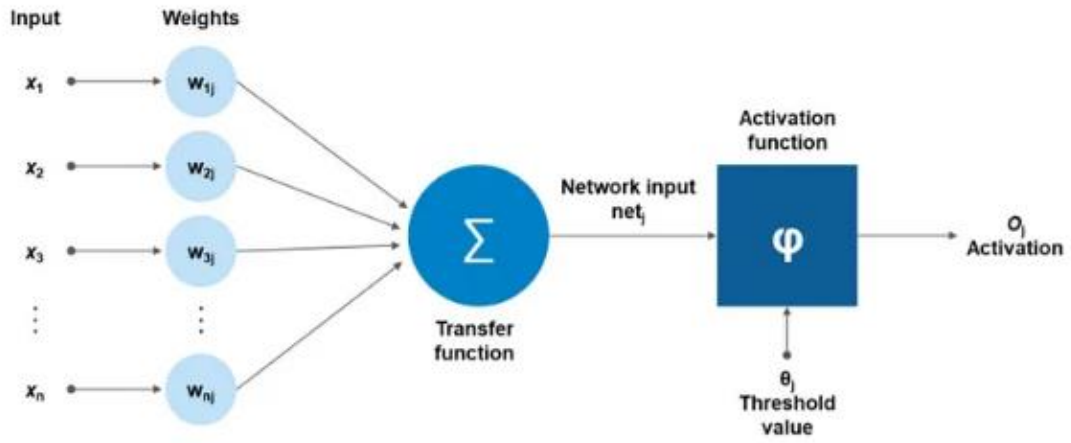


Figure II-18:Structure d'un Réseau Neurone Artificiel ANN

II.6.3-Architecteur des réseaux de neurones

La topologie ou l'architecture d'un réseau neuronal artificiel (ANN) décrit la manière dont les neurones sont connectés et organisés. En général, les ANN peuvent adopter une connectivité totale, où chaque neurone est relié à tous les autres neurones du réseau, ou une connectivité locale, où les neurones sont connectés uniquement à leurs voisins proches. On distingue ainsi deux principales topologies de ANN : les réseaux de neurones non récursifs, également appelés réseaux « feed-forward », et les réseaux de neurones récursifs, également connus sous le nom de réseaux « feed-back » [36]. .

II.6.4-Réseaux de neurones non bouclés

Les réseaux de neurones non bouclés, aussi connus sous les noms de réseaux « proactifs », « detype perceptron », ou encore « feed-forward », sont caractérisés par une propagation dessignaux dans une seule direction, allant de la couche d'entrée à la couche de sortie, sans aucuneboucle de rétroaction. Ils sont généralement considérés comme statiques, car les entrées et lessorties sont indépendantes dans le temps. Ce type de réseau neuronal est souvent utilisé pourdes tâches telles que l'approximation de fonctions non linéaires, la classification, ou encore lamodélisation de processus statiques non linéaires [37].

II.6.5-Réseaux de neurones bouclés

Les réseaux « récurrents » ou bien « feed-back » se caractérisent par la présence, aumoins, d'une boucle de rétroaction des neurones de sorties vers les neurones d'entrée. Ces réseaux sont dynamiques ; ils régissent par des équations aux différences nonlinéaires à cause des retards associés aux connexions Ils sont utilisés fréquemment àl'affectation des tâches de modélisation de systèmes dynamiques, de commande de processus, ou de filtrage [37].

II.6.4-Réseaux de neurones convolutifs

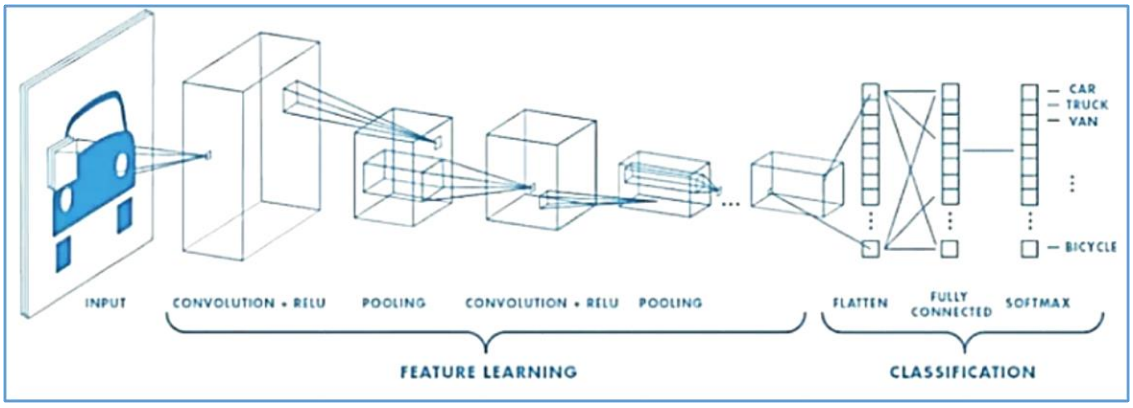
Sont des outils utilisés pour l'apprentissage en profondeur, particulièrement adaptés auximages mais aussi employés dans d'autres domaines comme le texte et les signaux.Inspirés de la structure biologique du cortex visuel, ils utilisent des arrangements decellules activées par des sous-régions visuelles appelées champs réceptifs. Contrairement à d'autres réseaux neuronaux, les neurones dans une couche convolutivese connectent aux sous-régions des couches précédentes au lieu d'être entièrement connectés [38].

II.6.5-Modèles d'apprentissage profond

Cette section mettra en lumière les modèles d'apprentissage profond que nous avons choisis pour notre proposition, à savoir les CNN, LSTM et RNN.

II.6.5.1-Réseau de neurones à convolution

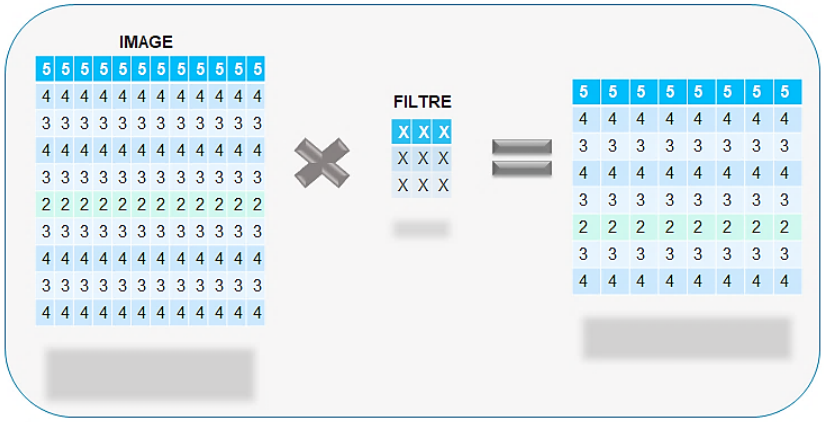
Les réseaux de neurones à convolution (CNN) (Figure II-19) tirent leur nom de l'utilisation de l'opération mathématique deconvolution. Ils se distinguent en ce sens qu'ils emploient la convolution au lieu de la multiplicationmatricielle classique dans au moins l'une de leurs couches. Les CNN se révèlent être parmi les meilleurs algorithmes d'apprentissage, car ils excellent dans l'extraction de fonctionnalités significatives à partir dedonnées localement corrélées. Une fois les caractéristiques extraites par les noyaux convolutifs, elles sont, ensuite traitées par des unités de traitement non linéaires, aussi appelées fonctions d'activation. Celles-cine se contentent pas seulement d'apprendre des abstractions, mais introduisent également de la non-linéarité dans l'espace des fonctionnalités. Cette non-linéarité crée des modèles d'activation variés pourdifférentes réponses, facilitant ainsi la distinction des différences sémantiques dans les images.



FigureII-19: Architecture de base de CNN

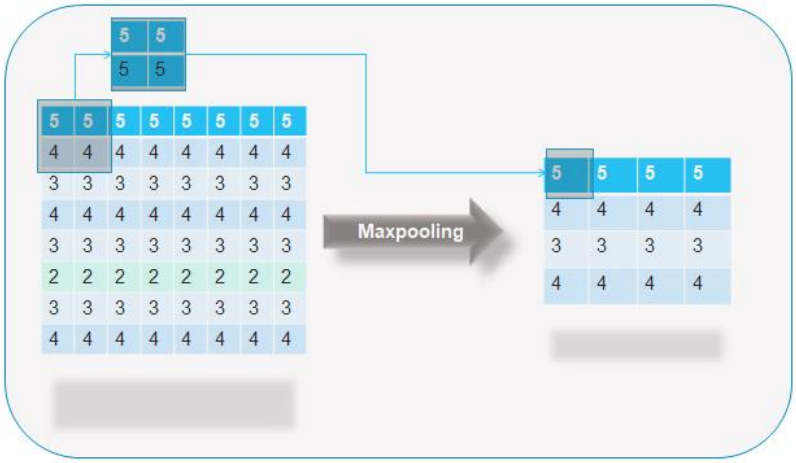
- **Couche de convolution :** La convolution est une étape fondamentale dans le traitement des images. Elle consiste à extraire des entités à partir d'une image en

préservant la relation entre les pixels. Cette opération mathématique utilise des petits carrés de données d'entrée, appelés filtres (voir la figure II-20) ou noyaux, pour apprendre les caractéristiques de l'image [39].



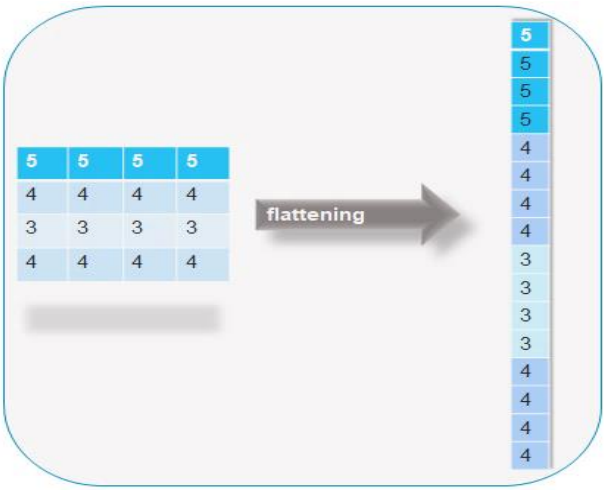
FigureII-20:L'opération de convolution

- **La couche de mise en commun (Pooling) :** Est typiquement positionnée entre deux couches de convolution. Elle effectue un processusd'échantillonnage discret. Son objectif est de réduire la dimensionnalité (voir la figure II-21) de la représentationd'entrée, comme une image ou une matrice de sortie de couche cachée, en tenant comptedes caractéristiques présentes dans les régions regroupées. Il existe plusieurs types depooling [39].



FigureII-21:Opération de mise en commun (Pooling)

- **La couche d'aplatissement (flattening)** : La couche d'aplatissement convertit les données en un format unidimensionnel en prenant tous les neurones d'une couche précédente et en le disposant dans une seule dimension. Cela permet de passer des données de sortie 2D ou 3D des couches de convolution et de mise en commun à un format de vecteur 1D (voir la figure II-22) qui peut être alimenté dans une couche entièrement connectée (fullyconnected) pour la classification ou la régression.



FigureII-22:La couche d'aplatissement

- **Couche entièrement connecté(fully-connected) :** Représente une étape cruciale dans le processus de traitement des données. Elle agit Comme un point de convergence où les informations extraites lors des phases précédentes, Telles que la convolution et le pooling, sont agrégées. En utilisant des vecteurs de poids et D'entrée, un produit scalaire est calculé pour générer la sortie finale (voir la figure II-23). Cette étape peut être Comparée à une opération de fusion des informations, visant à produire une représentation Consolidée et optimisée des données d'entrée [39].

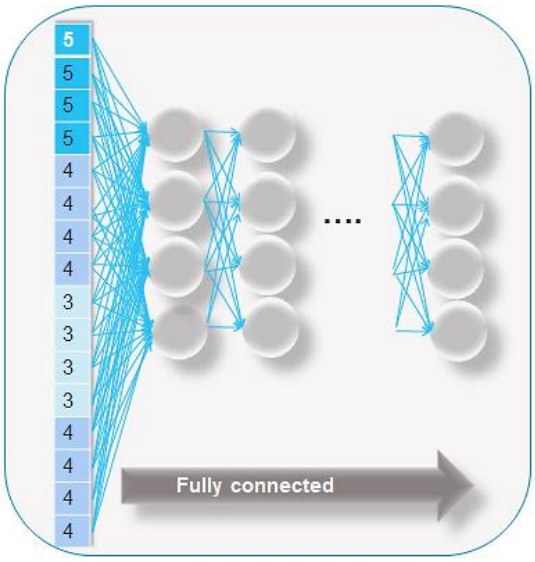


Figure II-23:Couche entièrement connecté(fullyconnected)

II.6.5.2-Réseaux Neuronaux Récurrents

Les Réseaux Neuronaux Récurrents (RNN) sont une version importante des réseaux neuronaux, particulièrement utile dans le traitement du langage naturel. Ils portent ce nom car ils répètent la même action pour chaque élément d'une série, et leur résultat dépend des calculs précédents. On peut les imaginer comme ayant une sorte de « mémoire » qui enregistre les informations des étapes précédentes. En théorie, les RNN pourraient utiliser des séquences de données de n'importe quelle longueur, mais en pratique, ils se concentrent généralement sur un nombre limité d'étapes en arrière. Les RNN permettent aux prédictions antérieures d'influencer les calculs futurs grâce à ce qu'on appelle des « états cachés » [40].En se référant à la figureII-24, on peut examiner en détail un Réseau Neuronaux Récurrents

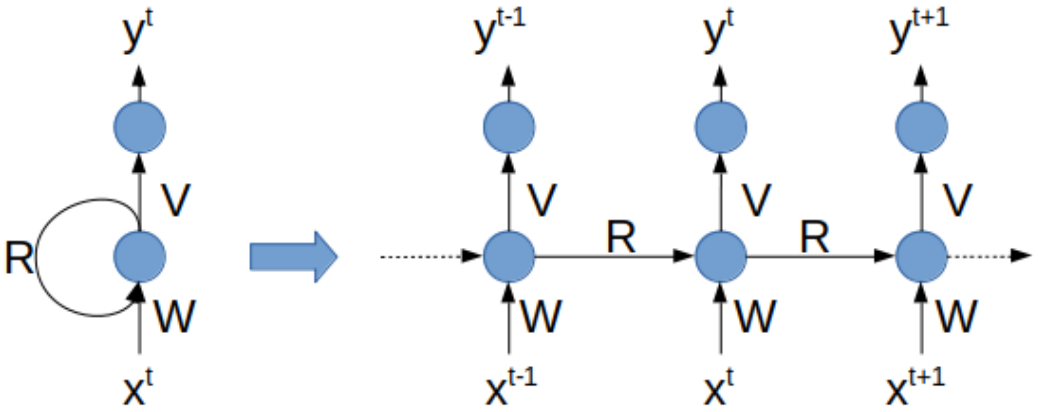
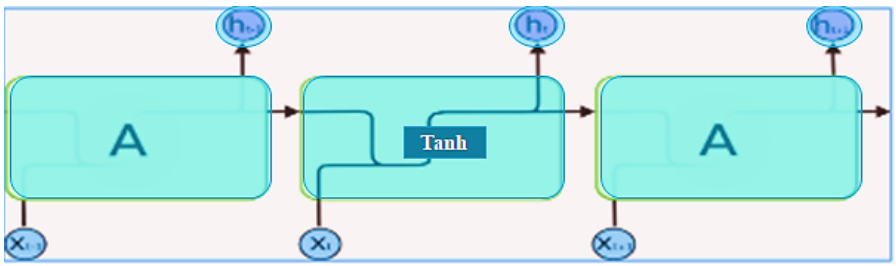


Figure II-24:Un Réseau Neuronaux Récurrents (RNN)

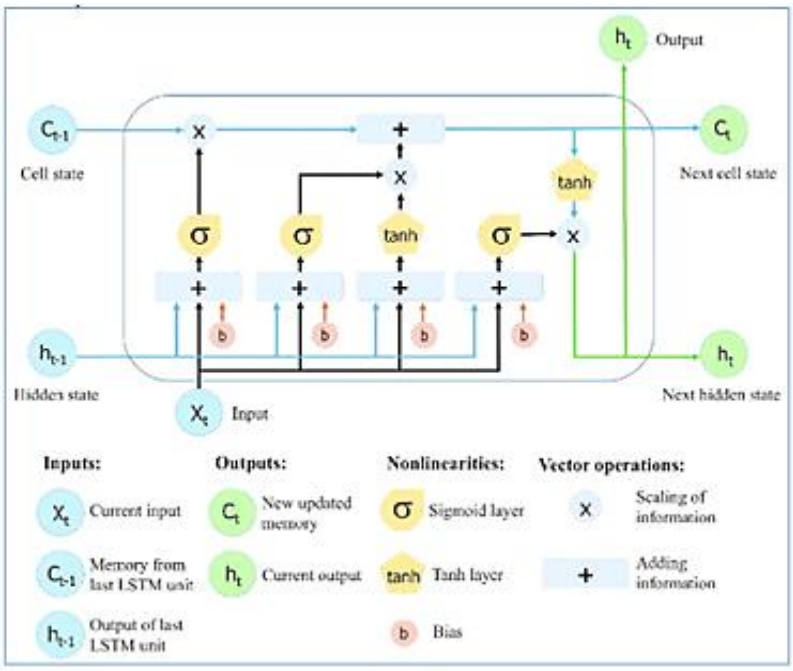
II.6.5.3-Réseaux Long Short-Term Memory

Ce sont un type spécial de RNN, capable d'apprendre les dépendances à long terme. Ils ont été introduits par (Hochreiter et Schmidhuber, 1997), et ont été affinés et popularisés par de nombreuses personnes dans les travaux suivants. Ils fonctionnent extrêmement bien sur une grande variété de problèmes et sont maintenant largement utilisés (Hochreiter et Schmidhuber, 1997). Les LSTM sont explicitement conçus pour éviter le problème de dépendance à long terme. Se souvenir des informations pendant de longues périodes est pratiquement leur comportement par défaut, pas quelque chose qu'ils ont du mal à apprendre ! Tous les réseaux de neurones récurrents ont la forme d'une chaîne de modules répétitifs de réseau de neurones. Dans les RNN (voir la figure II-25) standard, ce module répétitif aura une structure très simple, telle qu'une seule couche de tanh[41].



FigureII-25:Architecture de RNN

Les LSTM ont également une structure en chaîne, mais le module répétitif à une structure différente. Au lieu d'avoir une seule couche de réseau neuronal, il y en a quatre, interagissant d'une manière très spéciale. La figureII-26met en avant les éléments cruciaux.



FigureII-26: LSTM

Un réseau LSTM typique est composé de blocs de mémoire appelés cellules. Deux états sont en cours transféré à la cellule suivante, l'état de la cellule et l'état caché. L'état cellulaire est la chaîne principale de flux de données, qui permet aux données de circuler en avant essentiellement inchangées. Cependant, certaines transformations linéaires peuvent se produire. Les données peuvent être ajoutées ou supprimées de l'état de la cellule via des portes sigmoïdes. Une porte est similaire à une couche ou à une série d'opérations matricielles, qui contiennent différents poids individuels. Les LSTM sont conçus pour éviter le problème de dépendance à long terme car ils utilisent des portes pour contrôler le processus de mémorisation. La première étape de la construction d'un réseau LSTM consiste à identifier les informations qui ne sont pas requises et qui seront manquées de la cellule à cette étape. Ce

processus d'identification et d'exclusion de données est décidé par la fonction sigmoïde, qui prend la sortie de la dernière unité LSTM $(ht-1)$ au temps $t-1$ et l'entrée courante Xt au temps t. De plus, la fonction sigmoïde détermine quelle partie de l'ancienne sortie doit être éliminée. Cette porte est appelée la porte de l'oubli (ou ft); où ft est un vecteur avec des valeurs allant de 0 à 1, correspondant à chaque nombre dans l'état de cellule, $Ct-1$

$$ft = (Wf\,[ht-1\,, Xt\,] + bf)$$

Ici, σ est la fonction sigmoïde, et Wf et bf sont les matrices de poids et le biais, respectivement, la porte du oubliez. L'étape suivante consiste à décider et à stocker les informations de la nouvelle entrée Xt dans l'état de cellule ainsi qu'à mettre à jour l'état de cellule. Cette étape contient deux parties, la couche sigmoïde et la seconde la couche $tanh$. Tout d'abord, la couche sigmoïde décide si les nouvelles informations doivent être mises à jour ou ignorées (0 ou 1), et deuxièmement, la fonction $tanh$ donne du poids aux valeurs qui sont passées, en décidant de leur niveau d'importance (−1 à 1). Les deux valeurs sont multipliées pour mettre à jour le nouvel état de cellule. Cette nouvelle mémoire est ensuite ajoutée à l'ancienne mémoire $Ct-1$ résultant en Ct.

$$it = (Wi\,[ht-1\,, Xt\,] + bi) \qquad \text{Eq I-1}$$

$$Nt = tanh(Wn\,[ht-1\,, Xt\,] + bn) \qquad \text{Eq I-2}$$

$$Ct = Ct-1\,ft + Nt \qquad \text{Eq I-3}$$

Ici, $Ct-1$ et Ct sont les états de cellule au temps $t-1$et t, tandis que W et b sont les matrices de poids et le biais, respectivement, de l'état de la cellule. – Dans la dernière étape, les valeurs de sortie ht sont basées sur l'état de la cellule de sortie Ot mais il s'agit d'une version filtrée. Tout d'abord, une couche sigmoïde décide quelles parties de l'état de la cellule parviennent à la sortie. Ensuite, la sortie du la porte sigmoïde Ot est multipliée par les nouvelles valeurs créées par la couche $tanh$ à partir de l'état de la cellule, avec une valeur comprise entre $-1\ et\ 1$.

$$Ot = (Wo\,[ht-1\,, Xt\,] + bo\,) \qquad \text{Eq I-4}$$

$$h\,t = Ottanh(Ct\,) \qquad \text{Eq I-5}$$

Ici, Wo et bo sont les matrices de poids et le biais, respectivement, de la porte de sortie[41].

II.7-IA Générative

IA Générative est une branche d'IA qui se concentre sur la création de nouveaux contenus, tels que des images, du texte ou de la musique, à l'aide de modèles d'apprentissage automatique. Contrairement à d'autres approches de l'IA qui se concentrent sur des tâches spécifiques comme la classification ou la prédiction, l'AI générative vise à stimuler la créativité des machines en leur permettant de produire des résultats autonomes et originaux, souvent en imitant les caractéristiques des données d'entraînement**.**

II.7.1-Architectures couramment utilisées en AI Générative

- **Réseaux Génératifs Adverses (GAN) :** Les GAN sont composés de deux réseaux de neurones en compétition : un générateur qui crée du contenu synthétique (images, texte, etc.) et un discriminateur qui essaie de déterminer si le contenu est réel ou généré. Ces deux réseaux s'entraînent de manière itérative, permettant au générateur de produire du contenu de plus en plus réaliste. Parmi les applications populaires de cette technologie, on peut citer la modification ou la création d'images, la colorisation d'images en noir et blanc, ou encore l'amélioration de la définition d'une image (voir la figureII-27). Il est par exemple possible de créer de faux visages grâce à cette technologie.[42]



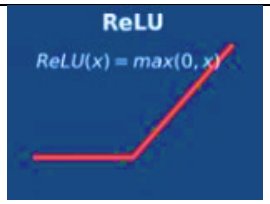
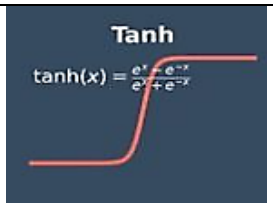
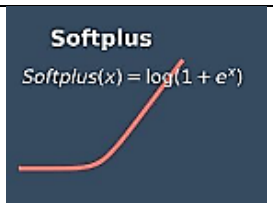
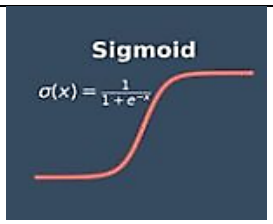
FigureII-27:La génération de visages via les GAN

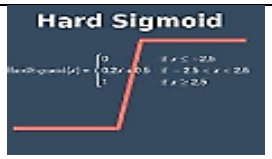
- **Réseaux Neuronaux Génératifs (GNN) :** Les GNN sont des modèles génératifs basés sur des réseaux neuronaux qui apprennent à modéliser la distribution des données d'entraînement pour générer de nouvelles données réalistes. Contrairement aux GAN, les RNG n'utilisent pas de compétition entre un générateur et un discriminateur, mais plutôt une approche unifiée où un seul réseau est entraîné pour générer des données.[43]

II.8-Fonctions d'activation

Les fonctions d'activation sont des éléments essentiels dans les réseaux de neurones, car elles introduisent la non-linéarité nécessaire à la modélisation de relations complexes entre les données. Le choix de la fonction d'activation appropriée dépend de la nature de la tâche à accomplir et des caractéristiques des données.

Tableau II -1 : Les fonctions d'activation

Fonction	Type	Equation	Allure	Abréviation
Unités Linéaires Rectifié	Linéaire	$F(x) = max(0, x)$		Relu
Unités Linéaires Exponentielles	Linéaire	$F(x) = \begin{cases} xsix > 0 \\ a(e^x - 1)sinon \end{cases}$		Elu
LeakyReLU	Linéaire	$f(x) = \begin{cases} xsix > 0 \\ axsinon \end{cases}$		Leaky Relu
Fonction Tangente Hyperbolique	Polynomiale	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$		Tanh
Softmax	Normalisation	$\frac{e^{xi}}{\sum_j e^{xj}}$ Pour chaque Elément e_j		Softmax
Sigmoïde	Logistique	$f(x) = \frac{1}{1 + e^{-x}}$		Sigmoid

Fonction de Seuil (Echelon unitaire)	Linéaire	$f(x) = \begin{cases} 0 & six < seuil \\ 1 & six \geq seuil \end{cases}$		Heaviside

II.9-Aggrégation des modèles

L'agrégation de modèles dans le domaine de l'intelligence artificielle (IA) et de l'apprentissage automatique est une technique utilisée pour combiner plusieurs modèles individuels en un modèle global plus performant. Cette approche vise à améliorer la précision et la robustesse des prédictions en exploitant la diversité des modèles agrégés.

II.9.1-Techniques d'agrégation de modèles

- **Bagging (Bootstrap Aggregating) :**
  - Crée plusieurs modèles de base (par exemple des arbres de décision) en utilisant des échantillons bootstrap différents du jeu de données d'entraînement.
  - Agrège les prédictions de ces modèles de base (par vote majoritaire pour la classification, moyenne pour la régression) pour obtenir une prédiction finale plus robuste.[44]
- **Boosting**
  - Construit des modèles de base de manière séquentielle, en se concentrant à chaque étape sur les exemples mal classés par le modèle précédent.
  - Attribue des poids plus importants aux modèles les plus performants pour la prédiction finale.
  - Algorithmes populaires : AdaBoost, Gradient Boosting, XGBoost.[44]
- **Stacking**
  - Entraîne d'abord plusieurs modèles de base différents sur les données.
  - Utilise les prédictions de ces modèles de base comme entrées pour entraîner un méta-modèle qui effectue la prédiction finale.
  - Permet de combiner les forces de différents types de modèles.[44]

II.10-Internet d'objet

Est la toile invisible qui tisse un lien numérique entre les objets physiques, leur permettant de communiquer, de collecter des données et de prendre des décisions autonomes, transformant ainsi notre environnement en un écosystème intelligent et connecté.

II.10.1-Architecture d'IoT

Architecture IoT proposé d'un point de vue technique, est divisé en trois couches :

II.10.1.1-Couche Perception (ou Capteurs)

- Cette couche représente le niveau le plus bas de l'architecture IoT où les données physiques sont collectées. Les capteurs, les dispositifs de mesure et les actionneurs sont situés dans cette couche.
- Les capteurs peuvent être de divers types, tels que des capteurs de température, d'humidité, de mouvement, de lumière, etc.
- Les dispositifs dans cette couche convertissent les données physiques en données numériques pour un traitement ultérieur.

II.10.1.2-Couche Réseau (ou Connectivité)

- La couche réseau est responsable de la transmission des données collectées des capteurs vers les couches supérieures pour le traitement et l'analyse.
- Cette couche comprend les protocoles de communication, les réseaux sans fil (comme Wi-Fi, Bluetooth, Zigbee, LoRa, etc.), ainsi que les passerelles IoT qui agrègent et transmettent les données vers le Cloud ou le réseau local.

II.10.1.3-Couche Application (ou Services)

- C'est la couche supérieure où les données provenant des capteurs sont traitées, analysées et utilisées pour prendre des décisions.
- Les applications IoT, les services cloud, les algorithmes d'analyse de données, L'intelligence artificielle et l'apprentissage automatique sont souvent impliqués dans cette couche.
- Les utilisateurs interagissent avec les données via des applications et des interfaces utilisateur pour surveiller, contrôler et prendre des décisions basées sur les informations fournies par l'IoT [45].

II.11-Conclusion

En conclusion, ce chapitre a exploré les bases de l'IA et du prétraitement, mettant en lumière L'importance des prétraitements, du ML et DL, des réseaux neuronaux biologiques et desapplications IoT. Ensemble, ces technologies ouvrent de vastes possibilités pour améliorer notreinteraction avec le monde physique et résoudre des problèmes complexes. Elles promettent unavenir où les machines peuvent apprendre, raisonner et interagir de manière autonome, ouvrant lavoie à une société plus intelligente et plus connectée.

Chapitre III : Résultats du Système

III.1-Introduction

Dans ce chapitre, nous présentons en détail les différentes étapes et outils utilisés dans notre étude pour développer et évaluer un modèle de réseau de neurones convolutifs (CNN) appliqué à la classification de signaux audio. Nous commençons par décrire les matériels et logiciels employés, ainsi que les bibliothèques utilisées. Ensuite, nous introduisons la méthodologie proposée, suivie d'un diagramme détaillant le système envisagé et l'architecture CNN utilisée. La base de données est décrite avec une attention particulière au prétraitement des données, incluant les coefficients cepstraux en fréquences Mel (MFCC) et le champ angulaire Gramian (GAF). Nous expliquons aussi les différentes étapes de traitement du signal, comme le redimensionnementet la décomposition du signal. Les résultats expérimentaux sont présentés à travers des graphiques de perte et de précision pour la validation et l'entraînement, des rapports de classification, et diverses matrices de confusion. Enfin, nous comparons notre approche avec des travaux connexes et discutons de la réalisation du nœud d'acquisition et des techniques d'adaptation et de masquage des données.

III.2-Matériels utilisées

Le déploiement des modèles CNN pour la classification nécessite deux phases séquentielles du processus : la première phase est celle de l'apprentissage, où le modèle acquiert des connaissances, suivie de la phase d'inférence, où le modèle est déployé pour faire des prédictions et des classifications. La phase d'apprentissage est logicielle (soft), tandis que la phase d'inférence est (hard) et est implémentée sur une plateforme Arduino.

III.2.1-Software

III.2.1.1-Python

Python est un langage de programmation puissant, facile à apprendre et largement utilisé. Il est particulièrement adapté à la programmation scientifique en raison de sa simplicité, de son extensibilité, de sa portabilité et de sa vaste bibliothèque de modules. Python est utilisé dans de nombreux domaines, y compris le traitement audio, l'analyse d'images, la programmation web et les interfaces graphiques**.** De plus,Python est le langage de programmation open source le plus employé par les informaticiens. Ce langage s'est propulsé en tête de la gestion d'infrastructure, d'analyse de données ou dans le domaine du développement de logiciels. En effet, parmi ses qualités, Python permet notamment aux développeurs de se concentrer sur ce qu'ils font plutôt que sur la manière dont ils le font. Il a libéré les développeurs des contraintes de formes qui occupaient leur temps avec les langages

plus anciens. Ainsi, développer du code avec Python est plus rapide qu'avec d'autres langages.

Les principales utilisations de Python par les développeurs sont :

- Programmation d'applications.
- Création des services web.
- Génération des codes.
- Métaprogrammation.
- Techniquement, ce langage servira surtout pour le scripting et l'automatisation (interaction avec les navigateurs web) [43].

III.2.1.2-MATLAB

La plateforme MATLAB est optimisée pour résoudre des problèmes scientifiques et d'ingénierie. Le langage MATLAB matriciel est la manière la plus naturelle au monde pour exprimer les mathématiques computationnelles. Les graphiques prédéfinis permettent de visualiser et d'obtenir facilement des informations à partir des données. Une vaste bibliothèque de toolboxes prédéfinies qui permette immédiatement d'en savoir plus sur des algorithmes essentiels à votre domaine. L'environnement desktop est propice à l'expérimentation, à l'exploration et à la découverte. Ces outils et ces fonctionnalités MATLAB font tous l'objet de tests rigoureux et sont conçus pour fonctionner ensemble [44].

III.2.2- Hardware

III.2.2.1-PC portable

Les caractéristiques de notre PC portable DESKTOP-O5CJ0QN sont les suivants:

- Système d'exploitation : Windows 10 Professionnel
- Processeur : Intel Core i5 - 6300U CPU @ 2.40GHz 2.50GHZ
- Mémoire RAM : 4 Go (3.88 Go utilisable).
- Modele du système : HP probook 640 G2

III.2.2.2-Capteur AD8232

Le module économique de capteur ECG AD 8232 est spécialement conçu pour détecter les activités électriques du cœur. Étant donné la nature souvent bruitée des signaux ECG générés par le cœur, l'AD 8232 est conçu pour extraire et amplifier les petits signaux malgré la présence de bruit de fond. Ce bruit de fond est principalement causé par les activités musculaires et les artefacts de mouvement du patient. La figure III-1 illustre un exemple de ce

module de capteur, qui est non invasif et capable de mesurer la fréquence cardiaque, fournissant un signal directement exploitable par divers contrôleurs tels que MSP430, Arduino ou Raspberry Pi. Cette conception permet d'obtenir rapidement un signal de sortie à partir d'un contrôleur intégré ou d'un convertisseur analogique-numérique (ADC), tout en conservant une consommation d'énergie ultrabasse [45].

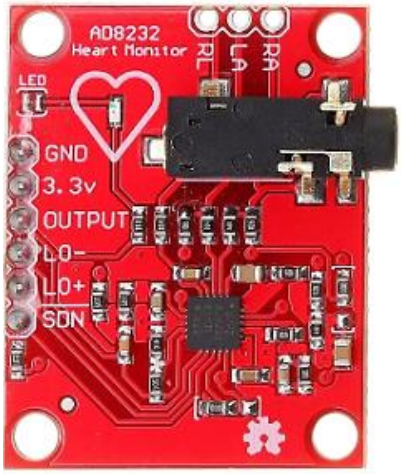


Figure III-1 : Capteur ECG AD8232

Et on relier ce capteur avec des électrodes, ce dernier utilisées dans ce projet sont des électrodes jetables qui offrent une alternative rapide, facile et plus hygiénique aux électrodes réutilisables ou aux électrodes humides. Ces électrodes sont pré-gélifiées et sont appelées électrodes sèches. Au lieu d'utiliser un système d'électrodes à 12 dérivations et de conserver l'appareil en vrac, il a été utilisé un système d'électrodes à 3 dérivations où les électrodes sont placées sur le poignet (voire la figure III-2).



Figure III-2: Les électrodes utilisées

III.2.2.3-Carte Arduinouno

L'ArduinoUno (voir la figure III-3) est une carte électronique populaire qui peut être utilisée pour réaliser une variété de projets. Elle est équipée d'un petit ordinateur appelé microcontrôleur qui permet de contrôler différentes parties d'un projet. L'ArduinoUno est très apprécié car il est facile à utiliser. Il vous suffit de brancher quelques fils et de taper un peu de code sur votre ordinateur pour le faire fonctionner. C'est un outil idéal pour découvrir la programmation et l'électronique.

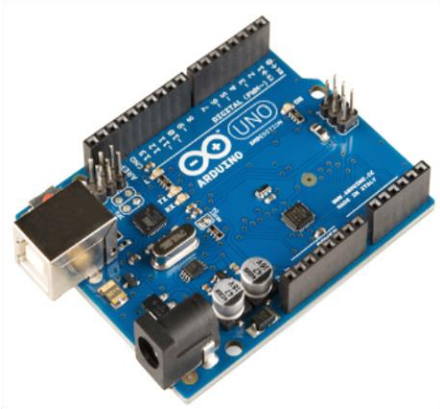


Figure III-3: CarteArduinoUno

III.3-Bibliothèques utilisés

Le tableau III-1 montre les bibliothèques utiliser

Tableau III-1 : Les bibliothèques utilisées

Bibliothèque	Description	Logo
Matplotlib	Matplotlib est une bibliothèque Python pour tracer des graphiques bidimensionnels. Elle est utilisée dans diverses interfaces utilisateur et permet de développer des applications de rapports, des applications analytiques interactives etdes applications de tableau de bord [46].	matplotlib
Tensorflow	TensorFlow est une bibliothèque open-source pour la programmation de flux de données, offrant un bon support pour l'apprentissage automatique et les réseaux de neurones profonds. Il permet de travailler efficacement avec des tableaux multidimensionnels et offre une grande extensibilité pour le calcul sur des ensembles de données	TensorFlow

	massifs [47].	
Sklearn	Scikit-learn est une bibliothèque Python pour l'apprentissage automatique supervisé et non supervisé. Elle offre des outils puissants pour la classification, la régression, le regroupement et la réduction de la dimensionnalité [48].	
Librosa	Librosa est une bibliothèque Python pour l'analyse de la musique et de l'audio. Elle est largement utilisée pour extraire des caractéristiques, analyser les spectres et manipuler des séries temporelles audio. Cette bibliothèque est précieuse pour la récupération d'informations musicales, le traitement des signaux audio et les applications d'apprentissage automatique [49]	
Keras	La bibliothèque Keras est une bibliothèque open source écrite en Python qui sert de couche d'abstraction pour les frameworks de deeplearning tels que TensorFlow, Microsoft Cognitive Toolkit (CNTK) et Theano. Elle facilite la création et l'entraînement de réseaux de neurones artificiels. Keras offre une interface simple et intuitive pour la construction de modèles de deeplearning, ce qui en fait un choix populaire parmi les chercheurs et les praticiens en apprentissage automatique [50].	
Pyts (Python for Time Series)	La bibliothèque Pyts (Python for Time Series) est un outil open source en Python conçu pour faciliter la manipulation et l'analyse des séries temporelles. Elle propose une gamme de fonctionnalités pour transformer les séries temporelles en formats compatibles avec les algorithmes de machine learning, notamment en représentations sous forme d'images ou de matrices. Pyts offre également des outils pour l'extraction de caractéristiques, la classification et la visualisation des séries temporelles, ce qui en fait un choix précieux pour les tâches impliquant des données temporelles dans le	

	domaine de l'apprentissage automatique.	

III.4-Méthodologie proposée

Dans cette approche, nous avons développé un système de classification des signaux ECG en utilisant deux méthodes de prétraitement, à savoir les coefficients MFCC ainsi que le GAF. Dans la première méthode, nous avons utilisé les coefficients MFCC comme descripteurs caractéristiques avec un modèle CNNpour la classification. Tout d'abord, les données ont été prétraitées en extrayant les signaux ECG à partir d'un fichier CSV, puis calculer les MFCC pour chaque signal. Ces MFCC servent de représentation des caractéristiques fréquentiels des signaux ECG. Ensuite, les données ont été préparées en les remodelant pour les adapter au modèle CNN. Le modèle CNN construit est composé de couches de convolution, de regroupement maximum et de couches entièrement connectées, avec une couche de sortie pour la classification avec une fonction d'activation softmax. Après avoir divisé les données en deux ensembles d'entraînement et de validation, le modèle a été entraîné en utilisant la fonction de perte de catégorie croisée et l'optimiseur Adam. Les performances du modèle ont été évaluées sur l'ensemble de validation à l'aide de plusieurs métriques telles que la perte, l'exactitude, la précision, le rappel et le score F1. De plus, les performances du modèle ont été analysées en calculant la matrice de confusion et en traçant les courbes caractéristiques de fonctionnement de récepteurs(ROC) pour évaluer la capacité de classification du modèle pour chaque classe. Enfin, le modèle a été testé sur un ensemble de test distinct et ses performances ont été évaluées à l'aide de diverses métriques de performance. Alors avec la méthode GAF, nous avons pris des données de série temporelle qui ont été transformées en image GAF, puis elles ont suivi le même cheminement pour la classification via le modèle CNN.

III.5-Système proposé

La figure III-4 illustre le diagramme du processus de classification des signaux ECG avec les méthodes MFCC et GAF, Cela met en évidence les différentes étapes du processus de classification, en mettant en avant les deux méthodes spécifiques utilisées pour cette tâche.

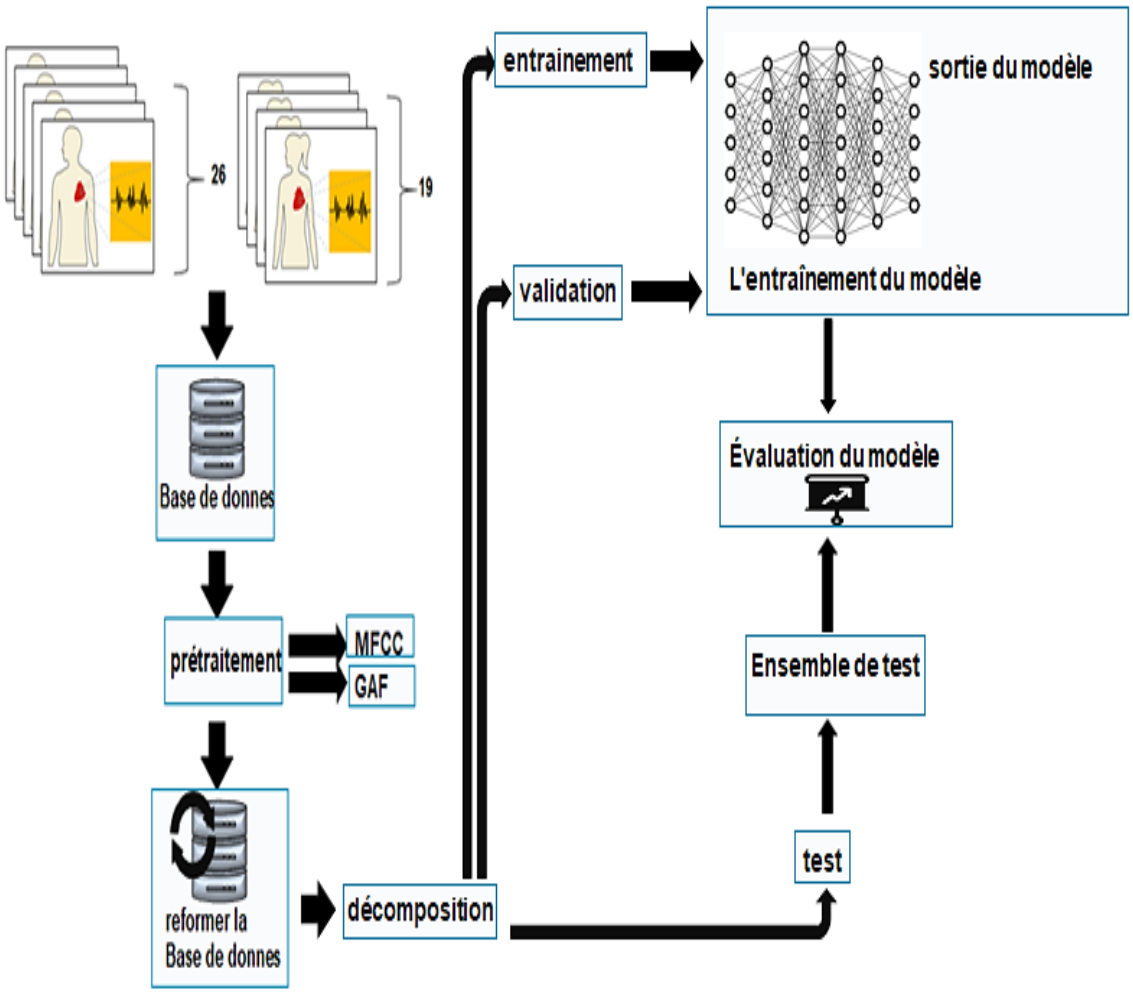


Figure III-4: Système de modèle proposé

III.5.1-Description de Base de données

La base de données MIT Arrhythmia contient des enregistrements ECG de 45 sujets, répartis comme suit :

- 19 femmes, âgées de 23 à 89 ans.
- 26 hommes, âgés de 32 à 89 ans.

Chaque battement est annoté par au moins deux cardiologues. Les enregistrements sont effectués à une fréquence d'échantillonnage de 360 Hz. Cette base de données est utilisée pour entraîner et évaluer le modèle de classification des battements de cœur. Les annotations de cette base de données sont utilisées pour créer cinq catégories de battements conformément à la norme AAMI EC57 (Association for the Advancement of Medical Instrumentation), qui sont essentielles pour la tâche de classification des arythmies.À savoir :

Tableau III-2 : Une Analyse selon la Classification AAMI

Catégorie	Description	Typologie De battement cardiaque AAMI	Nombre des Signaux
N	Battement Normal	Normal (N)	90 589
		Bloc de branche droit (R)	
		Bloc de branche gauche (L)	
VEB	Battement Ectopique Ventriculaire	Battement auriculaire prématuré (A)	2779
		Battement auriculaire prématuré aberré (a)	
		Battement prématuré nodal (J)	
		Battement prématuré supraventriculaire (S)	
		Battement d'échappement auriculaire (e)	
		Battement d'échappement nodal (j)	
SVEB	Battement Ectopique Supraventriculaire	Contractions ventriculaires prématurées (V)	7234
		Échappement ventriculaire (E)	
F	Battement de Fusion	Fusion de ventriculaire et normal (F)	801
Q	Inconnu	Stimulé (/)	29 930
		Fusion de stimulé et normal (f)	
		Non classé (Q)	
		Bruité (B)	
Totale			**131 333**

La figure III-5 montre le nombre de signaux pour cinq catégories différentes de battements cardiaques

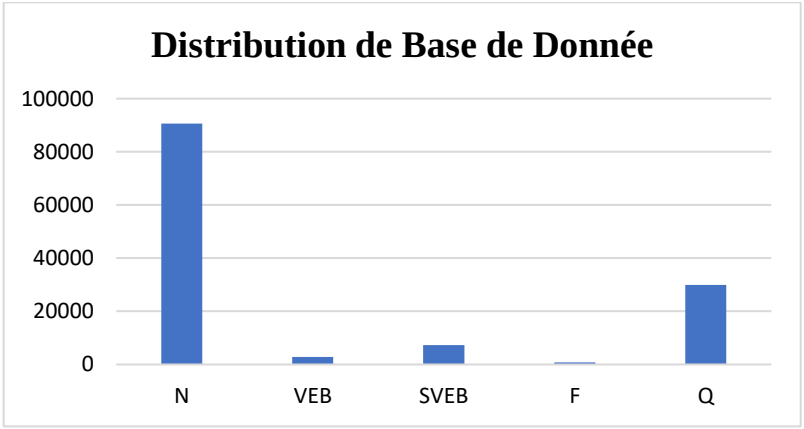


Figure III-5 : Visualisation de la distribution des données

III.5.2-Prétraitement

III.5.2.1- Mel-FrequencyCepstral Coefficients

On a utilisé le prétraitement MFCC pour extraire les caractéristiques distinctives des signaux électrocardiographiques (ECG). Cette méthode de prétraitement permet de représenter de manière efficace les modulations fréquentielles du signal ECG. Les MFCC ainsi obtenus ont été intégrés dans le processus d'analyse pour la classification des données ECG. Cette approche met en évidence l'importance des techniques de traitement du signal dans le domaine médical, en particulier pour la classification des signaux physiologiques tels que les ECG.La figure III-6 montreReprésentation des MFCC

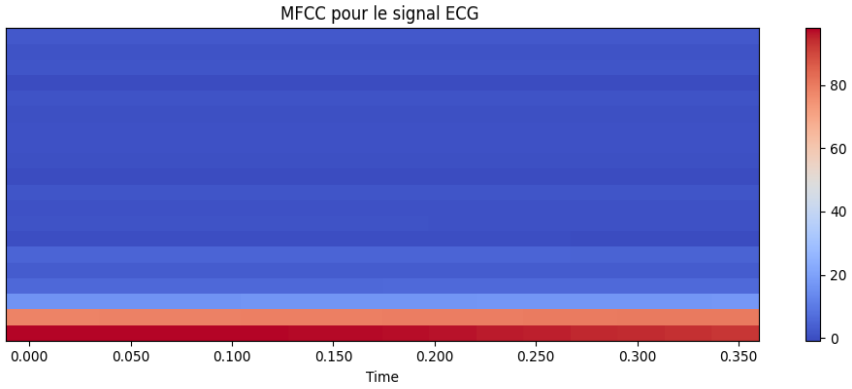


Figure III-6 : Représentation des MFCC

III.5.2.2-Gramian Angular Field

On a utilisé le GAF comme une méthode de transformation des signaux ECG en images. GAF transforme les signaux ECGen images GAF, elles sont visualisées à l'aide de la bibliothèque matplotlib, fournissant ainsi une représentation visuelle des séries temporelles sous forme d'images colorées. Cette représentation graphique permet de capturer les relations angulaires entre les différentes valeurs de la série temporelle.

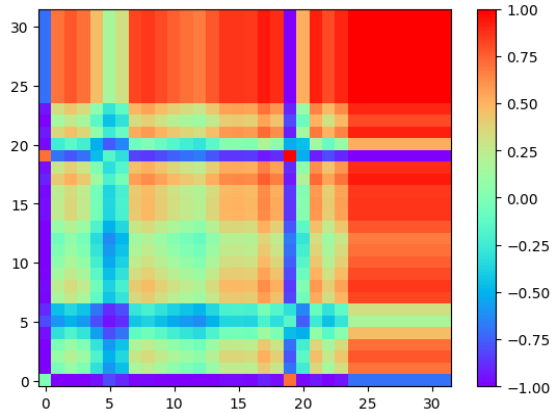


Figure III-7:GAF des signaux ECG

III.5.3-Redimensionnement

Dans l'analyse des signaux ECG pour la classification des maladies cardiaques, la préparation des données est cruciale. La première étape consiste à extraire les caractéristiques fréquentielles MFCC des signaux ECG. Ensuite, un redimensionnement des données est nécessaire pour les adapter à l'entrée d'un modèle CNN. Ce redimensionnement organise les données en un tenseur tridimensionnel, ajoutant une dimension supplémentaire pour indiquer qu'il s'agit de données uni canal. Cette étape assure la compatibilité des données avec l'architecture du CNN, permettant une utilisation efficace des caractéristiques MFCC pour la classification des battements cardiaques. En résumé, le redimensionnement des données est essentiel pour leur préparation et leur utilisation par le modèle CNN.

III.5.4-Décomposition du signal

La décomposition signaux ECG consiste en une division en deux parties (Voir figure)

- **Partie 1 :** 70% des signaux ECG originaux pour la partie d'entrainement des réseaux neurones
- **Partie 2 :** 30% des signaux ECG qui reste seront réservé pour la phase validation et des tests des réseaux neuronaux, Validation et 20% pour les tests. Parmi ces signaux, 10% sont utilisés pour test final voir la figure III-8

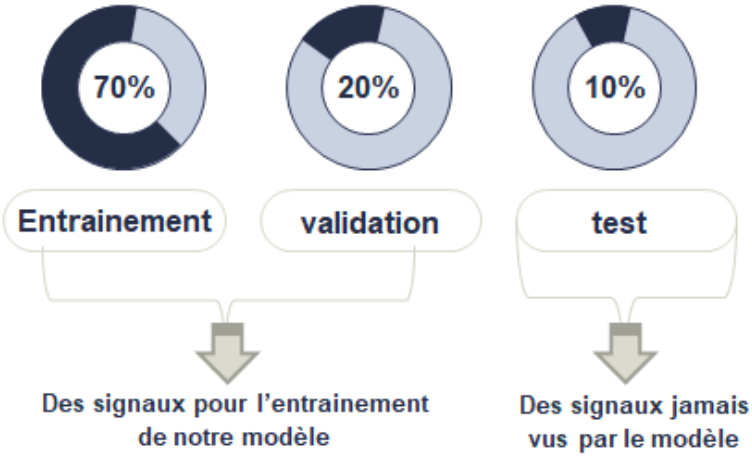


Figure III-8: Décomposition des fichiers

III.5.5-Modèle CNN

Nous avons développé notre propre architecture d'apprentissage profond fondée sur les réseaux neuronaux CNN. La figure III-5présente les différentes étapes de l'entraînement du réseau CNN, englobant la préparation des données, la conception du modèle de réseau, la spécification de la fonction de perte, ainsi que l'optimisation voire la figure III-9

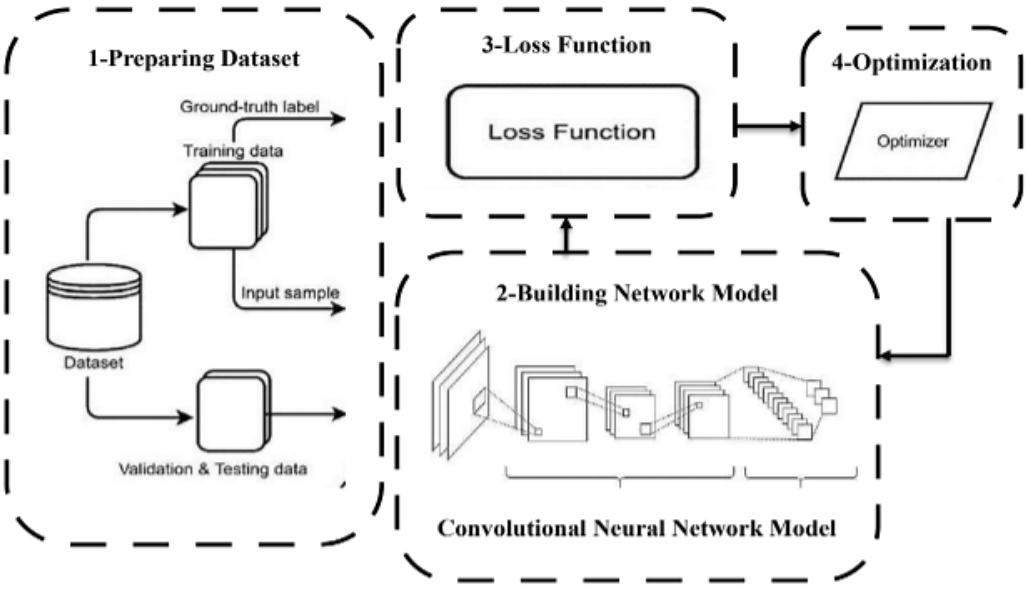


Figure III-9 : Schéma synoptiquede processus d'entraînement de CNN

III.5.5.1-Architecture utilisée

L'architecture de réseau neuronal utilisée dans cette étude est spécifiquement conçue pour aborder un problème de classification. Elle se caractérise par une succession de couches, chacune jouant un rôle crucial dans le processus d'apprentissage. La première couche, une couche de convolution (Conv2D), est déployée pour extraire des caractéristiques saillantes à partir des données d'entrée, représentées sous forme d'images. Cette couche utilise 32 filtres de dimension 3x3, activés par la fonction ReLU, afin de capturer les motifs locaux significatifs présents dans les images traitées. Pour réduire la dimensionnalité des données et favoriser l'apprentissage, une couche de max pooling (MaxPooling2D) est appliquée, opérant avec une fenêtre de pooling de dimension 2x2. Cette opération vise à conserver les caractéristiques les plus pertinentes tout en réduisant la taille de la représentation spatiale. Par la suite, les données sont aplenties (Flatten) pour être acheminées vers une couche dense (Dense) comportant 100 neurones, activés par la fonction ReLU. Cette couche dense vise à apprendre des combinaisons linéaires des caractéristiques extraites précédemment, contribuant ainsi à la création de représentations de plus haut niveau des données. La couche dense suivante, comprenant 32 neurones, poursuit cette tâche en exploitant davantage les relations non linéaires entre les caractéristiques extraites, toujours à l'aide de la fonction d'activation ReLU. La couche de sortie, une couche dense avec 5 neurones, adopte la fonction d'activation softmax afin de produire des probabilités pour chaque classe de la classification. Cela permet d'interpréter les sorties du réseau comme des distributions de probabilité sur les différentes classes, facilitant ainsi la prise de décision. Concernant l'évaluation des performances du modèle, celui-ci a démontré une précision remarquable lors de

l'entraînement, atteignant 99.98% sur l'ensemble des données d'entraînement, avec une perte minimale de 0.0007. Ces résultats témoignent de la capacité du modèle à s'adapter de manière précise aux données d'entraînement. Lors de la validation, le modèle a maintenu une performance élevée, avec une précision de 99.97% et une perte de 0.0016, confirmant ainsi sa capacité à généraliser efficacement à de nouvelles données. Enfin, lors du test sur un ensemble de données distinct, le modèle a également obtenu des résultats satisfaisants, avec une précision de 99.97% et une perte de 0.0007. Ces performances robustes confirment la fiabilité du modèle dans la résolution du problème de classification considéré.

Tableau III-3: Exploration des Couches

	Couche	**Type**	**MFCC**	**GAF**
			Paramètres	**Paramètres**
	Couche1	Conv2D	Filtres : 32, Taille : (3, 3), Activation : ReLU	Filtres : 32, Taille : (3, 3), Activation : ReLU
		MaxPooling2D	Taille du pool : (2, 2)	Taille du pool : (2, 2)
	Couche 2	Flatten		
	Couche 3	Dense	Neurones : 100, Activation : ReLU	Neurones : 100, Activation : ReLU
	Couche 4	Dense	Neurones : 32, Activation : ReLU	Neurones : 32, Activation : ReLU
	Couche de sortie	Dense	Neurones : 5, Activation : Softmax	Neurones : 5, Activation : Softmax
Entrainement	**Précision**	0.9998		0,9998
	Perte	0.0007		0,0005
Validation	**Précision**	0.9997		0,9987
	Perte	0.0016		0,012
Test	**Précision**	0.9997		/
	Perte	0.0007		/

La figure III-10 illustre un schéma de réseau neurones convolutifs (CNN) couramment utilisé pour la reconnaissance d'images

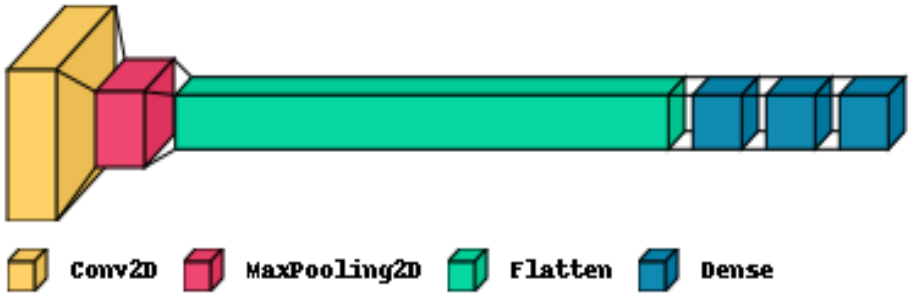


Figure III-10 : Architecture CNN Utiliser en 3D

La figure III-7 représente l'architecture d'un réseau de neurones convolutif (CNN). Le modèle commence par une couche d'entrée qui reçoit des données sous forme de tableaux 2D de dimensions 20x16. Ensuite, une couche de convolution (Conv2D) applique 32 filtres de taille 3x3 sur les données, suivie d'une fonction d'activation. Une couche de max pooling (MaxPooling2D) réduit ensuite les dimensions des cartes de caractéristiques. Les données sont ensuite aplaties par une couche Flatten pour être utilisées par des couches pleinement connectées (Dense). Le modèle contient trois couches Dense : la première connecte 2016 neurones d'entrée à 100 neurones de sortie, la deuxième connecte 100 neurones d'entrée à 32 neurones de sortie, et la troisième connecte 32 neurones d'entrée à 5 neurones de sortie, chaque couche étant suivie d'une fonction d'activation. Finalement, la couche de sortie produit un vecteur de 5 dimensions, correspondant aux différentes classes de sortie possibles.

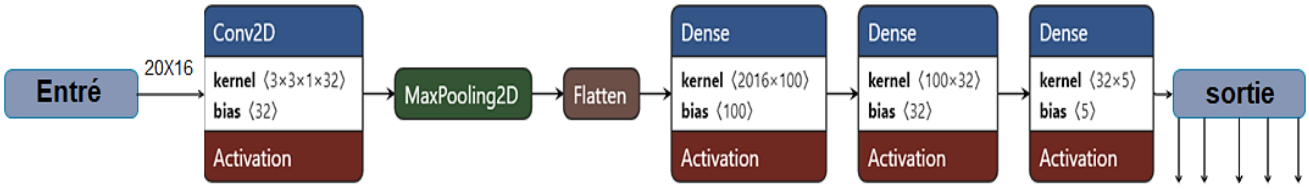


Figure III-11 : Reconnaissance d'images étape par étape

III.6-Discussion des résultats

III.6.1-Graphe des pertes et de précision

Les deux graphiques présentés illustrent la performance d'un modèle de ML au cours de son entraînement. Le premier graphique (A) montre la perte de validation et d'entraînement, tandis que le second(B) présente la précision de validation et d'entraînement.

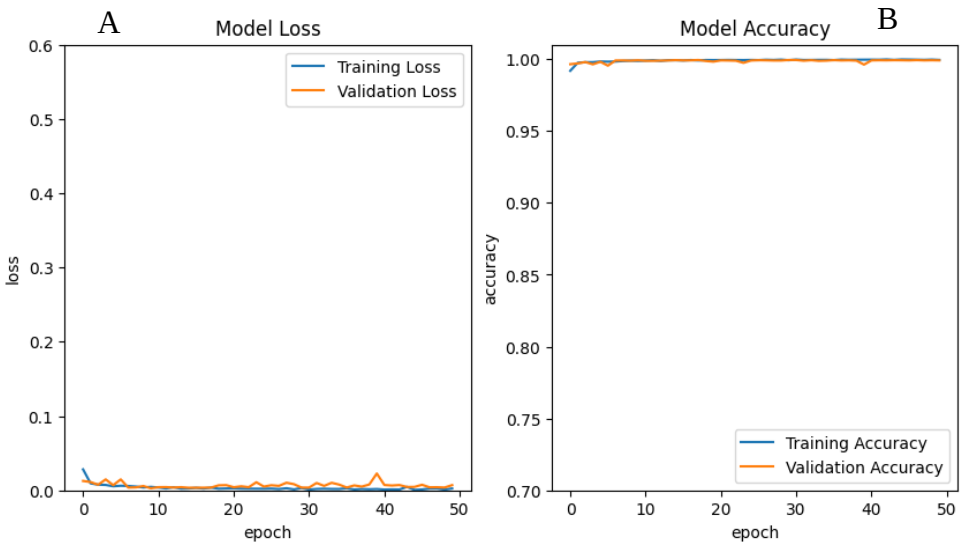


Figure III-12 : Graphedes perte (A) et des précision (B) de validation et d'entraînement

Le graphe (B) illustre l'évolution de la précision de validation et d'entraînement en fonction du nombre d'époques. La précision, qui mesure le pourcentage d'instances correctement classées, augmente de manière constante lors des premières époques, montrant que le modèle s'améliore. Toutefois, une précision d'entraînement qui atteint trop rapidement 100 % peut indiquer un sur-apprentissage. La précision de validation, calculée sur un jeu de données distinct, augmente généralement plus lentement. Si elle commence à diminuer après une période d'augmentation, cela peut aussi indiquer un sur-apprentissage.Le graphe (A) montre l'évolution de la perte de validation et d'entraînement au fil des époques. La perte, représentant l'erreur moyenne du modèle, diminue progressivement, signalant une amélioration continue de la performance du modèle.

III.6.2-Caractéristique de fonctionnement du récepteur (courbe ROC)

L'analyse de la courbe ROC (voir la figure III-9) indique que le modèle CNN présenté est un classificateur très performant pour la tâche de distinction de cinq classes de signaux audio. La forme optimale de la courbe et l'AUC maximale de 1 démontrent la capacité du modèle à discriminer efficacement les classes et à fournir des prédictions fiables.

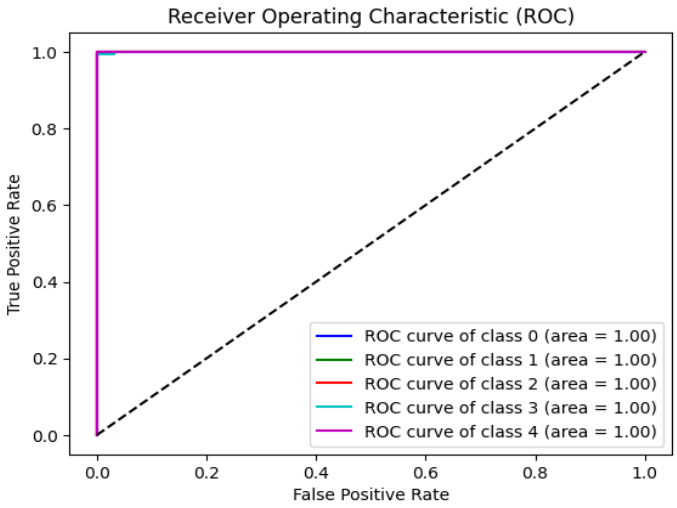


Figure III-13:courbe ROC

III.6.3-Rapport de classification

Le rapport de classification est un outil d'évaluation complet utilisé pour analyser les performances d'un modèle de classification. Il fournit un résumé détaillé des principales métriques pour chaque classe, facilitant ainsi l'évaluation de la précision et de l'efficacité du modèle. Les principales composantes du rapport de classification incluent :

- **Précision** : Elle représente la proportion de prédictions positives correctes parmi l'ensemble des prédictions positives. C'est le rapport entre les vrais positifs (VP) et la somme des vrais positifs (VP) et des faux positifs (FP). La formule mathématique est

$$Précision = \frac{VP}{VP + FP}$$

- **Rappel** : Il représente la proportion de prédictions positives correctes parmi l'ensemble des instances réellement positives. C'est le rapport entre les vrais positifs (VP) et la somme des vrais positifs (VP) et des faux négatifs (FN). La formule mathématique est :

$$Rappel = \frac{VP}{VP + FN}$$

- **F1-score** : est une mesure de la performance d'un modèle de classification qui combine la précision et le rappel en un seul indicateur. Il est défini comme la moyenne harmonique de la précision et du rappel. La formule mathématique du F1-score est :

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

En utilisant les notations pour la précision et le rappel, le F1-score peut également être exprimé comme :

$$F1 - score = 2 \times \left(\frac{VP}{2 \times VP + FP + FN}\right)$$

Le F1-score prend en compte à la fois la précision et le rappel, fournissant une seule mesure qui équilibre les deux. Il est particulièrement utile lorsqu'on a besoin d'un équilibre entre précision et rappel

- **Support** : C'est le nombre des signaux de chaque classe dans la base de données.

Tableau III-4 : Rapport de Classification la méthode MFCC

	Précision	**Rappel**	**F1-score**	**Support**
N	1 .00	1 .00	1 .00	18026
VEB	1 .00	0.99	0 .99	518
SVEB	1 .00	0 .99	0 .99	1477

F	0.99	0.99	0 .99	170
Q	1 .00	1 .00	1 .00	1699
Accuracy			0.99	21890
Macro avg	0 .99	0 .99	0 .99	21890
Weightedavg	0.99	0.99	0.99	21890

Le tableau III-4présenté fournit un rapport de classification détaillé pour un modèle de classification utilisant la méthode MFCC. Voici une analyse des résultats :

- **Classe N :** est classée avec une précision, un rappel et un F1-score parfaits de 1.00. Cela signifie que le modèle a correctement identifié toutes les instances de la classe 0 sans aucune erreur. Avec un support de 18,026, cette classe est largement représentée dans le jeu de données.
- **Classe VEB :** la précision est parfaite à 1.00, indiquant qu'il n'y a pas de faux positifs. Le rappel est très élevé à 0.99, suggérant une très faible proportion de faux négatifs. Le F1-score, également à 0.99, confirme la performance globale élevée pour cette classe.
- **Classe SVEB :** montre également une précision parfaite de 1.00 et un rappel de 0.99. Cela signifie que presque toutes les instances de cette classe ont été correctement identifiées. Le F1-score de 0.99 démontre une excellente performance globale pour cette classe.
- **Classe F :** une précision et un rappel légèrement inférieurs à ceux des autres classes, tous deux à 0.99, ce qui reste néanmoins très élevé. Le F1-score de 0.99 reflète cette excellente performance malgré le support relativement faible de 170.
- **Classe Q :** toutes les métriques de performance sont parfaites, avec une précision, un rappel et un F1-score de 1.00. Avec un support de 1.699, cette classe est bien représentée et correctement classé.

Les métriques montrent que le modèle est capable de classifier les données avec une très grande précision et un très faible taux d'erreurs.

III.6.4-Matrice de Confusion

La matrice de confusion de taille 5x5 montre les performances d'un modèle de classification CNN sur un ensemble de données des images. Les lignes de la matrice représentent les classes 5 classes réelles ou "vrais classe", tandis que les colonnes représentent les classes prédites par le modèle.

III.6.4.1-Matrice de Confusion du prétraitement MFCC

On commence notre analyse par la classe 0 (la classe N), la classe 1 (la classe VEB), la classe 2 (la classe SVEB) et la classe 4 (la classe Q), qui sont correctement classées à 100%. En revanche, la classe 3 (la classe F) est classée correctement à 99%, avec 0,1% de confusion avec la classe SVEB. En conclusion, cette matrice montre que le modèle CNN assimile, classe et prédit correctement les images.

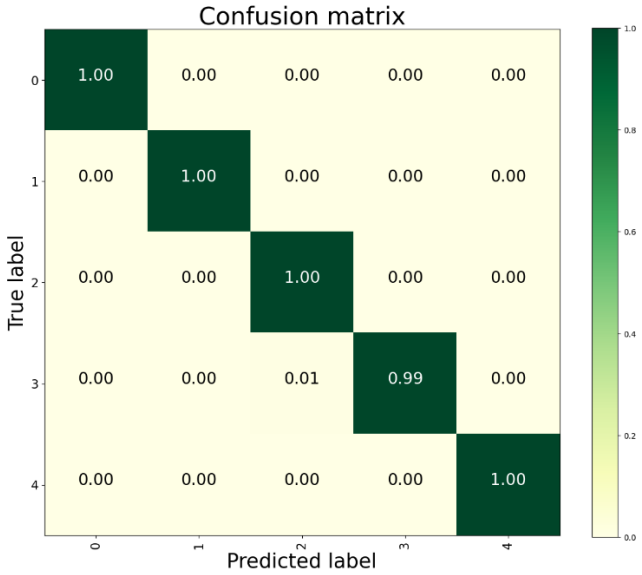


Figure III-14 : Matrice de Confusion de prétraitement MFCC

III.6.4.2-Matrice de Confusion du prétraitement GAF

Nous entamons notre analyse par la classe 0 (catégorie N) et la classe 4 (catégorie N), qui sont classées correctement à 100%. La classe 1 (catégorie VEB) est classée avec précision à 98%, avec 0,1% de confusion avec la classe 0 (catégorie N) et 0,1% avec la classe 2 (catégorie SVEB). La classe 2 (catégorie SVEB) est classée avec exactitude à 99%, avec 0,1% de confusion avec la classe 1 (catégorie VEB). Enfin, la classe 3 (catégorie F) est classée correctement à 95%, avec 3% de confusion avec la classe 2 (catégorie SVEB) et 2% avec la classe 4 (catégorie Q). La matrice semble fournir des résultats globalement solides, avec des taux de classification élevés pour la plupart des classes.

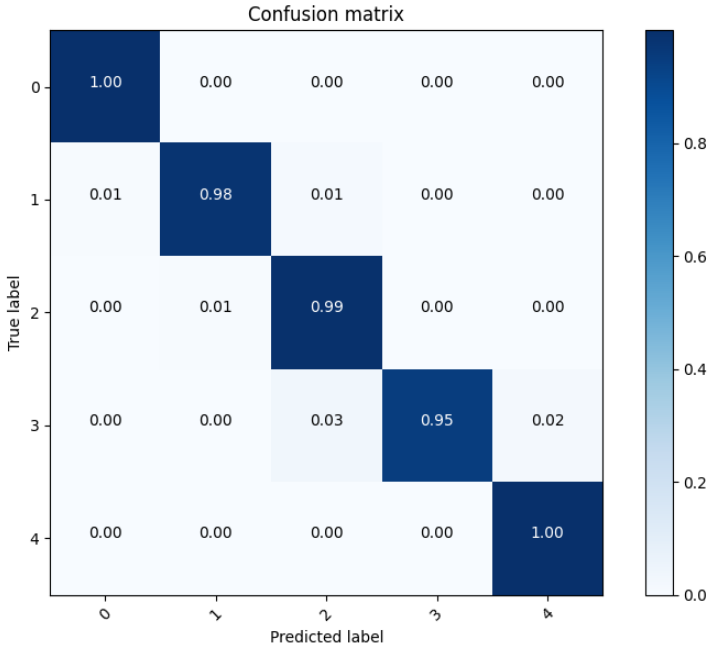


Figure III-15: Matrice de Confusion du Modèle CNN après le prétraitement GAF

III.6.4.3-Comparaison des résultatsentre MFCC et GAF

En comparant les deux matrices de confusion, le prétraitement MFCC semble être préférable pour plusieurs raisons. Tout d'abord, il offre des taux de classification parfaits pour la plupart des classes, ce qui indique une précision extrêmement élevée dans la classification des données. De plus, le faible taux de confusion de seulement 0,1% avec la classe 3 (F) suggère une grande capacité du modèle à distinguer entre les différentes classes, même celles présentant des similarités subtiles. Enfin, la simplicité et l'efficacité du prétraitement MFCC en font un choix attractif, offrant des performances exceptionnelles tout en conservant une certaine facilité d'implémentation et de compréhension. Ainsi, dans cette comparaison, le prétraitement MFCC émerge comme le choix préféré pour la classification des données.

Tableau III-5 : Comparaison entre MFCC et GAF

	Accuracy	**F1 score**	**Rappel**	**Précision**	**Perte**
MFCC					
Entrainement	99.99%	99.98%	99.98%	99.98%	0.0014

Validation	99.97%	99.96	99.96%	99.96%	0.0016
GAF					
Entrainement	99.98%	99.98%	99.98%	99.98%	0.0005
Validation	99.87%	99.87%	99.87%	99.87%	0.012

III.6.4.4-Partie de Test

Dans cette phase, nous avons utilisé le meilleur modèle sauvegardé lors de la phase précédente avec un ensemble de test représentant 10% des données. Après le prétraitement par MFCC, cette étape est essentielle pour évaluer les performances globales du modèle sur des données non utilisées pendant les phases d'entraînement et de validation.

III.6.4.4.1-Matrice de Confusion du test

Matrice de confusion montre que toutes les classes sont correctement classées à 100% et qu'il n'y a aucune confusion entre les classes, on peut dire que le modèle a une performance parfaite sur l'ensemble de test. Cela signifie que le modèle a réussi à classifier chaque exemple dans la classe correcte sans aucune erreur. On pourrait dire que le modèle a atteint un niveau de performance optimal et qu'il est très précis dans sa capacité à distinguer entre les différentes classes du problème. En d'autres termes, le modèle est capable de généraliser efficacement à de nouvelles données et de les classifier avec une grande exactitude.

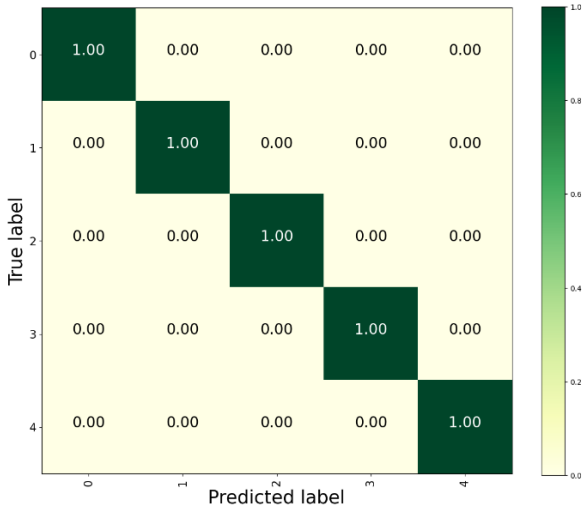


Figure III-16 : Matrice de Confusion du test

III.6.4.4.2-Évaluation des Performances du Modèle CNN

Le modèle a été évalué sur un ensemble de test démontre une performance exceptionnelle avec une accuracy de 99.97%, un F1-score de 99.97%, un rappel de 99.96%, une précision de 99.97%, et une perte de 0.0007. Ces valeurs indiquent une précision, une

sensibilité et un équilibre quasi parfaits entre les prédictions positives et négatives, ainsi qu'une erreur très faible.

Tableau III-6 : Tableau d'évaluation des performances

	Accuracy	**F1-Score**	**Rappel**	**Précision**	**Perte**
Test	99.97%	99.97%	99.96%	99.97%	0,0007

III.7-Réalisation du nœud d'acquisition

Le système repose sur plusieurs composants interconnectés pour son fonctionnement fluide. Au cœur de l'ensemble, le capteur ECG capture l'activité électrique cardiaque, relayant ensuite ces données vers le microcontrôleur Arduino. Ce dernier, en tant que centre de traitement, se charge de convertir les informations ECG en un format numérique exploitable. Parallèlement, le capteur AD8232, doté de trois électrodes, s'intègre au dispositif en étant connecté à la carte ArduinoUno à travers des fils de connexion, garantissant ainsi une acquisition précise et fiable des signaux électriques. Le tableau ci-dessous fournit une description détaillée de la configuration de cette connexion avec l'ArduinoUno.

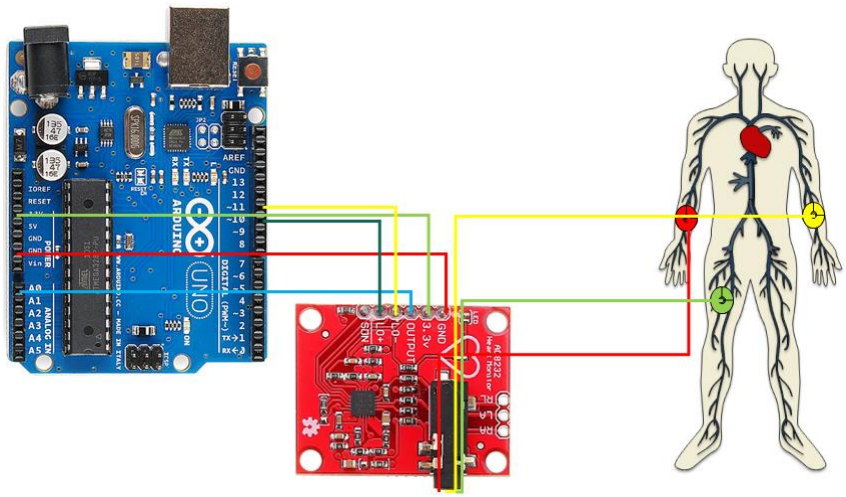


Figure III-17: Montage du nœud d'acquisition

Tableau III-7 : L'interconnexion entre ECG AD8232 et ArduinoUno

Fonction	**Branche AD8232**	**Carte ArduinoUno**
Power Supply	3.3V	3.3V

Output Signal	OUTOUT	A0
Lead Off Detect+	LO+	10
Lead Off Detect-	LO-	11
Ground	GND	GND

Le placement des électrodes sur le corps humain est représenté dans la figure III-18

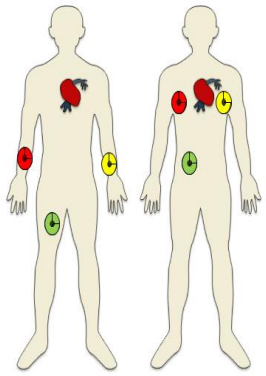


Figure III-18 : Les zones de placement des électrodes

L'arrangement des électrodes pour le capteur AD8232 est essentiel pour garantir une lecture précise des signaux d'ECG. Selon cette configuration, l'électrode rouge est positionnée sur le bras droit, l'électrode jaune sur le bras gauche et l'électrode verte sur la jambe droite. Ces positions sont fondamentales pour assurer une acquisition fiable et optimale des données cardiaques. Une fois la carte Arduino est mise en marche, les signaux émanant du capteur sont acheminés vers la carte et peuvent être observés via le traceur série alors que les valeurs peuvent être affichées sur le moniteur série. Le signal mesuré avec l'AD8232 est illustré dans la figure suivante.

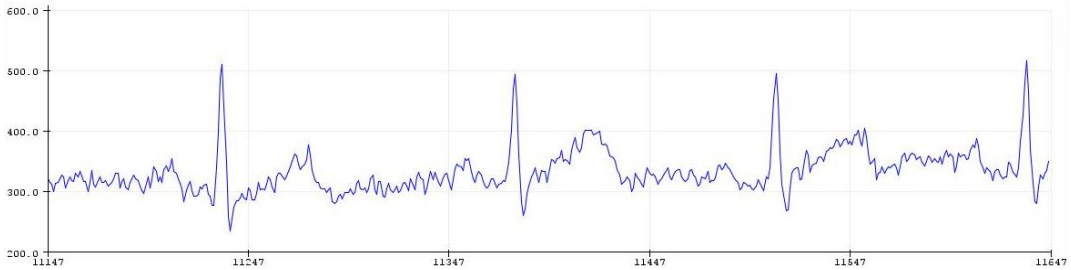


Figure III-19: Signal récolté

III.8-Adaptation des Données

A partir des données reçues sur le moniteur on prend aléatoirement un échantillon de données successives. Cet échantillon est converti un fichier ayant l'excusions.csv sur Matlab.

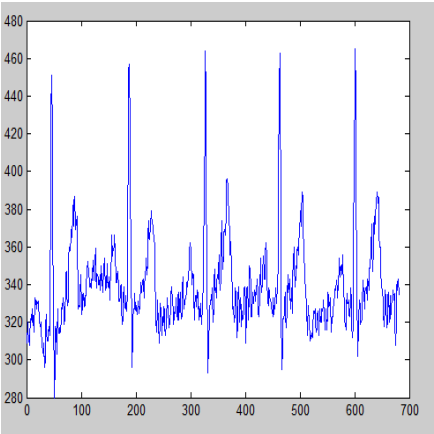


Figure III-20: signal ECG émané de AD83232

De la même manière on ramène notre base de données et on également un échantillon de données successive

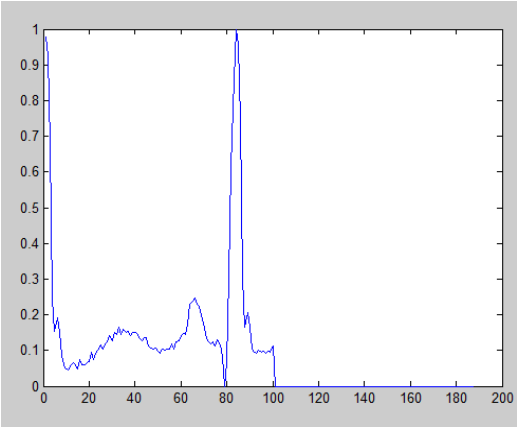


Figure III-21 : signal ECG de la base de données

Comme deuxième étape on adapte les données qui apparaissent dans le 1er échantillon pour être comme les signaux dans la base des données utiliser par les adapter à notre étude.

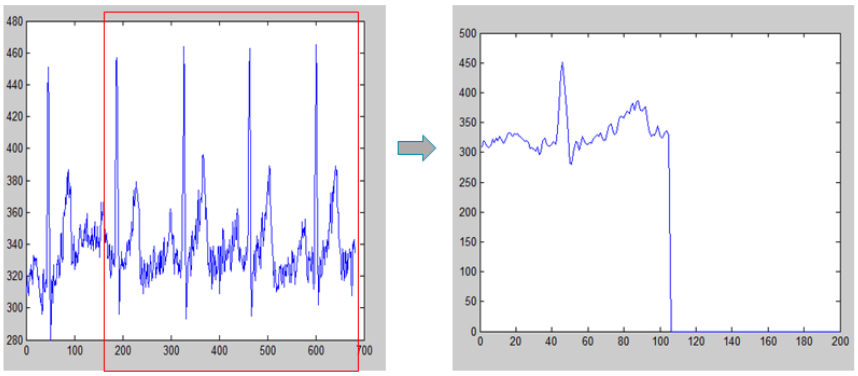


Figure III-22: signal ECG après l'adaptation par masquages de données

III.9-Prédiction et test des signaux récolté

À la fin de l'adaptation à l'échantillon de la base de données, notre échantillon a été téléversé dans l'environnement Python. Nous avons ensuite suivi les mêmes étapes que celles de la phase d'entraînement et de la phase de test, après l'extraction des coefficients MFCC et le redimensionnement. Nous avons utilisé le meilleur modèle enregistré, l'avons téléchargé, puis testé sur notre échantillon. Les résultats obtenus (voir figure III-23) montrent les probabilités prédites pour chaque classe ainsi que la classe prédite pour chaque signal.

```
[0.99999994 0.         0.         0.         0.        ]
Ce signal est de classe :  0
Coeur Noraml
[9.9999994e-01 4.0560967e-18 0.0000000e+00 0.0000000e+00 0.0000000e+00]
Ce signal est de classe :  0
Coeur Noraml
[9.9996251e-01 3.7465346e-05 1.2920821e-11 2.1156461e-14 2.3620426e-18]
Ce signal est de classe :  0
Coeur Noraml
```

Figure III-23 : Probabilités prédites pour chaque classe

Les probabilités très élevées (proches de 100%) pour la classe 0 et proches de 0% pour les autres classes indiquent une forte confiance du modèle dans ses prédictions. Tous les signaux analysés sont classés comme "Cœur Normal".

La figure III-24 illustre la matrice de confusion de notre modèle

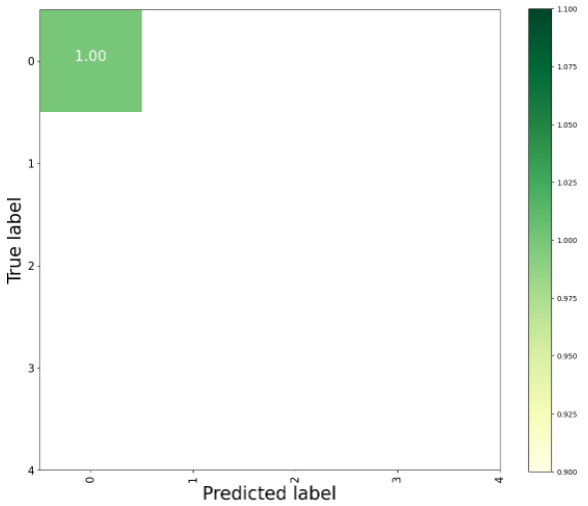


Figure III-24 : Matrice de confusion pour le test des signaux collectée

La matrice de confusion montre que le modèle prédit parfaitement la classe 0 (Cœur Normal) avec un taux de précision de 100%. Cependant, aucune prédiction n'est faite pour les classes 1 à 4

III.10-Comparaison avec des travaux précédentes

La performance de notre modèle CNN est comparée à celle d'études récentes dans le tableau ci-dessous, démontrant ainsi l'efficacité et la fiabilité de notre approche. Dans l'étude de M. R. A. Berkani et al. [17], le prétraitement par segmentation a été utilisé sur 1024 échantillons avec un modèle CNN-1D, atteignant une précision de 97 %. M. A. Imran et al. [18] ont utilisé la transformation en ondelettes continues (CWT) avec un modèle CNN-1D, atteignant une précision de 90,78 %. De même, V. K. Sreeniva [20] a appliqué les prétraitements GAF et MTF, associés à un modèle CNN-2D, pour obtenir une précision de 97 %. En revanche, notre étude combine différents prétraitements tels que MFCC et GAF avec le modèle CNN-2D. Ces approches ont démontré des performances prometteuses avec des précisions respectives de 99,89 % et 99,96 %. Ces résultats soulignent l'efficacité de notre approche dans la classification des données, offrant des performances supérieures à celles des études connexes, comme le montre le tableau ci-dessous. Cela indique que la conversion des signaux audio en coefficients cepstraux MFCC peut capturer des caractéristiques plus discriminantes pour la classification.

Tableau III-8 : Tableau Comparaison des travaux

Travail	Année	Prétraitement	Modèle	Accuracy
M R A. Berkani et Al [17]	2022	Segmentation sur1024 échantillons	CNN-1D	97%
M. A. Imran et Al [18]	2023	CWT	CNN- 1D	90.78%
V K. Sreeniva [20]	2021	GAF	CNN- 2D	97.00%
		MTF		
Notre approche	2024	GAF	CNN- 2D	99 ,89%
		MFCC		99,97 %

III.11-Conclusion

En conclusion, cette étude a comparé deux méthodes de classification des signaux ECG, à savoir les MFCC et les GAF, en utilisant des réseaux de neurones convolutifs. Les résultats montrent que la méthode MFCC offre des performances supérieures, avec des taux de classification très élevés et une faible confusion entre les classes. La simplicité et l'efficacité du prétraitement MFCC, combinées à des performances exceptionnelles, font de cette méthode le choix préféré pour la classification des signaux ECG. Le système développé, intégrant des composants tels que le capteur ECG AD8232 et le microcontrôleur Arduino, assure une acquisition précise et fiable des données cardiaques, ouvrant la voie à des applications potentielles dans la surveillance et le diagnostic médical.

Conclusion Générale

En conclusion, notre étude a démontré l'efficacité et la fiabilité d'un système intelligent pour la classification des signaux ECG en utilisant des réseaux de neurones convolutifs (CNN). La comparaison entre les méthodes MFCC et GAF a révélé que la méthode MFCC offre des performances supérieures, avec des taux de classification très élevés et une faible confusion entre les classes. La simplicité et l'efficacité du prétraitement MFCC, associées à des performances exceptionnelles, font de cette méthode le choix privilégié pour la classification des signaux ECG.

Le système développé, intégrant des composants tels que le capteur ECG AD8232 et le microcontrôleur Arduino, garantit une acquisition précise et fiable des données cardiaques. Ce système ouvre de nouvelles perspectives pour des applications potentielles dans la surveillance et le diagnostic médical, en particulier pour minimiser les erreurs médicales dans les situations d'urgence.

L'implémentation du modèle CNN permet une détection et une classification rapides et automatiques des maladies cardiovasculaires. Ce système intelligent vise à améliorer la qualité des soins de santé et à fournir une assistance précieuse aux professionnels médicaux, contribuant ainsi à la réduction des taux de mortalité associés aux maladies cardiovasculaires. Par ailleurs, l'intégration de ces technologies dans les dispositifs médicaux de surveillance continue représente une avancée significative pour la prévention et la gestion des affections cardiaques.

En somme, notre projet a non seulement validé l'utilité des réseaux de neurones convolutifs pour l'analyse des signaux ECG, mais a également montré l'importance des méthodes de prétraitement adaptées comme les MFCC. L'avenir de la détection des maladies cardiovasculaires repose sur le développement et l'intégration de systèmes intelligents capables de fournir des diagnostics précis et rapides, tout en réduisant la charge de travail des professionnels de santé et en améliorant les résultats pour les patients.

Bibliographie

[1] :Gal, V. (2019). *Vers une nouvelle Interaction Homme Environnement dans les jeux vidéo et pervasifs: rétroaction biologique et états émotionnels: apprentissage profond non supervisé au service de l'affectique* (Doctoral dissertation, Conservatoire national des arts et metiers-CNAM).

[2] :BOUZIANE, I. (2023). *Une méthode intelligente d'aide de diagnostic des maladies cardiaques a base des données D'échocardiographie* (Doctoral dissertation, Université EchahidChikh Larbi Tébessi-Tébessa).

[3] : St-Jean, R. (1990). *Le rôle de la phase du cycle cardiaque sur le potentiel évoqué moyen à un stimulus somesthésique chez l'humain*. Université du Québec à Montréal.

[4] : https://www.coeuretavc.ca/maladies-du-coeur/tests/%C3%A9lectrocardiogramme consulté le 12/03/2024.

[5] : Chapelon-Abric, C. (2004). Électrocardiogramme normal de l'adulte. *EMC-Cardiologie-Angéiologie*, *1*(1), 2-10.

[6]:EL BORDJI, A., & BELLOUATI, C. (2015). Analyse et Traitement du Signal ECG et EMG pour Estimer l'Activité Physique.

[7]: BOUTARFA, M. A. (2022). Système intelligent de prédiction des maladies cardiaques.

[8] :Holanda, R., Monteiro, R., &Bastos-Filho, C. (2023). Preprocessing selection for deep learning classification of arrhythmia using ecg time-frequency representations. *Technologies*, *11*(3), 68.

[9]: Khanji, C. (2019). Évaluation de la qualité des soins et des services préventifs cardiovasculaires en première ligne.

[10] : Huang, S. C., & Le, T. H. (2021). *Principles and labs for deep learning*.AcademicPress.

[11]: Académie nationale de médecine (France). (1891). *Bulletin de l'Académie nationale de médecine* (Vol. 25). Masson.

[12]:Ismail, Y. (Ed.). (2019). *Internet of things (IoT) for automated and smart applications*.BoD–Books on Demand.

[13]:Bengherbia, B., Berkani, M. R. A., Achir, Z., Tobbal, A., Rebiai, M., &Maazouz, M. (2022, September). Real-time smart system for ecg monitoring using a one-dimensional

convolutional neural network. In *2022 International Conference on Theoretical and Applied Computer Science and Engineering (ICTASCE)* (pp. 32-37). IEEE.

[14] : Ségas, E. (2023). *Contrôle biomimétique de prothèses à partir des mouvements résiduels et d'informations contextuelles* (Doctoral dissertation, Université de Bordeaux).

[15] :Sigurthorsdottir, H., Van Zaen, J., Delgado-Gonzalo, R., LemayMarouane, Z. A. (2019). Classification des battements cardiaques en utilisant les réseaux de neurones profonds.

[16] : HAMICI, L. (2022). L'appariement des données ECG à base des séries chronologiques.

[17] : Lin, Y. J., Chuang, C. W., Yen, C. Y., Huang, S. H., Huang, P. W., Chen, J. Y., & Lee, S. Y. (2019, March). Artificial intelligence of things wearable system for cardiac disease detection.In *2019 IEEE International Conference on Artificial Intelligence Circuits and Systems (AICAS)* (pp. 67-70).IEEE.

[18] : Chaabane, N. B. (2023). *Analyse de signaux physiologiques pour la prédiction de l'évolution pathologique par intelligence atificielle. Application à la maladie de Parkinson et à l'analyse quantifiée de la marche* (Doctoral dissertation, Université de Bretagne occidentale-Brest).

[19] :Amrouche, A., Abed, A., Hezil, N., Zalagh, M., Boubakeur, K. N., &Zitouni, A. (2023, May). DNN-SVM Automatic ECG Signals Heartbeat Classification. In *2023 10th International Conference on Electrical and Electronics Engineering (ICEEE)* (pp. 95-99). IEEE.

[20] Diker, A., Cömert, Z., Avcı, E., Toğaçar, M., &Ergen, B. (2019, November). A novel application based on spectrogram and convolutional neural network for ECG classification. In *2019 1st International Informatics and Software Engineering Conference (UBMYK)* (pp. 1-6). IEEE.

[21] Attabi, Y. (2008). *Reconnaissance automatique des émotions à partir du signal acoustique* (Doctoral dissertation, École de technologie supérieure).

[22]Wang, Z., & Oates, T. (2015). Imaging time-series to improve classification and imputation.arXiv [Preprint]. doi: 10.48550. *arXiv preprint arXiv.1506.00327*.

[23]Fetzer, J. H., &Fetzer, J. H. (1990). *What is artificial intelligence?* (pp. 3-27). Springer Netherlands.

[24] https://www.thats-ai.org/fr-CH/units/l-histoire-de-l-ia visité le 20/04/2024.

[25]http://www.intelligenceartificielle.fr/domaines_IA.php visité le 13/03/2024.

[26] Zhang, X. D. (2020). A matrix algebra approach to artificial intelligence.

[27] Abdennadher, S., &Cheffi, W. (2011). L'adoption du vote par internet aux assemblées générales des actionnaires de sociétés cotées en France: Une perspective institutionnaliste. *Systèmes d'information et management*, *16*(2), 35-71..Consulté le 03/04/2024.

[28] Mohammed, M., Khan, M. B., &Bashier, E. B. M. (2016). *Machine learning: algorithms and applications*. Crc Press.

[29]Thirumuruganathan, S. (2010). A detailed introduction to K-nearest neighbor (KNN) algorithm. *Retrieved March*, *20*, 2012.

[30] Hilali, H. (2009). *Application de la classification textuelle pour l'extraction des règles d'association maximales* (Doctoral dissertation, Université du Québec à Trois-Rivières)

[31] Garson, G. D. (2021). *Data analytics for the social sciences: applications in R*. Routledge.

[32] Bellahmer, H. (2020). *Implémentation et évaluation d'un modèle d'apprentissage automatique pour l'estimation de la valeur marchande de propriétés immobilières* (Doctoral dissertation, Université Mouloud Mammeri).

[33]Tahir, M., Naeem, A., Malik, H., Tanveer, J., Naqvi, R. A., & Lee, S. W. (2023). DSCC_Net: multi-classification deep learning models for diagnosing of skin cancer using dermoscopic images. *Cancers*, *15*(7), 2179.

[34]Rosebrock, A. (2017). *Deep learning for computer vision with python: Starter bundle*. PyImageSearch.

[35]Rosebrock, A. (2017). *Deep learning for computer vision with python: Starter bundle*. PyImageSearch.

[36]Dreyfus, G., Martinez, J. M., Samuelides, M., Gordon, M. B., Badran, F., Thiria, S., &Hérault, L. (2002). *Réseaux de neurones-Méthodologie et applications*.

[37] Abu Qudeiri, J. E., Saleh, A., Ziout, A., Mourad, A. H. I., Abidi, M. H., &Elkaseer, A. (2019). Advanced electric discharge machining of stainless steels: Assessment of the state of the art, gaps and future prospect. *Materials*, *12*(6), 907.

[38] : https://www.mathworks.com/help/nnet/ug/introduction- to-convolutional-neural-

networks.html. Visité 23/042024

[39] :Indolia, S., Goswami, A. K., Mishra, S. P., &Asopa, P. (2018). Conceptual understanding of convolutional neural network-a deep learning approach. *Procedia computer science*, *132*, 679-688.

[40] :MABREK, Z. (2020). Détection de la couleur de peau par Réseaux de Neurones à Convolution.

[41] :Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of long short-term memory (LSTM) neural network for flood forecasting. *Water*, *11*(7), 1387.

[42] : Charbonnier, F. (2021). Etude et application des réseaux adverses génératifs à la conversion de voix.

[43] : Brouillard, P. (2021). Apprentissage de modèles causaux par réseaux de neurones artificiels.

[44] :Caruana, R., &Niculescu-Mizil, A. (2006, June). An empirical comparison of supervised learning algorithms.In *Proceedings of the 23rd international conference on Machine learning* (pp. 161-168).

[45] :Domingo, M. C. (2012). An overview of the Internet of Things for people with disabilities. *journal of Network and Computer Applications*, *35*(2), 584-596.

[46] : https://www.journaldunet.fr/web-tech/dictionnaire-du-webmastering/1445304-python-definition-et-utilisation-de-ce-langage-informatique/ Visité le 04/05/2024.

[47] :https://fr.mathworks.com/help/matlab/learn_matlab/product-description.htmlVisité le 17/05/2024.

[48] :Prasad, A. S., &Kavanashree, N. (2019, July). ECG monitoring system using AD8232 sensor.In *2019 International Conference on Communication and Electronics Systems (ICCES)* (pp. 976-980).IEEE.

[49] :Poladi, S. R. (2018). *Matplotlib 3.0 Cookbook: Over 150 recipes to create highly detailed interactive visualizations using Python*. Packt Publishing Ltd..

[50] : Rampasek, L., & Goldenberg, A. (2016). TensorFlow: biology's gateway to deep learning?. *Cell systems*, *2*(1), 12-14.

[51] : Jolly, K. (2018). *Machine learning with scikit-learn quick start guide: classification, regression, and clustering techniques in Python*. Packt Publishing Ltd.

[52] : BABU, P. Ashok, NAGARAJU, V. Siva, et VALLABHUNI, Rajeev Ratna. Speech emotion recognition system with librosa.In : *2021 10th IEEE international conference on communication systems and network technologies (CSNT)*. IEEE, 2021. p. 421-424.

[53] :HE, Kaiming, ZHANG, Xiangyu, REN, Shaoqing, *et al.* Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In : *Proceedings of the IEEE international conference on computer vision*. 2015. p. 1026-1034.