



Université du Québec
à Rimouski

MÉMOIRE

PRÉSENTÉ À

L'UNIVERSITÉ DU QUÉBEC À RIMOUSKI

DANS LE CADRE DE LA MAÎTRISE EN INFORMATIQUE EN VUE DE L'OBTENTION

DU GRADE « MAÎTRE EN SCIENCES » (M.SC.)

PAR

@ MOHAMED ALI ABED

DÉVELOPPEMENT D'UN BRACELET MULTI-CAPTEUR PPG ET D'UN MODÈLE

D'APPRENTISSAGE POUR LA DÉTECTION DE PROBLÉMATIQUES

CARDIOVASCULAIRES

JUIN 2021

UNIVERSITÉ DU QUÉBEC À RIMOUSKI**Service de la bibliothèque**

Avertissement

La diffusion de ce mémoire ou de cette thèse se fait dans le respect des droits de son auteur, qui a signé le formulaire « Autorisation de reproduire et de diffuser un rapport, un mémoire ou une thèse ». En signant ce formulaire, l'auteur concède à l'Université du Québec à Rimouski une licence non exclusive d'utilisation et de publication de la totalité ou d'une partie importante de son travail de recherche pour des fins pédagogiques et non commerciales. Plus précisément, l'auteur autorise l'Université du Québec à Rimouski à reproduire, diffuser, prêter, distribuer ou vendre des copies de son travail de recherche à des fins non commerciales sur quelque support que ce soit, y compris l'Internet. Cette licence et cette autorisation n'entraînent pas une renonciation de la part de l'auteur à ses droits moraux ni à ses droits de propriété intellectuelle. Sauf entente contraire, l'auteur conserve la liberté de diffuser et de commercialiser ou non ce travail dont il possède un exemplaire.

Composition du jury :

Hussein Ibrahim, PhD, Président du jury, UQAR

Mehdi Adda, PhD, Professeur, Directeur de recherche, UQAR

Tarik Mohamed Moutacalli, PhD, Professeur, Codirecteur de recherche, UQAR

Hamid Mcheick, PhD, Professeur, Examineur externe, UQAC

Dépôt initial le : 15/04/2021

Dépôt final le : 17/06/2021

RÉSUMÉ

Ce mémoire étudie la faisabilité du développement d'un bracelet de surveillance cardiovasculaire utilisant trois capteurs cardiovasculaires Photoplethysmogram (PPG) afin de pouvoir détecter les anomalies liées à des maladies cardiovasculaires et éviter des complications. Plusieurs chercheurs ont traité ce sujet avec des dispositifs contenant un seul capteur PPG, d'autres ont utilisé des capteurs électrocardiogrammes (ECG). L'idée exclusive de cette recherche consiste à utiliser trois capteurs PPG pour améliorer la fiabilité des bracelets intelligents.

L'approche proposée est structurée en plusieurs étapes en commençant par le développement d'un bracelet intelligent qui intègre trois capteurs PPG. Par la suite, un algorithme choisit les données du meilleur capteur. Étant donné la non-disponibilité de jeux de données publiques pour les capteurs PPG, un algorithme d'apprentissage automatique a été développé pour approximer le signal ECG à partir d'un signal PPG dont des jeux de données de tests sont publiquement disponibles. Afin de détecter les problèmes cardiovasculaires, un algorithme d'apprentissage automatique a été développé. Finalement, une application mobile qui permet à l'utilisateur d'interagir avec le bracelet intelligent a été développée.

Les expérimentations réalisées sur ce bracelet ont été encourageantes pour la prédiction avec une précision d'entraînement de 98,46 % et de validation de 97,019 %.

Mots clés : [Bracelet intelligent ; Multicapteur PPG ; Apprentissage automatique ; Modèle prédictif].

REMERCIEMENTS

Je tiens à remercier mon directeur de recherche, le professeur Adda Mehdi de l'Université du Québec à Rimouski, de m'avoir offert l'opportunité de travailler avec lui, de son soutien et de fournir tous les moyens nécessaires pour réussir cette recherche .

Même si elle est très loin de moi, j'aimerais remercier ma famille pour tous ses conseils. Merci d'avoir toujours été là pour moi et de m'avoir soutenu durant mes études. J'aimerais également remercier tous les amis que j'ai pu rencontrer pendant ma maîtrise, avec qui j'ai passé des moments inoubliables et qui m'ont fortement soutenu.

AVANT-PROPOS

Cette recherche a été réalisé au laboratoire de l'intelligence artificielle, de la science des données et de leurs applications (LISA) de l'Université du Québec à Rimouski (UQAR). Il est présenté sous la forme d'un mémoire. Le premier chapitre présente une introduction générale concernant le problème des bracelets cardiovasculaires qui utilisent un seul capteur. Il aborde aussi le problème de conversion du signal PPG en signal ECG pour pouvoir utiliser les bases de données ECG publiquement disponibles.

Le deuxième chapitre présente une description générale des arythmies cardiaques et de l'apprentissage automatique. Le troisième chapitre contient l'état de l'art sur la santé intelligente et les bracelets intelligents. Le quatrième chapitre porte sur la contribution : développement d'un bracelet multicapteur, choix de la meilleure donnée des capteurs, conversion du signal PPG en ECG, détection des arythmies et mise en œuvre d'une application mobile. Le cinquième et dernier chapitre propose quelques pistes à considérer pour la poursuite de cette recherche.

TABLE DES MATIÈRES

Résumé	ii
Remerciements	iv
Avant-propos	vi
Table des matières	viii
Table des figures	x
Liste des tableaux	xii
LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES	xii
1 INTRODUCTION	1
1.1 SANTÉ INTELLIGENTE	1
1.2 PROBLÉMATIQUE	2
1.3 CONTRIBUTIONS	3
1.4 MÉTHODOLOGIE	4
2 CONCEPT DE BASE	5
2.1 INTRODUCTION	5
2.2 SIGNAUX PPG ET ECG	6
2.3 LES ARYTHMIES CARDIAQUES	9
2.4 APPRENTISSAGE AUTOMATIQUE	10
2.5 CONCLUSION	33
3 ÉTAT DE L'ART	35
3.1 BRACELET INTELLIGENT, DOMAINE D'UTILISATION	35
3.2 SANTÉ INTELLIGENTE	37
3.3 BRACELETS CARDIOVASCULAIRES	41
3.4 CONVERSION DE SIGNAUX ET DÉTECTION D'ARYTHMIES	43
4 DÉVELOPPEMENT DU BRACELET ET DES MODÈLES D'APPRENTISSAGES AUTOMATIQUES	51

4.1	INTRODUCTION	51
4.2	COLLECTE DE SIGNAL PPG À PARTIR DU BRACELET MULTICAPTEUR	53
4.3	CONVERSION DU SIGNAL PPG EN ECG	58
4.4	CLASSIFICATION DE SIGNAL ECG	63
4.5	ACCÈS A L'INFORMATION RETENUE	72
4.6	CONCLUSION	78
	Conclusion générale	80
	Bibliographie	83
.1	ANNEXE	99

TABLE DES FIGURES

2.1	Variabilité de la fréquence cardiaque (VRC)	7
2.2	Séquence typique d'événements électriques[51]	10
2.3	Types d'apprentissage automatique	11
2.4	Apprentissage supervisé	12
2.5	Apprentissage non supervisé	15
2.6	Apprentissage par renforcement	17
2.7	Exemple d'une architecture d'un réseau de neurones	20
2.8	Réseaux multicouches Feedforward (FNN)	22
2.9	Exemple de Max Pooling pour un CNN	27
2.10	Exemple d'architecture d'un modèle CNN	28
2.11	Représentation graphique du meilleur modèle statistique	32
3.1	Les étapes du développement	46
3.2	Caractéristiques des signaux d'un électrocardiogramme	47
4.1	Protocole de circulation des données	52
4.2	Bracelet intelligent multicateur PPG	53
4.3	Détails des composants du bracelet	54
4.4	Schéma électrique	56
4.5	Implémentation algorithmique pour choisir le meilleur capteur	57
4.6	Diagramme de connexion capteur ECG[115]	58
4.7	PPG capteur[19]	59
4.8	Modèle de conversion du signal PPG en ECG	60
4.9	Code source de l'implémentation du convertisseur	61
4.10	Score d'entraînement	62
4.11	Résultat de la conversion du signal PPG en ECG	63
4.12	Classification des rythmes cardiaques	64
4.13	Architecture du premier modèle	65
4.14	Architecture de deuxième modèle	66
4.15	Base de données ECG	67
4.16	Résultats du premier exemple	68
4.17	Résultats du deuxième exemple	70
4.18	Exécution de modèle sur Raspberry-py zéro	71
4.19	Circulation des données	73

4.20 Diagramme de classes	74
4.21 Base de données Firebase	75
4.22 Diagramme de cas d'utilisation	76
4.23 Identification de l'utilisateur	77

LISTE DES TABLEAUX

3.1	Performance globale pour les approches proposées	50
4.1	Description de cas d'utilisation globale	78

LISTE DES ABRÉVIATIONS, DES SIGLES ET DES ACRONYMES

ECG	L'électrocardiographie
PPG	Photopléthysmogramme
ML	Apprentissage automatique
FCN	Réseau entièrement convolutionnelles
AF	Atriale fibrillation
AVC	Accident vasculaire cérébral
MLP	Perceptron multi-couche
VRC	La variabilité de la fréquence cardiaque
SNA	Le système nerveux autonome
AR	L'oreillette droite haute
LA	L'oreillette gauche
IVS	Septum interventriculaire
RV	Les ventricules droits
LV	Les ventricules gauches
FC	La fréquence cardiaque
SNC	Le système nerveux central
WBAN	Capteur sans fil pour corps humain
LVAD	Dispositif d'assistance ventriculaire gauche
SVM	Machine à vecteurs de support
LPC	Caractéristiques des coefficients de prédiction linéaire
ICA	Analyse des composants indépendants
KNN	Classificateur des voisins les plus proches
CNN	Réseaux neuronaux à convolution
QRS	la combinaison de trois des déflexions graphiques observées sur un électrocardiogramme
RR	Temps qui sépare le début de deux QRS

CHAPITRE 1

INTRODUCTION

1.1 SANTÉ INTELLIGENTE

Les progrès technologiques dans les circuits intégrés et les communications sans fil ont permis de concevoir et de fabriquer des dispositifs de suivi portables intelligents légers et à très faible consommation d'énergie [96].

Ces dispositifs omniprésents ont été reconnus comme une technologie portative fondamentale pour une grande variété d'applications de systèmes cyberphysiques, y compris la surveillance environnementale, la santé, la sécurité, les domaines industriels et, bien sûr, l'Internet des objets [94].

La technologie portable est également très importante dans les soins de santé où les appareils électroniques intelligents permettent le suivi permanent des signes vitaux et éventuellement la détection précoce de troubles cardiaques, contribuant ainsi à fournir un traitement et une prise en charge optimaux [117, 103, 24, 109, 27, 74, 58].

1.2 PROBLÉMATIQUE

Afin d'assurer une surveillance efficace de la santé, un dispositif intelligent doit être porté par l'utilisateur à tout moment. En général, les appareils portables et les bracelets qui surveillent l'activité cardiovasculaire fonctionnent avec ou requièrent deux types de capteurs : l'électrocardiogramme (ECG) ou le photopléthysmogramme (PPG)[30].

Les capteurs ECG sont liés aux changements de potentiel électrique des cellules spécialisées dans la contraction et des cellules spécialisées dans l'automatisation et la conduction des influx[30, 39, 99, 128, 106]. Ces capteurs nécessitent généralement que des électrodes soient placées à des endroits spécifiques du corps et connectées à une carte d'acquisition, ce qui limite les mouvements de l'utilisateur ou produit de l'inconfort surtout si les capteurs sont portés en permanence.

Ces inconvénients ne sont pas rencontrés lors de l'utilisation des capteurs PPG, qui adoptent une technique optique simple permettant de trouver les changements volumétriques du sang dans la circulation périphérique à partir de différentes parties du corps[92]. Cependant, les mouvements brusques[137, 127] peuvent provoquer de fausses alertes. Afin de surmonter cet inconvénient, nous avons développé un prototype de bracelet intelligent qui fonctionne avec trois capteurs PPG. Pour utiliser ce bracelet dans le cadre de la santé intelligente, on a également mis au point un modèle d'apprentissage automatique qui effectue une classification du signal cardiovasculaire afin de détecter des arythmies cardiaques.

Il convient de noter que la recherche et la détection des arythmies cardiaques sont généralement effectuées à l'aide d'un moniteur d'électrocardiographie ambulatoire de type Holter qui enregistre le rythme cardiaque pendant des périodes de 24 à 48 heures[122]. Pour cette raison, la plupart des bases de données publiquement disponibles sont au format ECG.

Or, il est primordial de disposer d'une grande base de données pour créer un modèle de classi-

fication efficace, particulièrement lorsqu'il s'agit d'utiliser l'apprentissage profond. Donc, il faut effectuer une conversion du signal émis par le bracelet en format PPG au format ECG.

Notre recherche vise à répondre à deux grandes questions :

1. Comment développer un bracelet cardiovasculaire multicapteur ?
2. Comment créer un modèle d'apprentissage pour la détection des problèmes cardiovasculaires avec les données ECG et procéder à des prédictions en utilisant les données de capteurs PPG ?

1.3 CONTRIBUTIONS

Cette recherche a pour but de concevoir et développer un bracelet intelligent de surveillance cardiovasculaire multicapteur.

Afin d'atteindre cet objectif, les étapes suivantes ont été entreprises :

- Développer un bracelet à trois capteurs cardiovasculaires photoplethysmogram (PPG) qui se positionnent à des endroits différents autour du bras ;
- Recourir à un algorithme pour choisir les données du meilleur capteur (comparer les données obtenues par les trois capteurs et choisir le capteur ayant la valeur intermédiaire et qui entraîne un écart minimal par rapport aux deux autres capteurs dans une limite raisonnable) ;
- Implémenter un algorithme d'apprentissage automatique pour convertir le signal PPG en signal ECG ;
- Développer un algorithme d'apprentissage automatique pour détecter des problèmes cardiovasculaires ;

— Développer une application mobile pour l'interaction avec le bracelet ;

1.4 MÉTHODOLOGIE

Le premier chapitre présente les grands principes de la santé intelligente, la problématique ainsi que l'objectif de cette recherche et finalement la méthodologie de travail suivie. Le deuxième chapitre détaille les concepts de base liés au domaine d'étude : les signaux PPG et ECG, les arythmies cardiaques, le phénomène des réseaux de neurones artificiels, l'architecture, les types d'apprentissage les plus connus, les avantages et les inconvénients.

Le troisième chapitre aborde de plus près l'avancement réalisé par les chercheurs dans la technologie des bracelets intelligents et l'utilisation de modèles d'apprentissage automatique. L'avant-dernier chapitre explore la contribution matérielle du recherche (bracelet intelligent), la contribution logicielle (modèles d'apprentissage automatique, application mobile), les expérimentations ainsi les résultats obtenus.

La conclusion générale dresse le bilan des connaissances acquises durant cette recherche ainsi que les perspectives futures.

CHAPITRE 2

CONCEPT DE BASE

Ce chapitre, aborde les principes des signaux ECG (électrocardiogramme) et PPG (photopléthysmogramme), leur utilité et ce qu'ils ont en commun avec une étude sur les arythmies cardiaques. Le chapitre explore brièvement l'apprentissage automatique en commençant par les types d'apprentissage par réseaux de neurones.

2.1 INTRODUCTION

L'étude de la variation du rythme cardiaque (VRC) permet d'estimer la régulation de l'activité cardiaque par l'analyse de la corrélation entre les battements cardiaques successifs. Ce signal est déterminé par une électrocardiographie (ECG) ou une photopléthysmographie (PPG), il peut évaluer la détresse fœtale [119], révéler la neuropathie diabétique et d'autres problèmes vasculaires [110].

Il a également été démontré que le VRC prédit le mode de décès en cas d'insuffisance cardiaque chronique [57], ce qui soulève la perspective que le VRC pourrait s'avérer un guide précieux pour l'intervention clinique en cas de maladie cardiovasculaire [82].

2.2 SIGNAUX PPG ET ECG

La surveillance des changements dynamiques des paramètres physiologiques et biologiques au moyen de systèmes intégrés non invasifs peut jouer un rôle important dans une grande variété d'applications, y compris dans les domaines de la santé et de l'entraînement sportif [114, 111, 91]. Parmi plusieurs facteurs, les paramètres hémodynamiques (ex., fréquence cardiaque, perfusion tissulaire) obtenus par photopléthysmographie (PPG) et l'activité électrique du cœur (ECG) sont beaucoup étudiés [125, 78].

2.2.1 L'ÉLECTROCARDIOGRAPHIE (ECG)

Vers 1880, E Marey [72] et Augustus Waller [52] montrèrent qu'il est possible de suivre l'activité électrique du cœur à partir de la peau et, vers 1890, Willem Einthoven réalisa le premier enregistrement cardiographique [35]. L'activité électrique du muscle cardiaque qui change avec le temps (la somme de cette activité électrique lorsqu'elle est amplifiée et enregistrée en quelques secondes) peut être représentée par un ECG[100].

Le cycle cardiaque commence par une dépolarisation spontanée du nœud sinusal, une zone de tissu spécialisé située dans l'oreillette droite haute (AR). Une onde de dépolarisation électrique se propage à travers l'AR et le septum interauriculaire dans l'oreillette gauche (LA). Les oreillettes des ventricules sont séparées par un anneau fibreux électriquement inerte, de sorte que dans le cœur, le courant électrique se propage vers le nœud auriculo-ventriculaire (AV). Le nœud AV retarde le signal électrique pendant une courte période, puis l'onde de dépolarisation se propage le long du septum inter ventriculaire (IVS), via le faisceau de HIS et les branches droite et gauche du faisceau, dans les ventricules droits (RV) et gauche (LV). Par conséquent, avec une conduction normale, les deux ventricules se contractent simultanément, ce qui est important pour maximiser l'efficacité cardiaque[100].

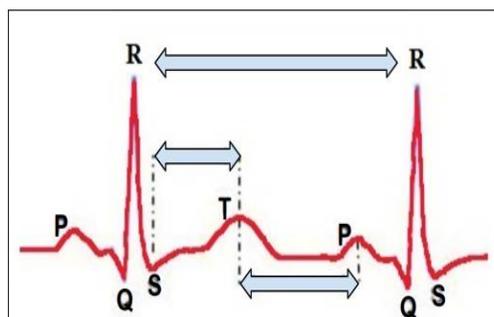


FIGURE 2.1 – Variabilité de la fréquence cardiaque (VRC)

Après une dépolarisation complète du cœur, le myocarde doit répondre avant qu'il puisse être prêt à dépolariser à nouveau pour le cycle cardiaque suivant.

Le signal de variabilité de la fréquence cardiaque (VRC) indique une régulation autonome de la fréquence cardiaque (FC). La principale méthode de dérivation du signal VRC consiste actuellement à acquérir le signal de l'électrocardiogramme (ECG), à appliquer des algorithmes de détection QRS appropriés pour localiser l'onde R et son pic, à trouver les intervalles RR et à effectuer une interpolation et un rééchantillonnage appropriés pour produire un tachogramme échantillonné uniformément (voir Figure 2.1) [6]. Ce processus peut parfois engendrer des erreurs dans le signal VRC en raison du dérivé, des interférences électromagnétiques et biologiques, et de la morphologie complexe du signal ECG [88].

2.2.2 PHOTOPLÉTHYSMOGRAPHIE (PPG)

Les changements de volume sanguin dans le lit micro vasculaire des tissus peuvent être détectés par une technique simple et peu coûteuse qui s'appelle photopléthysmographie (PPG)[9].

Le PPG est souvent utilisé de façon non invasive pour effectuer des mesures à la surface de la peau. La forme d'onde PPG comprend une forme d'onde physiologique pulsatile attribuée aux

changements cardiaques synchrones du volume sanguin à chaque battement du cœur. Bien que les composantes du signal PPG ne soient pas entièrement comprises, il est admis qu'elles peuvent fournir des renseignements précieux sur le système cardiovasculaire[28].

La technique a suscité un regain d'intérêt au cours des dernières années, en raison de la demande pour des technologies simples et portables à faible coût pour les soins primaires et les milieux cliniques communautaires, en raison également de la grande disponibilité de composants à faible coût et de petits semi-conducteurs, et grâce à l'avancement des techniques informatisées d'analyse des ondes pulsées[7]. La technologie PPG a été utilisée dans une large gamme de dispositifs médicaux disponibles dans le commerce pour mesurer la saturation en oxygène[113], la tension artérielle[135] et le débit cardiaque, évaluer la fonction autonome et détecter des problématiques vasculaires[108].

2.2.3 RELATION ENTRE PPG ET ECG

Les signaux PPG et ECG sont intrinsèquement corrélés[102], étant donné que la variation du volume du sang périphérique est influencée par les activités du myocarde ventriculaire gauche, et que ces activités sont contrôlées par les signaux électriques provenant du nœud sinusal (SA). Les caractéristiques de synchronisation, d'amplitudes et de formes d'onde du PPG contiennent des informations sur l'interaction entre le cœur et le système vasculaire conjonctif. Ces caractéristiques ont été traduites pour mesurer la fréquence cardiaque, la variabilité de la fréquence cardiaque, la fréquence respiratoire [63], la saturation en oxygène du sang [123], la pression artérielle [93] et pour évaluer la fonction vasculaire [76, 59].

Dans ce cadre, on s'est inspiré d'un appareil portable qui capture le signal PPG des utilisateurs sur une base quotidienne étant prédominante. Cette corrélation nous a inspirés pour non seulement déduire les paramètres ECG, mais aussi reconstruire la forme d'onde ECG à partir de la mesure PPG. Cette solution, si elle est fructueuse, peut fournir un dépistage ECG peu

coûteux pour une surveillance continue à long terme et permettre de tirer profit à la fois de la riche expérience clinique la base de données publiquement disponible du signal ECG et les avantages des capteurs PPG.

2.3 LES ARYTHMIES CARDIAQUES

Les arythmies et les fréquences cardiaques anormales ne se produisent pas nécessairement ensemble. Les arythmies peuvent se produire avec une fréquence cardiaque normale, ou avec des fréquences cardiaques lentes appelées bradyarrhythmies (moins de 50 battements par minute). Les arythmies peuvent également se produire avec des fréquences cardiaques rapides appelées tachyarythmies (plus rapide que 100 battements par minute)[71]. Sur un plan plus large, jusqu'à 40000 arrêts cardiaques se produisent chaque année au Canada[41].

Les arythmies cardiaques peuvent être causées par des différents facteurs tels que la blessure, le changement électrolytique dans le sang, la maladie coronarienne ou des rythmes cardiaques irréguliers (voir Figure 2.2).

Les types arythmies sont identifiés par leur origine dans le cœur et par le fait qu'elles le font battre lentement ou rapidement [85] :

- Les arythmies qui se situent au-dessus des ventricules, ou plus précisément les arythmies auriculaires ou supraventriculaires, et qui commencent dans les oreillettes ;
- Les arythmies auriculaires (les rythmes cardiaques rapides qui proviennent des oreillettes) ;
- Le ralentissement du rythme cardiaque se produit lorsque le stimulateur cardiaque est défectueux ou lorsqu'il y a un blocage de conduction des voies de conduction ;
- Les rythmes cardiaques rapides provenant des oreillettes qui comprennent la fibrillation auriculaire, le flutter auriculaire et la tachycardie supraventriculaire.
- Les rythmes cardiaques lents qui se produisent quand il y a un blocage dans les voies de conduction ou lorsque le stimulateur cardiaque échoue.

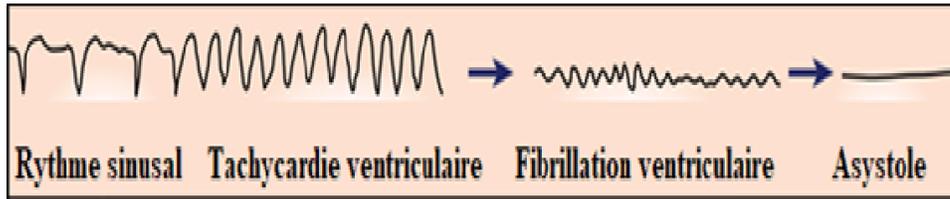


FIGURE 2.2 – Séquence typique d'événements électriques[51]

Grâce au développement de l'informatique et à l'apprentissage automatique nous sommes devenus capables de distinguer les changements cardiovasculaires. La machine joue un rôle important dans la classification des événements électriques du cœur. La section suivante présente les procédures d'apprentissage automatique avec certains types de réseaux de neurones et leur architecture.

2.4 APPRENTISSAGE AUTOMATIQUE

En 1943, McCulloch et Pitts ont développé le premier modèle d'un réseau neuronal artificiel. Dans leur article 'Modèle neuronal artificiel' [75], ils présentent un calcul logique des idées imminentes dans l'activité nerveuse, ils décrivent le concept d'un neurone vivant dans un réseau de cellules qui reçoit des entrées qui seront traitées pour générer une sortie.

Les réseaux de neurones artificiels (ANN) sont des programmes informatiques d'inspiration biologique conçus pour simuler la façon dont le cerveau humain traite l'information. Un ANN est formé de centaines d'unités simples, de neurones artificiels ou d'éléments de traitement liés à des coefficients (poids), qui constituent la structure neuronale et qui sont organisés en couches [5].

2.4.1 LES TYPES D'APPRENTISSAGE DES RÉSEAUX DE NEURONES

L'apprentissage est une phase du développement du réseau de neurones durant laquelle nous calculons les poids des neurones de telle manière que les sorties du réseau soient aussi proches que possible des sorties désirées.

Les approches d'apprentissage sont divisées en trois grands types [86] : supervisé, non supervisé et semi-supervisé (voir Figure 2.3)

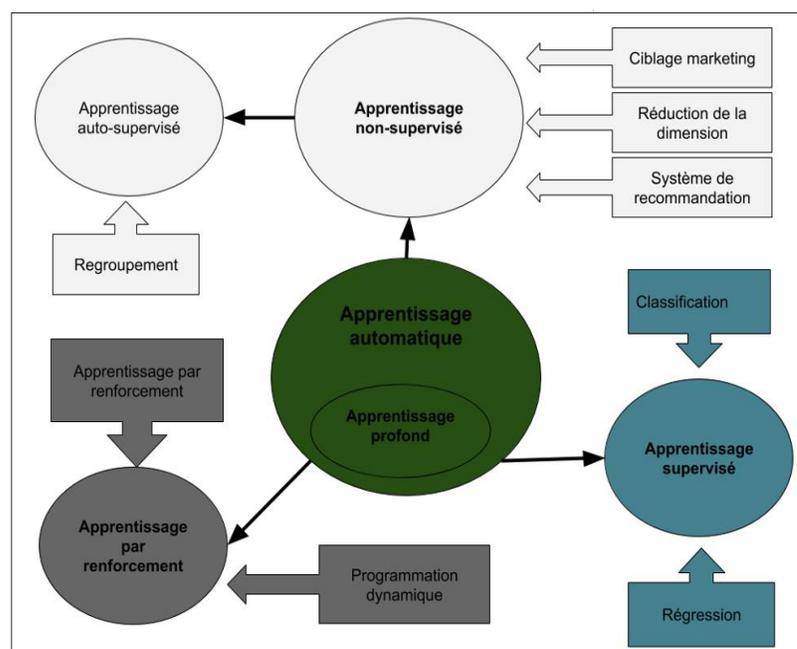


FIGURE 2.3 – Types d'apprentissage automatique

Apprentissage supervisé

Dans ce type d'apprentissage, les entrées et les sorties sont fournies à l'avance, comme le montre la figure ci-dessous (voir figure 2.4). Le réseau traite les entrées et compare les résultats

de l'ensemble d'apprentissage avec les sorties souhaitées. Pendant l'entraînement du réseau, des erreurs se propagent, ce qui amène le réseau à ajuster les poids[17]. Pour bien comprendre

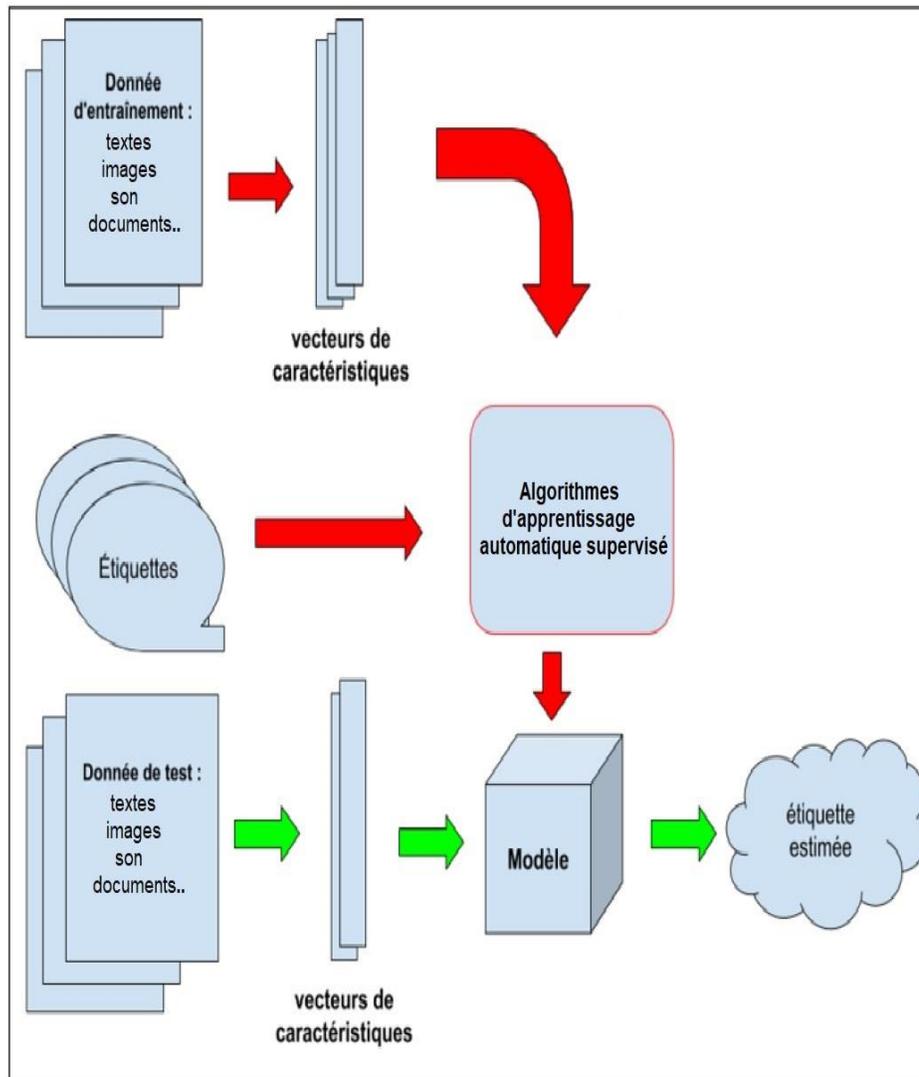


FIGURE 2.4 – Apprentissage supervisé

cette technique, prenons l'exemple d'un inspecteur qui découvre un ensemble d'indices et qui doit déterminer si les indices condamnent le suspect ou non. L'inspecteur est guidé par de

nombreux exemples passés d'enquête. L'examen des enquêtes antérieures (appelé ensemble d'apprentissage) permet à l'inspecteur d'apprendre davantage sur la culpabilité du suspect. Ce processus est un exemple d'apprentissage supervisé, et le résultat peut être appliqué pour déterminer la culpabilité du suspect.

Il existe deux principaux types d'apprentissage supervisé, la régression et la classification, où il y a une entrée X et une sortie Y et le but principal est de trouver une correspondance entre l'entrée et la sortie[10].

La régression est une technique d'apprentissage supervisé pour la prédiction de quantités numériques. Un exemple de tâches de régression est la prédiction de la valeur d'un inventaire particulier (cette tâche est différente de la prédiction de l'augmentation ou de la diminution de la valeur d'un stock particulier demain ou à un autre moment futur) et la prédiction du coût d'une maison dans un ensemble de données immobilières.

Les techniques de régression dans l'apprentissage automatique supervisé incluent la régression linéaire et la régression linéaire généralisée (également appelée analyse multivariée dans les statistiques traditionnelles).

L'objectif de la régression linéaire est de trouver la ligne la mieux adaptée qui représente un ensemble de données. Il faut se rappeler ces deux points clés : premièrement, la ligne de meilleure adéquation ne passe pas nécessairement par tous (ou même la plupart) les points de l'ensemble de données. Son but est de s'assurer que la ligne passe par le plus grand nombre possible de points dans l'ensemble des données. Deuxièmement, la régression linéaire ne détermine pas le polynôme le mieux ajusté : le polynôme le mieux ajusté est un polynôme de degré supérieur qui passe par de nombreux points dans un ensemble de données.

En outre, un ensemble de données dans le plan peut contenir deux ou plusieurs points situés sur une même ligne verticale, c'est-à-dire que ces points ont la même valeur x . Cependant, une

fonction ne peut pas passer par une telle paire de points : si deux points (x_1, y_1) et (x_2, y_2) ont la même valeur x , alors ils doivent avoir la même valeur y (c'est-à-dire $y_1 = y_2$). D'autre part, une fonction peut avoir deux ou plusieurs points situés sur la même ligne horizontale [73]. La régression linéaire permet de trouver la ligne la mieux adaptée qui représente un ensemble de données, mais la question qui se pose est la suivante :

1. Que se passe-t-il si une ligne du dessin ne correspond pas à l'ensemble de données ?

Cette question s'avère pertinente lorsqu'on travaille avec des ensembles de données. Une alternative à la régression linéaire est la régression non linéaire où le modèle qui est non linéaire est ajusté aux données d'entraînement. Avec un ensemble de données contenant des observations dont l'appartenance à une classe est connue, **la classification** consiste à déterminer la classe à laquelle appartient un nouveau point de données. Les classes font référence à des catégories et sont également appelées cibles ou étiquettes[120]. Parmi les techniques de classification existantes, se trouve la classification linéaire, le kNN (classificateur des voisins les plus proches), la régression logistique, les arbres de décision, les forêts aléatoires, les SVM (machine à vecteur de support), les classificateurs bayésiens, les CNN (réseaux de neurones à convolution), etc.

Apprentissage non supervisé

Dans ce type d'apprentissage, le système est censé découvrir des caractéristiques statistiquement saillantes des données d'entrée. Contrairement à l'apprentissage supervisé, il n'y a pas à priori de catégories dans lesquelles les modèles doivent être classés ; le système doit plutôt développer sa propre représentation des stimuli d'entrée.

Afin de mieux comprendre cette technique, nous allons revenir à l'inspecteur qui doit maintenant déterminer si les indices condamnent une ou plusieurs personnes.

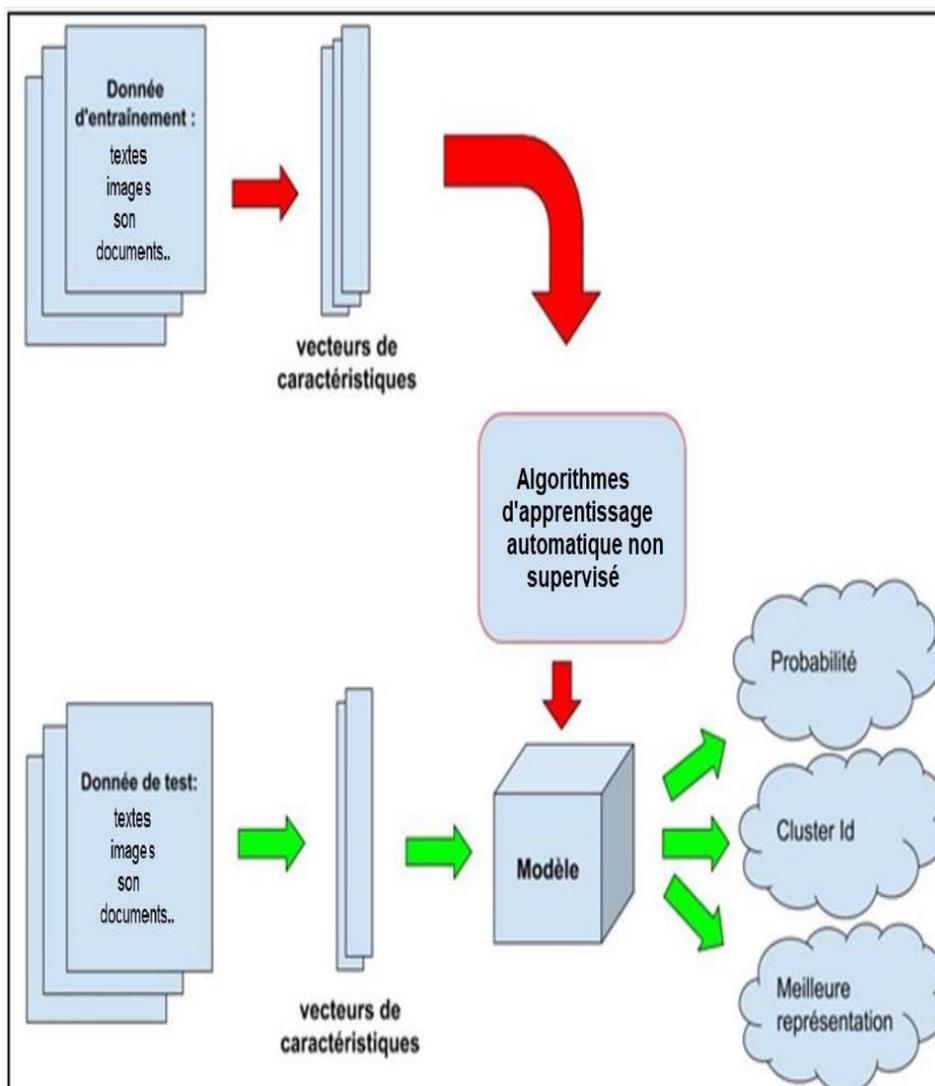


FIGURE 2.5 – Apprentissage non supervisé

Pour cette tâche, aucune donnée antérieure ne pourra servir pour identifier clairement le ou les suspects. Il s'agit d'un processus d'apprentissage non supervisé (voir Figure 2.5), qui consiste à estimer la relation entre les indices et les suspects. Un inspecteur peut croire que les indices condamnent un seul suspect, tandis qu'un autre peut être en désaccord, et il n'y a pas de critère

absolu pour déterminer qui a raison.

Apprentissage semi-supervisé

Comme son nom l'indique, l'apprentissage semi-supervisé se situe quelque part entre l'apprentissage non supervisé et l'apprentissage supervisé. On suppose généralement qu'il y a beaucoup plus de données non étiquetées que de données étiquetées. L'apprentissage semi-supervisé consiste à utiliser les données étiquetées pour classer les données non étiquetées[130].

En fait, la plupart des stratégies d'apprentissage semi-supervisé sont basées sur l'extension de l'apprentissage non supervisé ou supervisé pour inclure des informations supplémentaires typiques de l'autre paradigme d'apprentissage.

L'apprentissage semi-supervisé a une énorme valeur pratique. Dans de nombreuses tâches, il y a un manque de données étiquetées. Les étiquettes peuvent être difficiles à obtenir, car elles nécessitent des annotateurs humains, des dispositifs spéciaux ou des expériences lentes et coûteuses[130].

Apprentissage par renforcement

L'apprentissage par renforcement (voir figure 2.6) est un type d'apprentissage qui peut être considéré comme une forme intermédiaire des deux premiers types. Dans ce cas, afin que la machine puisse apprendre, elle exerce des actions sur l'environnement et obtient une réaction de ce dernier. Le système d'apprentissage classe son action comme bonne (gratifiante) ou mauvaise (punissable) en fonction de la réponse environnementale et ajuste en conséquence ses paramètres. En général, l'ajustement des paramètres se poursuit jusqu'à ce qu'un état d'équilibre se produise, quand il n'y aura plus de changements dans ses paramètres [8].

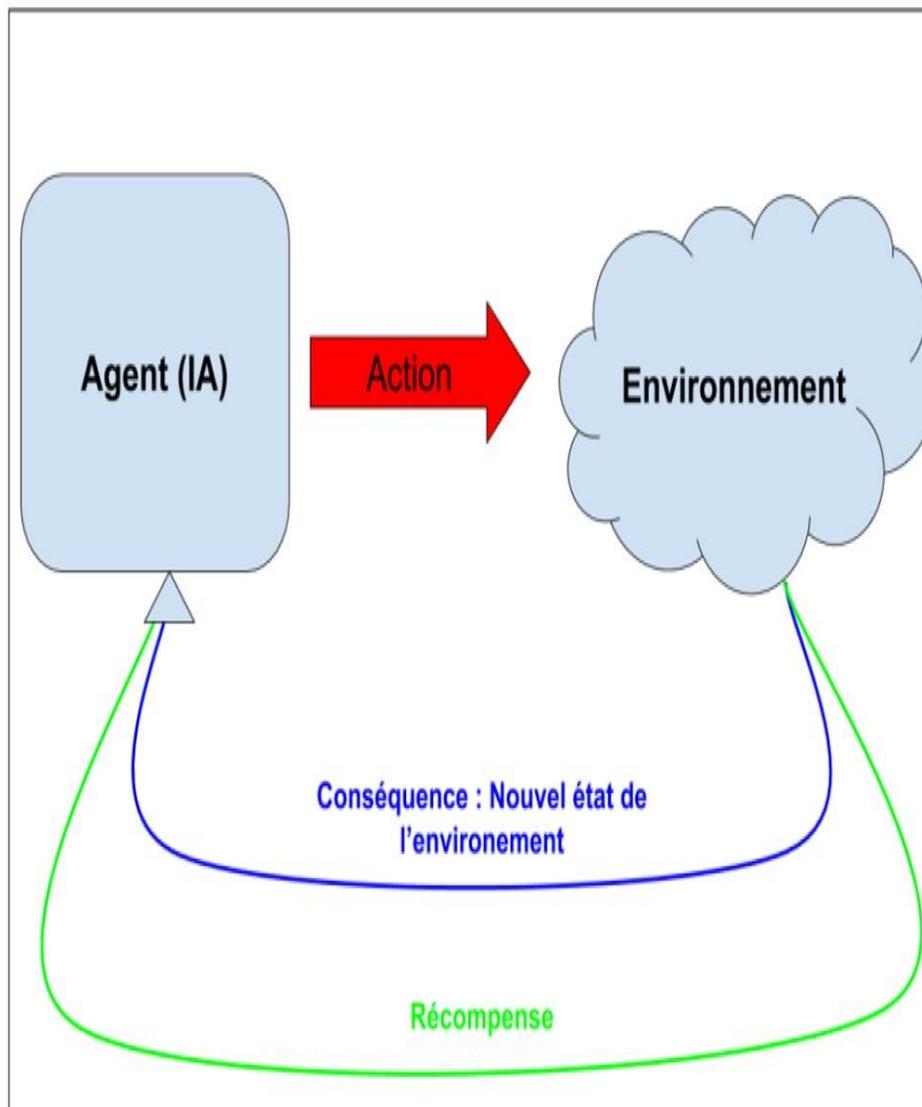


FIGURE 2.6 – Apprentissage par renforcement

Apprentissage profond

L'apprentissage profond est un sous-domaine de l'apprentissage automatique[3]. Il facilite la modélisation de relations et de concepts complexes en utilisant plusieurs niveaux de

représentation. L'apprentissage profond approprié dépend de la dimensionnalité des données et de la structure et peut donner une grande précision dans la tâche de classification.

Dans une optique plus globale, l'apprentissage profond et l'apprentissage supervisé impliquent la définition d'un modèle appelé réseau de neurones[66]. L'apprentissage profond permet de :

- Effectuer une estimation pour un point de données ;
- Calculer la perte ou l'erreur de chaque estimation ;
- Réduire l'erreur par descente de gradient.

L'apprentissage profond implique des hyperparamètres, qui sont comme des boutons et des cadrans dont les valeurs sont initialisées avant le processus d'entraînement [3]. Par exemple, le nombre de couches cachées et le nombre de neurones qui s'y trouvent sont des hyperparamètres. On rencontre de nombreux hyperparamètres dans les modèles d'apprentissage profond, dont certains sont répertoriés ici :

- Nombre de couches cachées ;
- Nombre de neurones dans les couches cachées ;
- Poids initiaux ;
- Fonction d'activation ;
- Fonction de coût ;
- Optimiseur ;
- Taux d'apprentissage ;
- Taux d'abandon.

Les trois premiers hyperparamètres de la liste sont nécessaires pour la configuration initiale d'un réseau de neurones profond. Le quatrième hyperparamètre est requis pour la propagation vers l'avant. Les trois hyperparamètres suivants (c'est-à-dire la fonction de coût, l'optimiseur et le taux d'apprentissage) sont nécessaires pour effectuer une propagation d'erreur vers l'arrière, souvent appelée simplement rétropropagation du gradient durant la phase d'apprentissage. Cette étape calcule un ensemble de valeurs qui sont utilisées pour mettre à jour les poids

dans le réseau afin d'améliorer sa précision. L'hyperparamètre final est utile pour réduire le surapprentissage dans le modèle. En général, la fonction de coût est le plus complexe de tous ces hyperparamètres[3].

2.4.2 ARCHITECTURE DES RÉSEAUX DE NEURONES

Cette sous-section présente certains types de réseaux de neurones : leur composition, les principales caractéristiques de leur architecture et les principes de leur fonctionnement.

Les récents développements des techniques de réseaux de neurones offrent des avancées remarquables dans l'apprentissage automatique et l'intelligence artificielle (IA). Les structures de réseaux complexes ont apporté de grands succès dans différents domaines, tels que la vision par ordinateur et le traitement du langage naturel[136]. Un réseau de neurones se compose d'un certain nombre de nœuds interconnectés, chaque nœud est un simple élément de traitement qui répond aux entrées pondérées qu'il reçoit d'autres nœuds (voir Figure 2.7).

Exemples de types de réseaux de neurones

MLP (Perceptron multicouche) : Le MLP peut séparer des données non linéaires parce qu'il s'agit de couches multiples. Il se compose généralement de trois types de couches (ou plus). Atkinson[95] a supposé que le nombre de couches dans un réseau renvoie au nombre de couches de nœuds et non au nombre de couches de poids. Cette dernière définition se trouve également dans la littérature de Bishop[22].

- Le premier type de couche est la couche d'entrée, où les nœuds sont les éléments d'un vecteur de caractéristique. Ce vecteur pourrait être constitué des bandes d'ondes d'un ensemble de données, de la texture de l'image[61] ou d'autres paramètres plus complexes [138].

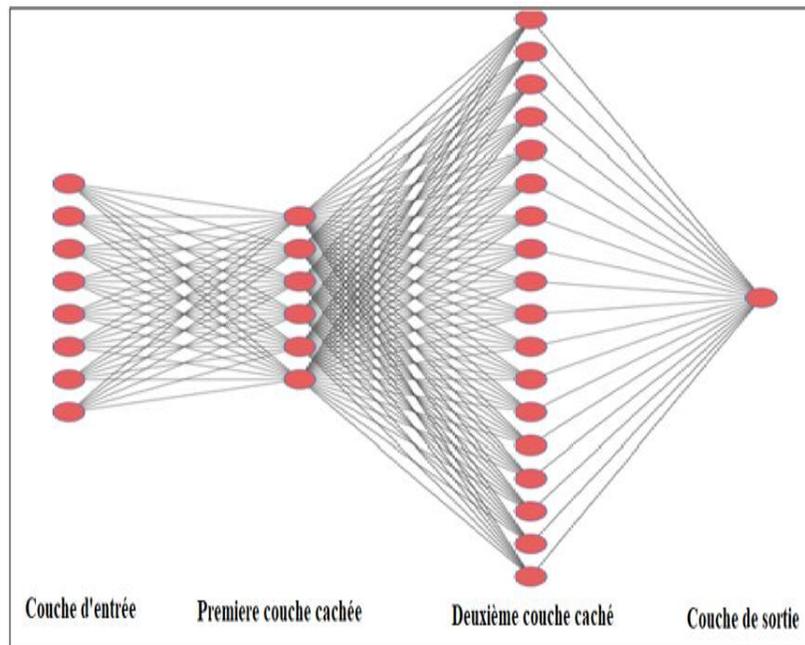


FIGURE 2.7 – Exemple d’une architecture d’un réseau de neurones

- Le deuxième type de couche est la couche interne ou cachée, car elle ne contient pas d’unités de sortie. Il n’y a pas de règles, mais la théorie montre qu’une couche cachée peut représenter n’importe quelle fonction booléenne. Une augmentation du nombre de couches cachées permet au réseau d’apprendre des problèmes plus complexes, mais on note que la capacité de généraliser est réduite et il y a une augmentation associée au temps d’entraînement [42]. Dans une autre recherche, Lippmann[67] suggère que si une deuxième couche cachée est utilisée, le nombre maximum de nœuds dans la deuxième couche cachée devrait être trois fois plus élevé que dans la première couche cachée.
- Le troisième type de couche est la couche de sortie qui présente les données de sortie. Par exemple, pour la classification des images, le nombre de nœuds dans la couche de sortie est égal aux classes de la classification [20].

Les réseaux multicouches Feedforward (FNN) : Les FNN sont de loin l'architecture de réseaux de neurones la plus courante et la plus utilisée. Ils sont une extension directe des perceptrons qu'on a étudié sur les neurones artificiels précédente et, fondamentalement, ils fonctionnent de la même manière. Cependant, les FNN sont utilisés pour résoudre des problèmes complexes nécessitant une puissance de calcul et des capacités cognitives importantes. Ces capacités ne peuvent pas être atteintes en utilisant un seul neurone. En fait, les FNN sont construits à l'aide de nombreux neurones artificiels qui sont disposés en couches.

- Couche d'entrée : ces couches introduisent les données d'entrée et les conditions de départ dans le réseau ;
- Couche cachée : ces neurones effectuent généralement une classification basée sur des caractéristiques uniques et statistiques dans les données. Deux couches cachées sont généralement suffisantes pour résoudre la plupart des problèmes, sans exiger une complexité excessive ou des procédures d'optimisation lourdes en calcul ;
- Couche de sortie : le résultat de tous les calculs à l'intérieur du réseau est présenté au monde extérieur à travers ces neurones.

Les principales caractéristiques de cette architecture se résument comme suit :

- Les informations ne circulent que dans un sens (entre en entrée, à travers la couche cachée et les résultats de sortie ne sont émis que par la couche de sortie) ;
- Des couches cachées peuvent être ajoutées ou supprimées pour modifier facilement la complexité des calculs sans avoir un impact majeur sur l'ensemble du réseau. Ci-dessous, nous pouvons voir un exemple très basique d'un FNN avec trois couches et cinq neurones (voir Figure 2.8).

Les neurones de la couche d'entrée sont désignés par la lettre A, les neurones de la couche cachée sont désignés par la lettre B et les neurones de la couche de sortie, par la lettre C. Dans ce réseau, nous avons également montré des exemples de tous les poids et biais, comme nous le trouvons dans un vrai FNN. Une autre architecture commune de réseau de neurones est

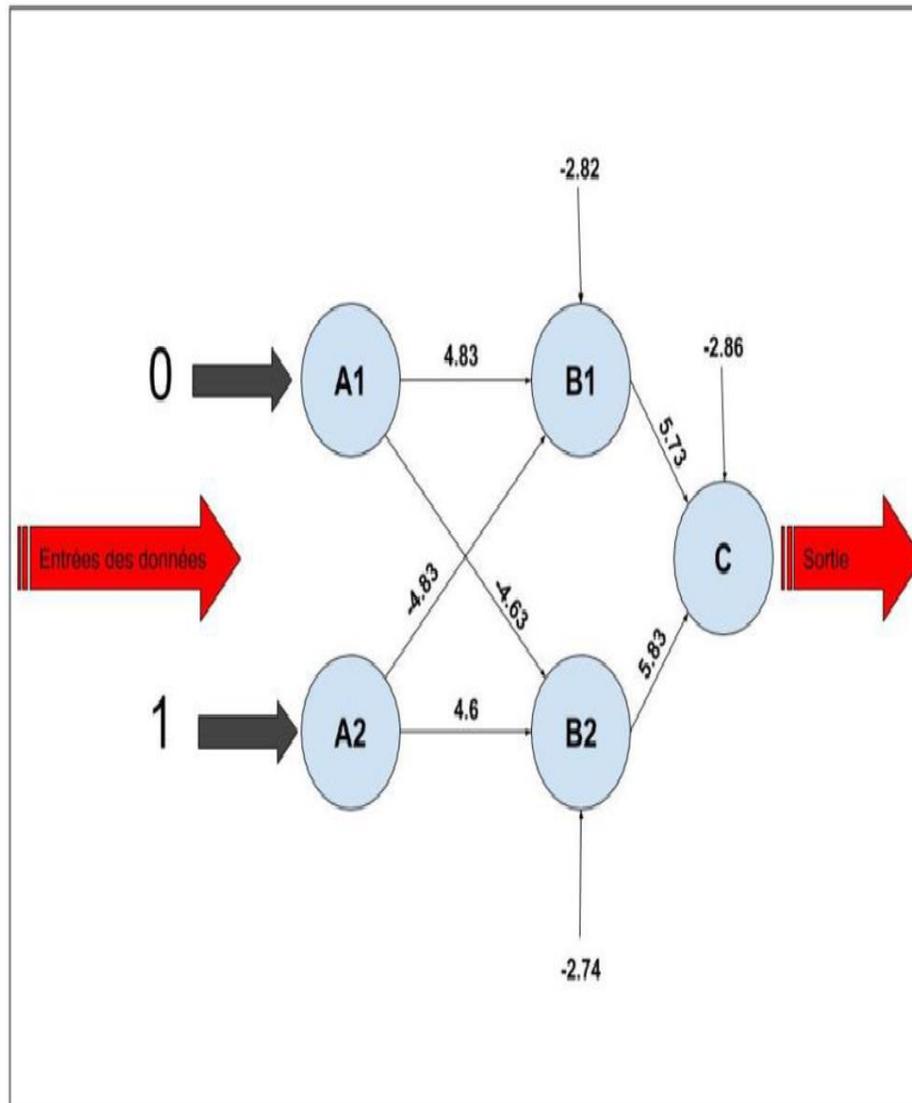


FIGURE 2.8 – Réseaux multicouches Feedforward (FNN)

le réseau de neurones récurrent ou feed-back (RNN). Dans ces réseaux, les sorties des noeuds sont utilisées comme entrées[64]. Ce type de réseaux est pratique dans des cas où nous souhaitons tenir compte du séquençement des données (information historique, temporelle, etc.)[25].

Les réseaux neuronaux convolutionnels (CNN ou ConvNets) sont une classe de réseaux spécialisés dans le traitement de données topologiques de type grille, tel que les images. Ils se composent de trois couches distinctes [69] :

- Convolutionnel ;
- Mise en commun ;
- Entièrement connecté.

Le CNN dispose d'une couche convolutionnelle qui est responsable d'appliquer un ou de nombreux filtres à une entrée. C'est cette couche qui distingue les réseaux neuronaux convolutifs des autres réseaux de neurones. Chaque couche convolutive contient un ou plusieurs filtres, appelés "noyaux convolutifs". Ce filtre est principalement une matrice d'entiers qui est utilisée sur un sous-ensemble de l'image d'entrée, ayant une taille qui lui est identique. Chaque pixel du sous-ensemble est multiplié par la valeur correspondante dans le noyau, puis le résultat est additionné pour obtenir une valeur unique. Cette opération est répétée jusqu'à la création d'une carte des caractéristiques de sortie[69].

Autres caractéristiques

Cette sous-section, nous allons présenter certaines caractéristiques : les fonctions d'activations, l'algorithme Max Pooling, le principe de l'algorithme d'optimisation, le taux d'apprentissage et le taux d'abandon.

Fonctions d'activation : Une fonction d'activation est une fonction non linéaire qui introduit la non-linéarité dans un réseau de neurones, empêchant ainsi une consolidation des couches cachées dans le réseau de neurones. Plus précisément, supposons que chaque paire de couches adjacentes dans un réseau de neurones n'implique qu'une transformation matricielle et aucune fonction d'activation. Un tel réseau est un système linéaire, ce qui signifie que ses couches peuvent être consolidées dans un système beaucoup plus petit.

Tout d'abord, les poids des arêtes qui relient la couche d'entrée avec la première couche cachée peuvent être représentés par une matrice : appelons-la W_1 . Ensuite, les poids des arêtes qui relient la première couche masquée à la seconde couche masquée peuvent également être représentés par une matrice : appelons W_2 . Répétons ce processus jusqu'à ce qu'on atteigne les bords qui relient la couche cachée finale avec la couche de sortie : appelons cette matrice W_k . Comme nous n'avons pas de fonction d'activation, nous pouvons tout simplement multiplier les matrices W_1, W_2, \dots, W_k ensemble et produire une matrice : appelons-la W . Nous pouvons ensuite remplacer le réseau de neurones d'origine par un réseau de neurones équivalent contenant une couche d'entrée, une seule matrice de poids W et une couche de sortie. En d'autres termes, nous n'avons plus notre réseau de neurones multicouche d'origine. Heureusement, nous pouvons empêcher le scénario précédent de se produire lorsqu'on spécifie une fonction d'activation entre chaque paire de couches adjacentes. Une fonction d'activation à chaque couche empêche cette consolidation matricielle. Par conséquent, nous pouvons maintenir toutes les couches intermédiaires cachées pendant le processus d'entraînement du réseau de neurones.

Pour simplifier, supposons qu'on a la même fonction d'activation entre chaque paire de couches adjacentes. Le processus d'utilisation d'une fonction d'activation dans un réseau de neurones se déroule en deux étapes décrites comme suit :

- Étape 1. Commençons avec un vecteur d'entrée de nombres x_1 ;
- Étape 2. Multiplions x_1 par la matrice de poids W_1 qui représente les arêtes qui relient la couche d'entrée avec la première couche cachée : le résultat est un nouveau vecteur x_2 ;
- Étape 3. Appliquons la fonction d'activation à chaque élément de x_2 pour créer un autre vecteur x_3 .

Répétons maintenant les étapes 2 et 3, sauf qu'on utilise le vecteur de départ x_3 et la matrice de poids W_2 pour les arêtes qui relient la première couche cachée avec la deuxième couche

cachée (ou juste la couche de sortie s'il n'y a qu'une couche cachée).

Au lieu d'utiliser la même fonction d'activation à chaque étape, nous pouvons remplacer chaque fonction d'activation par une fonction d'activation différente.

Bien qu'il existe de nombreuses fonctions d'activation, voici une liste des fonctions d'activation courantes, suivie d'une brève description de chacune d'elles :

- Sigmoid;
- Tanh;
- ReLU;
- ReLU6;
- ELU;
- SELU.

La fonction d'activation sigmoïde (Sigmoid) est basée sur la constante e d'Euler, avec une plage de valeurs entre 0 et 1, et sa formule est la suivante :

$$1/[1 + e^{(-x)}] \quad (2.1)$$

La fonction d'activation de Tanh est également basée sur la constante e d'Euler, et sa formule est la suivante :

$$[e^x - e^{(-x)}]/[e^x + e^{(-x)}] \quad (2.2)$$

La fonction d'activation ReLU (Rectified Linear Unit) est simple : si x est négatif alors ReLU (x) vaut 0 ; pour toutes les autres valeurs de x , ReLU (x) est égal à x . ReLU6 est spécifique à TensorFlow, et c'est une variante de ReLU (x) : la contrainte supplémentaire est que ReLU (x) vaut 6 lorsque $x \geq 6$.

ELU est une unité linéaire exponentielle et c'est l'enveloppe exponentielle de ReLU, qui remplace les deux segments linéaires de ReLU par une fonction d'activation exponentielle qui

est différente pour toutes les valeurs de x (y compris $x = 0$).

SELU est un acronyme pour Scaled Exponential Linear Unit, et il est légèrement plus compliqué que les autres fonctions d'activation et moins fréquemment[4] utilisé.

La fonction d'activation softmax bouge les valeurs d'un jeu de données à un autre ensemble de valeurs comprises entre 0 et 1, et dont la somme est égale à 1. Ainsi, softmax crée une distribution de probabilité. Dans le cas de la classification d'images avec des réseaux de neurones convolutifs (CNN), la fonction d'activation softmax déplace les valeurs de la couche cachée finale aux dix neurones de la couche de sortie. L'index de la position qui contient la plus grande probabilité est mis en correspondance avec l'index du nombre 1 dans le codage à chaud de l'image d'entrée. Si les valeurs d'index sont égales, l'image a été classée, sinon elle est considérée comme une non concordante.

La fonction sigmoïde est utilisée pour la classification binaire dans le modèle de régression logistique, ainsi que pour les portes dans les LSTM et les GRU. La fonction sigmoïde est utilisée comme fonction d'activation lors de la construction de réseaux de neurones, mais gardons à l'esprit que la somme des probabilités n'est pas nécessairement égale à 1. La fonction softmax généralise la fonction sigmoïde, elle est utilisée pour la multiclassification dans le modèle de régression logistique. La fonction softmax est la fonction d'activation de la couche entièrement connectée dans les CNN, qui est la couche cachée la plus à droite et la couche de sortie. Contrairement à la fonction sigmoïde, la somme des probabilités doit être égale à 1.

On peut utiliser la fonction sigmoïde ou softmax pour la classification binaire ($n = 2$)[49].

Max Pooling : Le but de Max Pooling est de sous-échantillonner une représentation d'entrée (image, texte, matrice de sortie de couche cachée, etc.) en réduisant sa dimension, le coût de calcul et le nombre de paramètres à apprendre. Il est simple à réaliser après avoir traité la carte des caractéristiques avec la fonction d'activation à l'étape précédente. Divisons la carte des caractéristiques mise à jour en 2×2 rectangles, et sélectionnons la plus grande valeur dans chacun de ces rectangles. Le résultat est un tableau plus petit qui contient 25 % de la carte des

caractéristiques (c'est-à-dire que 75 % des chiffres sont rejetés).

Plusieurs algorithmes permettent d'effectuer cette extraction : la moyenne des nombres dans chaque carré ; la racine carrée de la somme des carrés des nombres dans chaque carré ; ou le nombre maximum dans chaque carré.

Dans le cas des CNN, l'algorithme de Max Pooling sélectionne le nombre maximum dans chaque rectangle 2x2. La figure 2.9 montre le résultat de Max Pooling dans une CNN.

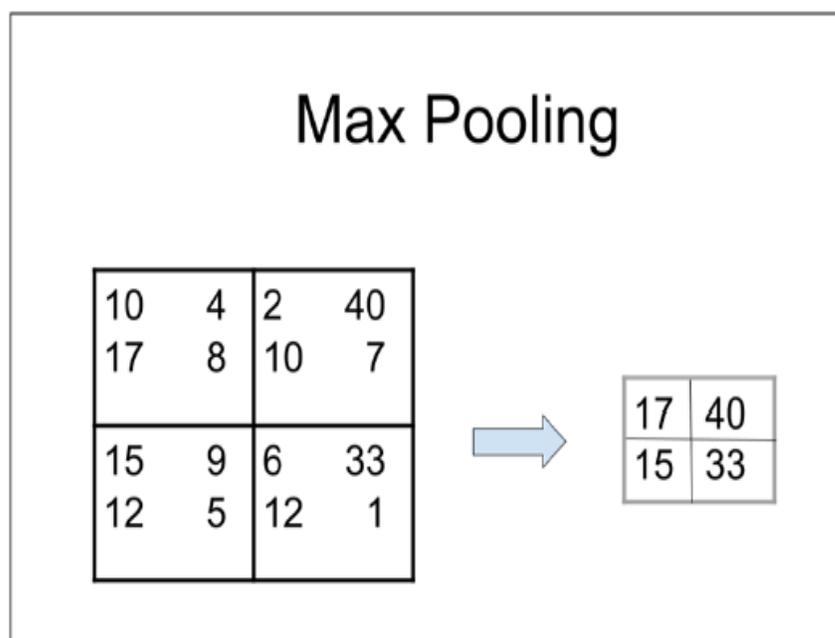


FIGURE 2.9 – Exemple de Max Pooling pour un CNN

Comme nous pouvons le voir, le résultat est un petit tableau carré dont la taille ne représente que 25 % de la carte d'entités précédente. Cette séquence est effectuée pour chaque filtre de l'ensemble de filtres qui ont été choisis dans la couche Conv2D. Cet ensemble peut avoir 8, 16, 32 filtres ou plus.

Les CNN sont organisées en couches de calcul successif alternant entre convolution et Max

Pooling. Par rapport à d'autres types de réseaux de neurones profonds, les CNN sont relativement faciles à former avec rétropropagation, principalement parce qu'ils ont une connectivité très faible dans chaque couche convolutionnelle. Dans une couche convolutionnelle, des filtres linéaires sont utilisés pour la convolution. Les principaux paramètres des CNN sont les paramètres (c'est-à-dire les poids) des filtres. Bien que le partage des paramètres réduise la capacité des réseaux, il améliore sa capacité de généralisation.

La figure ci-dessous (voir figure 2.10) présente un exemple de réseau CNN avec de nombreuses couches de convolution. Des filtres sont appliqués à chaque image d'entraînement et la sortie de chaque image convolutive est utilisée comme entrée dans la couche suivante.

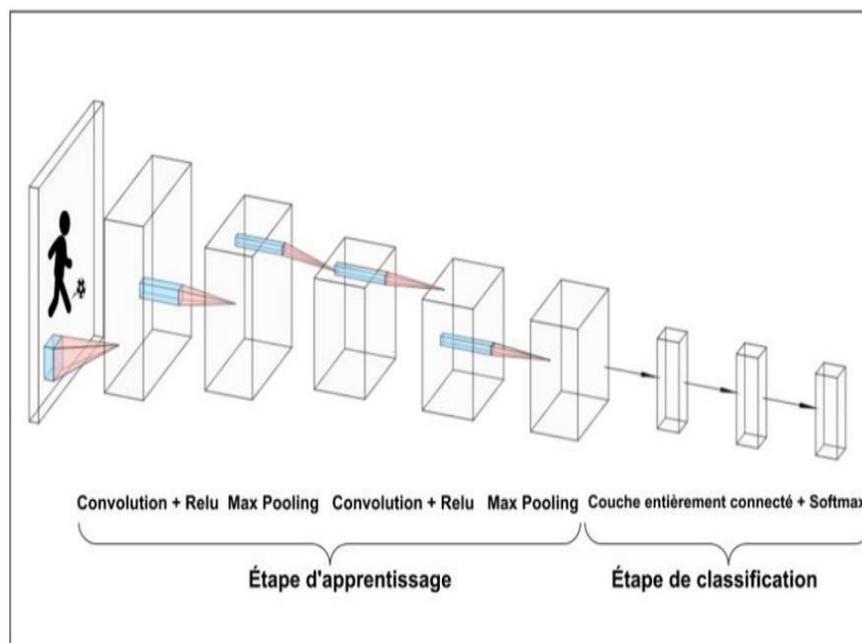


FIGURE 2.10 – Exemple d'architecture d'un modèle CNN

L'hyperparamètre de l'optimiseur : un optimiseur est un algorithme choisi en conjonction avec une fonction de perte. Son but est de converger vers la valeur minimale de la fonction

de coût pendant la phase d'apprentissage. De nombreux optimiseurs font différentes hypothèses sur la façon dont les nouvelles approximations sont calculées pendant le processus d'apprentissage. Certains optimiseurs n'impliquent que l'approximation la plus récente, tandis que d'autres utilisent une moyenne mobile qui prend en compte plusieurs approximations précédentes.

Il existe plusieurs optimiseurs bien connus, notamment SGD, RMSprop, Adagrad, Adadelta et Adam[107].

L'hyperparamètre du taux d'apprentissage : Le taux d'apprentissage est un nombre, souvent compris entre 0,001 et 0,05, qui affecte la magnitude du nombre qui est ajouté au poids actuel d'un nœud afin d'entraîner le modèle avec ces poids mis à jour. Le taux d'apprentissage a une sorte d'effet d'étranglement. Si la valeur est trop grande, la nouvelle approximation peut dépasser le point optimal ; s'il est trop petit, le temps d'entraînement peut augmenter considérablement[107]. Par analogie, imaginons qu'on est dans un train à réaction et qu'on est à 160 km d'une gare, la vitesse du train diminue à l'approche de gare, ce qui correspond à une diminution du taux d'apprentissage dans un réseau de neurones.

Taux d'abandon : Le taux d'abandon est une valeur décimale entre 0 et 1, généralement entre 0,2 et 0,5. Multiplions cette valeur décimale par 100 pour déterminer le pourcentage de neurones sélectionnés au hasard à ignorer lors de chaque passage avant dans le processus d'entraînement. Par exemple, si le taux d'abandon est de 0,2, alors 20 % des neurones sont sélectionnés au hasard et ignorés à chaque étape de la propagation directe. Un ensemble différent de neurones est sélectionné au hasard chaque fois qu'un nouveau point de données est traité dans le réseau de neurones. Notons que les neurones ne sont pas retirés du réseau de neurones : ils existent toujours, et les ignorer lors de la propagation directe a pour effet d'amincir le réseau de neurones [32].

2.4.3 AVANTAGES ET INCONVÉNIENTS D'UN RÉSEAU DE NEURONES

Parmi les avantages du réseau de neurones[81] :

- Après l'entraînement ANN, les données peuvent produire des résultats même avec des informations incomplètes ;
- La corruption d'une ou de plusieurs cellules de l'ANN ne l'empêche pas de générer une sortie ;
- Il dispose une mémoire distribuée qui permet la protection au niveau matériel ;
- Les réseaux de neurones artificiels apprennent les événements et prennent des décisions en commentant des événements similaires ;
- Après l'entraînement ANN, les données peuvent produire des résultats même avec des informations incomplètes ;
- Le réseau de neurones a une résistance naturelle aux données bruitées lors de l'apprentissage (si la base d'entraînement est assez grande, une erreur ne faussera pas la mise à jour des poids).

Parmi les inconvénients des réseaux de neurones artificiels (ANN)[29] :

- Les réseaux de neurones artificiels nécessitent des processeurs avec une puissance de traitement parallèle, conformément à leur structure ;
- Il n'y a pas de règles spécifiques pour déterminer la structure de l'ANN ;
- Le réseau est réduit à une certaine valeur de l'erreur sur l'échantillon, cette valeur ne donne pas des résultats optimaux
- Il faut trouver la bonne structure permettant au réseau de bien apprendre les exemples ;
- Le nombre exact de neurones caché pour un problème donné est difficile à prévoir (sauf dans certains cas : apprentissage de fonction booléenne par exemple). On peut aussi utiliser des algorithmes génétiques pour obtenir des meilleurs résultats.

Temps d'apprentissage

Si la base d'exemples est très grande, le temps d'apprentissage risque d'être long, par contre après l'apprentissage, le calcul des sorties à partir d'un vecteur d'entrée est rapide[47].

Surapprentissage (Over-fitting)

Pour bien comprendre le problème du surapprentissage, voici un exemple. Disons qu'on veut prédire si un étudiant obtiendra un entretien d'embauche en fonction de son CV. Supposons qu'on crée un modèle à partir d'un ensemble de données de 10000 CV et de leurs résultats. Ensuite, nous essayons le modèle sur l'ensemble de données d'origine, et il prédit les résultats avec une précision de 99 %. Mais vient la mauvaise nouvelle : lorsque nous exécutons le modèle sur un nouvel ensemble de données de CV, nous n'obtenons qu'une précision de 60 %. Notre modèle ne se généralise pas bien, de nos données d'entraînement aux données de tests. C'est ce qu'on appelle le surapprentissage, et c'est un problème courant dans l'apprentissage automatique. La régularisation aide à résoudre ce problème.

La régularisation résout ce problème en ajoutant un terme de pénalité à la fonction de coût, contrôlant ainsi la complexité du modèle. La régularisation est généralement utile lorsqu'on a :

- un grand nombre de variables ;
- un faible ratio d'observations et de variables ;
- une multicollinéarité élevée.

Il existe deux principaux types de régularisation : la régularisation L1 (erreur absolue moyenne) et la régularisation L2 (erreur quadratique moyenne). En général, L2 fonctionne mieux que L1 et efficace en termes de calcul[97].

L'ajout de paramètres à un modèle augmente sa complexité, la variance et diminue le biais. Faire face au biais et à la variance consiste à gérer le sousapprentissage et le surapprentissage[31].

Sous apprentissage (Underfitting)

Le sous apprentissage se produit lorsque le modèle prédictif généré lors de la phase d'entraînement ne s'adapte pas avec les données d'entraînement. D'une autre façon, le modèle prédictif n'est pas capable d'identifier les corrélations des données d'entraînement et évidemment il ne va pas se généraliser avec les données des tests. Dans ce cas de figure, nous disons que le modèle souffre d'un sous apprentissage[2].

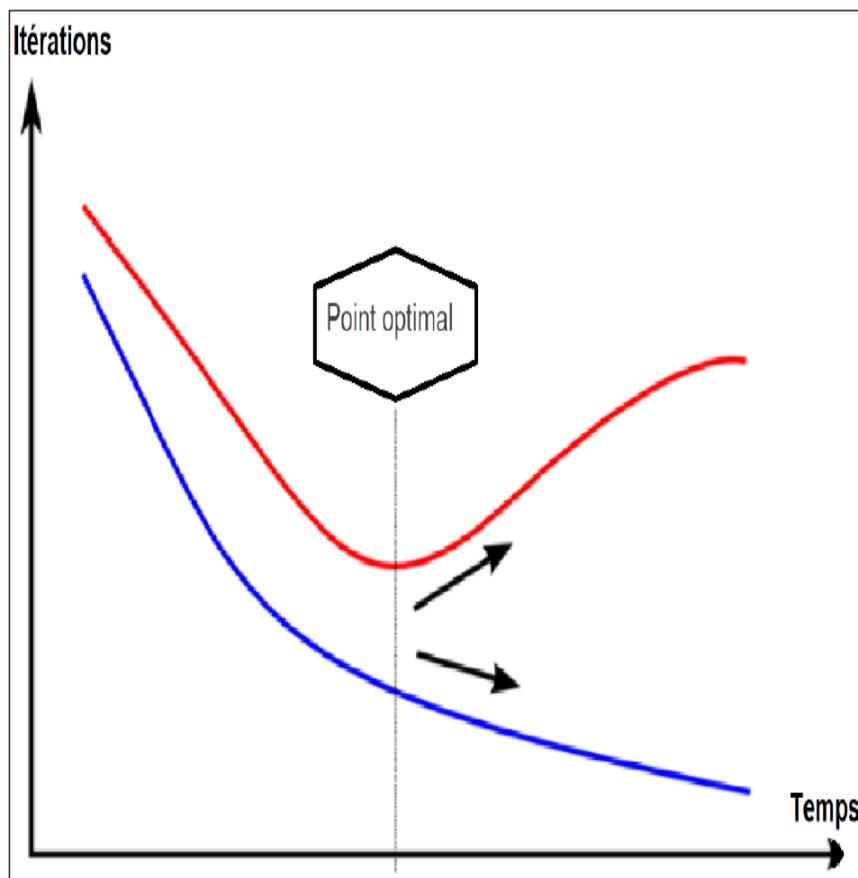


FIGURE 2.11 – Représentation graphique du meilleur modèle statistique

Dans la figure 2.11, la ligne rouge représente la fonction de coût pendant la phase de test et la

ligne bleue représente la fonction de coût pendant la phase d'entraînement. Le point optimal représente le meilleur modèle statistique. À gauche, le modèle est en sous-apprentissage à droite, il est en surapprentissage[18].

2.5 CONCLUSION

Dans ce chapitre, nous avons présenté un ensemble de concepts essentiels pour mieux comprendre la problématique et mieux apprécier les contributions de notre recherche. Nous avons abordé les principales techniques utilisées pour mesurer le rythme cardiaque. Par la suite, nous avons couvert les notions de base liées à l'apprentissage machine en général et aux réseaux de neurones en particulier.

CHAPITRE 3

ÉTAT DE L'ART

Ce chapitre présente un état de l'art composé de trois parties distinctes et succinctes. Tout d'abord, nous nous pencherons sur les bracelets intelligents, puis nous discuterons de l'utilisation de ces bracelets dans le contexte de la santé et enfin nous présenterons certaines approches et d'techniques de l'apprentissage automatique utilisées pour la conversion des signaux PPG en signaux ECG ainsi que la détection d'arythmies cardiaques.

3.1 BRACELET INTELLIGENT, DOMAINE D'UTILISATION

Au cours des deux dernières décennies, l'utilisation des bracelets électroniques a connu une évolution très importante. L'utilisation de ces gadgets relève de plusieurs domaines : la santé, le sport et la surveillance. Grâce aux progrès technologiques, ces dispositifs sont devenus de plus en plus petits, tout en offrant plus de fonctionnalités et une facilité d'utilisation.

Parmi ces dispositifs, les bracelets intelligents sont équipés de capteurs capables d'enregistrer le comportement des personnes, ainsi que d'analyser et d'interpréter d'autres données différentes prises par divers objets intelligents de la vie quotidienne connectés sans fil.

3.1.1 BRACELET INTELLIGENT, DOMAINE D'UTILISATION

Les premiers bracelets électroniques étaient utilisés pour la surveillance électronique des personnes placées en détention. Ils permettaient de s'assurer de la présence de la personne en question à leur domicile aux heures déterminées par l'autorité sous surveillance électronique fixe[118].

Grâce à cette méthode, on ne parle plus d'une alternative à l'emprisonnement, mais plutôt d'une surveillance sécurisée. En effet, le condamné même libre peut être obligé de garder le bracelet de surveillance sur lui pendant ses déplacements. Cette méthode a pour but d'empêcher l'ex-détenu de récidiver.

3.1.2 LE DOMAINE SPORTIF

Dans le domaine du sport, les bracelets ont d'abord été utilisés par les sportifs de haut niveau dans le but de suivre en permanence leur activité (rythme cardiaque, pression artérielle, etc.). Avec l'émergence des montres connectées dans les années 70, le grand public a pu se procurer ce genre d'article. En effet, l'évolution rapide des bracelets et l'inclusion de plus de fonctionnalités ont largement permis le déploiement de ces dispositifs à grande échelle[133]. Ils sont devenus de véritables outils de suivi pour les athlètes professionnels et amateurs, certains se vantant même de pouvoir remplacer les entraîneurs dans les salles de sport. La prolifération des appareils mobiles, de l'internet omniprésent et du Cloud Computing a déclenché une nouvelle ère de l'internet des objets, permettant aux chercheurs de créer des solutions spécifiques aux applications basées sur l'interconnexion entre les objets physiques et l'internet.

3.1.3 LE DOMAINE DE LA SANTÉ

Dans le domaine de la santé, les bracelets connectés ont incontestablement sauvé des vies. En effet, le lancement de ce dispositif a d'abord été fait pour les personnes âgées ou à mobilité réduite afin de pouvoir suivre leurs déplacements. Si la personne reste inactive trop longtemps, ou si elle est tombée, une alerte est lancée afin de venir rapidement à son secours[131].

En outre, les études qui intègrent des sources de données multiples, notamment des capteurs domestiques intelligents[54] et des données sur la santé environnementale, nécessiteront des plateformes pour collecter et gérer ces données à domicile, telles que Lab of Things[23] ou Piloteur[60] et fédérer ces données pour les analyser à l'aide de logiciels de systèmes de gestion distribués tels que PopMedNet[44].

3.2 SANTÉ INTELLIGENTE

Dans cette sous-section, nous présentons les approches existantes les plus connues en matière de santé intelligente, qui peuvent être divisées en deux grandes catégories :

- Appareils portables ;
- Capteur de mouvement et de chutes.

3.2.1 APPAREILS PORTABLES

Pour commencer, nous présentons **HealthGear**, un système portable en temps réel permettant de surveiller, de visualiser et d'analyser les signaux physiologiques. Il utilise un oxymètre de sang pour surveiller le niveau d'oxygène dans le sang (SpO2), la fréquence cardiaque et le pouls des patients pendant leur sommeil. Il est mis en œuvre grâce à la technologie Bluetooth via un téléphone portable qui stocke, transmet et analyse les données physiologiques et les

présente à l'utilisateur de manière intelligible[89]. Cette étude sur le sommeil a été couronnée de succès sur plusieurs fronts :

- Aucun des volontaires n'a rencontré de problème technique et tous ont collecté les données avec succès, ce qui est remarquable étant donné que les participants ont emporté le système chez eux et n'ont bénéficié d'aucune supervision ou orientation à la maison.
- Les algorithmes de détection automatique d'AOS (apnée obstructive du sommeil) ont identifié avec une précision de 100 % les trois cas connus d'AOS et ont clairement identifié un cas grave et deux cas léger, parmi le groupe de participants qui soupçonnaient être atteints d'AOS, mais n'avaient pas été diagnostiqués médicalement.

Une autre technologie est l'"**eWatch**", une plateforme informatique de détection et de notification portable intégrée dans une montre[15], ce qui la rend hautement disponible, instantanément consultable, idéalement située pour les capteurs et discrète pour les utilisateurs. L'eWatch détecte la lumière, le mouvement, le son et la température et fournit une notification visuelle, sonore et tactile. Le système offre un large éventail de capacités de traitement avec une autonomie de plusieurs jours permettant des études réalistes sur les utilisateurs. Cette recherche décrit un capteur portable et une plateforme informatique de notification pour la recherche contextuelle. Le site et la conception matérielle sont axés sur la fourniture d'une puissance de calcul suffisante pour exécuter localement des algorithmes d'apprentissage automatique, avec un facteur de forme confortable et une capacité de batterie suffisante pour des études d'utilisateurs prolongées.

Dans un autre recherche, les chercheurs Cunha et al. [21] ont proposé un système portable de surveillance des signes vitaux "**Vital Jacket**", qui surveille intelligemment les ondes de l'électrocardiogramme (ECG) et la fréquence cardiaque pour différents scénarios, tels que les applications sportives et de surveillance médicale. Vital Jacket Cardio possède trois ou

cinq dérivations ECG et un accéléromètre à trois axes. Toutes ces informations peuvent être relayées en temps réel, non seulement vers un PC, mais aussi vers un système d'information cardiologique via un réseau local sans fil ou des réseaux de données mobiles GPRS ou UMTS. **Le Wireless Body Area Network (WBAN)** a été introduit par Van Dam et al.[62] et Latre et al.[112] afin d'exploiter pleinement les avantages des technologies sans fil en matière de télémédecine et de santé mobile. Il s'agit d'un réseau de capteurs sans fil. Les communications par internet, intranet ou satellite sont utilisées pour la surveillance à distance des signes vitaux des patients.

3.2.2 CAPTEUR DE MOUVEMENT ET DE CHUTES

Nguyen et al.[126] ont proposé un dispositif mobile monté sur la taille qui peut alerter les soignants en cas d'urgence. Un accéléromètre triaxial et un modem autonome sont utilisés pour détecter les chutes et un circuit ECG à trois canaux pour déterminer la fréquence cardiaque. Dans cette étude, les chercheurs ont développé une méthode simple pour reconnaître avec précision les événements de chute.

Après 10 secondes de chute, si le sujet ne peut pas se relever ou s'asseoir, le système génère une alarme sonore à 50 Hz et envoie les données au serveur distant (Emergency Event). Ce système génère un son jusqu'à ce que le sujet s'assoie ou se relève.

Dans une autre recherche, Aud et al.[14] ont proposé un tapis intelligent, dans lequel un dispositif de détection des chutes est installé dans un revêtement de sol. Le capteur situé dans la zone du revêtement de sol peut détecter des problèmes, par exemple si quelqu'un marche sur le tapis ou si quelqu'un est couché à plat sur le sol.

Cette étude récente a exploré l'utilisation de l'imagerie électrique en champ proche dans les capteurs de sol. La conductivité du corps humain peut être détectée par ce système en émettant un champ électrique de basse fréquence. Ce champ est généré et détecté par un réseau

d'électrodes plates situées sous la surface du sol.

Oliver et Flores ont mis au point un système de caméra utilisant le traitement d'images. Ce système consiste généralement à extraire les informations nécessaires des données offertes par un capteur d'images qui reçoit ses informations d'un appareil photo ou d'une caméra infrarouge[50].

Sixsmith et al. [12] ont développé un système connu sous le nom de Smart Inactivity Monitor utilisant des capteurs matriciels (SIMBAD). Ce système est basé sur un réseau de capteurs infrarouges pyroélectriques installés sur le mur pour détecter l'activité d'une personne. La matrice de capteurs infrarouges du système peut localiser et suivre une cible thermique dans le champ de vision du capteur, ce qui signifie que seuls les objets chauds en mouvement sont vus et non l'arrière-plan statique. Cette matrice recueille l'emplacement, la taille et la vitesse des objets chauds en mouvement.

Zhuang et al.[129] ont proposé une approche de détection utilisant le signal audio d'un seul microphone de champ lointain. Ce travail est basé sur un modèle de mélange gaussien (GMM), lorsqu'un mouvement se produit, un super-vecteur a été créé pour modéliser chaque mouvement comme des segments de bruit. La différence entre les segments audio détermine l'occurrence des mouvements.

Alwan et al. [98] ont développé un système de détection basé sur les vibrations du sol qui est complètement passif et non intrusif pour le résident. Le système utilise un capteur piézoélectrique spécial couplé à la surface du sol à l'aide d'une masse et d'un ressort. Ces capteurs détectent l'occupation à tout moment. Un processeur identifie une chute en analysant les données de localisation, ce qui permet de différencier avec succès les modèles de vibration d'une chute humaine et d'un autre type de mouvement.

3.3 BRACELETS CARDIOVASCULAIRES

Les bracelets intelligents de qualité grand public ont rapidement fait leur entrée dans le domaine de la santé et de la recherche depuis 2014 [23]. La fonction technique, l'acceptabilité et l'efficacité du soutien à la santé et au bien-être doivent être validées dans des études de terrain plus vastes qui recrutent des participants vivant dans les conditions visées par les efforts de recherche sur les bracelets intelligents.

Dans cette sous-section, nous présenterons les bracelets cardiovasculaires les plus utilisés :

- **iBeat** est une montre intelligente qui aide à prévenir les maladies cardiaques en surveillant le rythme cardiaque. Elle a été conçue pour sauver des vies et réduire spécifiquement les centaines de milliers de personnes qui meurent chaque année de maladies cardiaques. iBeat est idéale pour la prévention des maladies cardiovasculaires, car elle détecte les symptômes des crises cardiaques et d'autres problèmes cardiaques. iBeat offre une aide immédiate lorsque les personnes âgées en ont le plus besoin. Elle dispose d'un bouton d'urgence qui permet de prévenir immédiatement les proches et le 911. Un autre avantage d'iBeat est qu'elle possède une connectivité cellulaire intégrée et ne nécessite pas de téléphone ou de connexion Internet[132].
- **HOLTER MONITOR** est un dispositif portable de santé cardiaque qui mesure et enregistre l'activité cardiaque d'une personne pendant 24 heures ou plus si nécessaire. Il fonctionne avec des piles et ressemble à un petit appareil photo. Le dispositif doit être fixé sur la peau. L'avantage de ce dispositif de santé cardiaque est qu'il est indolore et sans risque. Il peut être utilisé la nuit et n'affecte pas la qualité du sommeil. Le moniteur Holter peut déterminer si le rythme cardiaque d'une personne âgée est lent, rapide ou irrégulier. En outre, si une personne a un stimulateur cardiaque, le moniteur Holter peut être utilisé pour déterminer si le stimulateur fonctionne de manière optimale[45].

- **Zio Service** est un petit parchemin sans fil qu'une personne porte sur sa poitrine gauche pour suivre les battements de son cœur pendant deux semaines sans interruption afin de fournir un aperçu de sa santé cardiaque. Zio Service est l'une des innovations qui changent la détection et la gestion des maladies cardiovasculaires. Il détecte les arythmies cardiaques ou les rythmes cardiaques irréguliers. Les arythmies peuvent être un signe précoce d'affections telles que la fibrillation auriculaire, les maladies cardiaques, l'hypertension et le diabète. Plus les arythmies sont détectées tôt, plus elles sont faciles à gérer. Si la maladie n'est pas détectée à temps, elle peut entraîner de graves complications[68].
- **L'Apple Watch** surveille régulièrement le cœur d'une personne tout au long de la journée. Avec l'Apple Watch, nous pouvons vérifier le rythme et les performances cardiaques à tout moment et en tout lieu. L'Apple Watch détecte toute anomalie dans la santé du cœur et lance une alerte en cas de problème. Elle identifie les fréquences cardiaques anormalement basses ou élevées et les rythmes cardiaques irréguliers. L'Apple Watch dispose notamment d'un bouton d'urgence qui permet d'appeler en cas besoin. Lorsque nous appuyons sur ce bouton, les contacts que nous avons sélectionnés et les services d'urgence sont immédiatement prévenus. En plus de surveiller la fréquence cardiaque, l'Apple Watch peut suivre l'activité d'un individu, sa tension artérielle et son sommeil, tout en fournissant un aperçu de son niveau d'activité[70].
- **Fitbit** est une marque leader dans le domaine des appareils de fitness portables. Elle reconnaît que le cœur est au centre de tout ce que nous faisons et la nécessité de le suivre. Fitbit propose de nombreux appareils qui suivent le rythme cardiaque à partir du poignet. Fitbit Charge 2, par exemple, possède un moniteur de fréquence cardiaque intégré qui affiche la fréquence cardiaque de l'utilisateur. Il surveille la fréquence cardiaque quelle que soit l'activité pratiquée en étant assis, en marchant ou en faisant de l'exercice. Le Fitbit dispose de fonctions qui surveillent l'activité et la durée du

sommeil[116].

- **Implantable** : Parfois, une personne âgée a besoin de plus qu'un dispositif de santé cardiaque portable. Un dispositif de santé cardiaque implantable devient alors une option à considérer. Pour le contrôle du rythme, une personne âgée peut recevoir un défibrillateur automatique implantable (DAI) ou un stimulateur cardiaque. Le DAI est placé dans le tissu cardiaque pour surveiller le rythme cardiaque. Il contribue à rétablir un rythme cardiaque normal et à prévenir la mort cardiaque subite. Une personne âgée peut également recevoir un dispositif d'assistance ventriculaire gauche (DAVG) pour soutenir le cœur et favoriser la circulation sanguine. Lorsque le cœur d'une personne bat trop vite, trop lentement ou de façon irrégulière, elle peut avoir besoin d'un stimulateur cardiaque alimenté par une pile qui est implanté dans la poitrine. Il aide le cœur à battre à un rythme normal lorsqu'il est sur le point de ne plus pouvoir fonctionner efficacement, un DAVG aide le cœur à pomper le sang efficacement[38].

3.4 CONVERSION DE SIGNAUX ET DÉTECTION D'ARYTHMIES

Afin de permettre le développement de notre bracelet intelligent, nous avons recherché d'autres travaux qui tentent de résoudre les mêmes problèmes. Dans la sous-section suivante, nous présenterons plusieurs algorithmes qui traitent de la conversion et de la classification des signaux cardiovasculaires.

3.4.1 CONVERSION D'UN SIGNAL PPG EN UN SIGNAL ECG

Un nombre restreint de chercheurs ont traité de la conversion du signal PPG en ECG. Notamment, dans leur article intitulé "Reconstruction du complexe QRS à partir du PPG"[53]. Chiu et al. ont testé deux ensembles de données ouvertes (l'ensemble de données sur les signes

vitaux de l'Université de Queensland et l'ensemble de données du Beth Deaconess Medical Center). Les résultats de l'expérience ont confirmé l'efficacité de l'approche d'apprentissage profond proposée, ils ont été en mesure de reconstruire l'ECG à partir d'un seul signal PPG d'entrée avec la possibilité de faire des inférences en temps réel. D'autres résultats montrent l'importance de chaque module dans ce modèle et permettent d'obtenir une meilleure qualité du signal ECG. En conclusion, cette étude suggère que l'apprentissage profond peut être une approche potentielle et fiable pour reconstruire des signaux facilement disponibles.

Dans un autre article intitulé "ECG reconstruction via PPG"[102], les chercheurs ont proposé d'estimer la forme d'onde du signal ECG à l'aide de la mesure PPG en apprenant un modèle de signal qui relie les deux séries temporelles. Ils commencent par prétraiter les paires de signaux ECG et PPG pour obtenir des ensembles de signaux alignés dans le temps et normalisés. Ils segmentent ensuite les signaux en paires de cycles pour former un modèle linéaire qui met en correspondance les coefficients de la transformée discrète en cosinus (DCT) du cycle PPG avec ceux du cycle ECG correspondant. La forme d'onde de l'ECG est ensuite obtenue par la DCT inverse. Les statistiques des mesures de performance du système évaluées sur une base de données de référence montrent que le système proposé peut reconstruire avec précision le signal ECG.

3.4.2 LA DÉTECTION DES ARYTHMIES CARDIAQUES

La détection des arythmies cardiaques est devenue un domaine de recherche actif au cours des deux dernières décennies. En outre, sur la base de la revue de la littérature, il est établi que la recherche d'un modèle efficace de caractéristiques est un défi majeur pour améliorer la précision de la classification des troubles cardiaques.

Parmi les nombreux paradigmes d'apprentissage automatique, les chercheurs se sont concentrés sur le réseau neuronal artificiel, le perceptron multicouche (MLP), qui est l'une des

techniques les plus utilisées dans la reconnaissance d'images, la classification des formes, la modélisation des séries chronologiques, la commande non linéaire et les systèmes d'identification.

Les méthodes existantes d'extraction de caractéristiques peuvent ne pas être suffisantes pour détecter la possibilité de troubles cardiaques, car l'ECG est un signal quasi périodique, non linéaire et non stationnaire. Il est donc proposé d'utiliser une technique de transformation en ondelettes pour extraire les caractéristiques de l'ECG, qui sont utilisées pour classer les types d'arythmies cardiaques.

Pour commencer, Jalel et al.[87] ont proposé une recherche visant à présenter une approche pour la classification des arythmies cardiaques. La méthode proposée combine à la fois la machine à vecteur de support (SVM) et l'approche de l'algorithme génétique. Nous présentons le schéma des principales étapes de la classification de l'arythmie proposée dans la figure ci-dessous (voir Figure 3.1). Tout d'abord, vingt-deux caractéristiques du signal d'électrocardiogramme sont extraites. Les caractéristiques R, S, T, P, Q sont obtenus de manière semi-automatique à partir de la tension temporelle des signaux d'un électrocardiogramme présenter dans la figure 3.2.

L'algorithme génétique est utilisé pour améliorer la performance de généralisation du classificateur SVM. Pour ce faire, la conception du classificateur SVM est optimisée en recherchant la meilleure valeur des paramètres qui régulent sa fonction de discrimination et en recherchant le meilleur sous-ensemble de caractéristiques, puis en optimisant la fonction d'aptitude de la classification. Les résultats expérimentaux montrent que l'approche adoptée permet une meilleure classification des signaux ECG. Quatre types d'arythmie ont été distingués avec une précision de 93 % (tableau 3.1).

Dans le même contexte, une classification de cinq échantillons d'arythmie a été réalisée en utilisant des signaux cardiaques ECG avec des caractéristiques de coefficient de prédiction

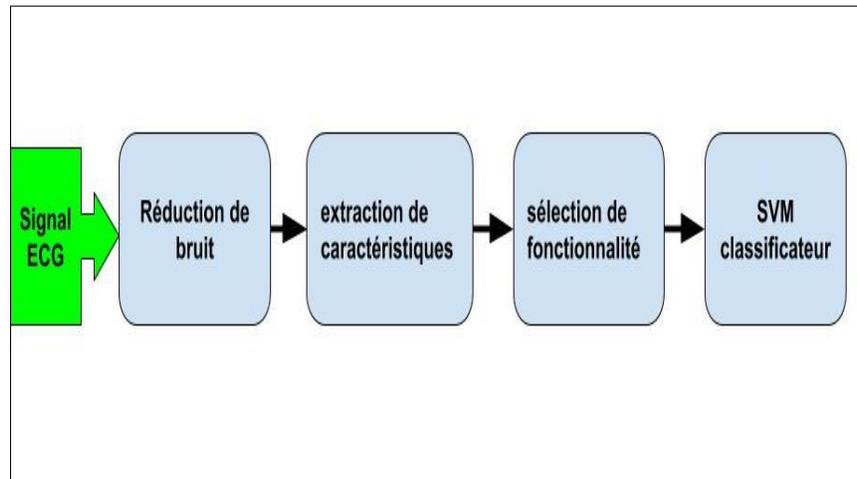


FIGURE 3.1 – Les étapes du développement

linéaire (LPC) et une classification SVM représentée par les chercheurs Mohseni et al.[36]. Chaque signal est cadré à des intervalles de temps de 1 à 5 secondes et pour chaque trame, certains coefficients LPC sont calculés. Les résultats du cadrage ont été examinés et observés en utilisant la méthode LPC, avec un cadrage de 1 seconde au mieux. En outre, les résultats des caractéristiques extraites sont également comparés aux caractéristiques des ondelettes. Dans la méthode proposée, ils ont obtenu une précision de plus de 99 % (tableau 3.1). L'objectif de cette étude est de classer les signaux ECG cardiaques avec les caractéristiques de traitement des coefficients de prédiction linéaire (LPC) et le classificateur SVM. Cinq échantillons d'arythmie ont été sélectionnés, chacun contenant trois fichiers et un total de 650 000 données d'arythmie et les échantillons ont été encadrés sur les segments de temps s1 à s5. Une normalisation a également été appliquée et les coefficients LPC ont été modifiés pour chaque segment temporel de 5 à 20.

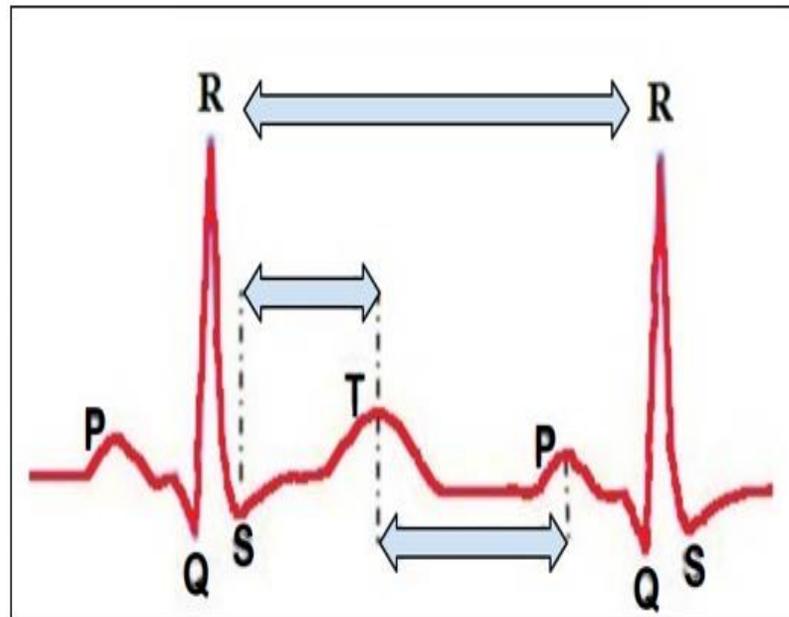


FIGURE 3.2 – Caractéristiques des signaux d'un électrocardiogramme

Dans une autre recherche, les chercheurs Sung-Nien et al [121] ont proposé un schéma pour intégrer l'analyse en composantes indépendantes (ICA) et les réseaux neuronaux pour la classification des battements de l'électrocardiogramme (ECG). L'ICA est utilisée pour décomposer les signaux ECG en une somme pondérée de composantes de base qui sont statistiquement indépendantes les unes des autres. Les projections sur ces composantes, ainsi que l'intervalle RR, forment ensuite un vecteur de caractéristiques pour le classificateur suivant. Deux réseaux neuronaux, dont un réseau neuronal probabiliste (PNN) et un réseau neuronal à rétropropagation (BPNN), sont utilisés comme classificateurs. À des fins expérimentales, des échantillons d'ECG affectés à huit types de battements différents ont été prélevés dans la base de données sur l'arythmie du MIT-BIH. Les résultats montrent une précision de classification élevée, supérieure à 98 %, avec l'un ou l'autre des classificateurs (tableau 3.1).

Suivant le même objectif, les chercheurs Valupadasu et al.[105] ont proposé un classificateur

de réseau de neurones multicouche pour la classification. Les poids d'apprentissage du MLP sont adaptés à l'aide d'un algorithme récursif partant des nœuds de sortie et remontant jusqu'à la première couche cachée. Le MLP possède une fonction d'activation sigmoïde qui est une fonction différentiable continue. Cette fonction fonctionne avec une méthode puissante et efficace de calcul de la rétro-propagation des erreurs. Cette méthode consiste à trouver les dérivées d'une fonction d'erreur par rapport aux poids et aux biais du réseau. L'ensemble du processus de classification se compose de deux phases : dans la première étape, le MLP est utilisé pour apprendre le comportement des données d'entrée à l'aide de l'algorithme de rétropropagation. Dans la deuxième étape, le MLP généré est testé en utilisant des données d'entrée inconnues (tableau 3.1).

L'algorithme de rétropropagation compare le résultat obtenu à ce stade avec le résultat attendu. Le MLP calcule le signal d'erreur en utilisant la sortie obtenue et la sortie souhaitée. Le signal d'erreur calculé est ensuite renvoyé au réseau neuronal et utilisé pour ajuster les poids de sorte qu'à chaque itération, l'erreur diminue et le modèle neuronal se rapproche de plus en plus de la production de la sortie souhaitée.

Le travail proposé avait une précision de classification égale à 98,8 % et les statistiques médicales sont obtenues comme suit : sensibilité 97,6 %, prédiction 98,7 % et spécificité 99,7 % (Tableau 3.1). Avec le schéma de caractéristiques d'ondelettes, un prototype de système d'alerte cardiaque a été mis en œuvre en utilisant Arduino Uno et GSM SIM 900A pour la surveillance à distance des patients.

Dans le même contexte, les chercheurs Prasad et al [65] ont proposé une méthode de classification des rythmes ECG utilisant une combinaison d'ondelettes et de réseaux neuronaux artificiels (ANN). La capacité de la transformée en ondelettes à décomposer le signal en différentes solutions permet une extraction précise des caractéristiques de détection des signaux non stationnaires tels que l'ECG. Un ensemble de coefficients discrets de la transformée contient le maximum d'informations sur l'arythmie sélectionnées à partir de la décomposition

en ondelettes. Ces coefficients, en plus des informations sur l'intervalle RR (la différence entre les pics QRS actuels et précédents), sont transmis au réseau neuronal à rétropropagation qui classe les arythmies.

Un classificateur de réseau neuronal basé sur les ondelettes a été proposé pour la classification des arythmies. L'ensemble de caractéristiques a été soigneusement choisi afin de disposer de suffisamment d'informations pour obtenir une bonne précision. Cet ensemble de caractéristiques est un sous-ensemble de coefficients DWT basés sur les ondelettes et d'informations sur l'intervalle RR. La précision de reconnaissance moyenne (96,79 %) est comparable à celle d'autres approches, même lorsque les 13 types d'arythmie différents de l'ensemble de données MIT-BIH ont été utilisés. (tableau 3.1).

Les chercheurs Awni et al [16] ont développé un réseau neuronal profond (DNN) pour classer 12 classes de rythme à l'aide d'ECG à une seule dérivation provenant de 53 877 patients ayant utilisé un dispositif de surveillance ECG ambulatoire à une seule dérivation. Lorsqu'il a été validé par rapport à un ensemble de données de test indépendant annoté par un comité de consensus composé de cardiologues praticiens certifiés, le DNN a atteint une aire moyenne sous la courbe caractéristique d'exploitation du récepteur (AUC) de 0,97. Le DNN a également été validé par rapport à un ensemble de données de tests indépendant annotés par un comité de consensus de cardiologues praticiens certifiés. Le score F1 moyen, qui est la moyenne harmonique de la valeur prédictive positive et de la sensibilité, pour le DNN (0,837) a dépassé celui du cardiologue moyen (0,780) (Tableau 3.1). Avec une spécificité fixée à cette moyenne obtenue par les cardiologues, la sensibilité du DNN a dépassé la sensibilité du cardiologue moyen pour toutes les classes de rythme.

Sur le même principe, Sannino et al [48] ont proposé un DNN développé à l'aide du cadre Tensor Flow, la bibliothèque d'apprentissage profond de Google. Il est composé de seulement sept couches cachées, avec respectivement 5, 10, 30, 50, 30, 10 et 5 neurones.

Dans le tableau 3.1 suivant, nous présentons les résultats obtenus pour chaque recherche citée

précédemment.

TABLEAU 3.1 – Performance globale pour les approches proposées

Modèle	RÉF.	Classes	Ensemble d'essais	Précision	Jeux de données
SVM et algorithme génétique	[87]	4	1403	93%	PTB[80], MIT-BIH[1]
LPC et SVM	[36]	5	650000	99%	MIT-BIH[1]
PNN et BPNN	[121]	8	4900	98%	MIT-BIH[1]
MLP	[105]	7	110000	99%	MIT-BIH[1]
DWT et MLP	[65]	12	105423	96,5%	MIT-BIH[1]
DNN	[16]	12	91232	83%	MIT-BIH[1]
DNN	[48]	3	4576	98,55%	MIT-BIH[1]

CHAPITRE 4

DÉVELOPPEMENT DU BRACELET ET DES MODÈLES D'APPRENTISSAGES AUTOMATIQUES

4.1 INTRODUCTION

Ce chapitre révèle les principales contributions du développement et de la réalisation d'un bracelet intelligent PPG multicateur qui détecte les asymptotes cardiaques des maladies arythmiques, notamment la fibrillation auriculaire (FA)[124].

Tout d'abord, nous utilisons un algorithme pour sélectionner le meilleur capteur. Ensuite, nous convertirons le signal PPG en un signal ECG qui est la base de notre modèle d'apprentissage. Ce signal converti sera utilisé pour la prédiction de l'état cardiaque de l'utilisateur.

Les données des capteurs PPG et les résultats obtenus à partir du modèle de classification seront envoyés à une base de données et seront accessibles via une application mobile.

Pour valoriser l'intérêt de cette recherche, nous suivrons les grandes étapes suivantes (voir Figure 4.1) :

- Première étape : collecter les signaux PPG du bracelet.
- Deuxième étape : choisir le meilleur capteur et le convertir en un signal ECG.
- Troisième étape : classifier le signal ECG.
- Quatrième étape : fournir une retroaction à l'utilisateur à travers l'application mobile.

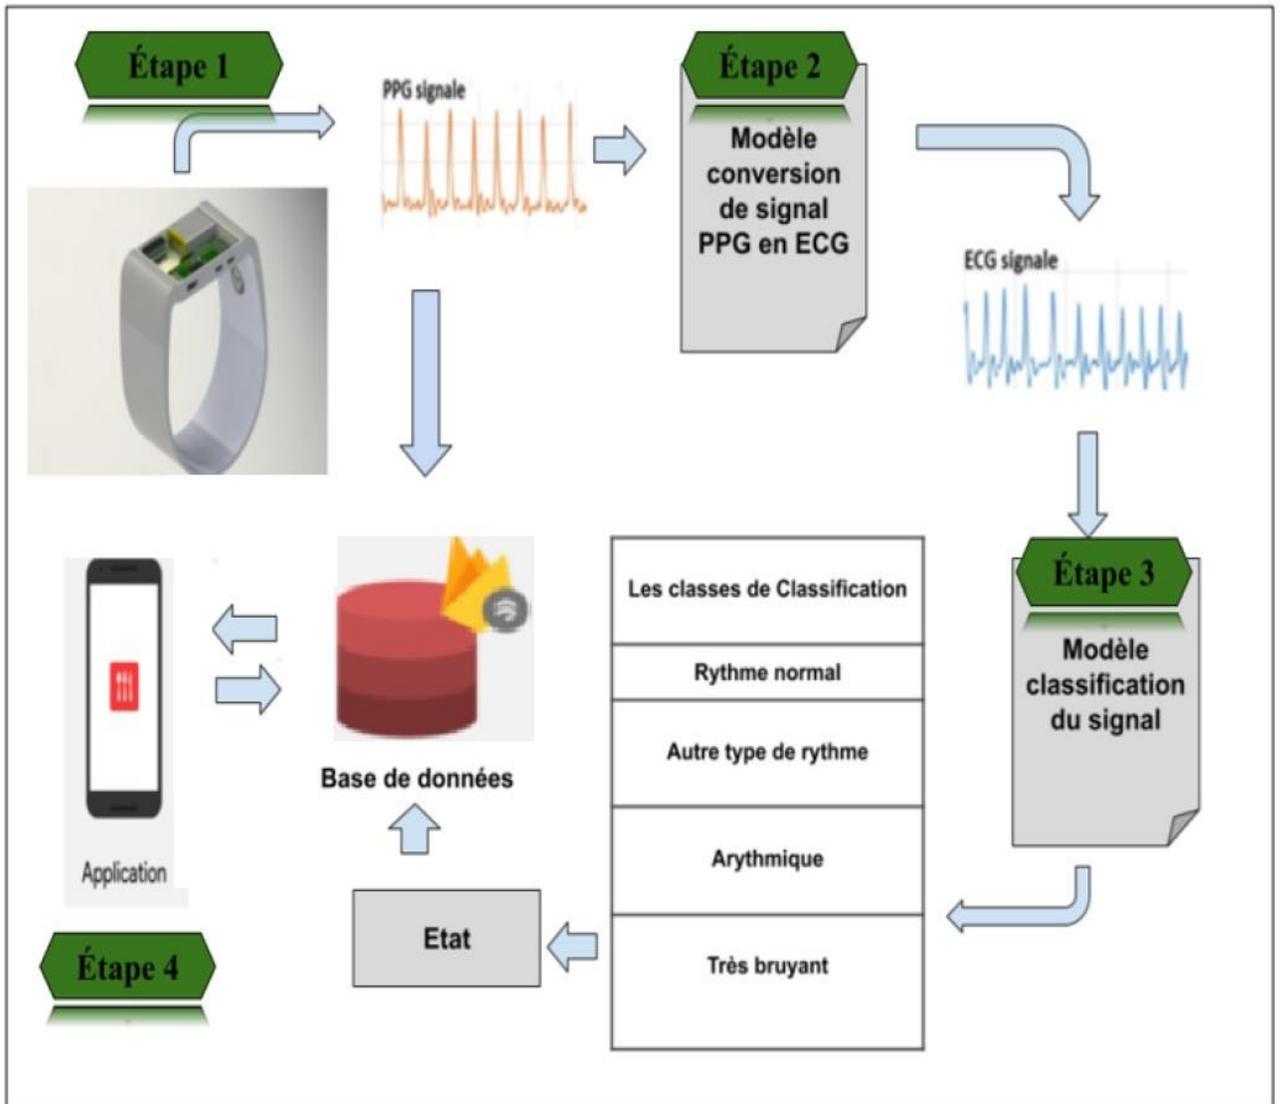


FIGURE 4.1 – Protocole de circulation des données

4.2 COLLECTE DE SIGNAL PPG À PARTIR DU BRACELET MULTICAPTEUR

Pour garantir une meilleure fiabilité du signal PPG, nous avons choisi d'installer trois capteurs PPG à différents endroits autour du bras afin d'obtenir de meilleurs résultats, sans limiter les mouvements de l'utilisateur et avoir une plus grande probabilité de réception du signal à chaque manipulation du bracelet pendant son utilisation (voir Figure 4.2).

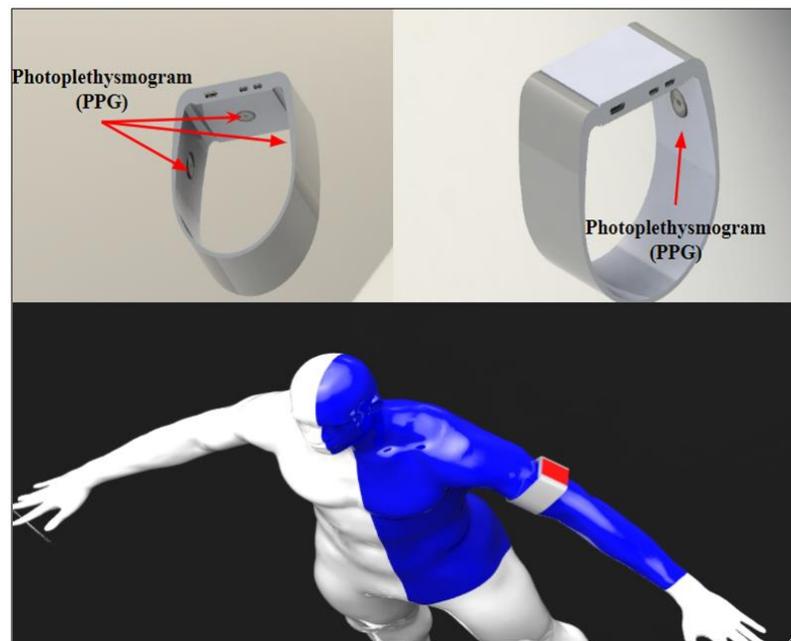


FIGURE 4.2 – Bracelet intelligent multicapteur PPG

Le bracelet est composé de plusieurs éléments illustrés dans la figure ci-dessous (voir Figure 4.3) :

- Carte Raspberry pi zéro : La Raspberry pi zéro est très petite, ce qui en fait une carte parfaite pour les projets IoT, elle est également équipée d'une technologie Bluetooth à faible consommation d'énergie qui minimise l'énergie consommée [11].

- MCP3008 : Le MCP 3008 est une puce intégrée de convertisseur analogique numérique (ADC) basée sur l'interface périphérique série. Il est interfacé avec Raspberry Pi, ce qui lui permet d'interpréter des tensions analogiques qui sont à leur tour émises par des capteurs analogiques pour refléter une mesure d'une caractéristique physique telle que l'accélération, l'intensité lumineuse, l'humidité du sol, l'humidité ou la température [37].
- Batterie lithium 5V : batterie rechargeable 5v 500ma[43].
- Trois capteurs PPG.

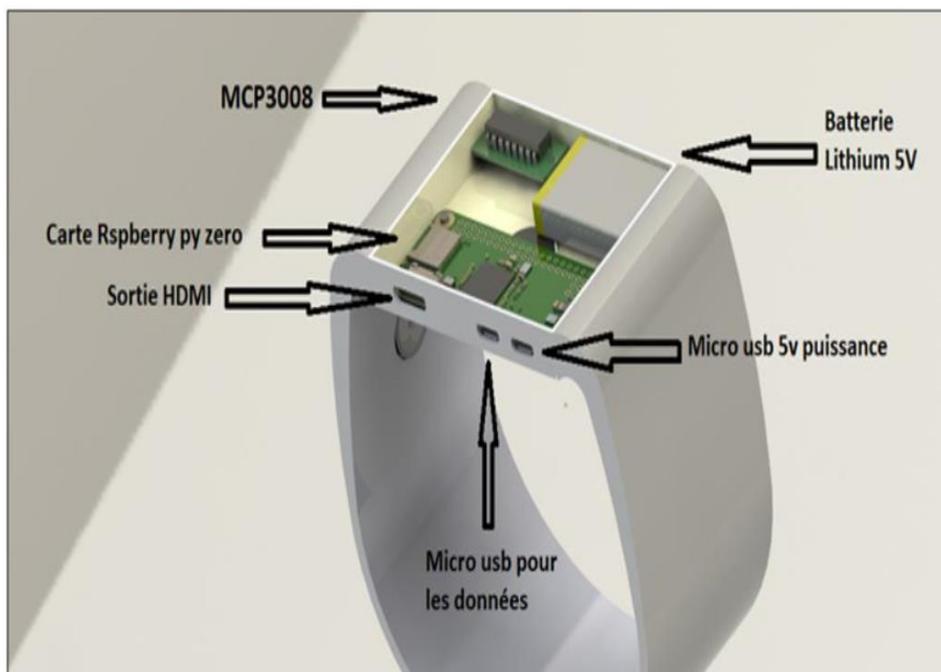


FIGURE 4.3 – Détails des composants du bracelet

4.2.1 SCHÉMA ÉLECTRIQUE

La première étape consiste à alimenter le circuit avec le source d'énergie. Il faut connecter le Vdd du MCP3008, la broche 16 aux 3.3V du Raspberry pi zéro (broche P1-01 en haut à

gauche), avec les câbles au milieu des capteurs PPG (fils rouges sur la figure4.4).

Les broches 14 (AGND) et 9 (DGND) du MCP3008 sont la masse des signaux analogiques et numériques. Ils sont connectés à la masse du Raspberry pi zéro, la broche P1-06 (3e en partant du haut, à droite), avec les masses des capteurs (fils noirs sur la figure 4.4).

Les 4 broches GPIO (CLK, Dout, Din et CS) du Raspberry sont connectés aux broches du MCP3008 :

- La broche 13 (CLK) est connectée au GPIO18 du Raspberry Pi zéro (fil jaune sur la figure4.4);
- La broche 12 (Dout) est connectée au GPIO23 (fil gris sur la figure4.4);
- La broche 11 (Din) est connectée avec le GPIO24 (fil bleu4.4);
- La broche 10 (CS) est connectée avec le GPIO25 (fil vert sur la figure4.4).

Finalement, nous connectons les câbles des sorties des capteurs avec les entrées analogiques de MCP3008 (CH0, CH1, et CH2) qui vont être transformés en signaux numériques et transmis par la suite à la carte Raspberry pi zéro.

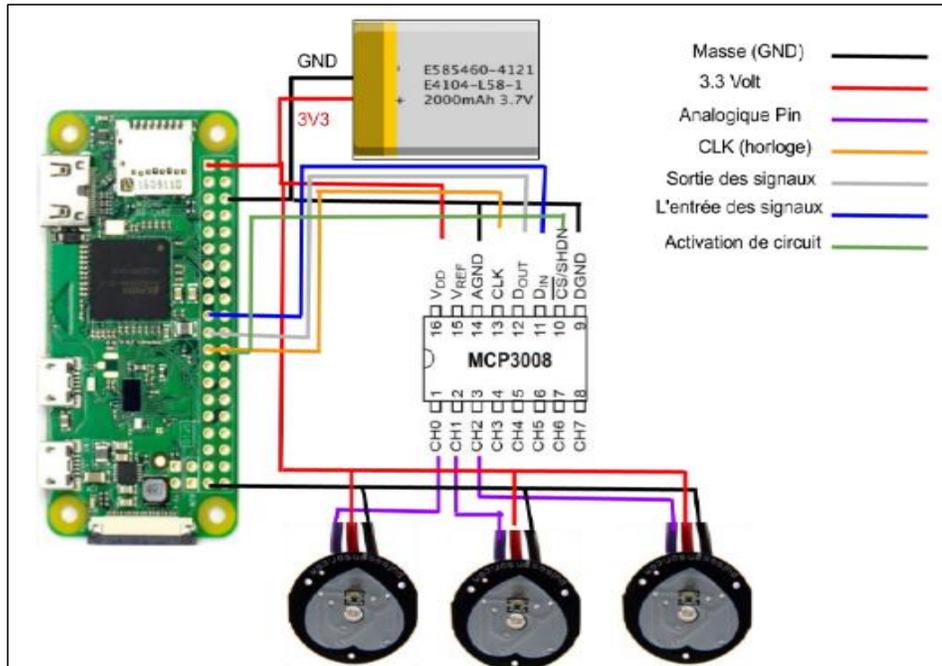


FIGURE 4.4 – Schéma électrique

Pour la programmation de la carte Raspberry pi zéro, nous avons développé un code où nous avons comparé les données obtenues par les trois capteurs, pour ensuite choisir le capteur ayant la valeur intermédiaire et qui possède l'écart minimum par rapport aux deux autres capteurs et dans une limite raisonnable (voir Figure 4.5).

```

G connexion_to_server.ino
reading1 = analogRead(pulsePin) ; //lire le signal du capteurs 1
reading2 = analogRead(pulsePin2); //lire le signal du capteurs 2
reading3 = analogRead(pulsePin3); //lire le signal du capteurs 3
// Fréquence cardiaque détectée Capteur 1.
if(reading1 > UpperThreshold && IgnoreReading1 == false){
  if(FirstPulseDetected1 == false){
    FirstPulseTime1 = millis();
    FirstPulseDetected1 = true; }
  else{
    SecondPulseTime1 = millis();
    PulseInterval1 = SecondPulseTime1 - FirstPulseTime1;
    FirstPulseTime1 = SecondPulseTime1; }
  IgnoreReading1 = true; }
// Battement de coeur bord détecté Capteur 1.
if(reading1 < LowerThreshold){
  IgnoreReading1 = false;
}
// Fréquence cardiaque détectée Capteur 2.
if(reading2 > UpperThreshold && IgnoreReading2 == false){
  if(FirstPulseDetected2 == false){
    FirstPulseTime2 = millis();
    FirstPulseDetected2 = true;
  }
  else{
    SecondPulseTime2 = millis();
    PulseInterval2 = SecondPulseTime2 - FirstPulseTime2;
    FirstPulseTime2 = SecondPulseTime2;
  }
  IgnoreReading2 = true;
}
// Fréquence cardiaque détectée Capteur 3.
if(reading3 > UpperThreshold && IgnoreReading3 == false){
  if(FirstPulseDetected3 == false){
    FirstPulseTime3 = millis();
    FirstPulseDetected3 = true;
  }
  else{
    SecondPulseTime3 = millis();
    PulseInterval3 = SecondPulseTime3 - FirstPulseTime3;
    FirstPulseTime3 = SecondPulseTime3;
  }
}

```

FIGURE 4.5 – Implémentation algorithmique pour choisir le meilleur capteur

Après avoir choisi le meilleur capteur, son signal va être converti en un signal ECG, afin d'utiliser les bases de données d'arythmie disponibles. Les données originales collectées par les capteurs seront également envoyées à l'application mobile pour être accessibles à l'utilisateur.

4.3 CONVERSION DU SIGNAL PPG EN ECG

Les signaux PPG et ECG sont intrinsèquement corrélés, car les changements de volume du sang périphérique sont influencés par les activités du myocarde ventriculaire gauche, et ces activités sont contrôlées par les signaux électriques du nœud sinusal auriculaire (AS). Le temps, l'amplitude et les caractéristiques de la forme d'onde du PPG contiennent des informations sur l'interaction entre le cœur et le système vasculaire conjonctif. Ces caractéristiques ont été traduites pour mesurer la fréquence cardiaque, la variabilité de la fréquence cardiaque et la fréquence respiratoire [63].

Nous nous sommes inspirés de cette corrélation afin de reconstruire la forme d'onde ECG à partir de la mesure PPG.

4.3.1 ACQUISITIONS DES DONNÉES D'ENTRAÎNEMENT

Tout d'abord, pour l'acquisition des données d'entraînement, nous avons utilisé une carte Raspberry pi zero avec deux capteurs : ECG (voir Figure 4.6) et PPG (voir Figure 4.7) permettant la collecte simultanée des données cardiovasculaires.

Les capteurs ECG sont équipés en moyenne de trois électrodes, placées dans trois endroits au niveau des poignets, des chevilles ou de la poitrine et du ventre[115] :

- Les électrodes des deux poitrines renvoient les variations électriques du cœur.
- Une électrode sur le ventre sert de mise à la terre.

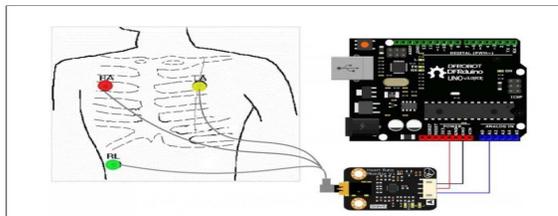


FIGURE 4.6 – Diagramme de connexion capteur ECG[115]

Le capteur PPG utilise la lumière infrarouge (IR) de faible intensité[137]. Lorsque la lumière traverse les tissus biologiques, elle est absorbée par les os, les pigments de la peau et le sang veineux et artériel.

Comme la lumière est plus fortement absorbée par le sang que par les tissus environnants, les changements dans le flux sanguin peuvent être détectés par les capteurs du PPG comme des changements d'intensité de la lumière.



FIGURE 4.7 – PPG capteur[19]

Étant donné que le PPG repose sur l'absorption de la lumière, il est important de s'assurer que le capteur donnera de bons résultats. Ce capteur a été testé dans des applications diverses et a donné de bons résultats [37].

4.3.2 MÉTHODE DE LA CONVERSION

Plusieurs techniques d'apprentissage automatique permettent de faire la conversion du signal PPG en signal ECG. Parmi ces techniques : la régression linéaire qui consiste à décrire les relations entre une variable expliquée (ou dépendante) avec plusieurs variables explicatives (ou indépendantes). Elle permet également d'effectuer des prévisions de la variable expliquée en corrélation avec les variables explicatives[43].

Dans ce modèle, nous établirons une relation entre deux signaux PPG et ECG en adaptant une meilleure courbe (voir Figure 4.8).

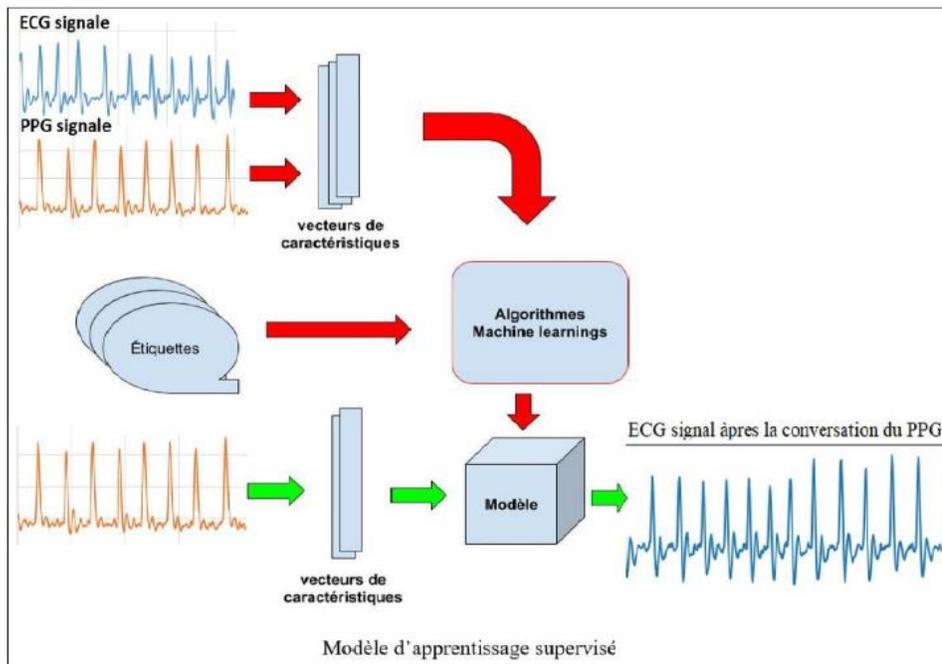


FIGURE 4.8 – Modèle de conversion du signal PPG en ECG

La régression linéaire ajuste un modèle linéaire avec des coefficients $w = (w_1, \dots, w_p)$ pour minimiser la somme résiduelle des carrés entre les cibles observées dans l'ensemble des données et les cibles prédites par l'approximation linéaire. Dans la figure ci-dessous (voir Figure 4.9), nous divisons les données de formation en deux tableaux différents : PPG et ECG, puis nous appliquons la régression linéaire afin de convertir le signal.

```
LineaireRegressionTrain.py
C:\Users\dali\Desktop> mohamed-ali-abad-ms-master > Model-Conversion > LineaireRegressionTrain.py ...
1 # -*- coding: cp1252 -*-
2 import time
3 import pickle
4 from sklearn.linear_model import LinearRegression
5 import numpy as np
6 import matplotlib.pyplot as plt
7
8
9 fichier = open("Data/teste2.txt", "r")
10 X = []
11 y = []
12 i = 0
13 ecg = []
14 ppg = []
15
16 for ligne in fichier:
17     d = ligne.split(",")
18     ppg.append(float(d[0]))
19     ecg.append(float(d[1]))
20     i += 1
21     if (i>200):
22         X.append(ppg)
23         y.append(ecg)
24         ecg = []
25         ppg = []
26         i = 0
27 fichier.close()
28 reg = LinearRegression().fit(X, y)
29 t = reg.score(X, y)
```

FIGURE 4.9 – Code source de l’implémentation du convertisseur

La figure ci-dessous (voir Figure 4.10) montre le score d’entraînement obtenu à partir du modèle de conversion afin d’avoir une évaluation qui garantisse un meilleur résultat de conversion :

```

CAL Invite de commandes
4.77955964e+02 2.58581580e+02 8.88510925e+01 2.41796058e+01
-9.05319856e+01 -2.51126538e+02 -3.23184430e+02 -2.66227552e+02
-1.42808645e+02 -3.07926831e+02 -4.75556828e+02 -4.36166893e+02
9.00447256e-01 1.75292548e+02 3.50049440e+02 3.29796693e+02
4.21802648e+02 5.47165911e+02 5.71684366e+02 6.28564871e+02
7.88392818e+02 9.47684237e+02 1.10779831e+03 1.00986325e+03
1.10627174e+03 1.28630769e+03 1.44309542e+03 1.38570373e+03
1.20864902e+03 1.20731363e+03 1.17398366e+03 1.14242414e+03
7.38926131e+02 6.42352291e+02 5.31689164e+02 3.42647546e+02
4.54106102e+01 -1.49292057e+02 -2.39780776e+02 -3.16084434e+02
-4.24966852e+02 -4.79948291e+02 -4.02633498e+02 -2.96649218e+02
-2.23974042e+02 -2.51261370e+02 -1.63017330e+02 2.46607462e+01
2.53984015e+02 2.56096938e+02 2.63274683e+02 3.61350551e+02
5.21462767e+02 7.11908947e+02 5.27733856e+02 5.42058729e+02
7.12761142e+02 8.48356685e+02 8.77398414e+02 8.88071977e+02
1.04129515e+03 1.33090956e+03 1.39217444e+03 1.43468058e+03
1.57061339e+03 1.56597946e+03 1.48018008e+03 1.34942483e+03
1.29963075e+03 1.20961768e+03 1.08580848e+03 8.44962064e+02
4.95382899e+02 4.00783000e+02 -2.54213174e+01 -2.01910638e+02
-3.67698443e+02 -4.77090259e+02 -4.93489372e+02 -5.31440772e+02
-6.50968721e+02 -7.02372238e+02 -6.13924578e+02 -4.71695733e+02
-2.97274471e+02 -1.33556144e+02 2.77950406e+01 2.05103854e+02
3.76554916e+02 5.25607270e+02 5.75803650e+02 8.12581406e+02
1.19450518e+03 1.38823115e+03 1.43686094e+03 1.57987680e+03
1.79523197e+03 1.87907752e+03 1.85235646e+03 1.78020064e+03
1.71940177e+03 1.61728332e+03 1.47201966e+03 1.30015253e+03
1.19810662e+03]]
le score d'entrainement est: 1.0

```

FIGURE 4.10 – Score d'entrainement

Un modèle constant qui prédit toujours la valeur attendue de y , sans tenir compte des caractéristiques d'entrée, obtiendrait un score R^2 de 0,0 et le meilleur score possible est de 1,0 [40]. Dans la figure ci-dessous (voir Figure 4.11), nous fournissons les résultats de la conversion où la première courbe représente notre meilleur signal de capteur PPG et la seconde courbe représente le résultat de la conversion dans une séquence de 16 secondes.

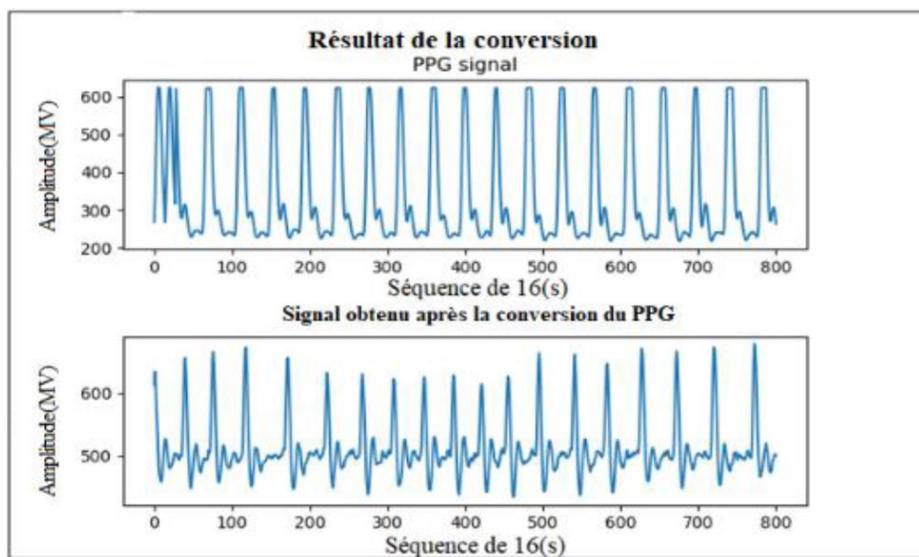


FIGURE 4.11 – Résultat de la conversion du signal PPG en ECG

Cette partie dévoile une approche basée sur l'apprentissage automatique pour reconstruire le signal ECG à partir du PPG. L'algorithme est évalué avec succès, en fonction du sujet, sur une base de données largement adoptée. Cet algorithme démontre qu'avec un système d'apprentissage qui est justifié à chaque étape de la conception, nous sommes capables de reconstruire avec précision le signal ECG en exploitant la relation des deux mesures.

Cette solution peut fournir un dépistage ECG peu coûteux pour une surveillance continue et à long terme, et tirer profit à la fois de la riche expérience clinique de la base de connaissances du signal ECG et de la facilité d'accès au signal PPG.

4.4 CLASSIFICATION DE SIGNAL ECG

Après la conversion du signal arrive l'étape suivante où nous détectons les anomalies selon lesquelles nous classifions le signal. La tâche de classification ECG actuelle consiste à décider à quelle classe l'ECG du patient peut être attribué. On compte quatre classes (voir Figure

4.12) :

- Rythme normal
- Arythmique
- Autre type de rythme
- Très bruyant

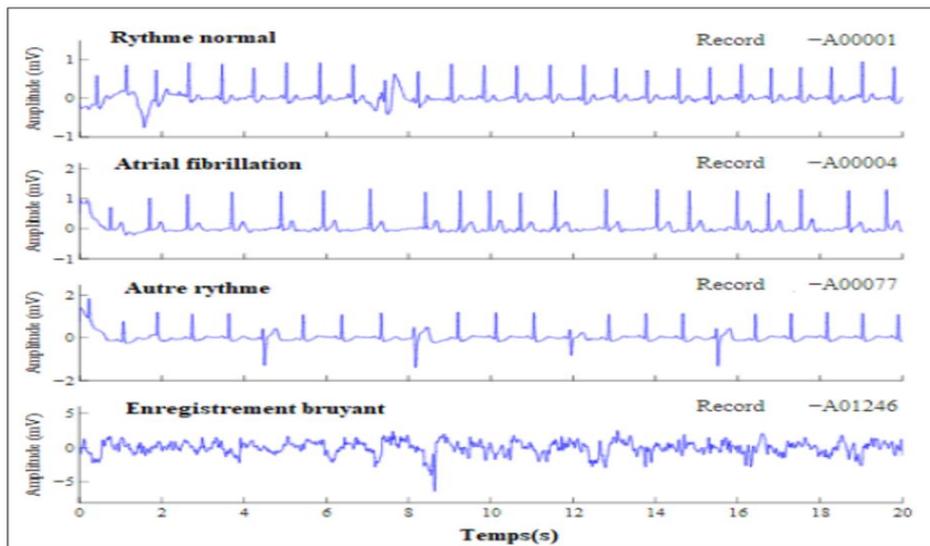


FIGURE 4.12 – Classification des rythmes cardiaques

4.4.1 MÉTHODE DE CLASSIFICATION DU SIGNAL ECG

Dans cette section, nous testons deux modèles d'apprentissage en profondeur basés sur deux architectures différentes pour classifier le signal ECG.

La première architecture (voir Figure 4.13) adaptée de Kachue [83], correspond à une architecture d'apprentissage en profondeur et requiert le cadre d'apprentissage ML TensorFlow [77] où les premières couches des neurones convolutives se comportent comme des extracteurs de fonctionnalités et, à la fin, certaines couches entièrement connectées sont utilisées pour prendre la décision finale sur les classes ECG. Toutes les couches de convolution appliquent

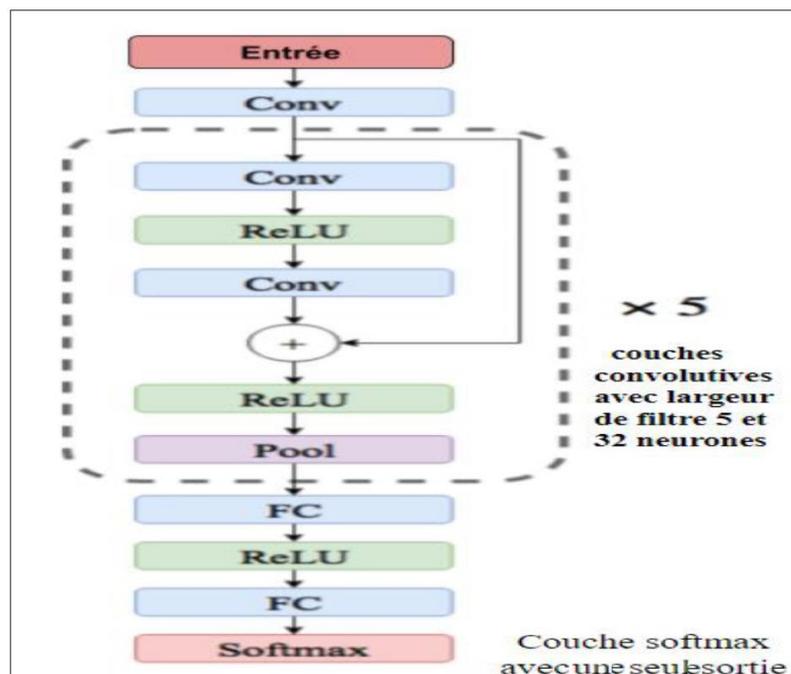


FIGURE 4.13 – Architecture du premier modèle

une convolution 1-D et chacune d'elles possède 32 noyaux de taille cinq. Le réseau est constitué de cinq blocs résiduels suivis de deux couches entièrement connectées comportant chacune 32 neurones et d'une couche softmax pour prédire les probabilités de classe de sortie. Chaque bloc résiduel contient deux couches convolutionnelles, deux non-linéarités ReLU, max pooling de la taille cinq et une couche pooling layer. Au total, un réseau profond est composé de 13 couches.

La deuxième architecture, adaptée de [101], a été aussi implémentée en utilisant TensorFlow. La perte d'entropie croisée sur les sorties softmax est utilisée comme fonction de perte (voir Figure 4.14).

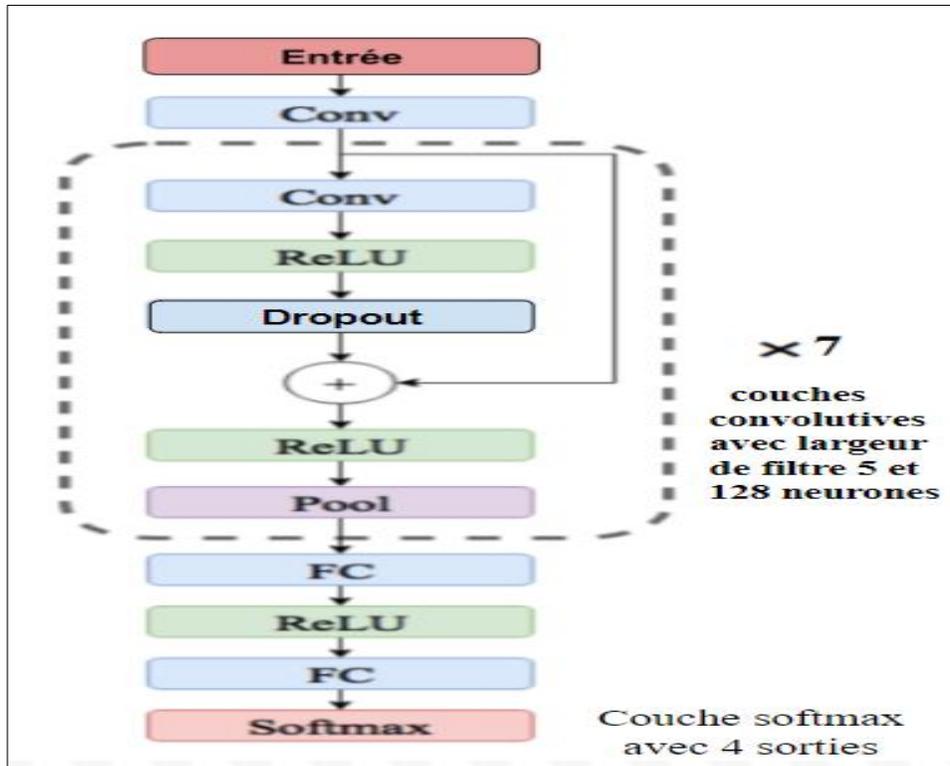


FIGURE 4.14 – Architecture de deuxième modèle

Dans le cas actuel, nous testons un CNN 1D avec l'architecture suivante : sept couches convolutives avec largeur de filtre cinq et 128 neurones + pooling max et dropout après chaque couche + GlobalAveragePooling + trois couches FCN avec (256/128/64) neurones + dropout après chaque couche + couche softmax avec quatre sorties. En outre, une procédure de prétraitement standard a été utilisée, comme la soustraction de la moyenne des valeurs de séries temporelles et la division par la valeur de l'écart type, la taille du lot était égale à 256. Toutes les parties de cet algorithme ont été implémentées au moyen du cadre de développement Keras [34].

Pour résumer, les deux modèles d'apprentissage utilisent deux architectures différentes : le

premier modèle se sert de cinq couches de convolution avec largeur de filtre de cinq et de 32 neurones, par contre le deuxième modèle utilise sept couches convolutives avec largeur de filtre de cinq et 128 neurones et un dropout après chaque couche.

4.4.2 BASE DE DONNÉES D'ENTRAÎNEMENT ECG

Les enregistrements ECG ont été collectés à l'aide du dispositif AliveCor[55]. Le kit d'entraînement contient 8 528 enregistrements ECG à une seule sonde d'une durée de neuf secondes à un peu plus de 60 s. Les enregistrements ECG ont été échantillonnés à 300 Hz et ils ont été filtrés en mode passe-bande par le dispositif. Toutes les données sont fournies au format compatible MATLAB V4 WFDB, chacune comprenant un fichier .Mat contenant l'ECG et des fichiers de types hea contenant les informations de forme d'onde. Les données fournies ne sont pas équilibrées, la plupart appartiennent à un rythme normal (60 % des données). La figure 4.15 présente un bref résumé des données disponibles.

Type	# enregistrement	Signifier	Durée (s)			
			Dakota du Sud	Max	Médian	Min
Ordinaire	5154	31,9	10,0	61,0	30	9,0
UN F	771	31,6	12,5	60	30	10,0
Autre rythme	2557	34,1	11,8	60,9	30	9,1
Bruyant	46	27,1	9,0	60	30	10,2
Total	8528	32,5	10,9	61,0	30	9,0

FIGURE 4.15 – Base de données ECG

Différentes opérations ont été utilisées pour créer l'ensemble des données comme la multiplication des données existantes.

4.4.3 LES RÉSULTATS DE CLASSIFICATIONS

Dans cette section, nous testons les deux modèles Kachue[83] et Pyakillya[101] avec la même base de données ECG.

Ci-dessous, nous produisons les résultats obtenus pour le premier exemple (voir Figure 4.16) :

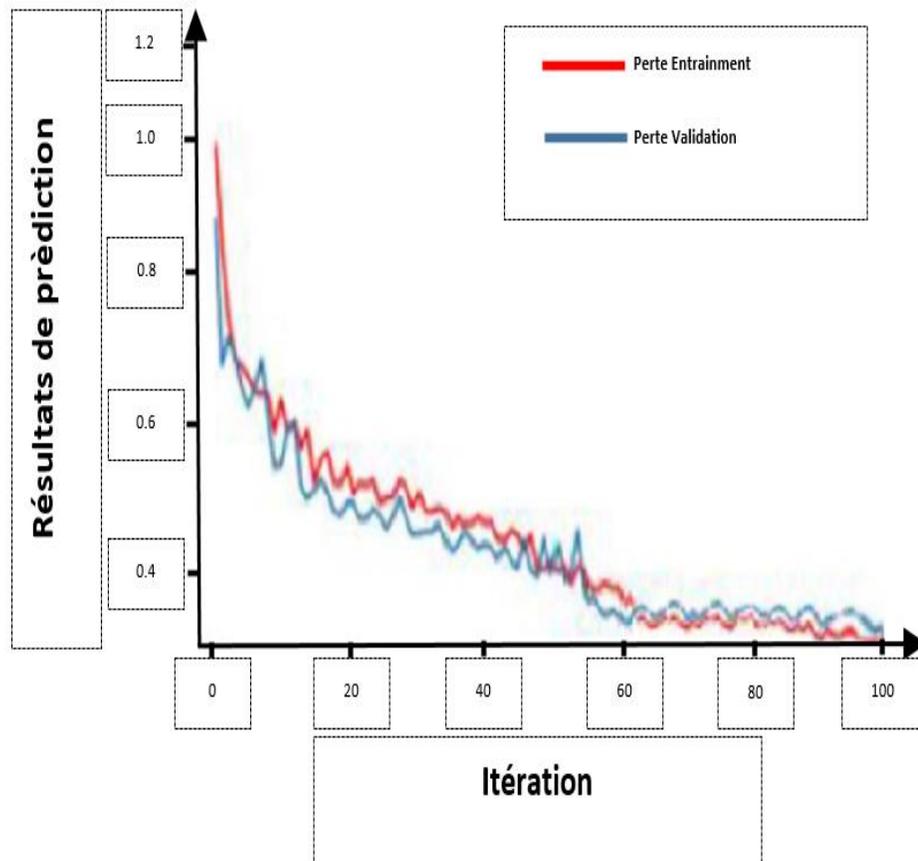


FIGURE 4.16 – Résultats du premier exemple

On constate, lors de l'exécution du premier exemple, les résultats suivants :

- Prédiction d'entraînement : 98,46 %
- Validation : 97,01 %

- Perte d'entraînement : 0,03 %

- Perte de validation : 0,05 %

Le modèle FCN utilisé dans l'article de Kachuee [83] concernant l'application de réseaux neuronaux convolutifs 1D, a comme meilleure précision obtenue sur les données de validation, environ 97,01%.

Pour obtenir ces résultats, nous avons procédé à l'adaptation des paramètres du réseau pour éviter le surapprentissage :

- Augmenter le dropout à 0,5

- Utiliser la validation croisée (K-fold)

La validation croisée est une mesure préventive puissante contre le surapprentissage. L'idée est d'utiliser les données d'entraînement initial pour générer plusieurs mini-tests d'entraînement. Dans la validation croisée standard à k plis, nous divisons les données en k sous-ensembles, appelés plis. Ensuite, nous entraînons itérativement l'algorithme sur k-1 plus tout en utilisant le pli restant (appelé "pli d'attente") comme ensemble de tests [134].

Pour le deuxième modèle représenté dans la figure ci-dessous (voir Figure 4.17) nous avons obtenu des résultats moins pertinents que pour le premier exemple testé.

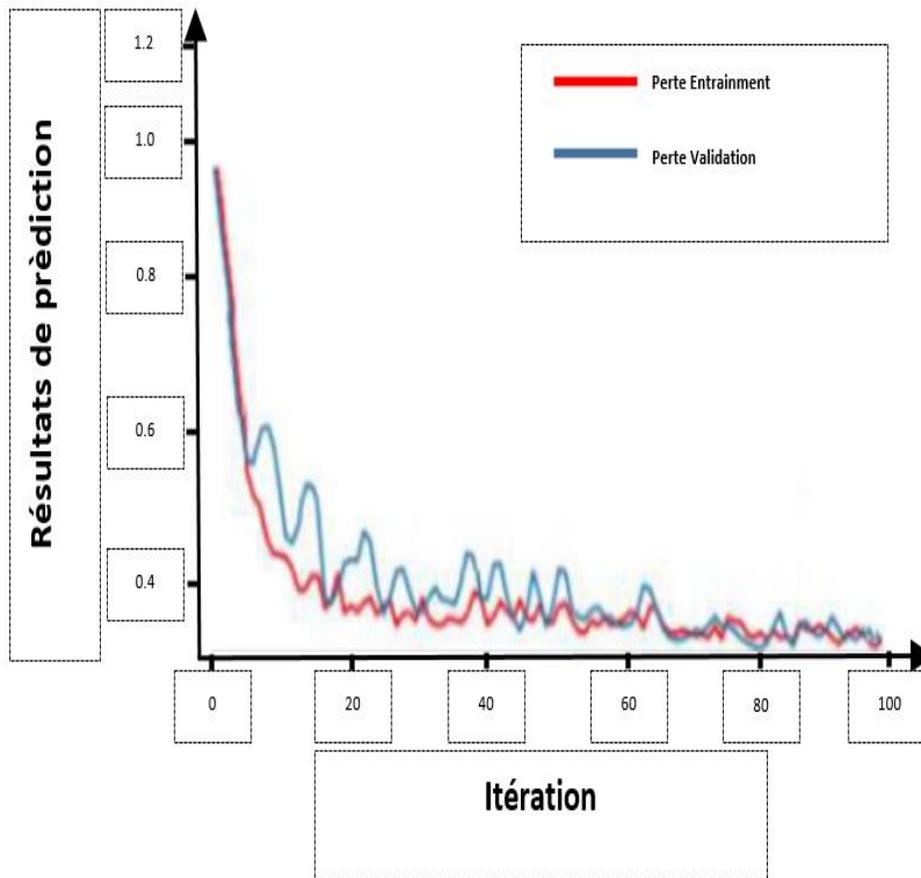


FIGURE 4.17 – Résultats du deuxième exemple

Le deuxième exemple([101]) a donné comme résultats :

- Prédiction d’entraînement : 91,54 %
- Validation : 82,75 %
- Perte d’entraînement : 0,07 %
- Perte de validation : 0,05 %

Selon les résultats, la première méthode suggérée [83] est capable de faire des prédictions sur les deux tâches avec une précision d’entraînement de 98,64 % et de validation 97,01 %.

La figure 4.18 ci-dessous montre les résultats obtenus après l’exécution du code sur notre carte

Raspberry-pi zéro :

```

Predict status client [68]
status for verification 4
Predict Heart beat for Sensor1 and 2 [67]
Predict Heart beat forSensor3 and 1 [67]
Predict heart beat for Sensor3 and 2 [67]
BPM for verification 78.79185817465529
Predict status client [68]
status for verification 4
Predict Heart beat for Sensor1 and 2 [67]
Predict Heart beat forSensor3 and 1 [68]
Predict heart beat for Sensor3 and 2 [68]
BPM for verification 76.65772326561901
Predict status client [68]
status for verification 4
Predict Heart beat for Sensor1 and 2 [67]
Predict Heart beat forSensor3 and 1 [68]
Predict heart beat for Sensor3 and 2 [65]
BPM for verification 73.33170373991689
Predict status client [68]
status for verification 4
Predict Heart beat for Sensor1 and 2 [67]
Predict Heart beat forSensor3 and 1 [68]
Predict heart beat for Sensor3 and 2 [67]
BPM for verification 71.80469123982766
Predict status client [68]
status for verification 4
Predict Heart beat for Sensor1 and 2 [67]
Predict Heart beat forSensor3 and 1 [68]
Predict heart beat for Sensor3 and 2 [68]
BPM for verification 70.21650087770627
Predict status client [68]
status for verification 4
Predict Heart beat for Sensor1 and 2 [67]
Predict Heart beat forSensor3 and 1 [68]
Predict heart beat for Sensor3 and 2 [67]
BPM for verification 69.34812760055478
Predict status client [68]
status for verification 4

```

FIGURE 4.18 – Exécution de modèle sur Raspberry-py zéro

D’après les résultats obtenus par le bracelet, notre programme a classé l’état de l’utilisateur dans la quatrième classe, ce qui équivaut à un battement de cœur normal.

Les deux exemples de code dans ce chapitre ont été créés et testés à l’aide de Python avec Keras intégrés à TensorFlow et entraînés sur Google Colab. Pour la comparaison entre les résultats obtenus par nos références([83],[101]) et nos résultats, nous avons constaté une amélioration

de 97,01 % au lieu de 93,4 %, mais le contraire se produit pour le deuxième exemple où nous avons constaté une diminution de la validité de 86,75 % à 82 %. Les algorithmes d'apprentissage automatique apprennent un modèle conditionné par les données fournies. En conséquence, les décisions prises par l'algorithme au cours du processus d'apprentissage peuvent varier de manière aléatoire.

L'impact est que chaque fois que l'algorithme d'apprentissage automatique est exécuté sur les mêmes données, il apprend un modèle légèrement différent. À son tour, le modèle peut faire des prédictions légèrement différentes et, lorsqu'il est évalué en fonction de perte ou de la validation, ses performances peuvent être légèrement différentes[26].

4.5 ACCÈS A L'INFORMATION RETENUE

Dans cette sous-section, nous présentons le flux de données de notre bracelet intelligent vers l'application mobile. Au début, nous fournissons le diagramme de classe de la base de données qui va permettre de comprendre la fonctionnalité. Ensuite, nous passons à l'application mobile où nous offrons le diagramme de cas d'utilisation qui va permettre de schématiser les besoins des utilisateurs et leurs attentes vis-à-vis du système.

4.5.1 ENREGISTREMENT DES DONNÉES EN TEMPS RÉEL

Les données récoltées par le bracelet intelligent sont envoyées à une base donnée Firebase. Cette base de données permet l'hébergement dans le Cloud en temps réel. Les données sont stockées sous format JSON et synchronisées en temps réel avec chaque utilisateur connecté [56] via une application mobile (voir Figure 4.19). Le bracelet recueille et traite les données vasculaires pour obtenir les résultats suivants : trois signaux PPG et un statut d'utilisateur. Ces résultats seront envoyés à une base de données qui est interfacée par une application mobile.

Cette dernière est l'interface entre l'utilisateur et le bracelet.

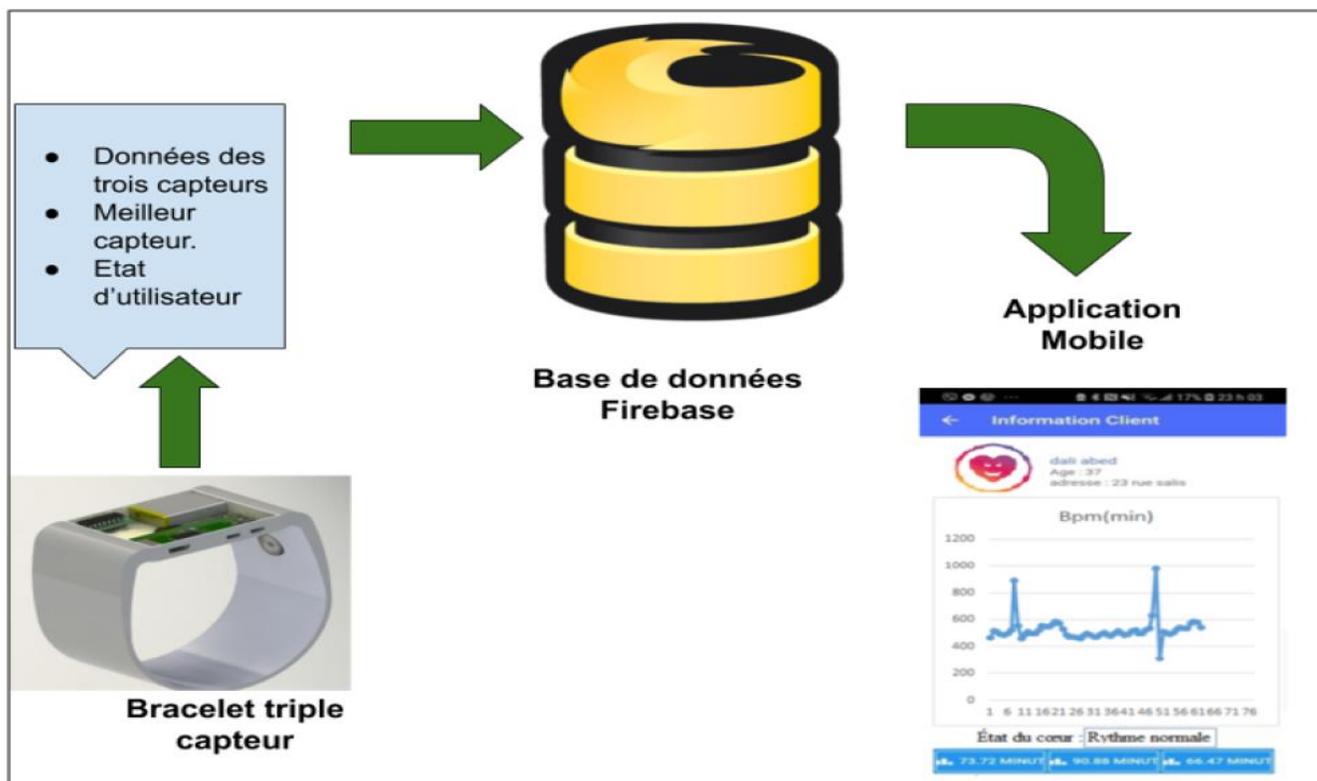


FIGURE 4.19 – Circulation des données

Dans le but de bien comprendre le système, nous présentons le diagramme de classes (voir Figure 4.20) qui donne une vue globale du système en présentant ses classes, ses interfaces, ses collaborations, et les relations entre elles.

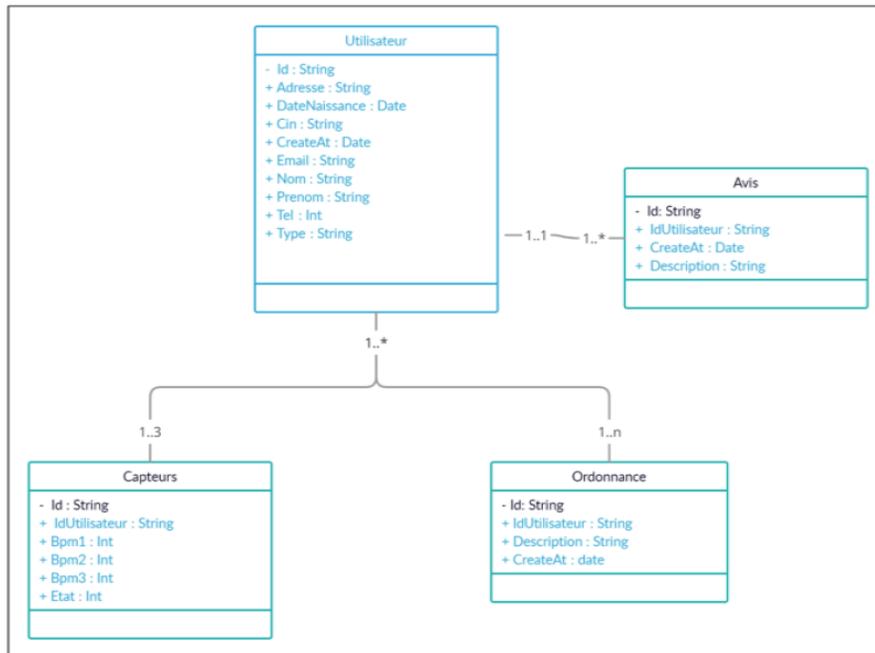


FIGURE 4.20 – Diagramme de classes

4.5.2 APPLICATION MOBILE

L'application mobile va permettre d'accéder à la base de données afin de consulter les données traitées par le bracelet. Pour le développement de l'application mobile, nous utilisons Ionic, créé en 2013 par Max Lynch, Ben Sperry et Adam Bradley. Ionic est un cadre qui permet de développer des applications mobiles pour Android et iOS. Basé sur AngularJS et Cordova, il permet de créer un code multisupport, en utilisant des langages web comme JavaScript, HTML et CSS [104].

La figure ci-dessous (voir Figure 4.21) montre l'interface graphique de la base de données Firebase. Dans la sous-section suivante, nous exposons le diagramme de cas d'utilisation et une description détaillée de cas d'utilisation utilisé pour l'application mobile.

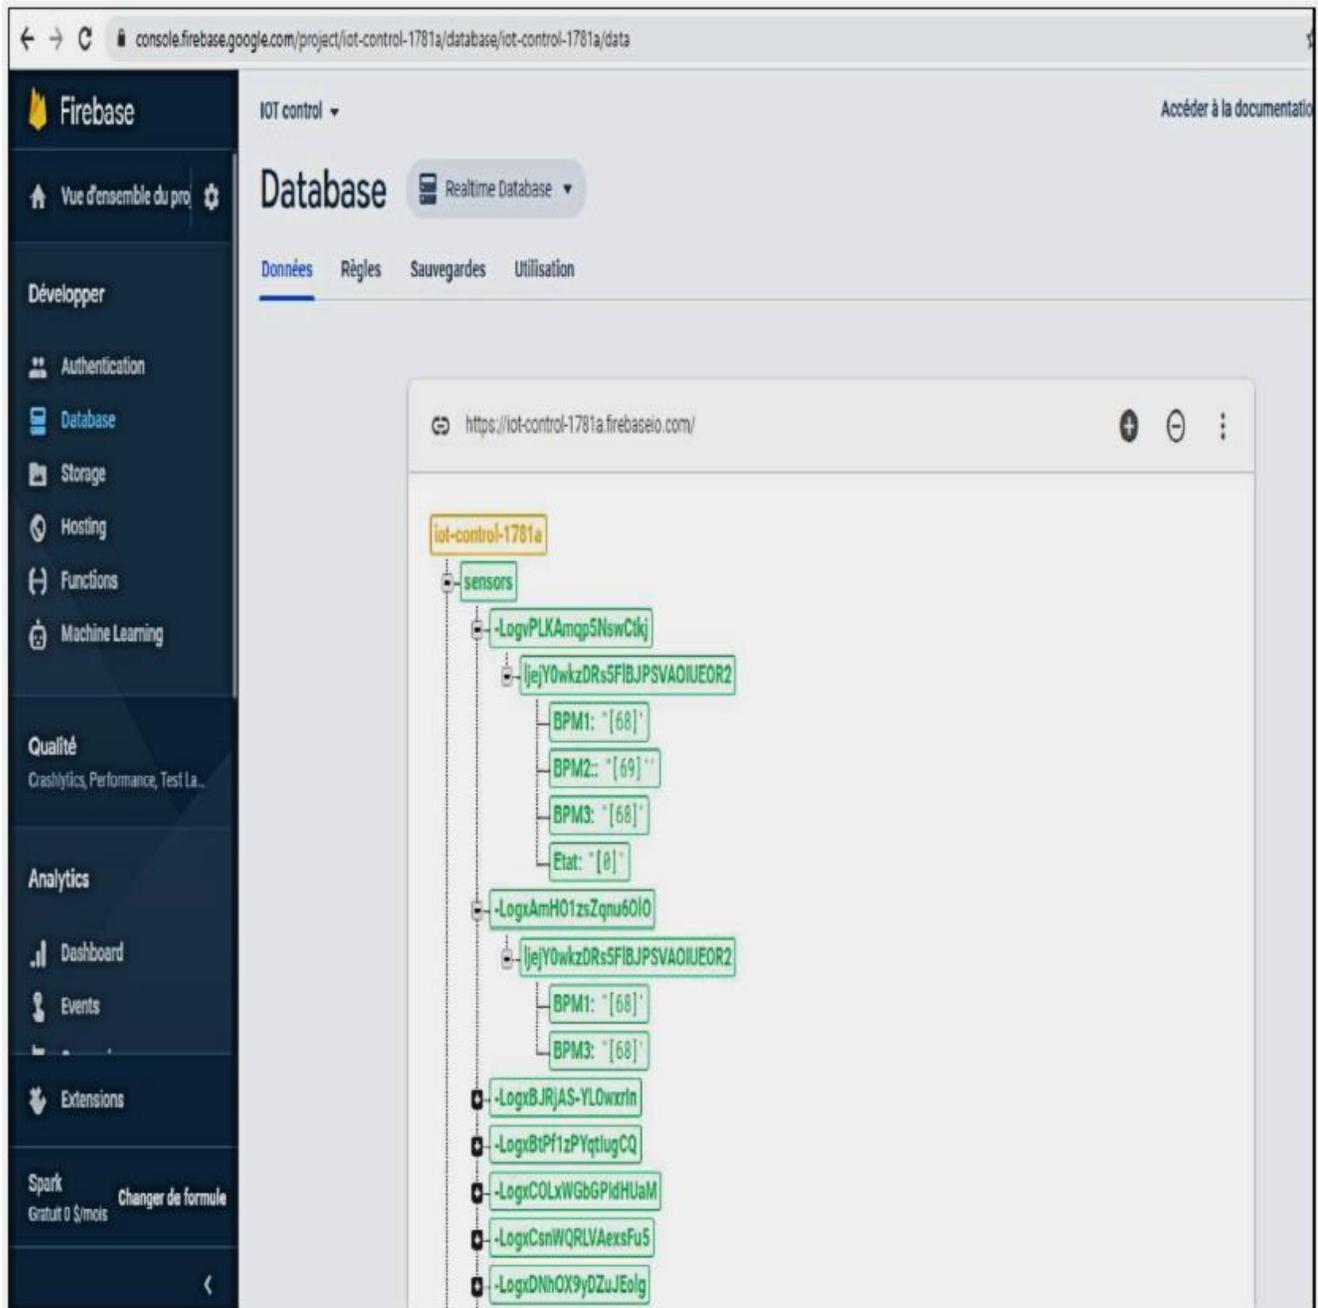


FIGURE 4.21 – Base de données Firebase

Diagramme de cas d'utilisation global

Un cas d'utilisation permet de schématiser les besoins des utilisateurs et leurs attentes d'un système. Elle représente une vue globale du fonctionnement de l'application (voir Figure 4.22).

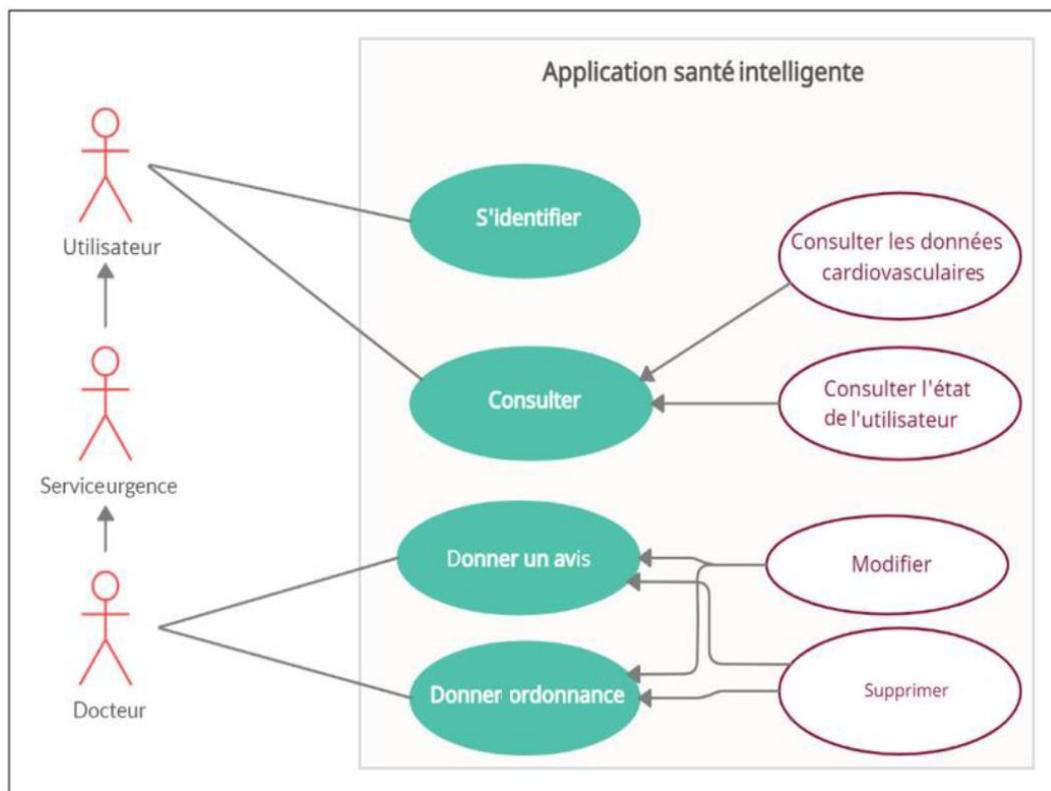


FIGURE 4.22 – Diagramme de cas d'utilisation

Dans la figure ci-dessus (voir Figure 4.23), chaque utilisateur (utilisateur de bracelet, service urgence et docteur) possède un identifiant et un mot de passe qui lui permettent d'accéder aux fonctionnalités de l'application selon son profil. Ce cas d'utilisation permet de sécuriser l'accès à l'application.

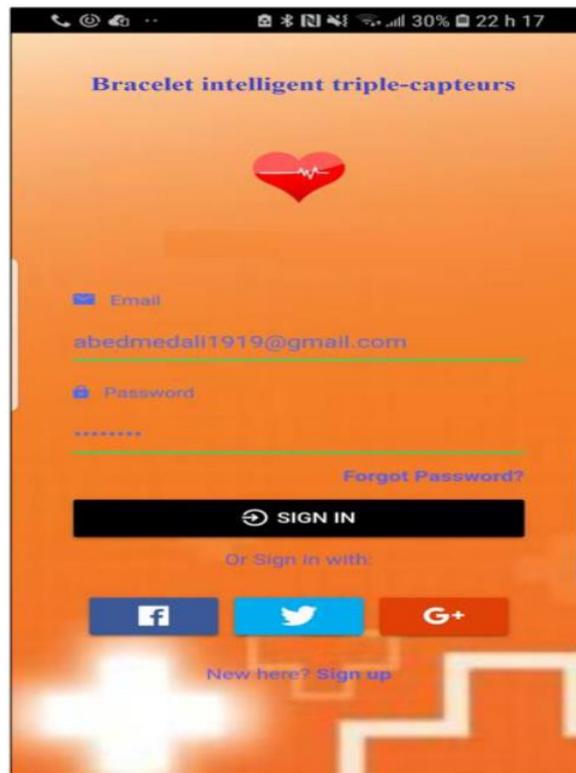


FIGURE 4.23 – Identification de l'utilisateur

Description de cas d'utilisation

Dans le tableau ci-dessous (Tableau 4.1), nous présentons une description détaillée de cas d'utilisation pour l'application mobile.

TABLEAU 4.1 – Description de cas d'utilisation globale

Cas d'utilisation	Gestion des utilisateurs		
Acteurs	Utilisateur	Service urgence	Docteur
Précondition	Authentification	Authentification	Authentification
Objectifs	<ul style="list-style-type: none"> + Consulter les données des capteurs. + Consulter l'état d'utilisateurs. + L'utilisateur saisit et valide les informations personnelles. + Consulter la sauvegarde dans la base de données. 	<ul style="list-style-type: none"> + Consulter les données des capteurs. + Consulter l'état d'utilisateurs. + Consulter la sauvegarde dans la base de données. + Consulter l'avis et l'ordonnance du docteur. 	<ul style="list-style-type: none"> + Consulter les données des capteurs. + Consulter l'état d'utilisateurs. + Consulter la sauvegarde dans la base de données. + Le docteur saisit et valide une ordonnance.
Scénario nominal	<ul style="list-style-type: none"> + Le système affiche la liste des tâches disponibles. + l'utilisateur choisit l'action à exécuter. + Le système exécute l'action requise. 	<ul style="list-style-type: none"> + Le système affiche la liste des tâches disponibles. + les services d'urgence choisie l'action à exécuter. + Le système exécute l'action requise. 	<ul style="list-style-type: none"> + Le système affiche la liste des tâches disponibles. + le docteur choisit l'action à exécuter. + Le système exécute l'action requise.

4.6 CONCLUSION

Dans ce chapitre, nous avons présenté une méthode de conversion du signal PPG en ECG, puis nous avons montré deux méthodes de classification des battements cardiaques ECG. Plus précisément, nous avons testé deux réseaux neuronaux convolutifs profonds avec des connexions résiduelles pour la tâche de classification de l'arythmie et nous avons montré que le premier exemple peut servir pour former des classificateurs précis pour la classification du signal ECG avec une précision de validation de 97,01 %. Les données collectées et traitées

par notre bracelet seront ensuite transférées dans une base de données pour être stockées et accessibles à l'aide d'une application mobile.

Les bracelets intelligents sont discrets et faciles à porter. Bien que la technologie intelligente des bracelets avec des biocapteurs puisse être utile dans diverses applications de soins de santé, une recherche rigoureuse sur leur utilisation en milieu clinique demeure nécessaire.

Malgré la difficulté de déterminer avec une grande précision les facteurs et les risques de maladie menaçant l'utilisateur, les résultats de notre modèle ont été prometteurs et ont montré que l'utilisation de ces bracelets pourrait sans doute contribuer à la protection de la santé et des vies des utilisateurs.

CONCLUSION GÉNÉRALE

Le but de cette recherche était la conception et le développement d'un prototype de bracelet multicapteur PPG à l'aide d'un modèle intelligent de détection des difficultés cardiovasculaires.

Ce développement était basé sur une hypothèse affirmant qu'un bracelet multicapteur PPG serait en mesure de pallier quelques limitations des bracelets existants sur le marché et qui ne contiennent qu'un seul capteur PPG. Ce développement est accompagné du développement de trois solutions logicielles. La première consiste en un algorithme qui convertit les signaux PPG en signaux ECG. La deuxième contribution logicielle consiste en un module d'apprentissage automatique pour détecter des arythmies cardiaques. Nous avons testé deux architectures d'apprentissage profond et les résultats obtenus étaient prometteurs. En effet, nous arrivons à avoir une précision de validation de l'ordre de 97,01 %. En outre, une procédure de prétraitement standard a été utilisée, comme la soustraction de la moyenne des valeurs de séries temporelles et la division par la valeur de l'écart type, la taille du lot était égale à 256. Toutes les parties de cet algorithme ont été implémentées au moyen du cadre de développement Keras.

L'apprentissage automatique n'offre pas seulement une carrière lucrative, il promet de résoudre des problèmes et de profiter aux entreprises et aux organisations à but non lucratif en faisant des prédictions et en prenant de meilleures décisions. Parmi les avantages, citons l'identification

facile des tendances et des modèles, l'amélioration continue, une large applicabilité, l'absence d'intervention humaine et le traitement de données multidimensionnelles et multivariées.

Inconvénients : forte propension à l'erreur, temps et ressources et acquisition des données.

La troisième contribution logicielle est une application mobile à travers laquelle l'utilisateur peut interagir avec le bracelet multicapteur.

Malgré les résultats intéressants obtenus, nous avons identifié plusieurs pistes pour améliorer le prototype développé ainsi que les solutions logicielles qui l'accompagnent. Du point de vue matériel, une miniaturisation est possible en remplaçant par exemple la carte Raspberry pi zero par une carte à microcontrôleur plus compacte. Du point de vue logiciel, il est possible de raffiner les algorithmes développés et de tester à une plus grande échelle tout en évaluant d'autres stratégies de calcul et de choix de la valeur du signal provenant du bracelet. En résumé, les données sont nécessaires, tout comme les bons modèles et la théorie qui les explique. Mais, dans l'ensemble, ce dont nous avons besoin, c'est de bonnes approches qui nous aident à comprendre comment interpréter les données, les modèles et les limites des deux afin de produire le meilleur résultat possible.

En d'autres termes, les données sont importantes. Mais, sans une approche solide, les données deviennent du bruit.

BIBLIOGRAPHIE

- [1] The mit-bih normal sinus rhythm database. <https://www.physionet.org/content/nsrdb/1.0.0/>, 2008.
- [2] Overfitting et underfitting. <https://mrmint.fr/overfitting-et-underfitting-quand-vos-algorithmes-de-machine-learning-derapent> 2017.
- [3] Aaron and Bengio. *Deep learning*, volume 1. MIT press Cambridge, 2016.
- [4] Abid. A fast feedforward training algorithm using a modified form of the standard backpropagation algorithm. *IEEE Transactions on neural networks*, 12(2) :424–430, 2001.
- [5] Agatonovic-Kustrin and Beresford. Basic concepts of artificial neural network (ann) modeling and its application in pharmaceutical research. *Journal of pharmaceutical and biomedical analysis*, 22(5) :717–727, 2000.
- [6] AL-Ziarjawey and Çankaya. Heart rate monitoring and pqrst detection based on graphical user interface with matlab. *International Journal of Information and Electronics Engineering*, 5(4) :311, 2015.

- [7] Allen. Photoplethysmography and its application in clinical physiological measurement. *Physiological measurement*, 28(3) :R1, 2007.
- [8] Alrubaye. *Intrusion Detection System Based on Carpenter/Grossberg Artificial Neural Network*. PhD thesis, Master Thesis. Department of Computer Science, Middle East University, 2014.
- [9] Anders and Öberg. Estimation of respiratory volumes from the photoplethysmographic signal. part i : experimental results. *Medical & biological engineering & computing*, 37(1) :42–47, 1999.
- [10] Andreas and Guido. *Introduction to machine learning with Python : a guide for data scientists*. " O'Reilly Media, Inc.", 2016.
- [11] Andrej and Kolo. Streaming pulse data to the cloud with bluetooth le or nodemcu esp8266. In *2016 5th Mediterranean Conference on Embedded Computing (MECO)*, pages 428–431. IEEE, 2016.
- [12] Andrew and Johnson. A smart sensor to detect the falls of the elderly. *IEEE Pervasive computing*, 3(2) :42–47, 2004.
- [13] Ang and Li. Tensorflow and keras-based convolutional neural network in cat image recognition. 2017.
- [14] Ashrafuddin and Devarakonda. Smart carpet : Developing a sensor system to detect falls and summon assistance. *Journal of gerontological nursing*, 36(7) :8–12, 2012.
- [15] Asim and Siewiorek. ewatch : a wearable sensor and notification platform. In *International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06)*, pages 4–pp. IEEE, 2006.

- [16] Awni and Rajpurkar. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature medicine*, 25(1) :65, 2019.
- [17] Barakat and Araújo. Machine learning and value generation in software development : a survey. *arXiv preprint arXiv :2001.08980*, 2020.
- [18] Barreiro and Flavio. *Interprétation d'images basée sur la technologie des réseaux de neurones*. PhD thesis, Haute école de gestion de Genève, 2018.
- [19] Becky and Cooper. *Getting started with Adafruit FLORA : making wearables with an Arduino-compatible electronics platform*. Maker Media, Inc., 2015.
- [20] Benediktsson and Sveinsson. Feature extraction for multisource data classification with artificial neural networks. *International journal of remote sensing*, 18(4) :727–740, 1997.
- [21] Bernardo and Pereira. Vital-jacket® : A wearable wireless vital signs monitor for patients' mobility in cardiology and sports. In *2010 4th International Conference on Pervasive Computing Technologies for Healthcare*, pages 1–2. IEEE, 2010.
- [22] Bishop. *Neural networks : a pattern recognition perspective*. 1996.
- [23] Blaine and David. Health at hand : a systematic review of smart watch uses for health and wellness. *Journal of biomedical informatics*, 63 :269–276, 2016.
- [24] Bodhi and Liu. An energy harvesting wearable ring platform for gestureinput on surfaces. In *Proceedings of the 12th annual international conference on Mobile systems, applications, and services*, pages 162–175, 2014.

- [25] Brakni. *Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire InfiniTEM*. PhD thesis, Université du Québec en Abitibi-Témiscamingue, 2011.
- [26] Jason Brownlee. Why do i get different results each time in machine learning? <https://machinelearningmastery.com/different-results-each-time-in-machine-learning/>, 2017.
- [27] Caldara and Vitali. A wearable sweat ph and body temperature sensor platform for health, fitness, and wellness applications. In *Sensors and Microsystems*, pages 431–434. Springer, 2014.
- [28] Chia-Yen and Lino. Classification of cognitive reserve in healthy older adults based on brain activity using support vector machine. *Physiological Measurement*, 2020.
- [29] Ciobanu and Maria. Advantages and disadvantages of using neural networks for predictions. *Ovidius University Annals, Series Economic Sciences*, 13(1), 2013.
- [30] Denisse and Esparza. A review on wearable photoplethysmography sensors and their potential future applications in health care. *International journal of biosensors & bioelectronics*, 4(4) :195, 2018.
- [31] Dietterich. Overfitting and undercomputing in machine learning. *ACM computing surveys (CSUR)*, 27(3) :326–327, 1995.
- [32] Tobias Domhan, Jost Tobias Springenberg, and Frank Hutter. Speeding up automatic hyperparameter optimization of deep neural networks by extrapolation of learning curves. In *Twenty-fourth international joint conference on artificial intelligence*, 2015.
- [33] PF Dubois. Python : Batteries included, volume 9 of computing in science & engineering. *IEEE/AIP*, May, 2007.

- [34] Ehsan and Juanes. Sciann : A keras wrapper for scientific computations and physics-informed deep learning using artificial neural networks. *arXiv preprint arXiv :2005.08803*, 2020.
- [35] Einthoven. The galvanometric registration of the human electrocardiogram, likewise a review of the use of the capillary-electrometer in physiology 1. *Annals of Noninvasive Electrocardiology*, 2(1) :93–93, 1997.
- [36] Elnaz and Shoeibi. Classification ecg of cardiac signals using lpc features and support vector machine. In *2nd International Conference on Knowledge-Based Research in Computer Engineering & Information Technology*, 2017.
- [37] June Energy and Vincent De Dobbeleer. Parcourir les catégories.
- [38] Eric and Chlebowski. Fully wireless implantable cardiovascular pressure monitor integrated with a medical stent. *IEEE Transactions on Biomedical Engineering*, 57(6) :1487–1496, 2010.
- [39] Eric and Hewson. Theme d : sensors, wearable devices, intelligent networks and smart homecare for health. *IRBM*, 34(1) :11–13, 2013.
- [40] Fabian and Varoquaux. Scikit-learn : Machine learning in python. *the Journal of machine Learning research*, 12 :2825–2830, 2011.
- [41] Fedoruk and Currie. Locations of cardiac arrest : affirmation for community public access defibrillation (pad) program. *Prehospital and disaster medicine*, 17(4) :202–205, 2002.
- [42] Foody. Using prior knowledge in artificial neural network classification with a minimal training set. *Remote Sensing*, 16(2) :301–312, 1995.

- [43] Foucart. Colinéarité et régression linéaire. *Mathématiques et sciences humaines. Mathematics and social sciences*, (173), 2006.
- [44] Francis and Hudson. Pcornet : turning a dream into reality, 2014.
- [45] Frank. Systèmes ambulatoires d'enregistrement de l'ecg. *La Lettre du cardiologue*, (469) :29–30, 2013.
- [46] Géron. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow : Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, 2019.
- [47] Gilleron. Apprentissage automatique, les réseaux de neurones, groupe de recherche sur l'apprentissage automatique, université de lille, 2007.
- [48] Giovanna and De Pietro. A deep learning approach for ecg-based heartbeat classification for arrhythmia detection. *Future Generation Computer Systems*, 86 :446–455, 2018.
- [49] Gulli. *Deep learning with Keras*. Packt Publishing Ltd, 2017.
- [50] Harville. Stereo person tracking with adaptive plan-view templates of height and occupancy statistics. *Image and Vision Computing*, 22(2) :127–142, 2004.
- [51] Heikki and Castellanos. Sudden death due to cardiac arrhythmias. *New England Journal of Medicine*, 345(20) :1473–1482, 2001.
- [52] Rudi Hoekema, Gérard JH Uijen, and Adriaan Van Oosterom. Geometrical aspects of the interindividual variability of multilead ecg recordings. *IEEE Transactions on Biomedical Engineering*, 48(5) :551–559, 2001.
- [53] Hong-Yu and Shuai. Reconstructing qrs complex from ppg by transformed attentional neural networks. *IEEE Sensors Journal*, 20(20) :12374–12383, 2020.

- [54] Mehdi Hussein and Atieh. Smart home design for disabled people based on neural networks. *Procedia Computer Science*, 37 :117–126, 2014.
- [55] Ikaro and Johnson. Af classification from a short single lead ecg recording : the physionet/computing in cardiology challenge 2017. In *2017 Computing in Cardiology (CinC)*, pages 1–4. IEEE, 2017.
- [56] IKG and Indrayana. Data structure comparison between mysql relational database and firebase database nosql on mobile based tourist tracking application. In *Journal of Physics : Conference Series*, volume 1569, page 032092. IOP Publishing, 2020.
- [57] Jae and Zhang. Ventricular arrhythmias underlie sudden death in rats with heart failure and preserved ejection fraction. *Circulation : Arrhythmia and Electrophysiology*, 11(8) :e006452, 2018.
- [58] Jamil and Yuce. Wireless body area network (wban) design techniques and performance evaluation. *Journal of medical systems*, 36(3) :1441–1457, 2012.
- [59] John and Murray. Development of a neural network screening aid for diagnosing lower limb peripheral vascular disease from photoelectric plethysmography pulse waveforms. *Physiological Measurement*, 14(1) :13, 1993.
- [60] John and Pisharoty. Piloteur : a lightweight platform for pilot studies of smart homes. In *Proceedings of the 1st ACM conference on embedded systems for energy-efficient buildings*, pages 110–119, 2014.
- [61] Kaminsky and Barad. Textural neural network and version space classifiers for remote sensing. *International Journal of Remote Sensing*, 18(4) :741–762, 1997.
- [62] Karen and Pitchers. Body area networks : Towards a wearable future. In *Proc. WWRF kick off meeting, Munich, Germany*, pages 6–7, 2001.

- [63] Walter Karlen, Srinivas Raman, Mark Ansermino, and Dumont. Multiparameter respiratory rate estimation from the photoplethysmogram. *IEEE Transactions on Biomedical Engineering*, 60(7) :1946–1953, 2013.
- [64] Katte. Recurrent neural network and its various architecture types. *International Journal of Research and Scientific Innovation (IJRSI)*, 5 :124–129, 2018.
- [65] Krishna and Sahambi. Classification of ecg arrhythmias using multi-resolution analysis and neural networks. In *TENCON 2003. Conference on convergent technologies for Asia-Pacific region*, volume 1, pages 227–231. IEEE, 2003.
- [66] Li and Yu. Deep learning : methods and applications. *Foundations and trends in signal processing*, 7(3–4) :197–387, 2014.
- [67] Lippmann. An introduction to computing with neural nets. *IEEE Assp magazine*, 4(2) :4–22, 1987.
- [68] Lobodzinski. Ecg patch monitors for assessment of cardiac rhythm abnormalities. *Progress in cardiovascular diseases*, 56(2) :224–229, 2013.
- [69] Lorrain. *Etude et conception de circuits innovants exploitant les caractéristiques des nouvelles technologies mémoires résistives*. PhD thesis, Université Paris-Saclay, 2018.
- [70] Maarten and Budts. Accuracy of apple watch measurements for heart rate and energy expenditure in patients with cardiovascular disease : Cross-sectional study. *JMIR mHealth and uHealth*, 7(3) :e11889, 2019.
- [71] Marek and Hoogendoorn. Advancement in cardiac imaging for treatment of ventricular arrhythmias in structural heart disease. *Ep Europace*, 21(3) :383–403, 2019.
- [72] Marey. Des variations électriques des muscles et du coeur en particulier, étudiées au moyen de l'électromètre de m. lippmann. *CR Acad Sci*, 82 :975–977, 1876.

- [73] Maria and Sinayskiy. Prediction by linear regression on a quantum computer. *Physical Review*, 94(2) :022342, 2016.
- [74] Mark and Busse. Rapid prototyping for wearables : concept design and development for head-and wrist-mounted wearables (smart watches and google glass). In *Proceedings of the Ninth International Conference on Tangible, Embedded, and Embodied Interaction*, pages 505–508, 2015.
- [75] Marsallil. Mcculloch-pitts neurons. In *The 2008 Annual Meeting of the consortium on cognitive science instruction (ccsi)*, pages 172–179, 2006.
- [76] Marston. Ppg, apg, duplex : which noninvasive tests are most appropriate for the management of patients with chronic venous insufficiency? In *Seminars in vascular surgery*, volume 15, pages 13–20. Elsevier, 2002.
- [77] Martín and Agarwal. Tensorflow : Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv :1603.04467*, 2016.
- [78] McCombie and Asada. Identification of vascular dynamics and estimation of the cardiac output waveform from wearable ppg sensors. In *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*, pages 3490–3493. IEEE, 2006.
- [79] McKinney. *Python for data analysis : Data wrangling with Pandas, NumPy, and IPython*. " O'Reilly Media, Inc.", 2012.
- [80] Michael and Koch. The ptb diagnostic ecg database. *National Metrology Institute of Germany*, 2012.
- [81] Mijwel. Artificial neural networks advantages and disadvantages. *Retrieved from LinkedIn : <https://www.linkedin.com/pulse/artificial-neuralnet-works-advantages-disadvantages-maad-m-mijwel>*, 2018.

- [82] Ming and Bi. Novel strategies and underlying protective mechanisms of modulation of vagal activity in cardiovascular diseases. *British journal of pharmacology*, 172(23) :5489–5500, 2015.
- [83] Mohammad and Fazeli. Ecg heartbeat classification : A deep transferable representation. In *2018 IEEE International Conference on Healthcare Informatics (ICHI)*, pages 443–444. IEEE, 2018.
- [84] Moroney. Firebase cloud messaging. In *The Definitive Guide to Firebase*, pages 163–188. Springer, 2017.
- [85] Muhammet and Dubourg. Analyse des comorbidités chez les patients hospitalisés pour un accident vasculaire cérébral ischémique et leurs influences sur la létalité. In *Annales de Cardiologie et d'Angéiologie*, volume 69, pages 31–36. Elsevier, 2020.
- [86] Andreas Müller, Sarah Guido, et al. *Introduction to machine learning with Python : a guide for data scientists*. " O'Reilly Media, Inc.", 2016.
- [87] Nasiri and Naghibzadeh. Ecg arrhythmia classification with support vector machines and genetic algorithm. In *2009 Third UKSim European Symposium on Computer Modeling and Simulation*, pages 187–192. IEEE, 2009.
- [88] Nazeran and Haltiwanger. Comparison of heart rate variability signal features derived from electrocardiography and photoplethysmography in healthy individuals. In *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 4289–4294. IEEE, 2006.
- [89] Nuria and Flores-Mangas. Healthgear : a real-time wearable system for monitoring and analyzing physiological signals. In *International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06)*, pages 4–pp. IEEE, 2006.

- [90] Onwubolu. *Introduction to SolidWorks : A comprehensive guide with applications in 3D printing*. CRC Press, 2017.
- [91] Oreggia and Guarino. Physiological parameters measurements in a cardiac cycle via a combo ppg-ecg system. In *2015 AEIT International Annual Conference (AEIT)*, pages 1–6. IEEE, 2015.
- [92] Patterson and Yang. A flexible, low noise reflective ppg sensor platform for ear-worn heart rate monitoring. In *2009 sixth international workshop on wearable and implantable body sensor networks*, pages 286–291. IEEE, 2009.
- [93] Payne and Symeonides. Pulse transit time measured from the ecg : an unreliable marker of beat-to-beat blood pressure. *Journal of Applied Physiology*, 100(1) :136–141, 2006.
- [94] Dimitrios Perera. Context aware computing for the internet of things : A survey. *IEEE communications surveys & tutorials*, 16(1) :414–454, 2013.
- [95] Peter and Tatnall. Introduction neural networks in remote sensing. *International Journal of remote sensing*, 18(4) :699–709, 1997.
- [96] Bernardo Rodrigues Pires, Michäel Devyver, Akihiro Tsukada, and Takeo Kanade. Unwrapping the eye for visible-spectrum gaze tracking on wearable devices. In *2013 IEEE Workshop on Applications of Computer Vision (WACV)*, pages 369–376. IEEE, 2013.
- [97] Po-Chuan and Hsieh. Predicting station level demand in a bike-sharing system using recurrent neural networks. *IET Intelligent Transport Systems*, 14(6) :554–561, 2020.
- [98] Prabhu and Kell. A smart and passive floor-vibration based fall detector for elderly. In *2006 2nd International Conference on Information & Communication Technologies*, volume 1, pages 1003–1007. IEEE, 2006.

- [99] Prajakta and Ozturk. mphasis : Mobile patient healthcare and sensor information system. *Journal of Network and Computer Applications*, 34(1) :402–417, 2011.
- [100] Price. How to read an electrocardiogram (ecg). part 1 : Basic principles of the ecg. the normal ecg. *South Sudan Medical Journal*, 3(2) :26–31, 2010.
- [101] Pyakillya and Mikhailovsky. Deep learning for ecg classification. In *Journal of physics : conference series*, volume 913, page 012004. IOP Publishing, 2017.
- [102] Qiang and Tian. Ecg reconstruction via ppg : A pilot study. In *2019 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, pages 1–4. IEEE, 2019.
- [103] Ragesh and Baskaran. A survey on futuristic health care system : Wbans. *Procedia Engineering*, 30 :889–896, 2012.
- [104] Rahat and Yusuf. *Ionic : Hybrid Mobile App Development*. Packt Publishing Ltd, 2017.
- [105] Rama and Chunduri. Automatic classification of cardiac disorders using mlp algorithm. In *2019 Prognostics and System Health Management Conference (PHM-Paris)*, pages 253–257. IEEE, 2019.
- [106] Reza and Price. Wearables : Has the age of smartwatches finally arrived? *Communications of the ACM*, 58(1) :45–47, 2014.
- [107] Ruder. An overview of gradient descent optimization algorithms. *arXiv preprint arXiv :1609.04747*, 2016.
- [108] Rundo and Ortis. An advanced bio-inspired photoplethysmography (ppg) and ecg pattern recognition system for medical assessment. *Sensors*, 18(2) :405, 2018.

- [109] Ryokai and Su. Energybugs : Energy harvesting wearables for children. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pages 1039–1048, 2014.
- [110] Said. Diabetic neuropathy—a review. *Nature clinical practice Neurology*, 3(6) :331–340, 2007.
- [111] Salvatore and Castagna. A miniaturized silicon based device for nucleic acids electrochemical detection. *Sensing and bio-sensing research*, 6 :90–94, 2015.
- [112] Sana and Higgins. A comprehensive survey of wireless body area networks. *Journal of medical systems*, 36(3) :1065–1094, 2012.
- [113] Sangeeta and Shaw. A real time analysis of ppg signal for measurement of spo2 and pulse rate. *International journal of computer applications*, 36(11) :45–50, 2011.
- [114] Santangelo and Sciuto. Sipm as miniaturised optical biosensor for dna-microarray applications. *Sensing and bio-sensing research*, 6 :95–98, 2015.
- [115] Seghir. *Extration de la frequence cardextraction de la frequence cardiaque foetale*. PhD thesis, université d’ Akli Mohand oulhadj-bouira, 2019.
- [116] Shahab and Khoshnevis. Accuracy of purepulse photoplethysmography technology of fitbit charge 2 for assessment of heart rate during sleep. *Chronobiology international*, 36(7) :927–933, 2019.
- [117] Sharma and Samay. Spark : personalized parkinson disease interventions through synergy between a smartphone and a smartwatch. In *International Conference of Design, User Experience, and Usability*, pages 103–114. Springer, 2014.
- [118] Slingeneyer. Gouvernamentalité et libération conditionnelle. In *Annales de Droit de Louvain*, volume 73, 2013.

- [119] Soothill and Ajayi. Prediction of morbidity in small and normally grown fetuses by fetal heart rate variability, biophysical profile score and umbilical artery doppler studies. *BJOG : An International Journal of Obstetrics & Gynaecology*, 100(8) :742–745, 1993.
- [120] Sotiris and Zaharakis. Supervised machine learning : A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160(1) :3–24, 2007.
- [121] Sung-Nien and Chou. Integration of independent component analysis and neural networks for ecg beat classification. *Expert Systems with Applications*, 34(4) :2841–2846, 2008.
- [122] Sylvain and Tremblay. Évaluation des technologies d'électrocardiographie ambulatoire pour le diagnostic d'arythmies cardiaques. 2018.
- [123] Takuo and Miyasaka. Pulse oximetry : its invention, contribution to medicine, and future tasks. *Anesthesia and analgesia*, 94(1) :S1–S3, 2002.
- [124] Tatjana and Ferro. Use of oral anticoagulants in patients with atrial fibrillation and renal dysfunction. *Nature Reviews Nephrology*, 14(5) :337, 2018.
- [125] Teng and Zhang. Continuous and noninvasive estimation of arterial blood pressure using a photoplethysmographic approach. In *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No. 03CH37439)*, volume 4, pages 3153–3156. IEEE, 2003.
- [126] Thuy-Trang and Cho. Automatic fall detection using wearable biomedical signal measurement terminal. In *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 5203–5206. IEEE, 2009.

- [127] Walter and Kobayashi. Photoplethysmogram signal quality estimation using repeated gaussian filters and cross-correlation. *Physiological measurement*, 33(10) :1617, 2012.
- [128] White and Ginger. Towards wearable aging in place devices. In *Proceedings of the 7th International Conference on Tangible, Embedded and Embodied Interaction*, pages 375–376, 2013.
- [129] Xiaodan and Huang. Acoustic fall detection using gaussian mixture models and gmm supervectors. In *2009 IEEE International Conference on Acoustics, Speech and Signal Processing*, pages 69–72. IEEE, 2009.
- [130] Xiaojin and Goldberg. Introduction to semi-supervised learning. *Synthesis lectures on artificial intelligence and machine learning*, 3(1) :1–130, 2009.
- [131] Xuan. *Reconnaissance des comportements d'une personne âgée vivant seule dans un habitat intelligent pour la santé*. PhD thesis, Université Joseph-Fourier-Grenoble I, 2008.
- [132] Yakang and Shi. ibeat : a toolbox for infant brain magnetic resonance image processing. *Neuroinformatics*, 11(2) :211–225, 2013.
- [133] Yaping and Zhang. Advances of flexible pressure sensors toward artificial intelligence and health care applications. *Materials Horizons*, 2(2) :140–156, 2015.
- [134] Ying. An overview of overfitting and its solutions. In *Journal of Physics : Conference Series*, volume 1168, page 022022. IOP Publishing, 2019.
- [135] Youngzoon and Cho. Non-constrained blood pressure monitoring using ecg and ppg for personal healthcare. *Journal of medical systems*, 33(4) :261–266, 2009.
- [136] Zebin and Zhang. Enhancing explainability of neural networks through architecture constraints. *IEEE Transactions on Neural Networks and Learning Systems*, 2020.

- [137] Zhang and Yuan. The effect of contacting force on photoplethysmographic signals. *Physiological measurement*, 25(5) :1323, 2004.
- [138] Zhao-Yin and Dai. Artificial neural network aided design of catalyst for propane ammoxidation. *Applied Catalysis A : General*, 161(1-2) :183–190, 1997.

.1 ANNEXE

.1.1 LOGICIELS

Python 3 s'impose comme l'un des langages les plus populaires pour le calcul scientifique. Grâce à sa nature interactive de haut niveau et à son écosystème de bibliothèques scientifiques en pleine maturation, c'est un choix attrayant pour le développement algorithmique et l'analyse exploratoire des données[33].



Keras intégrés à TensorFlow 2 TensorFlow est un système qui analyse des structures de données complexes dans des réseaux de neurones artificiels à des fins d'analyse et de traitement. Keras est une API de réseau neuronal de haut niveau, qui est écrite en Python pur. La bibliothèque de Keras utilise le backend TensorFlow pour effectuer des opérations de tensor par défaut[13].



Libs Numpy, Scipy, Pandas, Matplotlib : SciPy s'appuie sur l'objet de tableau NumPy et fait partie de la pile qui comprend des outils tels que Matplotlib, Pandas et SymPy avec des outils supplémentaires. La bibliothèque SciPy contient des modules pour des routines mathématiques efficaces telles que l'algèbre linéaire, l'interpolation, l'optimisation, l'intégration et les statistiques[79].



Scikit-learn est très facile à utiliser, mais il met en œuvre efficacement de nombreux algorithmes d'apprentissage automatique, ce qui en fait un excellent point d'entrée pour apprendre l'apprentissage automatique[46].



Firestore Cloud Messaging est conçu pour fournir une connexion à vos appareils via des messages et des notifications. Il est conçu pour être fiable, avec 98% des messages livrés aux appareils connectés en 500 ms ou moins[84].



Ionic est un cadre de développement d'applications hybrides qui permet aux développeurs de créer des applications mobiles natives à l'aide de la technologie Web[128]. Ionic Framework est entièrement encode source libre afin que les développeurs puissent créer et publier leurs applications sur le marché sans aucun coût [135].



Solidworks est un logiciel de conception 3D fonctionnant sous Windows[90].

