

الجمهورية الجزائرية الديمقراطية الشعبية  
REPUBLICQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
وزارة التعليم العالي و البحث العلمي  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique  
جامعة أبي بكر بلقايد- تلمسان  
Université Aboubakr Belkaïd- Tlemcen –  
Faculté de TECHNOLOGIE



## THESE

Présentée pour l'obtention du grade de DOCTORAT 3<sup>ème</sup> Cycle

En : Génie Biomédical

Spécialité : Télémedecine

Par : BENDIMERAD Abderrahmen

### Sujet

**Réalisation d'un système de surveillance cardiaque  
et respiratoire à distance**

Soutenue publiquement, le 22 / 09 / 2022 , devant le jury composé de :

M. DJEBBARI Abdelghani	Professeur	Univ. Tlemcen	Président
M. HADJ SLIMANE Zine-Eddine	Professeur	Univ. Tlemcen	Directeur de thèse
M. MEGNAFI Hichem	MCA	ESSA. Tlemcen	Examineur 1
M. BENALI Radhwane	MCA	Univ. Tlemcen	Examineur 2

*A mes chers parents,  
A tous les membres de ma famille,  
A tous ceux qui me sont chers.*

## **REMERCIEMENTS**

L'occasion m'est offerte ici, à l'heure où cette thèse s'achève, pour remercier vivement Monsieur HADJ SLIMANE Zine-Eddine, Professeur à l'université Abou-Bekr Belkaid pour les conseils et le support constant qu'il m'a apporté.

Je tiens à remercier respectueusement Monsieur DJEBBARI Abdelghani d'avoir accepté la présidence du jury.

Je remercie également Messieurs :

MEGNAFI Hichem et BENALI Radhwane qui m'ont honoré en acceptant de faire partie du jury.

***BENDIMERAD Abderrahmen***

**Abstract**

Electrocardiogram (ECG) represents the electrical activity of the heart. In our work, we present a new design of a wireless portable ECG. An ECG-derived respiration estimation was also developed. Two forms of sleep apnea have been identified : obstructive sleep apnea (OSA) and central sleep apnea (CSA). We propose an innovative classifier for sleep apnea detection based on single-lead ECG signals using continuous wavelet transform (CWT) and convolutional neural network (CNN). Deep learning CNN architectures GoogLeNet and SqueezeNet are used for wireless sleep apnea detection. We also propose a method of individual biometric identification based solely on the ECG signal using the CWT and CNN. Then, we create the scalograms as RGB images and finally we use the network architecture of the CNN to classify the resulting image-like representations. A test was performed and a maximum accuracy of 97.75% was achieved in detecting individual biometric identification using the signal ECG.

**Keywords:** Electrocardiogram (ECG), sleep apnea, Continuous Wavelet Transform (CWT), deep learning, Convolutional Neural Network (CNN), Biometrics, Telemedicine.

**Résumé**

Le signal électrocardiogramme (ECG) représente l'activité électrique du cœur. Dans notre travail, nous allons présenter une nouvelle architecture d'ECG portable sans fil. L'estimation de la respiration dérivée de l'ECG (EDR) est également développée. Deux formes d'apnée du sommeil dont identifiée : l'apnée du sommeil obstructive (OSA) et l'apnée du sommeil centrale (CSA). La transformée en ondelette continue (CWT) et le réseau neuronal convolutionnel (CNN) sont utilisées pour la détection de l'apnée du sommeil basé sur des signaux ECG à une seul dérivation. Les architectures CNN, GoogLeNet et SqueezeNet sont utilisées pour classifier l'ECG en deux catégories: apnée et normal. Un système d'identification biométrique basé sur les paramètres du signal ECG est développé. L'avantage de la méthode proposée est d'extraire les informations à partir d'un seul signal en utilisant le CWT et le CNN. Le CNN accepte les images RVB (red, green, blue). Ainsi, il est nécessaire dans un premier temps de convertir les données ECG en images en utilisant la transformée en ondelettes continue (CWT). Un résultat de 97,75 % de performance a été obtenu dans la détection de l'identification biométrique individuelle.

**Mots Clés :** Electrocardiogram (ECG), Apnée du sommeil, Transformée en ondelette continue (CWT), deep learning, réseau neuronal convolutionnel (CNN), Biométrie, Télé médecine.

**ملخص**

يمثل المخطط الكهربائي للقلب (ECG) النشاط الكهربائي للقلب. في عملنا ، نقدم تصميمًا جديدًا لجهاز تخطيط القلب اللاسلكي المحمول. كما تم تطوير تقدير التنفس المشتق من مخطط الكهربائي للقلب. تم تحديد نوعين من انقطاع النفس النومي: انقطاع النفس الانسدادي النومي (OSA) وانقطاع النفس النومي المركزي (CSA). نقترح مُصنَّفًا مبتكرًا لاكتشاف انقطاع النفس النومي بناءً على إشارات تخطيط القلب أحادية التسجيل باستخدام التحويل الموجي المستمر (CWT) والشبكة العصبية التلافيفية (CNN). تُستخدم بنيات التعلم العميق لشبكة CNN GoogLeNet و SqueezeNet لاكتشاف انقطاع التنفس أثناء النوم لاسلكيًا. نقترح أيضًا طريقة لتحديد الهوية الفردية تعتمد فقط على إشارة ECG باستخدام CWT و CNN. بعد ذلك ، نقوم بإنشاء Scalograms كصور RGB وأخيرًا نستخدم بنية شبكة CNN لتصنيف التمثيلات الشبيهة بالصور الناتجة. تم إجراء اختبار وتم تحقيق دقة قصوى بلغت 97.75% في الكشف عن تحديد الهوية الأحيائية الفردية باستخدام إشارة تخطيط القلب.

**الكلمات المفتاحية:** مخطط القلب الكهربائي (ECG) ، توقف التنفس أثناء النوم ، التحويل المستمر للموجات (CWT) ، التعلم العميق ، الشبكة العصبية التلافيفية (CNN) ، القياسات الحيوية ، التطبيق عن بعد.

# Table des matières

Dédicace	
Remerciement	
Résumé .....	4
Table des matières.....	5
Liste des figures.....	7
Liste des tableaux .....	9
Liste des abréviations .....	10
Introduction générale .....	11
I Généralités sur l'électrocardiographie et l'extraction du signal respiratoire .....	16
I.1 Introduction .....	16
I.2 Le Cœur.....	16
I.3 Tissu nodal .....	17
I.4 L'activation cardiaque .....	17
I.5 Phénomène mécanique.....	19
I.5.1 Les orifices cardiaques .....	19
I.5.2 Fonctionnement cardiaque .....	20
I.6 Phénomène électrique .....	22
I.7 Les phénomènes fondamentaux .....	24
I.8 Les morphologies de base.....	25
I.9 Extraction du signal respiratoire du Signal ECG.....	28
I.10 Conclusion.....	30
Bibliographie.....	30
II Suivi à distance des patients cardiaques via Smartphone.....	32
II.1 Introduction.....	32
II.2 Matériels et méthodes .....	34
II.3 Architecture du système .....	35
II.3.1 ECG Frontal analogique.....	36
II.3.2 Arduino UNO .....	37
II.3.3 Application Android pour smartphone.....	38
II.4 Conclusion .....	48
Bibliographie .....	48
III Transformée en Ondelettes Continue (CWT) et les réseaux de neurones convolutionnels (CNN).....	50
III.1 Introduction.....	50
III.2 Analyse temps-échelle (transformation en ondelettes).....	51
III.2.1 La transformation en ondelettes continue (CWT).....	55
III.2.2 La transformation en ondelettes discrète (DWT).....	55
III.2.3 Avantages et inconvénients de la transformée en ondelettes .....	57
III.3 Aperçu sur les réseaux de neurones convolutionnels (CNN).....	58
III.3.1 La couche de convolution .....	58
III.3.2 Couche d'activation .....	59
III.3.3 Couche de Pooling .....	60
III.3.4 La couche de Fully connected .....	61
III.4 Exemple d'Architecture CNN .....	61

III.4.1 LeNet .....	61
III.4.2. AlexNet .....	62
III.4.3 GoogLeNet .....	63
III.4.4 VGGNet.....	65
III.4.5 Residual Network (ResNet) .....	65
III.4.6 SqueezeNet .....	67
III.5 Conclusion .....	68
Bibliographie.....	68
IV GoogLeNet et SqueezeNet pour la détection sans fil de l'apnée du sommeil .....	70
IV.1 Introduction.....	70
IV.2 Base de données utilisée .....	73
IV.3 Méthode utilisée.....	74
IV.3.1 Représentation temps-fréquence du signal ECG.....	75
IV.3.2 Les architectures CNN utilisées.....	75
IV.4. Results and discussions.....	76
IV.5 Conclusion .....	81
Bibliographie.....	81
V Développement d'une nouvelle application en télémédecine pour l'identification des patients en utilisant la transformée en ondelettes continue (CWT) et les réseaux de neurones convolutifs (CNN).....	84
V.1 Introduction .....	84
V.2 Schéma fonctionnel du système .....	88
V.3. Base de données utilisées.....	89
V.4. Présentation de la méthode proposée.....	91
V.5. Résultat et discussion.....	93
V.6. Conclusion.....	96
Bibliographie.....	96
Conclusion Générale.....	98

# Liste des figures

I : Aspect normal d'un signal ECG .....	11
I.1 : Le Cœur .....	17
I.2 : Tissu nodal .....	18
I.3 : Situation du tissu nodal dans le cœur.....	18
I.4 : Les pompes cardiaques .....	19
I.5 : La fonction circulatoire (mécanisme de la fonction cardiaque).....	22
I.6 : Les Dérivations.....	24
I.7 : Les phénomènes fondamentaux .....	25
I.8 : Les morphologies de base.....	27
I.9 : Le Tracé électrocardiographique.....	28
I.10 : Le trajet de l'air dans l'appareil respiratoire.....	29
II.1 : La représentation générale du système de surveillance cardiaque sur Smartphone .....	35
II.2 : Principe de l'ECG mobile.....	36
II.3 : Emplacement des électrodes et le branchement de l'AD8232 avec Arduino Uno .....	37
II.4 : (a) Connexions entre Arduino Uno, le module ECG et le module Bluetooth, (b) organigramme du processus de transmission .....	38
II.5 : Algorithme de l'application développée.....	39
II.6 : L'interface principale de l'application du patient.....	42
II.7 : Enregistrement en temps réel du signal ECG.....	42
II.8 : Le fichier des données ECG.....	43
II.9 : Les données brutes du signal ECG .....	43
II.10 : Interface de chargement de fichiers.....	44
II.11 : Aperçu du signal ECG et du signal respiratoire à travers le Smartphone du médecin .....	44
II.12 : Tracé du signal ECG en temps réel sur ordinateur portable .....	45
et détection du complexe QRS.....	45
II.13 : Signal respiratoire dérivé du signal ECG.....	45
II.14 : Paramètres extraits du signal ECG.....	46
II.15 à 24: Enregistrement 1 à 10 (Individu 1 à 10).....	47
III.1 : Exemple de fonction d'ondelette (ondelette de Morlet).....	52
III.2 : l'évolution de l'ondelette de Morlet en fonction du facteur d'échelle $a$ .....	53
III.3 : l'ondelette de Morlet traduite pour différentes valeurs de $b$ .....	53
III.4 : Analyse temps-échelle (TO).....	54
III.5 : Boîtes de Heisenberg d'atomes d'ondelettes .....	54
III.6 : La transformée en ondelettes discrète décompose le signal en deux parties : Les approximations et les détails.....	56
III.7 : Décomposition en multi niveau .....	56
III.8 : Décomposition d'un signal bruité en approximations et en détails .....	57
III.9: Convolution in CNNs .....	59
III.10: Fonctionnement de la fonction d'activation ReLu .....	60
III.11: illustration d'une opération avec un max-pooling .....	60
III.12: Classification d'image par le CNN .....	61
III.13: Architecture du réseau LeNet-5 (Lecun et al., 1998).....	62
III.14: L'Architecture d'AlexNet (Krizhevsky et al., 2012).....	63
III.15: Module Inception (szegdy et al., 2015).....	64

III.16: Architecture du réseauVGGNet (Simonyan et al., 2015) .....	65
III.17: Connexion résiduelle (He et al., 2015).....	66
III.18: L'architecture du ResNet (He et al., 2015).....	66
III.19: Structure d'un Fire-module (Iandola et al., 2016) .....	67
III.20: L'architecture du réseau SqueezeNet (Iandola et al., 2016) .....	68
IV.1 Les enregistrements de l'ECG avec et sans apnée .....	73
IV.2: Surveillance à distance pour la détection de l'apnée du sommeil .....	73
IV.3: Schéma bloc de la méthode proposée.....	74
IV.4: Les données ECG transformée en image en utilisant le CWT .....	75
IV.5: Apprentissage et validation des performance du CNN (GoogLeNet architecture).....	79
IV.6: Apprentissage et validation des performance du CNN (SqueezeNet architecture).....	79
V.1 : L'Architecture du système d'indentification proposé.....	89
V.2 : L'ensemble des signaux ECGs pour les différentes personnes .....	91
V. 3 : Shéma bloc de la méthode proposée .....	92
V.4 : Analyse des résultats de la classification CNN (GoogleNet architecture).....	95



# Liste des tableaux

<b>II.1</b> Le processus global d'identification de l'arythmie dans les conditions physiques de marche et de repos .....	40
<b>II.2</b> Informations sur le patient et décision .....	46
<b>III.1</b> GoogLeNet incarnation of the Inception architecture (szegdy et al., 2015) .....	64
<b>IV.1</b> Analyse des résultats de la classification CNN (architecture GoogLeNet).....	79
<b>IV.2</b> Analyse des résultats de la classification CNN (SqueezeNet architecture).....	79
<b>IV.3</b> Comparaison des performances des algorithmes proposés avec les techniques existantes appliqués à la base de données Apnée-ECG de Physionet .....	80
<b>V.1</b> Représentation des données en catégories de classification .....	90
<b>V.2</b> Analyse des résultats de la classification CNN (architecture GoogLeNet).....	94
<b>V.3</b> Comparaison des résultats obtenus par rapport à d'autres méthodes existantes dans la littérature .....	95

# Liste des abréviations

ECG	Electrocardiogram
TF	Transformée de fourier
CWT	Transformée en ondelettes continue
CNN	Réseau de neurones convolutionnel
TCP/IP	Transport Control Protocol/Internet Protocol
EDR	Estimation de la respiration dérivée de l'ECG
HR	Heart Rate
TFCT	Transformée de fourier à court terme
DWT	Transformée en ondelette discrète
ReLu	unité linéaire rectifiée
OSA	Apnée du sommeil obstructive

## INTRODUCTION GENERALE

L'électrocardiogramme (ECG) représente l'activité électrique du cœur. L'enregistrement par des électrodes des deux phénomènes successifs de dépolarisation et de repolarisation, avec leurs morphologies variables suivant la place des électrodes, est à la base de l'électrocardiographie. La repolarisation étant un phénomène plus lent que la dépolarisation, les ondes correspondantes sont de moindre amplitude et de plus longue durée que les ondes de dépolarisation. Chaque contraction cardiaque voit se succéder les deux phénomènes, avec des morphologies différentes selon la place des électrodes exploratrices par rapport à la direction de propagation de ces deux processus. A la fin de l'enregistrement, nous allons obtenir trois paramètres importants P, QRS, T qui caractérisent l'activité cardiaque, et un quatrième paramètre d'importance non encore identifié l'onde U (figure 1).




Figure 1 : Aspect normal d'un signal ECG

La respiration est un processus physiologique. Il représente l'échange d'oxygène et de dioxyde de carbone entre les tissus du corps et l'atmosphère. La respiration est un facteur important pour surveiller les maladies, telles que l'apnée du sommeil, la dépression et l'arrêt cardiaque. Une fréquence respiratoire anormale est reconnue comme un indicateur de

détérioration comme l'arrêt cardiaque puisque 54% des personnes souffrant d'un arrêt cardiaque leurs fréquence respiratoire est supérieur à 27 respirations par minute.

De nombreuses études sont faites sur l'influence des mouvements respiratoires sur la forme du signal ECG. En effet, les différents changements au niveau de la fréquence cardiaque et au niveau de la morphologie du signal ECG sont dus principalement aux changements au niveau du rythme respiratoire. Einthoven et al. (1950) sont parmi les pionniers à démontrer la relation entre la fréquence cardiaque et la fréquence respiratoire. A partir de cette relation, divers travaux ont été mis en œuvre pour extraire le signal respiration directement à partir de l'ECG.

En 2014, Zeghoudi et al., 2014 ont proposé une méthode d'estimation et de calcul de rythme respiratoire à partir d'un signal ECG.

Bachir et al. (2017) ont proposé quatre nouvelles méthodes pour extraire le signal respiratoire de l'électrocardiogramme ECG (En Anglais ECG-Derived respiration). La première méthode est basée sur des mesures d'intervalle du signal ECG. La deuxième est basée sur la mesure de l'énergie de complexe QRS. La troisième méthode proposée est un procédé de transformation en ondelettes, en fonction de l'ondelette chapeau Mexicain pour estimer le signal respiratoire. La quatrième méthode d'estimation du signal respiratoire est le résultat de combinaison des trois premières méthodes proposées.

Les enregistrements du signal ECG ainsi le signal respiratoire sont examinés par les médecins, spécialistes dans un hôpital, une clinique ou un cabinet médical. L'enregistrement dure généralement que quelques minutes, ce qui n'est pas adapté à la détection d'anomalies car parfois les arythmies ne sont pas présentes au moment de l'enregistrement. Parfois, les établissements de santé sont très éloignés, les gens doivent donc se déplacer pour l'analyse cardiaque, de plus, les personnes âgées ne peuvent pas se rendre fréquemment à l'hôpital.

Un autre problème, l'électrocardiographe stockera les informations du signal ECG exploitables une fois le test est terminé. Il n'est donc pas possible d'obtenir les résultats de

l'ECG immédiatement, le patient doit se rendre à l'hôpital, à la clinique ou au cabinet privé quelques jours plus tard pour discuter les résultats avec un médecin. Il est important d'identifier une maladie cardiaque avant *que ce soit trop tard*. La transmission à distance des informations médicales, plus particulièrement cardiaque et respiratoire devient donc nécessaire. Le transfert des données médicales à distance est réalisé à partir de moyens de télécommunications. L'utilisation de ces moyens ainsi que l'ensemble des pratiques médicales qui s'en suit s'appelle la télémédecine.

Ces technologies facilitent le suivi des patients en analysant leurs antécédents et dossiers médicaux. Les développements récents (par exemple, les Smartphones, internet et les satellites) permettent l'échange d'informations médicales pour augmenter l'accès à des soins de qualité et rapides.

Dans ce contexte, nous avons développé une nouvelle conception d'ECG portable sans fil. Le prototype proposé est spécifiquement dédié aux patients cardiaques qui va leur permettre de garder un contact permanent avec leur médecin. L'appareil proposé est connecté sans fil à un Smartphone pour la transmission de données ECG. L'estimation de la respiration dérivée de l'ECG (EDR) est également développée. Les informations de l'ECG et le rythme respiratoire recueillies sur le Smartphone sont transférées aux médecins et au centre médical en cas d'urgence.

Une application très intéressante a été développée dans le cadre de cette thèse. Il s'agit d'un système de détection à distance de l'apnée du sommeil.

Une apnée du sommeil (OSA) est la cessation de flux nasal pendant plus de 10 s, alors que l'hypopnée est une diminution  $\geq 50\%$  du flux nasal avec une saturation en oxygène artériel ( $SaO_2$ ) diminuée d'au moins 4 %.

Une application mobile qui détecte l'apnée du sommeil pour une surveillance permanente et à distance des patients atteints de cette maladie (OSA) devient une nécessité capitale.

Une deuxième application a été développée dans le cadre de cette thèse. Il s'agit d'une nouvelle application en télémédecine pour l'identification des patients en utilisant la transformée en ondelettes continue (CWT) et les réseaux de neurones convolutifs (CNN).

Le principe est d'effectuer une mesure du signal ECG du patient et de le transmettre à distance à l'hôpital. La transformée en ondelettes continue (CWT) et les réseaux de neurones convolutifs (CNN) sont ensuite utilisés pour identifier le patient parmi plusieurs patients existants dans la base de données. Le service hospitalier transmet ensuite l'identité et le dossier médical du patient au médecin urgentiste.

Le premier modèle des réseaux de neurones convolutionnels a été proposé en 1998 par LeCun et al. (1998) pour la reconnaissance des chiffres du code postal écrits à la main. Ce réseau est appelé LeNet-5, ou simplement LeNet.

### **Organisation de la thèse :**

Dans le premier chapitre, nous ferons une présentation au préalable de l'électrophysiologie cardiaque et du signal respiratoire, où les concepts de base du système cardio-respiratoire seront présentés.

Dans le deuxième chapitre, une nouvelle conception d'ECG portable sans fil est présentée. Le prototype proposé est spécifiquement dédié aux patients cardiaques qui vont leur permettre de garder un contact permanent avec leur médecin. L'appareil proposé est connecté sans fil à un Smartphone pour la transmission de données ECG. L'estimation de la respiration dérivée de l'ECG (EDR) est également développée.

Une description de la transformée en Ondelettes Continue (CWT) et les réseaux de neurones convolutionnels (CNN) sera faite en chapitre III. Le CNN accepte les images RVB (red, green, blue). Ainsi, il est nécessaire dans un premier temps de convertir les données ECG en images en utilisant la transformée en ondelettes continue (CWT).

Dans le chapitre IV, la transformée en ondelette continue (CWT) et le réseau neuronal convolutionnel (CNN) sont utilisés pour la détection de l'apnée du sommeil basé sur des signaux ECG à une seule dérivation. Les architectures CNN, GoogLeNet et SqueezeNet sont utilisés pour classifier l'ECG en deux catégories : apnée et normal. Le prototype proposé

est spécifiquement dédié aux patients cardiaques. Il leur permet de rester en contact permanent avec leur médecin. L'appareil proposé est connecté sans fil à un Smartphone pour la transmission des données ECG.

Enfin, dans le cinquième chapitre, un système d'identification biométrique basé sur les paramètres du signal ECG. L'avantage de la méthode proposée est d'extraire les informations à partir d'un seul signal. L'application développée utilise la transformée en ondelettes continue (CWT) et les réseaux de neurones convolutifs (CNN). La méthode proposée est très prometteuse et offre des résultats d'identification très satisfaisante.

### **Bibliographie**

BACHIR M'HAMED SAADI, 'L'évaluation de l'influence de la respiration sur le rythme cardiaque et les paramètres du signal Electrocardiogramme (ECG)', thèse de doctorat soutenue en Janvier 2017 au département génie biomédical, faculté de technologie, Université de Tlemcen, Algérie.

Einthoven, W., Fahr, G. and DE Waart, A. (1950) 'On the direction and manifest size of the variations of potential in the human heart and on the influence of the position of the heart on the form of the electrocardiogram', *American Heart Journal*, Vol. 40, No. 2, pp.163–193.

LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.

Zeghoudi, A., Medjahed, O. B., Saadi, B. M. and HADJ Slimane, Z. (2014), 'Algorithme d'extraction du rythme respiratoire (AERR) à partir des signaux ECG', Conférence: BIOMEDICAL ENGINEERING INTERNATIONAL CONFERENCE (BIOMEIC'14), at Tlemcen Algeria.





# **CHAPITRE I : Généralités sur l'électrocardiographie et l'extraction du signal respiratoire**

## **I.1. Introduction**

Ce présent chapitre donne un aperçu général sur les différentes étapes d'enregistrement du signal Electrocardiogramme (ECG) ainsi que l'extraction du signal respiratoire. Une exploration du système cardio-respiratoire sera faite. Les deux signaux en question seront l'objet d'un traitement et d'une analyse en vue de leurs transmissions à distance.

## **I.2. Le Cœur**

Le cœur est un organe musculaire creux placé dans la cavité thoracique. Il se situe un peu à gauche du centre du thorax, en arrière du sternum : c'est un organe creux mû par un muscle, le myocarde, et enrobé du péricarde ; il est entouré par les poumons. Le cœur est situé dans le médiastin<sup>1</sup> (Rouvière and Delmas, 1985). Il est constitué de deux pompes : La pompe droite qui comprend l'oreillette droite et le ventricule droit qui s'occupe de la circulation pulmonaire dont le rôle est d'assurer les échanges gazeux avec l'aire. La deuxième partie comprend l'oreillette gauche et le ventricule gauche. Les deux s'occupent de la grande circulation (circulation aortique ou circulation systémique) et pompe le sang vers tout le reste du corps (voir la Figure I.1). Le tissu musculaire du cœur (myocarde) est unique puisqu'il partage des caractéristiques du tissu musculaire strié et du tissu musculaire lisse.

---

<sup>1</sup>Le médiastin est la région de la cage thoracique située entre les deux poumons

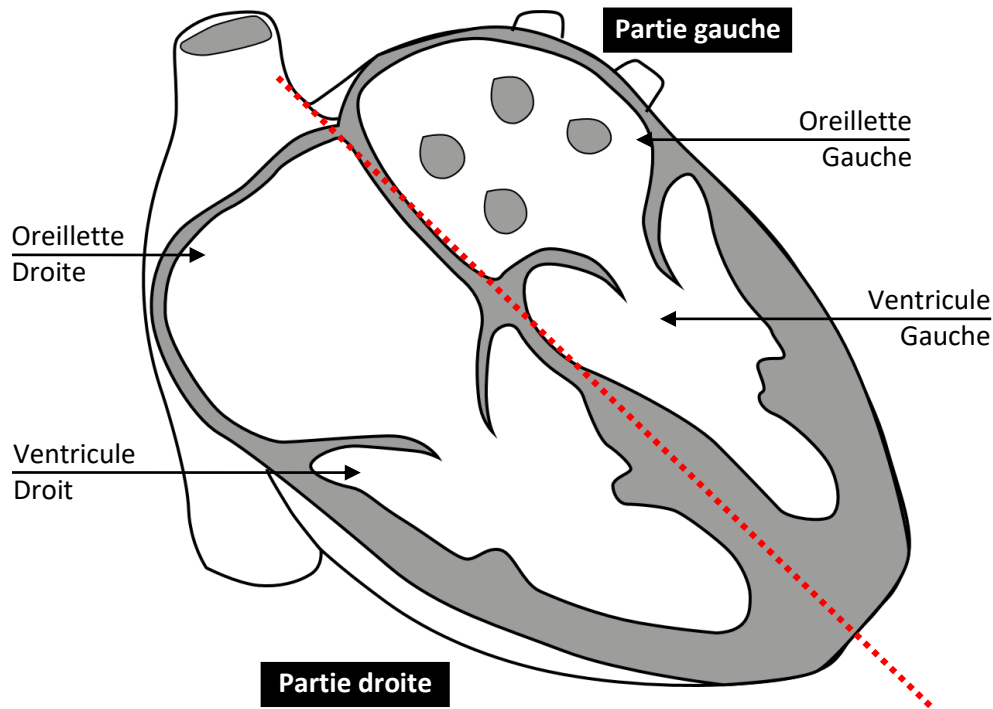



Figure I.1 : Le Cœur

### I.3. Tissu nodal

L'origine de la simulation de myocarde est résidé dans le cœur lui-même dans une région appelée le tissu nodal ; ce dernier n'est pas un réseau nerveux, Il s'agit d'un tissu cardiaque intra pariétal qui génère et conduit les impulsions électriques engendrant la contraction myocardique. Le tissu nodal est schématisé dans la figure I.2 qui est constitué de :

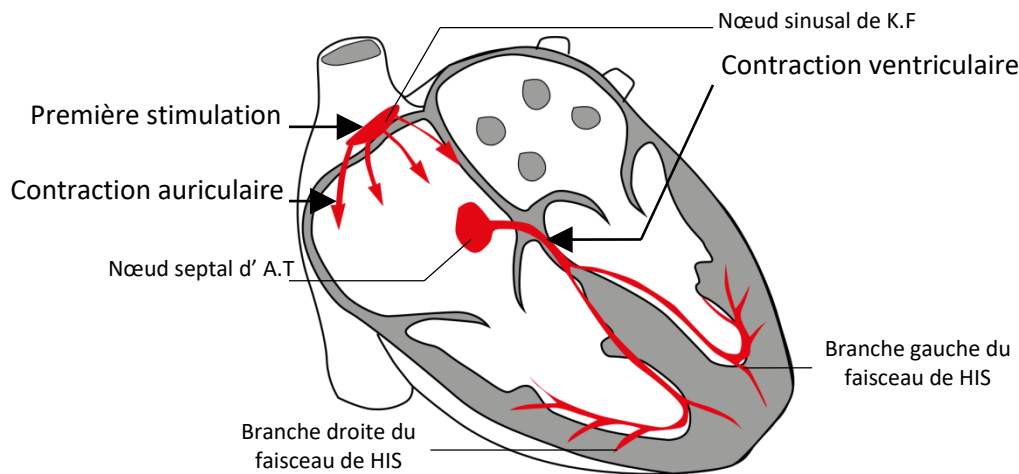
- Le nœud sino-auriculaire de Keith et Flach (KF), situé dans la cloison interauriculaire de l'oreillette droite.
- Le nœud auriculo-ventriculaire d'Aschoff-Tawara (AV), situé dans la partie supérieure de la cloison interventriculaire.
- Le faisceau auriculo-ventriculaire de His qui descend dans la cloison interventriculaire et se divise en une branche droite et une branche gauche pour chaque ventricule correspondant.
- Le faisceau de Purkinge Ramification terminales de chaque branche du faisceau de His. (Hertault, 1984)



**Figure I.2 : Tissu nodal**

#### **I.4. L'activation cardiaque**

La première stimulation part du nœud sino-auriculaire (K.F), et se diffuse aux deux oreillettes résultant la contraction auriculaire, l'onde de stimulation va se propager jusqu'au nœud auriculo-ventriculaire d'Aschoff-Tawara (A.V).L'onde de stimulation progresse simultanément dans les 2 ventricules, le droit et le gauche, empruntant des voies conductrices très rapides (le faisceau de His et le réseau de Purkinje), jusqu'à la pointe du cœur, provoquant la contraction des ventricules (Figure I.3).



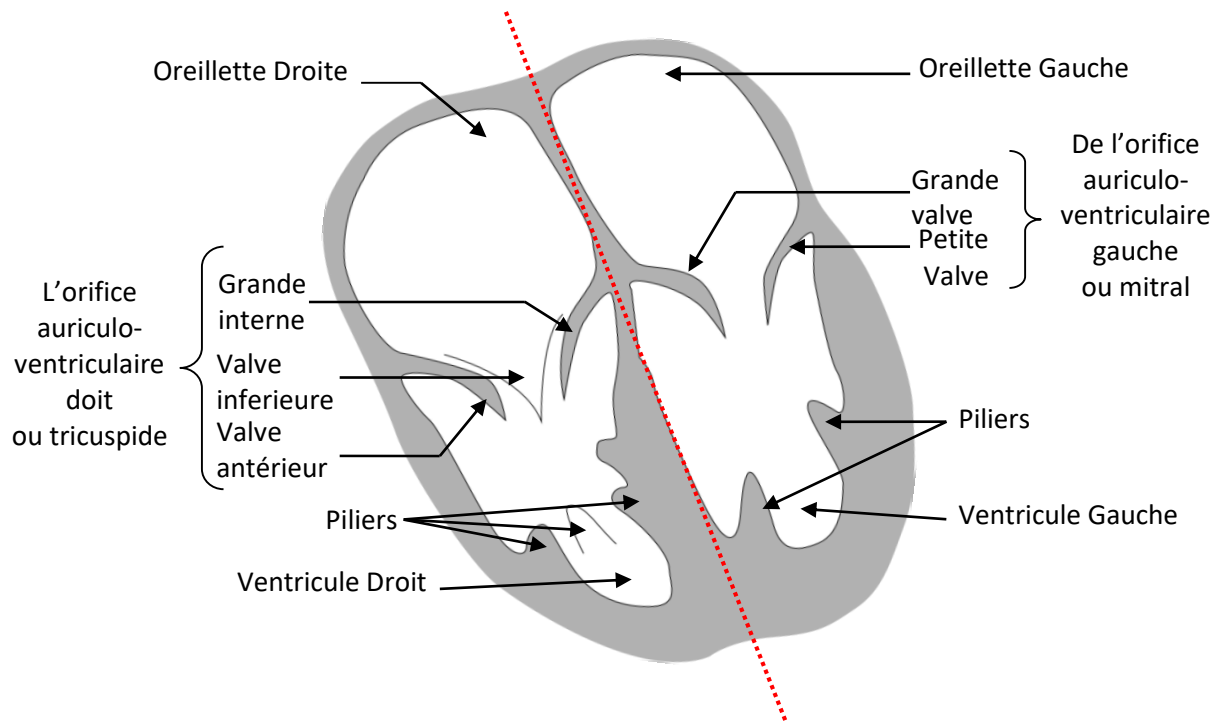
**Figure I.3 : Situation du tissu nodal dans le cœur**

## I.5. Phénomène mécanique

Comme susmentionné, le cœur est divisé en deux moitié droite et gauche, chaque moitié est constituée par une chambre appelée atrium ou oreillette qui reçoit le sang veineux, et par une autre chambre appelée ventricule, qui propulse le sang dans le long des artères. (Ernest et al., 1985).

### I.5.1. Les orifices cardiaques

La figure I.4 décrit les deux chambres qui sont séparées par l'orifice auriculo-ventriculaire muni de valve de fermeture. Cet orifice se ferme de bas en haut, du ventricule vers l'oreillette.



**Figure I.4 :** Les pompes cardiaques

Les deux ventriculaires sont séparées des gros vaisseaux par les orifices tricuspides, eux aussi munis de valves. Le principe essentiel de fonctionnement des valves est la différence des pressions entre la cavité auriculaire et la cavité ventriculaire.

- Si la pression est plus élevée dans l'oreillette, les valves s'ouvrent.

- Si la pression est plus élevée dans le ventricule, les valves se relèvent horizontalement et se ferment.

Le sang ne peut donc aller que dans un seul sens, les deux oreillettes se contractent en même temps, suivies de la contraction simultanée des deux ventricules.

### ***1.5.2. Fonctionnement cardiaque***

Chacune des pompes<sup>1</sup> cardiaques fonctionne suivant un rythme mécanique à deux temps :

- Le 1<sup>er</sup> temps s'appelle la systole (du grec, systole = contraction). C'est le temps actif du travail cardiaque, celui de la contraction musculaire de la cavité.
- Le 2<sup>ème</sup> temps s'appelle la diastole (du grec, diastole = dilatation). C'est le temps passif du repos cardiaque celui du relâchement des fibres musculaires et de la dilatation passive des cavités cardiaques sous l'effet de l'arrivée du sang.

Au niveau du cœur gauche, on observe consécutivement :

- A. La diastole générale entraîne une chute générale de pression dans les cavités cardiaque qui a pour effet :
- De fermer passivement les valvules sigmoïdes<sup>2</sup> et la communication avec l'aorte (pression dans l'aorte supérieure à la pression diastolique dans le ventricule). La pompe ventriculaire se trouve donc vide avec une pression qui tend vers la négative.
  - Remplissage de l'oreillette gauche par sang pulmonaire.
  - D'ouvrir les valvules auriculo-ventriculaires (pression dans le ventricule inférieur à la pression dans l'oreillette).
  - De réaliser l'aspiration par la cavité ventriculaire d'une partie du sang contenu dans la cavité auriculaire : pompe ventriculaire aspirante (pression ventriculaire inférieur à la pression auriculaire).

Très rapidement l'effet aspiration est remplacé par un remplissage passif sous l'effet de la pression veineuse (oreillette et ventricule sont en communication à ce stade).

- B. La systole auriculaire :


---

<sup>1</sup> Oreillette droite ventricule droit oreillette gauche ventricule gauche (4 pompes)

<sup>2</sup> Une valve sigmoïde est une valve artérielle assurant la liaison entre un ventricule et les vaisseaux partant du cœur. Il existe deux valves sigmoïdes, la valve aortique entre le ventricule gauche et l'aorte et la valve pulmonaire entre le ventricule droit et l'artère pulmonaire.

- Termine le remplissage ventriculaire en expulsant dans le ventricule le sang encore contenu dans la pompe auriculaire (10% environ) : pompe auriculaire foulante.
  - A la fin du remplissage ventriculaire, les pressions sont plus élevées dans le ventricule que dans l'oreillette : il y a fermeture des valvules auriculo-ventriculaires.
- C. La diastole auriculaire commence dès le début de la systole ventriculaire. En se contractant, la masse ventriculaire (systole ventriculaire) agrandit le volume de la pompe auriculaire qui aspire le sang veineux : pompe auriculaire aspirante.
- D. La systole ventriculaire est le temps le plus important de la pompe cardiaque envisagée dans un ensemble, les pompes ventriculaires étant beaucoup plus puissantes que les pompes auriculaires ; Il y a :
- D'abord mise en tension des muscles ventriculaires et donc de la cavité ventriculaire dont les modalités de remplissage viennent d'être étudiées. Les orifices ventriculaires sont encore fermés du fait du sens de fonctionnement des valves (pression aortique > pression ventriculaire > pression auriculaire). La pression augmente progressivement dans la cavité ventriculaire.
  - Ensuite, il y a ouverture des valvules tricuspides dès que la pression ventriculaire devient supérieure à la pression artérielle.
  - Enfin, éjection du sang ventriculaire dans l'artère par la contraction des muscles ventriculaires (contraction qui succède à la mise en tension préalable). C'est le stade de la pompe foulante ventriculaire.
- E. La diastole générale commence à la fin de contraction ventriculaire. Elle est due à la concomitance des diastoles auriculaires et ventriculaires. La durée des diastoles étant beaucoup plus longue que celles des systoles correspondantes, il y a chevauchement des diastoles.

On assistera au niveau du cœur droit au déroulement des mêmes phénomènes chronologiques. (Voir Figure I.5)



**Figure I.5 :** La fonction circulatoire (mécanisme de la fonction cardiaque)

## I.6. Phénomène électrique

Tout muscle en travail est un siège d'une onde de dépolarisation, c'est-à-dire d'un courant qui peut être enregistré par deux électrodes placées judicieusement. L'étude électrique du cœur, ou électrocardiographie, a pris une très grande importance en physiologie et pathologie cardiaque. L'électrocardiogramme est le résultat de l'enregistrement de l'activité électrique du cœur.

### I.6.1. Les dérivations électrocardiographiques

Elles correspondent aux points où sont placées les électrodes détectrices de l'activité cardiaque. En pratique trois sortes de dérivations sont utilisées ; les dérivations standards, unipolaires indirectes et unipolaire semi-directes qui sont montrées dans la figure I.6.

#### A. Les dérivations standards

Les plus anciennes, et les plus classiques. Elles représentent l'application théorique de l'utilisation de l'axe électrique du cœur (base-point) comme lieu des différences de potentiel maxima.

- On obtient la dérivation numérotée D2 dans la nomenclature internationale, la plus proche de l'axe électrique cœur, électrode est placé au poignet droit et l'autre à la cheville gauche.
- D1 en passant l'électrode de la cheville gauche au poignet gauche.
- D3 en passant l'électrode du poignet droit au poignet gauche.

#### B. Les dérivations unipolaires indirectes

Sont obtenues en utilisant une électrode passive (reliée aux deux membres non dépolarisés) pendant que l'électrode active étudie tour à tour les trois pôles du triangle dessiné par les dérivations standards.

Nous avons ainsi les dérivations :

- VR (poignet droit, R pour right),
- VL (poignet gauche, L pour left)
- VF (cheville gauche, F pour foot).

#### C. Les dérivations uni-polaires semi-directes

Utilisent une électrode passive, comme précédemment, et une électrode active placées directement sur le grill costal au contact du cœur. Ces dérivations précordiales sont indiquées par la lettre V suivie d'un chiffre qui indique, suivant des standards internationaux, la place exacte de l'électrode active sur la paroi thoracique.



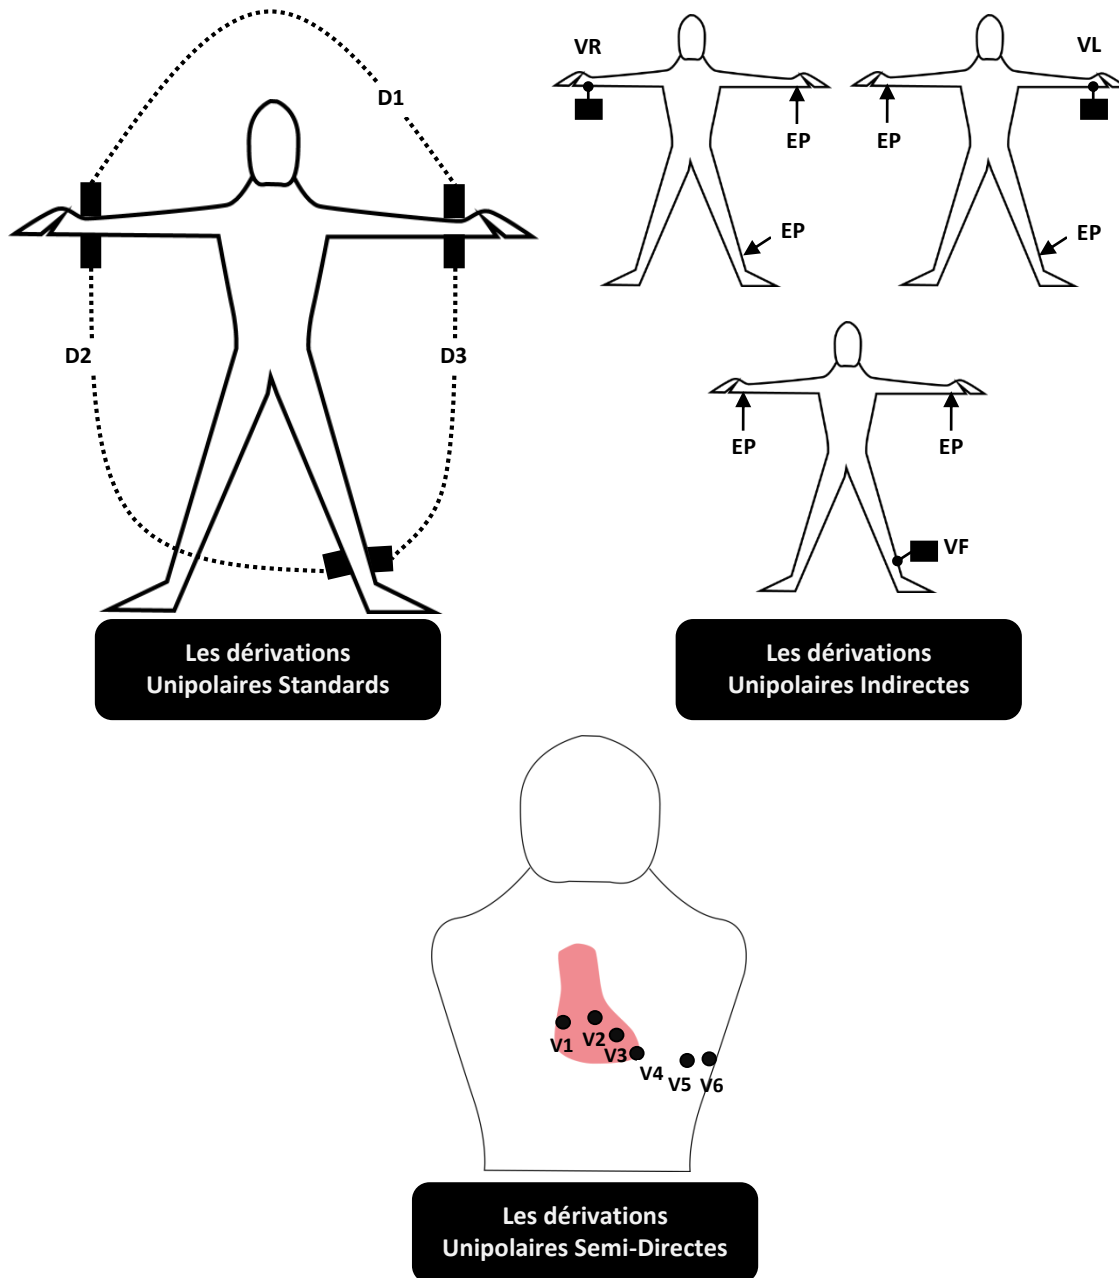


Figure I.6 : Les Dérivations

### I.7. Les phénomènes fondamentaux

La figure 7 montre les phénomènes fondamentaux de polarisation et dépolarisation d'une hypothétique cellule myocardique.

1. Au repos, la fibre de myocarde est dite polarisée : elle est chargée électriquement positivement à sa surface, négativement à l'intérieur.

2. La fibre musculaire cardiaque est excitée au point A. Dans la partie excitée les charges électriques s'inversent : positive à l'intérieur, négatif à la surface.
3. Du point A l'excitation se propage vers le point B. A ce moment, la moitié de fibre est dépolarisée et l'autre moitié au repos.
4. Quand l'excitation atteint le point B (extrémité de la fibre). Celle-ci est entièrement dépolarisée. La dépolarisation est le processus de transmission de l'excitation d'une extrémité à l'autre de la fibre selon une direction et dans un temps donné, dont la durée dépend de la longueur de la fibre.
5. La fibre cardiaque qui vient d'être dépolarisée, retrouve ses charges de repos à partir du point A : elle se repolarise. Le processus de repolarisation se propage de A en B. Lorsqu'il aura atteint le point B, la fibre aura retrouvé sa polarité de repos initiale, ce processus constitue la repolarisation. La repolarisation s'est donc effectuée ici à partir du point où a commencé l'excitation initiale.
6. La repolarisation peut également s'effectuer dans l'ordre inverse, à partir du point B, c'est-à-dire là où s'est terminer la dépolarisation. Le résultat est le même : La repolarisation est achevée. Mais le sens de repolarisation est ici inversé. (Hertault, 1984)




Figure I.7 : Les phénomènes fondamentaux

### I.8. Les morphologies de base


La figure 8 montre les morphologies du signal selon la place des électrodes par rapport au sens de propagation respective de dépolarisation et de la repolarisation.

1. L'électrode qui voit arriver la dépolarisation et qui se trouve placée sur l'axe de propagation de la dépolarisation, enregistre une électropositivité dont l'amplitude est proportionnelle à l'épaisseur de la fibre.
2. L'électrode qui voit fuir la dépolarisation et qui se trouve donc placée du côté électronégatif de ce processus, enregistre au contraire une électronégativité dont l'amplitude est également proportionnelle à la distance AB si l'électrode est placée sur l'axe de propagation de la dépolarisation.
3. L'électrode 3, situé à mi-chemin par rapport aux deux extrémités de la fibre, voit d'abord arriver l'onde de dépolarisation et enregistre donc une électropositivité, puis voit fuir l'onde de dépolarisation, dans la deuxième moitié de la fibre, et enregistre donc une électronégativité. Le complexe obtenu est un complexe dit diphasique d'abord positif puis négatif, dont l'amplitude totale est égale à l'amplitude soit de l'électropositivité, soit de l'électronégativité enregistrée respectivement au point B et au point A. Chaque électrode enregistre donc le même phénomène mais en donne une vision différente selon sa position par rapport à la fibre cardiaque
4. La repolarisation donne lieu, au point B, à une onde négative si la récupération, de A vers B. Le vecteur correspondant a alors une électronégativité en avant orientée vers l'électrode.
5. Par contre au point B, l'onde de repolarisation est positive si le processus se fait en sens inverse, de B vers A. l'électrode enregistre une positivité car elle voit fuir l'onde de repolarisation avec sa positivité en arrière. Une électrode, au point A, enregistre une onde de repolarisation et sa négativité.

La repolarisation étant un phénomène plus lent que la dépolarisation, les ondes correspondantes sont de moindre amplitude et de plus longue durée que les ondes de dépolarisation.

L'enregistrement par des électrodes de ces deux phénomènes successifs de dépolarisation et de repolarisation, avec leurs morphologies variables suivant la place des électrodes, est à la base de l'électrocardiographie. Chaque contraction cardiaque voit se succéder les deux

phénomènes, avec des morphologies différentes selon la place des électrodes exploratrices par rapport à la direction de propagation de ces deux processus (voir figure I.8). La succession de ces deux phénomènes correspondant globalement à ce qu'on appelle l'activation cardiaque, applicable aux oreillettes et aux ventricules d'où la distinction en activation auriculaire (dépolérisation et repolarisation auriculaire) et en activation ventriculaire (dépolérisation et repolarisation ventriculaire). Pour plus de simplicité, le terme d'activation concernera seulement le processus de dépolérisation.



**Figure I.8 :** Les morphologies de base

- L'onde p correspond à la l'onde d'inversion de polarisation auriculaire qui va déclencher la systole auriculaire.
- Le complexe QRS correspond à l'onde d'inversion de polarisation qui va déclencher la systole ventriculaire. L'intervalle pour mesure le temps de conduction auriculo-ventriculaire.
- Onde Q : c'est la première déflexion négative précédant une onde négative.
- Onde R : c'est la première déflexion positive, qu'elle soit ou non précédée d'une onde Q.
- Onde S : c'est la première déflexion négative suivant une onde positive (onde R)

- Le segment ST marque la dépolarisation ventriculaire totale (Gilbert, 1981)

L'onde t est contemporaine de la contraction ventriculaire et marque électriquement le retour de la polarisation normale du muscle ventriculaire (Voir figure I.9)





Figure I.9 : Le Tracé électrocardiographique

## I.9. Extraction du signal respiratoire du Signal ECG

Le poumon est comme un alvéole géant qui se gonfle et se dégonfle à chaque cycle ventilatoire. Le mouvement ventilatoire spontané se fait par des muscles qui soulèvent la cage thoracique. L'augmentation de volume des poumons provoque une dépression qui aspire l'air. Lors de l'inspiration, le diaphragme s'abaisse et pousse les viscères pour permettre aux poumons de grandir. L'expiration est passive mais la respiration est active. La ventilation s'effectue dans la cavité thoracique grâce aux unités fonctionnelles respiratoires, aux voies aériennes, ainsi qu'aux plèvres (Bayet ; West, 2012) (Bachir, 2017). Le trajet de l'air dans l'appareil respiratoire est représentée dans la figure I.10.



**Figure I.10 :** Le trajet de l'air dans l'appareil respiratoire

La respiration est un facteur important pour surveiller les maladies, telles que l'apnée du sommeil, la dépression et l'arrêt cardiaque. Une fréquence respiratoire anormale est reconnue comme un indicateur de détérioration comme l'arrêt cardiaque puisque 54% des personnes souffrant d'un arrêt cardiaque leurs fréquence respiratoire est supérieur à 27 respirations par minute.

De plus, en soins primaires, la fréquence respiratoire est un outil de prédiction de la pneumonie. (Dong et al., 2020). Plusieurs méthodes sont utilisées pour extraire le signal respiratoire partir du signal ECG. Dans le travail de (Lázaro et al., 2020), une méthode pour dériver la fréquence respiratoire d'un brassard qui enregistre l'électrocardiogramme à trois canaux (ECG) utilisant trois paires d'électrodes sèches (sans hydrogel), est présenté. Des études des respirations typiques basées sur les caractéristiques ECG-(EDR)<sup>3</sup> sont présentés dans le travail de (Dong et al., 2020). En 2014, Zeghoudi et al., 2014 ont proposé

<sup>3</sup>Signal respiratoire dérivé de l'électrocardiogramme

une méthode d'estimation et de calcul de rythme respiratoire à partir d'un signal ECG. L'étude est principalement basée sur l'influence de l'effet mécanique de la respiration sur le changement de l'amplitude de pic R. Dans un autre travail, Park et al., 2008 développent un algorithme amélioré pour l'extraction du signal respiratoire de l'électrocardiogramme (ECG) dans les soins à domicile. Šprager and Zazula, 2013, proposent une approche pour la détection du rythme cardiaque et de la respiration basée sur un interféromètre optique et la transformée en ondelettes est proposée.

## I.10. Conclusion

Dans ce chapitre, nous avons présenté les principes fondamentaux de l'électrocardiographie ainsi que l'extraction du signal respiratoire. Une exploration du système cardio-respiratoire a été faite. Le signal ECG sera utilisé dans les chapitres suivants pour détecter l'apnée du sommeil et pour une identification biométrique.

### Bibliographie :

BACHIR M'HAMED SAADI, 'L'évaluation de l'influence de la respiration sur le rythme cardiaque et les paramètres du signal Electrocardiogramme (ECG)', thèse de doctorat soutenue en Janvier 2017 au département génie biomédical, faculté de technologie, Université de Tlemcen, Algérie.

Bayat, S. 'Mécanique ventilatoire 2' , L2 - UE Respiratoire, Université de Picardie

Dong, K., Zhao, L. and Liu, C. (2020) 'Respiratory Signal Extraction from ECG Signal', *Feature Engineering and Computational Intelligence in ECG Monitoring*, pp. 227-243, Springer, Singapore. [https://doi.org/10.1007/978-981-15-3824-7\\_13](https://doi.org/10.1007/978-981-15-3824-7_13)

Ernest, G., Donald, J. G. and Ronan, O. (1985), 'Anatomie', Editeur : Masson, 12086.

Gilbert, H., M. (1981), 'Manuel électrocardiographie', MEDSI, 2864390663.

Hertault, J. (1984) 'Comprendre L'ECG', Maloine, ISBN. 2-904 557-04-0.

Lázaro, J., Reljin, N., Bailon, R., Gil, E., Noh, Y., Laguna, P. and Chon, K. (2020) 'Electrocardiogram derived respiratory rate using a wearable armband', *IEEE, Transactions on Biomedical Engineering*, Vol.68, No.3, pp.1056-1065.

Park, S. B., Noh, Y. S., Parka, S. J. and Yoon, H. R. (2008), 'An improved algorithm for respiration signal extraction from electrocardiogram measured by conductive textile electrodes using instantaneous frequency estimation', *Medical&biological engineering &computing*, Vol.46, No.2, pp.147-158.

Rouvière, H. and Delmas, A. (1985) 'Anatomie humaine. Descriptive, Topographique et fonctionnelle', Editeur : MASSON.

Šprager, S. and Zazula, D. (2013), 'Detection of heartbeat and respiration from optical interferometric signal by using wavelet transform', *Computer methods and programs in biomedicine*, Vol.111, No. 1, pp.41-51.

Zeghoudi, A., Medjahed, O. B., Saadi, B. M. and HADJ Slimane, Z. (2014), 'Algorithme d'extraction du rythme respiratoire (AERR) à partir des signaux ECG', Conférence: BIOMEDICAL ENGINEERING INTERNATIONAL CONFERENCE (BIOMEIC'14), at Tlemcen Algeria.



## **CHAPITRE II : Suivi à distance des patients cardiaques via Smartphone**

### **II.1. Introduction**

Les maladies cardiovasculaires sont la principale cause de décès dans le monde et l'un des problèmes de santé les plus graves. En 2016, les maladies cardiovasculaires étaient responsables de près d'un tiers de tous les décès dans le monde (Naghavi et al., 2017).

Au cours des dernières décennies, les maladies cardiovasculaires ont entraîné plus de 17 millions de décès (Roth et al., 2018). Les statistiques prédisent que les maladies cardiovasculaires seraient la cause de plus de 23 millions de décès en 2030 dans le monde (Lozano et al., 2012), bien que les pays en développement ont connu des taux plus élevés de décès, mais cette maladie était plus grave dans les pays développés (Tefera et al., 2017). Le stress au travail, l'obésité, le manque d'activité physique, l'hypertension, le tabagisme, la mauvaise alimentation et la consommation excessive d'alcool (Musinguzi et al., 2020), ce mode de vie et cette négligence ont montré des résultats catastrophiques, plusieurs personnes, même plus jeunes (moins de 35 ans) souffrent maintenant de maladies cardiaques graves, telles que les troubles de la tension artérielle, l'hypertension, l'arrêt cardiaque et la crise cardiaque (Ashrafuzzaman et al, 2013).

Une arythmie cardiaque est un groupe de conditions liées à un rythme cardiaque irrégulier. Certaines arythmies peuvent même provoquer des symptômes potentiellement mortels, il est donc essentiel de prévenir l'arythmie cardiaque. L'électrocardiogramme (ECG) est l'un des outils non invasifs les plus utilisés par les médecins pour diagnostiquer les maladies cardiaques : C'est le moyen d'enregistrer et de mesurer l'activité électrique du cœur (Lloyd-Jones et al. 2009). L'analyse de l'électrocardiogramme (ECG) peut fournir des informations de diagnostic précieuses sur les activités cardiaques. Par conséquent, l'utilisation et l'interprétation du signal ECG ont une très grande importance.

Un signal ECG est examiné par un médecin, le test peut être effectué par un spécialiste dans un hôpital, une clinique ou un cabinet médical. L'enregistrement dure généralement que quelques minutes, ce qui n'est pas adapté à la détection d'anomalies car parfois les arythmies ne sont pas présentes au moment de l'enregistrement.

Parfois, les établissements de santé sont très éloignés, les gens doivent donc se déplacer pour l'analyse cardiaque, De plus, les personnes âgées ne peuvent pas se rendre fréquemment à l'hôpital.

Un autre problème, l'électrocardiographe stockera les informations du signal ECG du cœur exploitables une fois le test est terminé. Il n'est donc pas possible d'obtenir les résultats de l'ECG immédiatement, le patient doit se rendre à l'hôpital, à la clinique ou au cabinet privé quelques jours plus tard pour discuter les résultats avec un médecin. Il est important de d'identifier une maladie cardiaque avant *que ce soit trop tard*.

La télémédecine est l'utilisation des moyens de télécommunications pour le transfert des données médicales à distance. Ces technologies facilitent le suivi des patients en analysant leurs antécédents et dossiers médicaux (Sethi et al, 2019). Les développements récents (par exemple, les Smartphones, internet et les satellites) permettent l'échange d'informations médicales pour augmenter l'accès à des soins de qualité et rapides.

Dans (gaynor et al, 2010), les auteurs ont proposé une méthode pour partager les informations médicales entre des applications hétérogènes via des services Web. Agarwal at al., (2010) ont présenté la conception et le développement d'un système de surveillance d'ECG sans fil, basé sur Internet pour la transmission sécurisée de données ECG en temps réel à l'aide du protocole TCP/IP vers un terminal distant. Giorgio et al., (2015) ont également décrit un dispositif utilisant des technologies de transmission sans fil pour effectuer un contrôle à distance des patients à domicile et à l'extérieur. Dans (Dai et al., 2015), une méthode de détection des ondes R en temps réel pour la télémétrie ECG ambulatoire sans fil a été développée.

Récemment, de nombreux systèmes de soins de santé utilisant des appareils Android ont été développés. Tarapiah et al., (2017) ont présenté un système de surveillance à distance des patients utilisant la technologie GSM cellulaire pour envoyer un message court (SMS) au médecin. Une nouvelle compression sans perte de donnée ECG dans un SMS sur des appareils à ressources limitées comme les téléphones mobiles pour une utilisation efficace dans les systèmes de la surveillance de la santé à distance a été développée par Diana et al, (2017). Dans (Al-Aubidy et al., 2017), un système de surveillance des soins de santé en temps réel utilisant un réseau de capteurs sans fil a été présenté.

Dans ce chapitre, une nouvelle conception d'ECG portable sans fil est présentée. Le prototype proposé est spécifiquement dédié aux patients cardiaques qui va leur permettre de garder un contact permanent avec leur médecin. L'appareil proposé est connecté sans fil à un Smartphone pour la transmission de données ECG. L'estimation de la respiration dérivée de l'ECG (EDR) est également développée (Marchionni et al., 2013), (Scalise et al, 2011).

## **II.2. Matériels et méthodes**

La conception du système est présentée dans le schéma de la **figure II.1**. Le système proposé est composé de trois parties principales :

- Un électrocardiogramme mobile
- Un module Bluetooth
- Une analyse par Smartphone

L'électrocardiogramme mobile détecte et envoie les données ECG au smartphone en temps réel par communication Bluetooth. Le Smartphone enregistre et analyse le signal ECG, mesure la fréquence cardiaque et détecte les anomalies à l'aide d'une application développée.

Lorsque l'anomalie apparaît, le Smartphone alerte le patient et commence à enregistrer les données jusqu'à ce que le signal ECG redevient normal, et l'enregistrement s'arrête. Dans

l'étape suivante, l'application envoie les données enregistrées au centre médical via le protocole de transmission Internet (TCP/IP), et notifie le médecin par SMS.




Figure II.1 : La représentation générale du système de surveillance cardiaque sur Smartphone


### II.3. Architecture du système

La figure II.2 montre le schéma bloc du système développé. Il contient :

- trois électrodes,
- un ECG frontal analogique,
- une carte Arduino,
- un module Bluetooth pour établir la communication avec le Smartphone.

Dans ce projet, la première dérivation D1 a été utilisée pour permettre plus de mobilité au patient. Les électrodes gauche et droite ont été placées 2 cm sous les clavicules, dans la fosse infraclaviculaire, et l'électrode de masse est placée au-dessus de la crête iliaque.


L'ECG Frontal analogique détecte et traite le signal cardiaque, puis le transmette vers le Smartphone du patient via la carte Arduino Uno et le module Bluetooth.



**Figure II.2 :** Principe de l'ECG mobile

### II.3.1. ECG Frontal analogique

La détection du signal ECG est effectuée via le module AD8232. Il s'agit d'un amplificateur d'instrumentation à faible coût et de haute précision, d'un bloc de conditionnement de signal intégré pour ECG et d'autres applications de mesure biométrique. Il mesure l'activité électrique du cœur grâce à des électrodes posées sur la peau. Il produit les valeurs analogiques continues en fonction de l'entrée donnée par les électrodes. Les résultats de mesure finals peuvent être affichés sous forme d'électrocardiogramme. Il est conçu pour extraire, amplifier et filtrer les signaux de bio-potentiel moins énergétique en présence de conditions bruyantes, telles que celles créées par le mouvement, de plus, il y a un voyant LED qui vibrera au rythme d'un battement de cœur. Les électrodes de ce module ont 3 broches connectées par un câble de 30 pouces de longueur. La figure II.3 montre les capteurs placés sur le LA, le RA et le RL du patient.

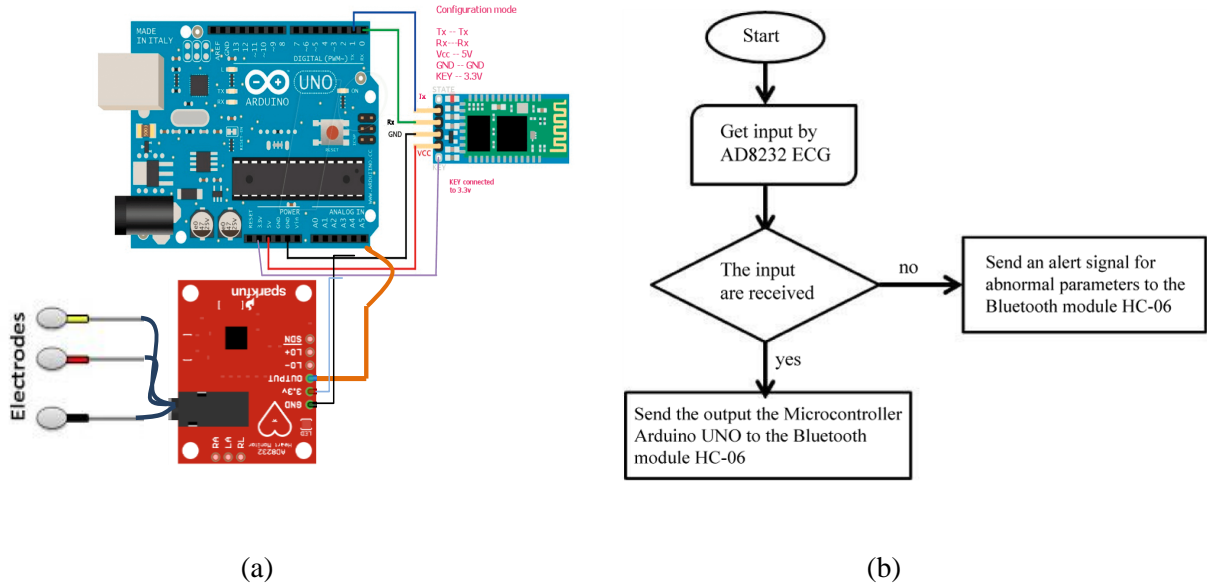


**Figure II.3 :** Emplacement des électrodes et le branchement de l'AD8232 avec Arduino Uno

### II.3.2. Arduino UNO

L'Arduino UNO est un microcontrôleur 8 bits basée sur l'ATmega328. Il dispose de 14 broches d'entrée/sortie numériques, de 6 entrées analogiques, d'un oscillateur à cristal de 16 MHz, d'une prise d'alimentation, d'un en-tête ICSP, d'une connexion USB et d'un bouton de réinitialisation.

L'Arduino UNO renvoie une valeur linéaire de 0 à 1023 correspondant respectivement à 0V et +5V. Pour la transmission en série, le débit en bauds est de 9600 bps et un taux d'échantillonnage de 320 échantillons par seconde est utilisé. Arduino Uno dispose d'une fonction de communication USART intégrée qui permet la transmission et la réception USART via les broches numériques 1 et 0. Pour la communication série, les broches 1 et 0 d'Arduino UNO doivent se connecter aux modules Bluetooth Rx et Tx. Un module Bluetooth HC-06 effectue la transmission du signal entre Arduino UNO et le téléphone Android. L'Arduino Uno peut également communiquer avec un ordinateur portable via un câble USB (Voir Figure II.4).



**Figure II.4 :** (a) Connexions entre Arduino Uno, le module ECG et le module Bluetooth, (b) organigramme du processus de transmission

### II.3.3. Application Android pour smartphone

L'application Android reçoit le signal numérisé, traite les données ECG et les affiche à l'utilisateur via une interface d'unité graphique (GUI) personnalisée. La figure II.5 montre l'organigramme de l'application développée.




Figure II.5 : Algorithme de l'application développée



Le processus commence par une connexion Bluetooth avec la carte Arduino. L'algorithme met en mémoire tampon en continu 10 secondes, l'enregistrement simultané du signal ECG et de l'activité du patient. Le segment du signal ECG est analysé par deux filtres numériques. Le premier est un filtre passe-bande (0,5-150 Hz) pour supprimer les bruits d'interférence haute fréquence et le décalage de la ligne de base. Le second est un filtre coupe-bande pour éliminer les bruits d'interférence électromagnétique à 50 Hz. Le signal ECG filtré est ensuite traité pour détecter et mesurer les valeurs moyennes de la fréquence cardiaque, d'amplitude et de durée QRS du segment. La reconnaissance de l'activité du patient, pendant l'enregistrement ECG, est extrêmement importante. Elle permet une identification précise des cas d'arythmie. Cette partie est développée à l'aide de la classe API Activity Recognition Transition. Elle prend en charge les activités suivantes : dans un véhicule, en vélo, en courant, immobile et en marchant. L'algorithme principal traite les paramètres ECG et l'activité du patient pour détecter si le signal enregistré est normal ou anormal (Hertault, 1984). Dans ce chapitre, la décision arythmique n'est construite que dans le cas des conditions de repos et de marche comme présentées dans le tableau II.1.

Paramètre	Condition	Signification	Identification d'arythmie	Décision
Fréquence cardiaque (bpm)	Moins de 50	Battements très long	Bradycardie	Arythmique
	$50 \leq HR < 85$	Normal	Non	Normal
	$85 \leq HR < 99$	Battements rapides	Prédiction d'arythmie	Arythmique
	$100 \leq HR < 119$	Battements très rapides	Prédiction d'arythmie	Arythmique
	Plus de 119	Battements très rapides	Tachycardie	Arythmique
Amplitude du QRS (mV)	Moins de 0.5	Très faible amplitude	Prédiction d'arythmie	Arythmique
	$0.5 \leq A_{QRS} \leq 2.6$	Normal	Non	Normal
	Plus de 2.6	Amplitude élevé	Prédiction d'arythmie	Arythmique
Durée du QRD (s)	$0.06 \leq T_{QRS} \leq 0.1$	Normal	Non	Normal
	$0.1 < T_{QRS}$	Durée prolongée	Prédiction d'arythmie	Arythmique

**Tableau II.1** : Le processus global d'identification de l'arythmie dans les conditions physiques de marche et de repos.

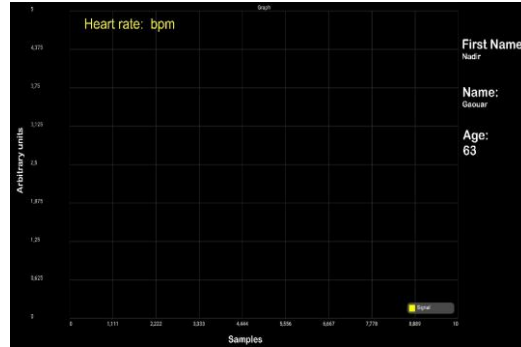
Lorsque l'arythmie est détectée, l'application alerte l'utilisateur afin de prendre les mesures nécessaires selon la recommandation du médecin (par exemple: prendre un repos ou un médicament). En même temps, un enregistrement continu du signal ECG est activé. L'enregistrement s'arrête lorsque le signal ECG redevient normal. L'application stocke les données dans la mémoire du Smartphone, puis envoie immédiatement un SMS et un fichier au médecin pour un examen plus approfondi.

L'application proposée a été développée en utilisant Eclipse et Android SDK pour les applications des Smartphones, et le langage de programmation Matlab pour l'application Laptop. L'API Android minimale (interface de programmation d'applications) utilisée est l'API de niveau 8 qui peut être implémentée sur Android 2.2 et plus.

Le système obtient les signaux d'entrée du corps humain à l'aide d'électrodes à 3 fils. Il vérifie si les trois entrées sont reçues correctement et envoie le signal au module Bluetooth en le transmettant à un Smartphone. L'application Android traite les données reçues et affiche l'état physique, la fréquence cardiaque moyenne, la durée moyenne du QRS, l'amplitude moyenne du QRS et la forme d'onde ECG toutes les 10 secondes sur l'interface graphique.

Chez le patient :

L'application contient les informations du patient, prénom, nom et âge. L'interface principale de l'application est illustrée sur figure II.6. Au milieu, la section de l'affichage du tracé ECG, en haut à gauche la fréquence cardiaque est affichée, à droite les informations du patient.



**Figure II.6 :** L'interface principale de l'application du patient

La figure II.7 montre le tracé en temps réel de l'ECG sur l'écran du téléphone portable du patient. Comme on peut le voir, une acquisition claire avec une très grande précision. Une bonne performance de filtrage a été obtenue permettant la suppression des bruits et en particulier la correction de la ligne de base.



**Figure II.7 :** Enregistrement en temps réel du signal ECG

Le but du système est d'acquérir l'ECG en temps réel. Le signal ECG peut être visualisé. L'application dédiée au patient enregistre les données brutes du signal ECG dans un fichier .txt (Figure II.8). En cas d'anomalie comme le dossier est envoyé directement au médecin avec alarme.

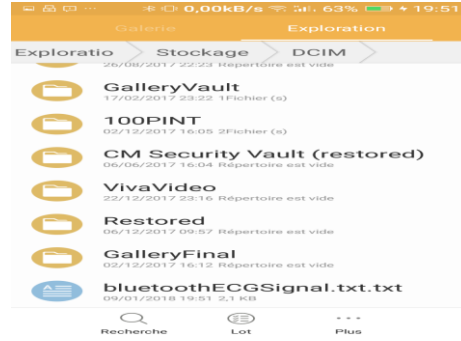


Figure II.8 : Le fichier des données ECG

La Figure II.9 montre les données brutes contenues dans le fichier via Smartphone.



Figure II.9 : Les données brutes du signal ECG

### An niveau du centre médical

Avec l'application Android du Smartphone, le médecin reçoit le fichier contenant les données brutes ECG où il peut les visualiser et les analyser. L'interface de l'application présentée dans la figure II.10, permet au médecin de charger le fichier reçu du patient. Une autre interface est réalisées (voir la figure II.11). Son rôle est de retracer les données de l'ECG, indique la fréquence cardiaque, calcule le complexe QRS et extrait le signal respiratoire.

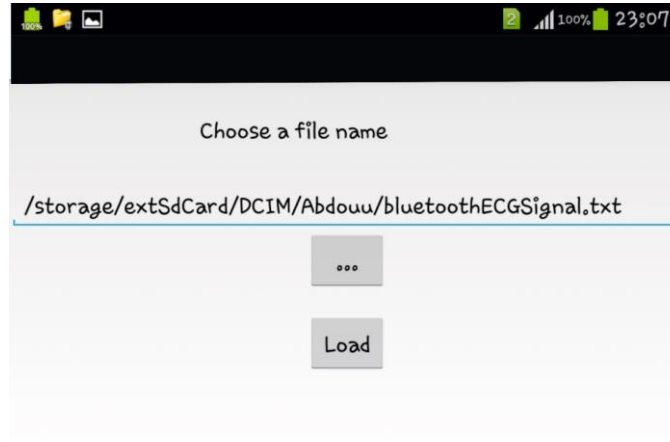


Figure II.10 : Interface de chargement de fichiers

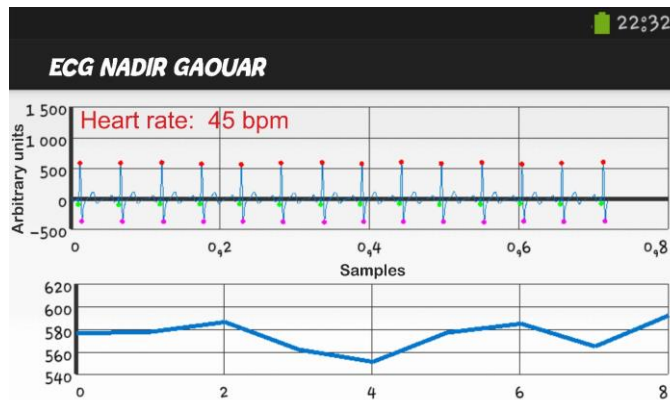


Figure II.11 : Aperçu du signal ECG et du signal respiratoire à travers le Smartphone du médecin

Une deuxième acquisition sur un ordinateur portable programmé sous Matlab est réalisée. Ce programme charge le fichier de données brutes du patient, trace le signal ECG (Figure II.12). Le signal respiratoire est ensuite extrait du signal ECG (Figure II.13). Sur la figure II.14, on remarque que le programme a identifié l'arythmie (bradycardie) tout en indiquant la fréquence cardiaque et le calcul du complexe QRS (amplitude, durée)




Figure II.12 : Tracé du signal ECG en temps réel sur ordinateur portable et détection du complexe QRS

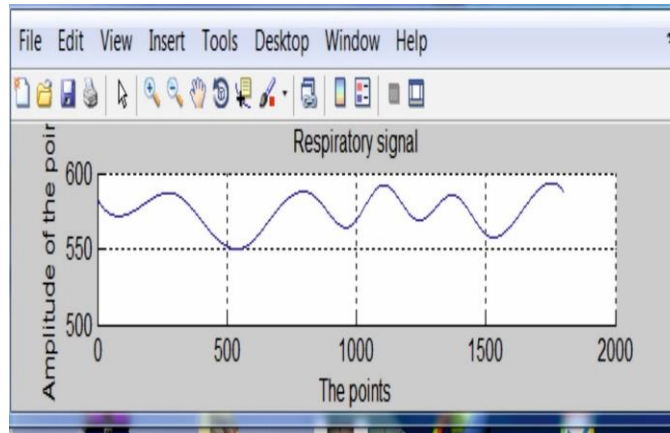


Figure II.13 : Signal respiratoire dérivé du signal ECG

ECGData.Parameters	
	2
1 'Heart rate'	45
2 'QRS Amplitude'	'NORMAL'
3 'QRS Duration'	0.1000
4 'Identification Arrhythmia'	'Bradycardia'

**Figure II.14 :** Paramètres extraits du signal ECG

Afin de connaître les performances de notre application, nous l’avons testé sur une population de 10 personnes avec différents âges, sexe et en situation de repos. Le tableau II.2 montre les informations des personnes. Les résultats de détection d'arythmie obtenus à partir de l'application sont mentionnés.

Individu	Age	Sexe	Identification d'arythmie	Alarme
1	26	Male	Non	Non
2	65	Male	Non	Non
3	23	Femelle	Non	Non
4	35	Male	Non	Non
5	30	Male	Non	Non
6	65	Femelle	Prédiction d'arythmie	Oui (patient et médecin)
7	18	Male	Non	Non
8	22	Femelle	Non	Non
9	48	Male	Bradycardie	Oui (patient et médecin)
10	32	Femelle	Non	Non

**Tableau II.2 :** Informations sur le patient et décision

Les figures II.15 à II.24 montrent les enregistrements des signaux ECG obtenus par l’Android pour différent personne.




Figure 15 : Enregistrement 1 (Individu 1)




Figure 16 : Enregistrement 2 (Individu 2)




Figure 17 : Enregistrement 3 (Individu 3)




Figure 18 : Enregistrement 4 (Individu 4)



Figure 19 : Enregistrement 5 (Individu 5)




Figure 20 : Enregistrement 6 (Individu 6)



Figure 21 : Enregistrement 7 (Individu 7)




Figure 22 : Enregistrement 8 (Individu 8)




Figure 23 : Enregistrement 9 (Individu 9)




Figure 24 : Enregistrement 10 (Individu 10)



## II.4. Conclusion

Dans ce chapitre, une nouvelle conception d'un système en télémédecine pour la surveillance à distance des patients cardiaques à l'aide d'un smartphone a été présentée, les informations de l'ECG recueillies sur le Smartphone ont été transférées informant le médecin et le centre médical en cas d'urgence.

En perspective, nous envisageons d'améliorer nos services médicaux à distance en ajoutant plus de cas (sains et pathologiques), en les associant aux informations possibles afin de détecter de nouvelles arythmies et comparer les résultats avec ceux des médecins.

### Bibliographie :

Agarwal, V., Thatha, R., & Chandramouli, C. (2010) 'Design and development of a wireless internet-based ECG monitoring system for ambulatory applications', *International Journal of Biomedical Engineering and Technology*, Vol.4, No.3, pp.257-275.

Al-Aubidy, K. M., Derbas, A. M., & Al-Mutairi, A. W. (2017), 'Real-time healthcare monitoring system using wireless sensor network', *International Journal of Digital Signals and Smart Systems*, Vol.1, No.1, pp.26-42.

Ashrafuzzaman, M., Huq, M. M., Chakraborty, C., Khan, M. R. M., Tabassum, T., & Hasan, R. (2013) 'Heart attack detection using smart phone', *International Journal of Technology Enhancements and Emerging Engineering Research*, Vol. 1, No.3, pp.2347-4289.

Dai, C., Deng, Y., & Chen, F. (2015) 'A real-time R-wave detection method for wireless ambulatory ECG telemetry', *International Journal of Biomedical Engineering and Technology*, Vol.19, No.1, pp.26-39.

Diana, M., & Deisy, C. (2017) 'Lossless compression for transmitting 'ECG in SMS' with high quality for mobile telecardiology Systems', *International Journal of Ad Hoc and Ubiquitous Computing*, Vol.26, No.3, pp.157-166.

Fariborzi, H. & Moghavvemi, M. (2009) 'Wireless monitoring of cardiac activity: a critical review', *International Journal of Biomedical Engineering and Technology*, Vol.2, No.1, pp.4-28.

Gaynor, M., Myung, D., Restuccia, J., & Moulton, S. (2010) 'Designing infrastructure to exchange electronic medical records with web services', *International Journal of Biomedical Engineering and Technology*, Vol.3, No.3/4, pp.393-412.

Giorgio, A. (2015) 'A wireless electronic device for the personal safety of chronically ill persons for indoor and outdoor use', *International Journal of Biomedical Engineering and Technology*, Vol.18, No.1, pp.72-85.

J. Hertault, (1984) (Comprendre L'ECG), maloine, ISBN. 2-904 557-04-0

Lloyd-Jones, D., Adams, R., Carnethon, M., De Simone, G., Ferguson, T. B., ... & Hong, Y. (2009) 'Heart disease and stroke statistics—2009 update: a report from the American Heart Association Statistics Committee and Stroke Statistics Subcommittee', *Circulation*, Vol.119, No.3, pp.21-181.

Lozano, R., Naghavi, M., Foreman, K., Lim, S., Shibuya, K., Aboyans, V., ... & Remuzzi, G. (2012) 'Global and regional mortality from 235 causes of death for 20 age groups in 1990 and 2010: a systematic analysis for the Global Burden of Disease Study 2010', *The Lancet*, Vol. 380, No. 9859, pp.2095-2128.

- Marchionni, P., Scalise, L., Ercoli, I., & Tomasini, E. P. (2013) 'An optical measurement method for the simultaneous assessment of respiration and heart rates in preterm infants', *Review of Scientific Instruments*, Vol.84, No.12, 121705.
- Musinguzi, G., Ndejjo, R., Ssinabulya, I., Bastiaens, H., van Marwijk, H., & Wanyenze, R. K. (2020) 'Cardiovascular risk factor mapping and distribution among adults in Mukono and Buikwe districts in Uganda: small area analysis', *BMC cardiovascular disorders*, Vol. 20, No. 284, pp.1-12.
- Naghavi, M., Abajobir, A. A., Abbafati, C., Abbas, K. M., Abd-Allah, F., Abera, S. F., ... & Fischer, F. (2017) 'Global, regional, and national age-sex specific mortality for 264 causes of death, 1980–2016: a systematic analysis for the Global Burden of Disease Study 2016', *The Lancet*, Vol. 390, No. 10100, pp.1151-1210.
- Roth, G. A., Abate, D., Abate, K. H., Abay, S. M., Abbafati, C., Abbasi, N., ... & Borschmann, R. (2018) 'Global, regional, and national age-sex-specific mortality for 282 causes of death in 195 countries and territories, 1980–2017: a systematic analysis for the Global Burden of Disease Study 2017', *The Lancet*, Vol. 392, No. 10159, pp.1736-1788.
- Scalise, L., Marchionni, P., & Ercoli, I. (2011, August). Non-contact Laser-based Human Respiration Rate Measurement. In *AIP Conference Proceedings* (Vol. 1364, No. 1, pp. 149-155). American Institute of Physics.
- Sethi, D., & Anand, J. (2019) 'Big data and WBAN: prediction and analysis of the patient health condition in a remote area', *Engineering and Applied Science Research*, Vol.46, No.3, pp.248-255.
- Tarapiah, S., Daadoo, M., & Atalla, S. (2017) 'Android-based real-time healthcare system', *International Journal of Medical Engineering and Informatics*, Vol.9, No.3, pp.253-268.
- Tefera, Y. G., Abegaz, T. M., Abebe, T. B., & Mekuria, A. B. (2017) 'The changing trend of cardiovascular disease and its clinical characteristics in Ethiopia: hospital-based observational study', *Vascular health and risk management*, Vol. 13, pp.143-151.

## CHAPITRE III : Transformée en Ondelettes Continue (CWT) et les réseaux de neurones convolutionnels (CNN)

### III.1. Introduction

La transformée de Fourier fournit des informations de fréquence d'un signal. Par contre, cette transformée ne nous dit pas quand dans le temps ces composantes de fréquences existent. La transformée de Fourier est idéale pour les signaux stationnaires qui ne changent pas avec le temps. La transformation de Fourier à court terme est apparue en 1940 par Gabor et Ville. Ces derniers proposèrent une représentation des signaux à la fois dans le domaine du temps et des fréquences. Les composantes fréquentielles d'un signal sont calculées à partir d'une série de portions du signal à analyser. Une fenêtre temporelle à largeur fixe est alors utilisée. Cette fenêtre est balayée sur tout le signal à analyser. Le choix de la durée de la fenêtre est délicat. En effet, plus la fenêtre temporelle est étroite (correspondant à une précision temporelle élevée), plus la précision fréquentielle est faible. La dualité des précisions de la représentation temps-fréquence est l'inconvénient majeur de la transformée de Fourier à court terme (TFCT). C'est à partir de l'observation des inconvénients de la TFCT (précisions fréquentielles et temporelles fixes) que Jean Morlet proposa en 1975 une autre approche donnant naissance à la théorie des ondelettes.

L'analyse en ondelettes constitue une suite logique des travaux abordés dans le cadre de l'analyse temps-fréquence. L'apport de cette technique est l'utilisation d'une famille d'atomes temps-fréquence obtenue en dilatant et en translatant une ondelette analysante.

Un réseau de neurones artificiels est l'un des algorithmes d'intelligence artificielle les plus sophistiqués au monde. A l'origine inspiré du fonctionnement des neurones biologiques, cet algorithme est capable d'apprendre à réaliser n'importe quelle tâche (Conduire une voiture, jouer aux échecs, entretenir une conversation, ou encore reconnaître et classer des images). Le Machine Learning est un domaine de l'intelligence artificielle qui consiste à

programmer une machine pour que celle-ci apprenne à réaliser des tâches en étudiant des données de ces dernières. ça consiste à développer un modèle en se servant d'un algorithme d'optimisation pour minimiser les erreurs entre le modèle (modèles linéaires, arbre de decision, Support Vector Machines) et nos données. Le Deep Learning est un domaine du Machine Learning dans lequel, au lieu de développer un des modèles cités ci-dessus, on développe à la place ce qu'on appelle des réseaux de neurones artificiels. Dans le Deep Learning, l'apprentissage est réalisé par des réseaux de neurones dits "profonds", c'est à dire avec un grand nombre de couches de neurones intermédiaires. Les réseaux de neurones convolutionnels (en anglais Convolutional neural networks), aussi connus sous les noms de CNNs, est une architecture en Deep Learning qui va pouvoir nous permettre de travailler avec des images. Le célèbre Yann LeCun inventa les premiers réseaux de neurones convolutifs, réseaux qui sont capable de reconnaître et de traiter des images, en introduisant au début de ces réseaux des filters mathématiques qu'on appelle Convolution et Pooling. Ce qui va être expliqué dans ce présent chapitre.

### III.2. Analyse temps-échelle (transformation en ondelettes)

Lorsqu'on parle de représentation temps-échelle (RTE), on pense classiquement aux ondelettes. Les premiers travaux liés à la théorie des ondelettes sont apparus dans les années 30 à l'occasion des études de Lusin et Caldéron. Mais c'est en 1975 que Jean Morlet définit pour la première fois la transformation en ondelettes (TO). La validité théorique n'a été confirmée que 9 ans plus tard, en 1984, par Alex grossman.


La famille d'ondelette est déduite à partir d'ondelette mère  $\psi(t)$  par la formulation suivante :

$$\Psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (\text{III.1})$$

Avec  $a$  correspondant au facteur d'échelle. Ainsi définir  $|a| < 1$  dilate la fonction  $\psi(t)$  et prendre  $|a| > 1$  la comprime.  $b$  correspond au paramètre de translation.


Le paramètre d'échelle  $a$  de la transformée en ondelettes est comparable à celui du paramètre fréquence de la transformée de Fourier à court terme (TFCT).

L'ondelette mère  $\psi(t)$  représente une courte oscillation de moyenne nulle. Un exemple est illustré sur la figure III.1.




**Figure III.1 :** Exemple de fonction d'ondelette (ondelette de Morlet)

La figure III.2, montre l'évolution de l'ondelette de Morlet en fonction du paramètre d'échelle  $a$ . Sur les figures III.2.b et III.2.c, le signal est compressé ( $|a| > 1$ ). Les figures III.2.d et III.2.e, montrent que le signal est dilaté ( $|a| < 1$ ).




**Figure III.2 :** l'évolution de l'ondelette de Morlet en fonction du facteur d'échelle  $a$

La valeur  $b$  de la formule (III.1), correspond au paramètre de translation. La figure III.3 montre l'ondelette de Morlet translatée pour différentes valeurs de  $b$ .



**Figure III.3 :** l'ondelette de Morlet translatée pour différentes valeurs de  $b$ .

L'analyse en ondelette consiste donc, en une représentation temps-échelle du signal à analyser suivant la configuration suivante :




**Figure III.4 :** Analyse temps-échelle (TO)

L'analyse temps-échelle nous conduit à deux types de transformations en ondelettes : continues (CWT) et discrètes (DWT).

### Boîtes de Heisenberg d'atomes d'ondelettes

L'écart-type en temps est proportionnel au facteur d'échelle  $a$  tandis que l'écart-type en fréquence est inversement proportionnel à  $a$ .



**Figure III.5 :** Boîtes de Heisenberg d'atomes d'ondelettes

### III.2.1. La transformation en ondelettes continue (CWT)

La transformation en ondelettes continue (CWT) d'un signal  $x(t)$  est donnée par :

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \Psi\left(\frac{t-b}{a}\right) x(t) dt \quad (\text{III.2})$$

Où  $\Psi(t)$  est l'ondelette mère analysante.  $a$  est un facteur d'échelle de dilatation temporelle et  $b$  est un facteur de translation dans le temps.

Le résultat de la transformation en ondelettes continue (TOC) est donc des coefficients  $W$  fonction de  $a$  (facteur d'échelle) et de  $b$  (facteur de translation).

Les coefficients  $W(a, b)$  décrivent la corrélation entre le signal à analyser et l'ondelette mère analysante.

La transformation en ondelettes continue (CWT) produit une représentation temps-échelle similaire à celle de la représentation temps-fréquence produite par la transformée de Fourier à court terme (TFCT).

### III.2.2. La transformation en ondelettes discrète (DWT)

Lorsque les paramètres d'échelle et de translation  $a$  et  $b$  prennent des valeurs discrètes avec :

$$a = 2^j \quad \text{et} \quad b = n.2^j, \quad \text{Où } j \text{ et } n \text{ sont des nombres entiers.}$$

On obtient alors la transformation en ondelettes discrètes (DWT) définie par la relation suivante:


$$W(i, m) = 2^{-\frac{i}{2}} \sum_{n \in \mathbb{Z}} x(n) \Psi\left(\frac{n}{2^i} - m\right) \quad (\text{III.3})$$

L'inconvénient majeur de la transformée en ondelettes discrète (DWT) est qu'elle produit un nombre élevé de coefficients pour représenter un signal exigeant un temps de calcul élevé pour reconstituer le signal d'origine.




La transformée en ondelettes discrète décompose le signal en deux parties :

- les approximations qui correspondent à la basse fréquence
- les détails qui correspondent à la haute fréquence




**Figure III.6 :** La transformée en ondelettes discrète décompose le signal en deux parties : Les approximations et les détails

Le processus de décomposition peut être réitérée, de sorte qu'un signal peut être décomposé en plusieurs composantes de basse résolution : ceci s'appelle l'arbre de décomposition d'ondelette (voir figure ci-après).



**Figure III.7 :** Décomposition en multi niveau

Un exemple d'application sur un signal bruité est représenté sur la figure suivante :



**Figure III.8 :** Décomposition d'un signal bruité en approximations et en détails

### III.2.3. Avantages et inconvénients de la transformée en ondelettes

Les avantages qu'offre la transformée en ondelettes (TO) dans l'analyse temps-échelle sont les suivants :

- travailler en sous bandes avec la possibilité de séparer les composantes du bruit du reste du signal,
- la transformée en ondelettes offre une grande aptitude à prendre en charge plusieurs traitements numériques du signal de façon quasi simultanée (fenêtrage, débruitage, détection, filtrage et reconstitution du signal),

Les inconvénients de la transformée en ondelettes sont les suivants :

- les ondelettes n'existent pas à un instant spécifique ou à une fréquence spécifique. Elles sont bien localisées dans le temps en fréquence mais pas avec une grande précision,
- l'un des inconvénients majeur de la transformée en ondelettes est qu'elle nécessite un bon choix d'ondelette mère analysante pour les différentes applications en traitement numérique du signal.


### **III.3. Aperçu sur les réseaux de neurones convolutionnels (CNN)**

En 1998, Yann LeCun (LeCun et al., 1998) a introduit le concept du réseau de neurone convolutionnel, appelé "CNN". C'est un exemple d'apprentissage par rétro-propagation du gradient qui a des applications dans la reconnaissance des chiffres manuscrits qui sont utilisés pour les chèques et les codes postaux. Ainsi, plusieurs applications utilisant les CNNs ont émergé dans les décennies suivantes. En imagerie médicale, les réseaux neuronaux convolutifs peuvent détecter efficacement la présence ou non de cellules cancéreuses dans les images. Les différentes composantes qui constituent le principe de base des réseaux neuronaux convolutifs sont : la couche de convolution, la couche d'activation, la couche de pooling et la couche fully-connected qui est un perceptron qui traite les caractéristiques obtenues depuis les couches précédentes.

#### **III.3.1. La couche de convolution**

La couche de convolution applique un ensemble de filtres convolutifs aux images d'entrée, chacun d'entre eux activant certaines caractéristique des images. On vous donne une matrice d'entrée arbitrairement grande et la plus petite que nous appelons le noyau ou filtre. La convolution entre l'entrée et le noyau produira une autre matrice. Les valeurs contenants à l'intérieur de la matrice de sortie sont obtenues en faisant glisser le noyau au dessus de l'entrée et en effectuant une multiplication de valeurs adjacentes puis en les additionnant. La taille de la sortie peut être facilement calculée comme la taille de l'entrée moins la taille du noyau plus un. La figure III.9 représente un exemple d'opérations de convolution avec

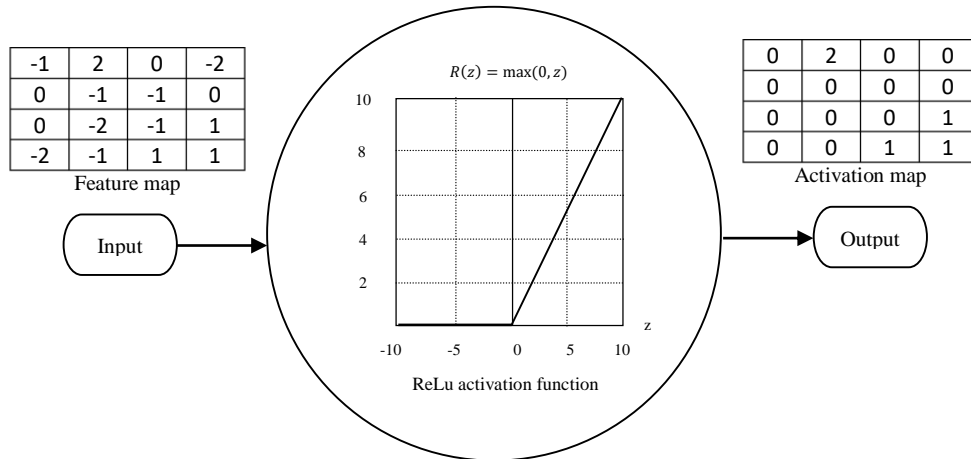
une couche de taille  $6 \times 6 \times 1$  et un filtre de taille  $3 \times 3 \times 1$ . L'image modifiée aura une meilleure représentation des caractéristiques que l'image d'origine. Un réseau neuronal convolutif a en général de nombreuses couches de convolution et chaque couche de convolution a son propre ensemble de noyaux ou de filtres (salvaris et al., 2018). A la fin de l'opération, on obtient un feature map ou aussi activation map.



**Figure III. 9:** Convolution in CNNs

### III.3.2. Couche d'activation


Une fois les features maps extraites, l'étape suivante consiste à les déplacer vers la couche d'activation. De la même manière que les réseaux de neurones artificiels, les CNNs utilise une fonction d'activation pour la création d'une carte de données d'entrée non linéaire. Il existe un certain nombre de fonctions d'activation différentes avec des propriétés différentes telles que : Sigmoid, tangente hyperbolique (*Tanh*) et l'unité linéaire rectifiée (*ReLU*) (salvaris et al., 2018). Dans notre travail, nous choisissons la fonction ReLu la plus utilisée actuellement (Lecun, 2015). ReLu permet un apprentissage plus rapide et plus efficace en remplaçant les valeurs négatives par des zéros et en conservant les valeurs positives (figure III.10). The output of ReLu layer is a rectified feature map. A la sortie de la couche d'activation, seules les caractéristiques activées sont transmises à la couche suivante. On obtient une carte de données rectifiée.



**Figure III.10:** Fonctionnement de la fonction d'activation ReLu

### III.3.3. Couche de Pooling

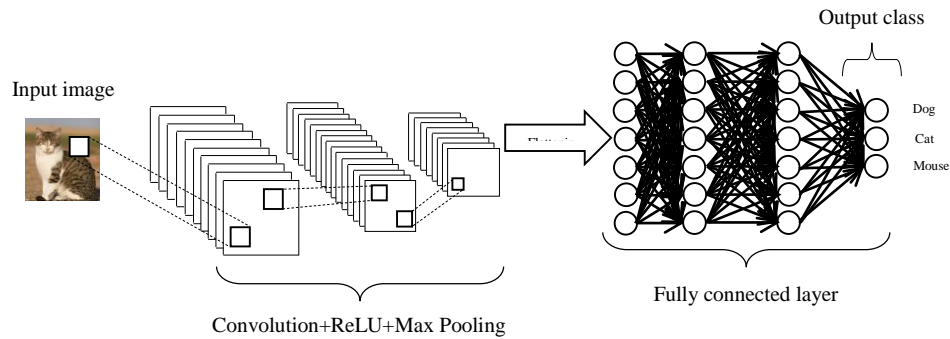
La carte de données rectifiée ainsi obtenue passe à travers la couche de Pooling. La couche de pooling simplifie la sortie en réalisant un sous-échantillonnage non linéaire, ce qui permet ainsi de réduire le nombre de paramètres que le réseau doit apprendre. Cela rend la représentation plus petite et plus gérable (Manaswi, 2018). Le type de pooling le plus populaire est le max pooling, où les valeurs maximales sont prises après une couche de convolution. Comme vous pouvez voir sur la figure III.11, c'est simplement la sélection de l'intensité la plus grande parmi une sélection de pixels. L'idée derrière un max-pooling est que les informations importantes d'une image sont rarement contenues dans des pixels adjacents, et elles sont souvent contenues dans des pixels plus sombres (Skansi, 2018).



**Figure III.11:** illustration d'une opération avec un max-pooling

### III.3.4. La couche de Fully connected

La couche finale est la couche fully connected (en anglais fully connected layer), dont la sortie est utilisée pour effectuer la classification. Après un nombre spécifique de convolutions, ReLU and Max pooling, la couche fully connected s'applique sur une entrée préalablement aplatie où chaque entrée est connectée à tous les neurones. Cette couche fonctionne exactement de la même manière qu'un réseau feed-forward traditionnel (Aggarwal, 2018). Les couches de fully connected sont présentes à la fin des architectures de CNN. La Figure III.12 représente une architecture typique d'un réseau de neurone convolutif pour la classification d'une image. La tâche consiste à prédire la catégorie d'un animal : chien, chat ou souris.




**Figure III.12:** Classification d'image par le CNN

## III.4. Exemple d'Architecture CNN

### III.4.1. LeNet

En 1998, LeCun et al. proposent le premier modèle du réseau de neurones convolutif pour la reconnaissance des chiffres du code postal écrits à la main. Ce réseau est appelé LeNet-5, ou simplement LeNet (LeCun et al., 1998). LeNet-5 comprend 7 couches, deux couches de convolution, deux couches d'average pooling, deux couches fully-connected et une couche de sortie avec une connection Gaussian (figure III.13). L'image d'entrée est une image à 32x32 pixels. Cette image est convoluée pour se transformer en six canaux de 28 par 28 pixels qui sont ensuite réduits par un average pooling à 14 par 14 pixels. La couche Pooling est à nouveau suivie par une couche de convolution et une couche pooling.


La couche finale est la couche fully connected, dont la sortie est utilisée pour effectuer la classification. Les couches de convolution sont appelées  $C_x$ , les couches subsampling sont appelées  $S_x$  et les couches fully connected sont appelées  $F_x$ , où  $x$  est l'indice de la couche.



**Figure III.13:** Architecture du réseau LeNet-5 (Lecun et al., 1998)

### III.4.2. AlexNet


AlexNet est proposé par (Krizhevsky et al., 2012). Cette architecture a remporté le concours ImageNet LSVRC (ImageNet Large Scale Visual Recognition Challenge) en 2012 où il s'est retrouvé dans le top-5 avec un taux d'erreur de 15.3%, contre 26,2 % obtenus par la deuxième meilleure entrée. Le jeu de données ImageNet est composé d'environ 1.2 millions d'images à haute résolution réparties sur un total de 1000 classes différentes. L'architecture AlexNet est très similaire à celle de LeNet-5, mais avec plus de couches. Cette architecture utilise cinq couches de convolution et trois couches de pooling. AlexNet commence avec des images à  $224 \times 224 \times 3$  en entrée. Une diminution progressive de la taille de l'image ( $224 \rightarrow 55 \rightarrow 27 \rightarrow 13$ ) est observée avec diminution progressive de la taille des filtres ( $11 \rightarrow 5 \rightarrow 3$ ). Après le passage de l'image dans les couches de convolution, de pooling et d'activation, une carte de caractéristiques est obtenue. L'architecture d'AlexNet is représentée sur la figure III.14 (Krizhevsky et al., 2012).



**Figure III.14:** L'Architecture d'AlexNet (Krizhevsky et al., 2012)

### III.4.3. GoogLeNet

GoogLeNet est composé de plusieurs couches appelées couches d'inception (szegdy et al., 2015). il est le gagnant du challenge ILSVRC 2014. L'idée de base est d'avoir des filtres en parallèle avec des champs récepteurs de taille multiple (pyramide spatiale). Cette architecture contient 9 modules 'inception'. Un exemple de module inception est représenté sur le figure III.15. Elle consiste à la concaténation des cartes de caractéristiques obtenus à la sortie des quatre modules de convolution de taille  $1 \times 1$ ,  $3 \times 3$  et  $5 \times 5$  mises en parallèle. GoogLeNet comprend 22 couches de profondeur en ne comptant que les couches avec paramètres (ou 27 couches si on compte aussi le pooling) et nécessite des images d'entrée d'une taille de  $224 \times 224 \times 3$ , comme indiqué dans le tableau III.1.






**Figure III.15:** Module Inception (szegdy et al., 2015)

Type	Output size
input image	224x224x3
Convolution	112x112x64
max pool	56x56x64
Convolution	56x56x192
max pool	28x28x192
inception (3a)	28x28x256
inception (3b)	28x28x480
max pool	14x14x480
inception (4a)	14x14x512
inception (4b)	14x14x512
inception (4c)	14x14x512
inception (4d)	14x14x528
inception (4e)	14x14x832
max pool	7x7x832
inception (5a)	7x7x832
inception (5b)	7x7x1024
avg pool	1x1x1024
dropout (40%)	1x1x1024
Linear	1x1x1000
Softmax	1x1x1000

**Table III.1:** GoogLeNet incarnation of the Inception architecture (szegdy et al., 2015)

#### III.4.4. VGGNet

Simonyan et al. (2015) ont introduit le réseau VGGNet. Ils ont proposé un réseau de neurone convolutionnel (CNN) à 19 couches, dans lequel de très petits filtres de taille  $3 \times 3$  sont appris. Durant l'apprentissage, la taille de l'image RGB de sortie du ConvNets est fixée à  $224 \times 224 \times 3$ . En 2014, lors du concours ILSVRC, VGGNet était l'une des entrées les plus performantes, par contre le gagnant était GoogLeNet, qui avait un taux d'erreur dans le top 5 de 6,7 % par rapport au taux d'erreur dans le top 5 de 7,3 % pour VGGNet. L'architecture du réseau VGGNet is représentée sur la figure III.16 (Simonyan et al., 2015).



**Figure III.16:** Architecture du réseau VGGNet (Simonyan et al., 2015)

### III.4.5. Residual Network (ResNet)

ResNet a été introduit en 2015 par He et al. (2015) lors de la compétition ILSVRC and COCO où les auteurs ont également remporté les 1ères places sur les tâches de détection ImageNet, localisation de ImageNet, détection et segmentation des images COCO où il se sont retrouvé dans le top-5 avec un taux d'erreur de 3,57%, qui a abouti au premier classifieur avec des performances de niveau humain. L'architecture du ResNet, utilise des blocs résiduels avec un nombre élevé de couches et a pour but de réduire l'erreur de training. Les auteurs posent de nombreux problèmes d'optimisation, comme celui de l'évanescence des gradients (mais aussi celui de l'explosion des gradients). Il propose des connexions spéciales et un usage intensif de la normalisation des lots. ResNet utilise 152 couches— 8×plus profond mais moins complexe que le réseau VGG net (Simonyan et al., 2015). Afin de résoudre le problème du gradient de disparition / explosion, ResNet a introduit le concept appelé Réseau résiduel. Il s'agit essentiellement de deux couches denses avec une "connexion de saut" ou connexion résiduelle représentée sur la figure III.17. Alors que l'entraînement vise d'ordinaire à estimer une fonction  $F$  telle que  $\hat{y} = F(x)$ , on cherche ici la fonction telle que :  $y = F(x) + x$ . En d'autres termes, la fonction  $F$  estime le résidu  $\hat{y} - x$  (d'où le nom de bloc résiduel). L'architecture ResNet complète est représentée sur la figure III.18 où nous avons tous les blocs résiduels qui sont empilés les uns sur les autres

très profondément. Chacun de ces blocs résiduels a deux couches de convolution 3x3 et double périodiquement le nombre de filtres et effectue un sous-échantillonne spatiale en utilisant stride 2.




Figure III.17: Connexion résiduelle (He et al., 2015)





Figure III.18: L'architecture du ResNet (He et al., 2015)


### III.4.6. SqueezeNet

SqueezeNet a été lancé en 2016 par des chercheurs de l'Université de Californie, Berkeley et de l'Université de Stanford (Iandola et al., 2016). SqueezeNet est un réseau de neurone convolutionnel (CNN) qui s'est concentré principalement sur l'amélioration de la précision afin de créer un réseau neuronal plus petit avec moins de paramètres qui peut plus facilement s'intégrer dans la mémoire de l'ordinateur et peut être transmis plus facilement sur un réseau informatique. SqueezeNet atteint une précision de niveau AlexNet sur ImageNet avec 50 fois moins de paramètres. Les auteurs ont également compressé SqueezeNet à moins de 0,5 Mo, soit 510 fois moins qu'AlexNet sans compression. Iandola

et al. (2016) introduisent les Fire-modules, un nouveau bloc de construction à partir duquel on construit des architectures CNN. Ils implémentent la couche d'expansion avec deux couches de convolution distinctes : une couche avec des filtres de 1x1, et une autre couche avec des filtres de 3x3 (figure III.19). Ensuite, ils concatènent les sorties de ces couches. L'architecture du SqueezeNet est représentée sur la figure III.20 (Iandola et al., 2016). Le SqueezeNet commence par une couche de convolution autonome (conv1), suivie de 8 modules Fire (fire 2-9), en terminant par une couche conv finale (conv10).



**Figure III.19:** Structure d'un Fire-module (Iandola et al., 2016)



**Figure III.20:** L'architecture du réseau SqueezeNet (Iandola et al., 2016)

### III.5. Conclusion

La technologie du deep learning s'est avérée excellente dans le domaine de la classification et de la reconnaissance. Les réseaux de neurones convolutionnels (CNN), est une

architecture en Deep Learning. Dans ce chapitre, un aperçu sur les réseaux de neurones convolutionnels (CNN) a été fait. Plusieurs exemples d'Architecture de CNN ont été présenté à savoir : LeNet, AlexNet, GoogLeNet, VGGNet, ResNet et SqueezeNet. Dans les chapitres suivants, nous allons présenter deux applications du deep learning ainsi que le CNN dans le domaine de la classification des signaux physiologiques.

## **Bibliographie**

Aggarwal C.C. (2018) Convolutional Neural Networks. In: Neural Networks and Deep Learning. Springer, Cham. [https://doi.org/10.1007/978-3-319-94463-0\\_8](https://doi.org/10.1007/978-3-319-94463-0_8)

He, K., Zhang, X., Ren, S., and Sun, J. (2015). Deep residual learning for image recognition. arXiv 1512.03385.

Iandola, F.N., Han, S., Moskewicz, M.W., Ashraf, K., Dally, W.J., Keutzer, K. 'SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size' arXiv:1602.07360v4 (2016)

Krizhevsky, A., Sutskever, I. and Hinton, G.E. 'ImageNet classification with deep convolutional neural networks', Advances in neural information processing systems, 2012, pp. 1097–1105

LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278–2324.

Manaswi N.K. (2018). Convolutional Neural Networks. In: Deep Learning with Applications Using Python. A press, Berkeley, CA. [https://doi.org/10.1007/978-1-4842-3516-4\\_6](https://doi.org/10.1007/978-1-4842-3516-4_6)

Salvaris, M., Dean, D. and Tok, W.H. (2018). Convolutional Neural Networks. In: Deep Learning with Azure. A press, Berkeley, CA. [https://doi.org/10.1007/978-1-4842-3679-6\\_6](https://doi.org/10.1007/978-1-4842-3679-6_6)

Simonyan, K. and Zisserman, A. 'Very Deep Convolutional Networks for Large-Scale Image Recognition', arXiv:1409.1556v6, 2015

Skansi S. (2018) Convolutional Neural Networks. In: Introduction to Deep Learning. Undergraduate Topics in Computer Science. Springer, Cham. [https://doi.org/10.1007/978-3-319-73004-2\\_6](https://doi.org/10.1007/978-3-319-73004-2_6)

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich A.. Going deeper with convolutions. In IEEE International Conference on Computer Vision and Pattern Recognition(CVPR), pp. 1–9, June 2015.



## CHAPITRE IV : GoogLeNet et SqueezeNet pour la détection sans fil de l'apnée du sommeil

### IV.1. Introduction

Le sommeil est très important pour la santé. En effet, bien dormir est aussi important pour préserver le capital jeunesse, favoriser les relations sociales, favoriser la mémorisation, diminuer le mauvais stress et ses effets néfastes sur l'organisme et autres bienfaits. Une apnée du sommeil est la cessation de flux nasal pendant plus de 10 s, alors que l'hypopnée est une diminution  $\geq 50$  % du flux nasal avec une saturation en oxygène artériel ( $SpO_2$ ) diminuée d'au moins 4 %. Il existe deux formes : l'apnée obstructive du sommeil et l'apnée centrale du sommeil, et des chevauchements sont possibles (apnée mixte du sommeil). Une apnée centrale est caractérisée par la cessation simultanée du flux nasal et des efforts respiratoires. Une apnée obstructive est caractérisée par la présence de mouvements thoraciques et/ou abdominaux (efforts de respiration) pendant un épisode apnéique (Garrigue et al, 2003). L'apnée mixte du sommeil, troisième type, est une combinaison des facteurs de l'apnée centrale et de l'apnée obstructive. Des études basées sur la population aux États-Unis ont montré que la prévalence de l'apnée obstructive du sommeil (OSA) est plus élevée chez les personnes âgées que chez les adultes d'âge moyen. Avec une population croissante de patients âgés aux États-Unis, ce nombre devrait doubler d'ici 2030. A la recherche d'un traitement pour l'apnée obstructive, l'âge devient de plus en plus important pour la chirurgie des apnées du sommeil (Jeffrey, 2020). Chez les enfants, l'AOS peut causer des problèmes à l'école ou une hyperactivité (Saus et al., 2019). Les complications cardiovasculaires ou les comorbidités telles que l'hypertension, l'insuffisance cardiaque, les maladies coronariennes, les maladies cérébrovasculaires, le diabète sucré et l'obésité - ce sont également des facteurs de risque de mortalité en coronavirus (COVID-19) - sont couramment observées dans le syndrome d'apnée obstructive du sommeil (SAOS) patient (Pzarli et al., 2020).

Par conséquent, la détection du syndrome d'apnée du sommeil fournira aux gens plus d'informations sur la santé du sommeil. La polysomnographie (PSG) est très utilisée pour le diagnostic de l'OSA. Cependant, elle nécessite du personnel qualifié. Elle est aussi coûteuse en termes de temps et d'argent. La polysomnographie consiste à mesurer plusieurs paramètres dont l'électroencéphalographie (EEG), les mouvements oculaires (EOG), l'électrocardiogramme (ECG) et l'activité des muscles squelettiques (EMG) ainsi que l'effort respiratoire, le débit d'air et la saturation en oxygène (Kim et al, 2020).

Ces dernières années, différentes méthodes ont été explorées pour la détection de l'apnée du sommeil à l'aide de divers signaux physiologiques. (Varon et al., 2015) utilisent deux nouvelles caractéristiques dérivées de l'ECG et deux caractéristiques bien connues dans l'analyse de la variabilité de la fréquence cardiaque. (Kim et al., 2018), ont identifié des biomarqueurs acoustiques indicatifs de la sévérité des troubles respiratoires du sommeil en analysant les sons respiratoires collectés chez un grand nombre de sujets pendant toute la nuit de sommeil.

Six algorithmes différents ont été employés par Zarei et al., (2020). Ces algorithmes permettent l'extraction du signal EDR (ECG-derived respiration) à partir d'un ECG monodérivation. Les résultats sont comparés. Les caractéristiques sélectionnées sont introduites dans les différents classifieurs pour classer les patients OSA et les sujets normaux. Wang et al., (2020), proposent une nouvelle méthode pour diagnostiquer l'OSA, l'indice de fluctuation respiratoire, qui caractérise avec précision la distribution des gouttes respiratoires dans une série temporelle de PSG sans avoir besoin de compter manuellement les épisodes.

Plusieurs études ont proposé des méthodes d'analyse du ronflement comme alternative à la PSG. Dans ce contexte, Emoto et al., (2018) ont développé une technique basée sur un réseau de neurones artificiels (ANN) capable de détecter les épisodes de ronflement/respiration à partir des sons du sommeil enregistrés à l'aide d'un microphone monocanal sans contact. Deux nouvelles méthodes ont été développées, appelées «



sélection d'activation la plus discriminante » et « sélection de colonne la plus discriminante » pour la détection des événements d'apnée-hypopnée en utilisant uniquement des signaux d'oxymétrie de pouls (Rolón et al., 2017). Singh et al., (2020) ont proposé une nouvelle approche utilisant la décomposition basée sur l'analyse du spectre singulier en mode glissant de l'intervalle des battements cardiaques et des signaux respiratoires dérivés de l'ECG pour la détection des événements d'apnée.

Plusieurs méthodes peu coûteuses basées sur des signaux ECG à dérivation unique ont été développées pour le processus de détection de l'apnée du sommeil, telles que les paramètres gaussiens inverses normaux et le renforcement adaptatif qui sont introduits pour le diagnostic d'apnée du sommeil assisté par ordinateur à partir de signaux ECG à dérivation unique (Hassan, 2016). Jafari, (2013) a combiné les caractéristiques spectrales avec les caractéristiques du domaine de phase pour obtenir de meilleurs résultats de classification pour la détection de l'apnée du sommeil.

Dans notre travail, nous avons utilisé la transformée en ondelette continue (CWT) et le réseau neuronal convolutionnel (CNN) pour la détection de l'apnée du sommeil basé sur des signaux ECG à une seule dérivation. Les architectures CNN, GoogLeNet et SqueezeNet sont utilisées pour classifier l'ECG en deux catégories: apnée et normal (figure IV.1) (Szegedy et al., 2015)(Iandola et al., 2016). Les méthodes proposées peuvent être utilisées comme une méthode de détection de l'apnée du sommeil peu coûteuse et non invasive par rapport aux méthodes plus conventionnelles.

Dans le présent travail, une architecture de télésurveillance de l'apnée du sommeil a été développée. Le prototype proposé est spécifiquement dédié aux patients cardiaques. Il leur permet de rester en contact permanent avec leur médecin. L'appareil proposé est connecté sans fil à un Smartphone pour la transmission des données ECG (voir figure IV.2). Les principaux éléments du système sont composés des parties suivantes : un circuit de conditionnement du signal ECG ; un module Bluetooth s'interfaçant avec Arduino, pour l'échange de données ; le traitement du signal et enfin un smartphone Android est choisi

pour transmettre des informations médicales au médecin et au centre médical. Seuls le médecin et le cardiologue auront accès aux informations de diagnostic du patient.




Figure IV.1 Les enregistrements de l'ECG avec et sans apnée




Figure IV.2: Surveillance à distance pour la détection de l'apnée du sommeil

## IV.2. Base de données utilisée


Les méthodes proposées ont été évaluées sur une base de données Apnea-ECG, disponible gratuitement sur Physionet (Goldberger et al., 2000), (Penzel et al., 2000). La raison d'utiliser cette base de données est sa disponibilité dans le domaine public et a été utilisée dans la littérature pour développer des modèles de détection de l'apnée du sommeil. Les données sont constituées de 70 enregistrements. Chaque enregistrement comprend un signal ECG, un ensemble d'annotations d'apnée (Fait par des experts sur la base de la respiration enregistrée simultanément et des signaux associés) et un ensemble d'annotations

QRS générées par la machine. Les enregistrements varient en durée d'un peu moins de 7 heures à près de 10 heures chacun. Le temps passé en respiration normale varie entre 11 et 535 minutes. Le temps passé en troubles respiratoires varie entre 0 et 534 minutes. Les 70 enregistrements sont classés en trois groupes. Le groupe d'enregistrements d'apnée (classe A) a été défini comme ayant 100 minutes ou plus avec des troubles respiratoires. Le second groupe appelé « apnées limites » (classe B) qui regroupe certaines apnées d'importance incertaine. Les enregistrements ayant moins de 5 minutes de troubles respiratoires ont été classés dans le groupe normal (contrôle ou classe C).

### IV. 3. Méthode utilisée

La Figure IV.3 représente le schéma bloc de la méthode proposée pour la détection automatique de l'apnée du sommeil en utilisant les réseaux neuronaux convolutifs (CNN). Le processus est divisé en deux parties comme suit :

- Une représentation temps-fréquence du signal ECG,
- Utilisation d'une architecture de réseau neuronal convolutif avec plusieurs couches : couche convolutif, couche d'activation, couche de pooling et la couche "fully Connected". Ces couches ont été décrites dans le chapitre précédent.



**Figure IV.3:** Schéma bloc de la méthode proposée

#### IV.3.1. Représentation temps-fréquence du signal ECG

Le CNN accepte les images RVB (red, green, blue). Ainsi, il est nécessaire dans un premier temps de convertir les données ECG en images en utilisant la transformée en ondelettes continue (CWT). Le CWT appliqué aux formes d'onde ECG donne des images dans le plan temps-fréquence.

Le CWT est donné par :


$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \Psi\left(\frac{t-b}{a}\right) x(t) dt$$

Où:  $\psi(t)$  représente l'ondelette mère.

$a$  et  $b$  sont respectivement les facteurs d'échelle (ou de dilatation) et de translation.

La représentation temps-fréquence du signal ECG est représentée sur la figure IV.4.

Ces représentations sont appelées scalogrammes. Les images de scalogramme sont ensuite chargées en tant que banque de données d'images.



**Figure IV.4:** Les données ECG transformée en image en utilisant le CWT

### IV.3.2. Les architectures CNN utilisées

Il existe plusieurs types d'architectures de réseaux neuronaux convolutifs. Exemple : LeNet (LeCun et al., 1998), AlexNet (Krizhevsky et al., 2012), GoogLeNet (Szegedy et al., 2015), VGGNet (Siomonyan et al., 2014), ResNet (He et al., 2015) et SqueezeNet (Iandola et al., 2016).

Ce sont les architectures les plus populaires de CNN qui diffèrent en termes de couches internes et de techniques utilisées. Compte tenu des avantages et des limites des méthodes citées, nous avons choisi une méthode de classification basée sur les architectures CNN d'apprentissage en profondeur GoogLeNet et SqueezeNet. GoogleNet a des modules de démarrage qui ont moins de paramètres et moins de complexité de calcul qu'une seule couche convolutive 3x3 ou 5x5. Les stratégies de conception architecturale de SqueezeNet consistent à diminuer judicieusement la quantité de paramètres dans un CNN tout en essayant de préserver la précision. Une autre stratégie consiste à maximiser la précision sur un nombre limité de paramètres.

#### **IV.4. Results and discussions**

Les signaux ECG sont obtenus à partir de la base de données Apnea-ECG, disponible gratuitement sur Physionet (Goldberger et al., 2000), (Penzel et al., 2000). Cette base de données contient des enregistrements de signaux ECG de patients souffrant d'apnée du sommeil (a01-a20), des enregistrements de signaux de patients présentant des cas limite (borderline-case patients) (b01-b05) et des patients classés contrôle (c01-c10).

Dans notre travail, 112 enregistrements de 10 secondes, choisis de façon aléatoire, sont extraits des signaux ECG. Les 112 enregistrements comportent 39 enregistrements de cas normaux et 73 enregistrements de patients souffrants d'apnée du sommeil. L'objectif est d'entraîner un classifieur à pouvoir distinguer entre un cas normal et un cas souffrant d'apnée du sommeil.

Comme mentionné ci-avant, nous appliquons le CWT au signaux ECG pour les représenter en format image avant de les transmettre au réseau CNN.

Pour qu'elle soit compatible avec les architectures GoogLeNet et SqueezeNet, chaque image RGB est configuré en images de taille 224/224/3 et 227/227/3 respectivement.

Le processus de classification utilise deux étapes : l'étape d'apprentissage et l'étape de test. Les enregistrements de la base de données sont divisés en deux groupes, à savoir, un groupe

utilise pour l'apprentissage, et un groupe pour le test de validation. Ainsi, 34 enregistrements sont utilisés pour les ensembles d'apprentissage, c'est-à-dire 30 % et les 78 restants, c'est-à-dire 70 % sont utilisés pour les ensembles de test.

Les tableaux IV.1 et IV.2 ainsi que les figures IV.5 et IV.6, représentent les différents resultants de classification et la performance des parameters du réseau CNN durant l'étape d'apprentissage et de test.

Les résultats incluent le numéro d'époque (En anglais Epoch), le numéro d'itération, le temps écoulé, la précision du mini-lot (mini-batch accuracy), la précision de la validation (validation accuracy) et la valeur de la fonction de perte pour les données de validation.

Pour GoogLeNet, il a atteint une précision de 98,72 % à l'époque = 20 avec une perte de validation la plus faible de 0,0431. Pour SqueezeNet, il a atteint une précision de 100 % à l'époque = 12 avec une perte de validation la plus faible de  $3,4387 \times 10^{-7}$ .

Le tableau IV.3 résume la performance de notre méthode par rapport à d'autres méthodes utilisant la même base de données (Physionet's Apnea-ECG Database). Dans notre travail, les méthodes proposées sont basées sur des signaux ECG à dérivation unique qui peuvent être utilisés comme méthode peu coûteuse de détection de l'apnée du sommeil et non invasive par rapport aux méthodes les plus conventionnelles.

Selon le tableau IV.3, les algorithmes discutés dans [Varon et al. (2015), Zarei and Asl (2020), Singh et al. (2020), Pinho et al. (2019), Viswabhargav et al. (2019)] ont extrait différentes caractéristiques de la variabilité de la fréquence cardiaque (HRV) et des signaux respiratoires dérivés de l'ECG (EDR) et ont obtenu une précision de 84,74 %, 93,26 % , 94,30%, 82,12% et 78,07% respectivement.

Hassan (2016) décompose les signaux ECG en portion d'une minute. Les segments du signal ECG seront ensuite en sous-bandes à l'aide d'une transformée en ondelettes à facteur Q (TQWT). Il modélise ensuite les sous-bandes TQWT à l'aide de la loi inverse-gaussien

normal symétrique (NIG). Le résultat final obtenu par Hassan atteint une précision de 87,33%.

Artín-González et al. (2017) introduit un système d'identification de l'OSA basée sur différentes techniques. Ces techniques sont : Cepstrum Coefficients (CC), Filterbanks (Fbank) and Detrended Fluctuation Analysis (DFA). Ils ont atteint une précision par segment de 84,76 % en les appliquant sur la base de données Apnea-ECG Physionet.

Dans le travail proposé par Li et al. (2019), l'entropie floue (SI<sub>Tr</sub>-fApEn) a été utilisée pour détecter l'apnée du sommeil et analyser différents états pathologiques des patients atteints d'ASA. Une valeur de précision de 86,70% a été rapportée.

Zarei et Asl (2019) ont utilisé une extraction de caractéristiques non linéaires à l'aide des coefficients de la transformée en ondelettes (WT) obtenus par une décomposition du signal ECG et utilisé comme entrée d'un classifieur SVM (support vector machine). Ils ont obtenu une précision de 95,71%.

Binish et al. (2020) divisent le signal ECG en segments de durée d'une minute et les sépare en bandes de fréquences à l'aide de la méthode de décomposition de Fourier. La méthode donne une précision de 92,59 % sur la base de données Apnea-ECG Physionet, en utilisant un classifieur (SVM) avec le noyau gaussien.

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:48	40.00%	43.15%	0.9664	0.1723	1.0000e-04
5	10	00:02:32	100.00%	94.87%	0.2558	0.2784	1.0000e-04
10	20	00:04:25	100.00%	97.44%	0.0488	0.0983	1.0000e-04
15	30	00:06:00	100.00%	93.59%	0.0319	0.1066	1.0000e-04
<b>20</b>	<b>40</b>	<b>00:07:41</b>	<b>100.00%</b>	<b>98.72%</b>	<b>0.0089</b>	<b>0.0431</b>	<b>1.0000e-04</b>

Table VI.1: Analyse des résultats de la classification CNN (architecture GoogLeNet)

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:05	80.00%	65.38%	0.4573	0.8430	0.0003
2	5	00:00:14	90.00%	100.00%	<b>0.3628</b>	<b>0.1928</b>	0.0003
4	10	00:00:24	100.00%	100.00%	<b>0.0010</b>	<b>0.0026</b>	0.0003
5	15	00:00:34	100.00%	100.00%	<b>0.0248</b>	<b>0.0060</b>	0.0003
7	20	<b>00:00:43</b>	<b>100.00%</b>	100.00%	<b>4.7684e-08</b>	<b>1.9435e-05</b>	0.0003
9	25	<b>00:00:53</b>	<b>100.00%</b>	100.00%	<b>7.1526e-08</b>	<b>1.0240e-06</b>	0.0003
10	30	<b>00:01:03</b>	<b>100.00%</b>	100.00%	<b>0.0012</b>	<b>7.5500e-07</b>	0.0003
12	35	<b>00:01:13</b>	<b>100.00%</b>	<b>100.00%</b>	<b>-0.0000e+00</b>	<b>3.4387e-07</b>	0.0003
14	40	<b>00:01:23</b>	<b>100.00%</b>	<b>100.00%</b>	<b>1.1921e-08</b>	<b>1.2685e-07</b>	0.0003
15	<b>45</b>	<b>00:01:33</b>	<b>100.00%</b>	<b>100.00%</b>	<b>8.1173e-05</b>	<b>1.8493e-07</b>	0.0003

Table IV.2: Analyse des résultats de la classification CNN (SqueezeNet architecture)




Figure IV.5: Apprentissage et validation des performance du CNN (GoogLeNet architecture)






Figure IV.6: Apprentissage et validation des performance du CNN (SqueezeNet architecture)

Authors	Feature	Method used	Accuracy (%)
Varon et al. (2015)	HRV and ECG-derived respiration signals (EDR)	LS-SVM (RBF kernel)	84,74%
Hassan (2016)	Normal inverse Gaussian modeling	AdaBoost	87,33%
artín-González et al. (2017)	Cepstrum Coefficients, Filterbanks and Detrended Fluctuation Analysis	Logistic Regression, Linear Discriminant Analysis and Quadratic Discriminant Analysis	84,76%
Li et al. (2019)	Heart Rate Variability (HRV)	Sliding trend fuzzy approximate entropy & LF/HF	86,70%
Pinho et al. (2019)	HRV and ECG-derived respiration signals (EDR)	SVM and ANN	82,12%
Viswabhargav et al. (2019)	HRV and ECG-derived respiration signals (EDR)	SVM	78,07%
Zarei and Asl (2019)	Discrete wavelet transform (DWT)	SVM (RBF kernel)	95,71%
Zarei and Asl (2020)	HRV and ECG-derived respiration signals (EDR)	KNN	92,83%
		RUSBoost	87,63%
		GentleBoost	<b>93,26%</b>
		SubspaceKNN	88,70%
		SVM (RBF kernel)	93,14%
		ANN	91,94%
Binish et al. (2020)	Fourier decomposition	Bagging	91,44%
		KNN	90,57%
		LogitBoost	85,84%
		SVM	<b>92,59%</b>
		ANN-SCG+K-means clustering	99,20%
Singh et al. (2020)	HRV and ECG-derived respiration signals (EDR)	SVM (RBF kernel)	94,30%
Notre travail	Raw ECG	CNN (GoogLeNet)	<b>98,72%</b>
		CNN (SqueezeNet)	<b>100%</b>

Table IV.3: Comparaison des performances des algorithmes proposés avec les techniques existantes appliqués à la base de données Apnée-ECG de Physionet

## IV.5. Conclusion

Nous avons présenté un réseau neuronal convolutif (CNN) d'apprentissage profond pour la détection sans fil de l'apnée du sommeil. Dans notre travail, nous nous sommes concentrés sur GoogLeNet et SqueezeNet comme modèles CNN. Les signaux ECG sont obtenus à partir de la base de données Apnea-ECG, disponible gratuitement sur Physionet. Des représentations temps-fréquence basées sur des ondelettes des signaux ECG sont utilisées pour créer des scalogrammes. Des images RVB de scalogrammes sont générées et ensuite utilisées comme entrées CNN. En comparaison avec les études de la littérature précédentes, les performances les plus élevées sont obtenues en utilisant les architectures GoogLeNet et SqueezeNet avec une valeur de précision moyenne de 98,72 % et 100 % respectivement. Une acquisition en temps réel et une transmission sans fil d'un électrocardiogramme ont également été conçues.

## Bibliographie

- artín-González, S.M., Navarro-Mesa, J.L., Juliá-Serdá, G., Kraemer, J.F., Wessel, N. and Ravelo-García, A.G. (2017) 'Heart rate variability feature selection in the presence of sleep apnea: an expert system for the characterization and detection of the disorder', *Comput. Biol. Med.*, Vol. 91, pp.47–58.
- Binish, F., Singh, P., Singhal, A. and Pachori, R. B. (2020) 'Detection of apnea events from ECG segments using Fourier decomposition method', *Biomedical Signal Processing and Control*, Vol. 61, 102005.
- Emoto, T., Abeyratne, U. R., Kawano, K., Okada, T., Jinnouchi, O. and Kawata, I. (2018) 'Detection of sleep breathing sound based on artificial neural network analysis', *Biomedical Signal Processing and Control*, Vol.41 pp.81-89.
- Garrigue, S., Bordier, P. and Clémenty, J. (2003) 'Apnées du sommeil et stimulation cardiaque : mécanismes d'action et perspectives. Sleep apnea syndrome and cardiac pacing: what mechanisms and which patients?' *Annales de Cardiologie et d'Angéiologie*, Vol. 52, pp.239–245.
- Goldberger, A.L., Amaral, L.A., Glass, L., Hausdorff, J.M., Ivanov, P.C., Mark, R.G., Mietus, J.E., Moody, G.B. Peng, C.K. and Stanley, H.E. (2000) 'Physiobank, physiotoolkit, and physionet: components of a new research resource for complex physiologic signals', *Circulation*, Vol.101, No. 23, pp.215–e220.
- Hassan, A. (2016) 'Computer-aided obstructive sleep apnea detection using normal inverse Gaussian parameters and adaptive boosting', *Biomedical Signal Processing and Control*, Vol.29, pp.22-30.
- He, K., Zhang, X., Ren, S., and Sun, J. (2015). Deep residual learning for image recognition. arXiv 1512.03385.
- Iandola, F.N., Han, S., Moskewicz, M.W., Ashraf, K., Dally, W.J. and Keutzer, K. (2016) 'SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size', arXiv:1602.07360v4
- Jaffari, A. (2013) 'Sleep apnoea detection from ECG using features extracted from reconstructed phase space and frequency domain', *Biomedical Signal Processing and Control*, Vol.8, pp.551-558.

- Jeffrey J. Stanley (2020) 'Sleep apnea surgery in the elderly', *Operative Techniques in Otolaryngology-Head and Neck Surgery*, Vol. 31, No.3, pp.260-264. <https://doi.org/10.1016/j.otot.2020.07.012>
- Kim, S. and Kim, K.B (2020) 'Orthodontics in Obstructive Sleep Apnea Patients: A Guide to Diagnosis, Treatment Planning, and Interventions', Springer Nature Switzerland AG 2020. <https://doi.org/10.1007/978-3-030-24413-2>
- Kim, T., Kim, J. and Lee, K. (2018) 'Detection of sleep disordered breathing severity using acoustic biomarker and machine learning techniques', *BioMedical Engineering OnLine*, Vol.17, No.16.
- Krizhevsky, A., Sutskever, I. and Hinton, G.E. 'ImageNet classification with deep convolutional neural networks', *Advances in neural information processing systems*, 2012, pp. 1097–1105
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Li, Y., Pan, W., Li, K., Jiang, Q. and Liu, G. (2019) 'Sliding Trend Fuzzy Approximate Entropy as a Novel Descriptor of Heart Rate Variability in Obstructive Sleep Apnea', *IEEE Journal of Biomedical and Health Informatics*, Vol.23, No. 1, pp.175-183.
- Pazarlı, A.C, Ekiz, T. and İlik, F (2020) 'Coronavirus disease 2019 and obstructive sleep apnea syndrome, Sleep Breath'. <https://doi.org/10.1007/s11325-020-02087-0>
- Penzel, T., Moody, G.B., Mark, R.G., Goldberger, A.L. and Peter, J.H. (2000) 'The Apnea-ECG database', *Computers in Cardiology*, pp.255-258.
- Pinho, A. , Pombo, N. , Silva, B.M.C., Bousson, K. and Garcia N. (2019) 'Towards an accurate sleep apnea detection based on ECG signal: The quintessential of a wise feature selection', *Applied Soft Computing Journal*, Vol. 83, 105568.
- Rolón, R.E., Larrateguy, L.D., Di-Persia, L.E., Spies, R.D. and Rufiner, H.L. (2017) 'Discriminative methods based on sparse representations of pulse oximetry signals for sleep apnea–hypopnea detection', *Biomedical Signal Processing and Control*, Vol.33, pp.358-367.
- Saus, J.A., Hopper, K.R. and O'Neal, B.J. (2019) 'Sleep Apnea. In: Fox, III C., Cornett E., Ghali G. (eds) *Catastrophic Perioperative Complications and Management*', Springer, Cham. [https://doi.org/10.1007/978-3-319-96125-5\\_1](https://doi.org/10.1007/978-3-319-96125-5_1)
- Simonyan, K. and Zisserman, A. 'Very Deep Convolutional Networks for Large-Scale Image Recognition', arXiv:1409.1556v6, 2015
- Singh, H., Tripathy, R. K. and Pachori, R. B. (2020) 'Detection of sleep apnea from heart beat interval and ECG derived respiration signals using sliding mode singular spectrum analysis', *Digital Signal Processing*, Vol.104, 102796.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A. 'Going deeper with convolutions', *In IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, June (2015), pp.1-9.
- Varon, C., Caicedo, A., Testelmans, D., Buyse, B. and Van-Huffel, S. (2015) 'A novel algorithm for the automatic detection of sleep apnea from single-lead ECG', *IEEE Transactions on Biomedical Engineering*, Vol.62, No.9, pp. 2269-2278.
- Viswabhargav, C.S., Tripathy, R. and Acharya, U.R. (2019) 'Automated detection of sleep apnea using sparse residual entropy features with various dictionaries extracted from heart rate and EDR signals', *Comput. Biol. Med.*, Vol.108, pp.20–30.

Wang, F., M. Hsu, S. Fang, L. Chuang, H. Chan, The Respiratory Fluctuation Index: A global metric of nasal air flow or thoracoabdominal wall movement time series to diagnose obstructive sleep apnea, *Biomedical Signal Processing and Control*, 49 (2019) 250-262.

Zarei, A. and Asl, B. M. (2019) 'Automatic Detection of Obstructive Sleep Apnea Using Wavelet Transform and Entropy-Based Features From Single-Lead ECG Signal', *IEEE Journal of Biomedical and Health Informatics*, Vol. 23, No. 3, 2019, pp.1011-1021.

Zarei, A. and Asl, B.M (2020) 'Automatic classification of apnea and normal subjects using new features extracted from HRV and ECG-derived respiration signals', *Biomedical Signal Processing and Control*, Vol.59, 101927.

## **Chapitre V : Développement d'une nouvelle application en télémédecine pour l'identification des patients en utilisant la transformée en ondelettes continue (CWT) et les réseaux de neurones convolutifs (CNN)**

### **V.1. Introduction**

Les technologies de l'information et de communications, interactives et non interactives, sont de plus en plus utilisées pour la surveillance à distance des malades à domicile. La télémédecine utilise ces techniques pour améliorer les soins à distance à travers une opération interactive entre le médecin et le malade.

La télémédecine et ces pratiques ont suscité beaucoup d'intérêt au sein de la communauté médicale. Parmi ces pratiques, nous pouvons citer : la surveillance à domicile des mouvements thoraco-abdominaux chez les malades atteints de maladies respiratoires. Cette surveillance continue peut éviter des traumatismes. Prenons par exemple, la surveillance à distance pour la thérapie de ventilation à long terme.

Souvent, le médecin urgentiste est confronté à un patient inconscient sans pièce d'identité. Notre système propose une solution rapide et même très efficace pour identifier le patient. Le principe est d'effectuer une mesure du signal électrocardiogramme (ECG) du patient et de l'envoyer à distance à l'hôpital. L'étape suivante est l'utilisation du réseau neuronale convolutionnel (CNN) pour l'identification et la classification du signal parmi les signaux déjà existants dans une base de données. Le service hospitalier transmet ensuite l'identité et le dossier médical du patient au médecin urgentiste, ce qui rend cette méthode unique dans un système de télémédecine.

La technologie de la reconnaissance biométrique, appelée biométrie, est une technologie qui identifie les personnes grâce à des analyses statistiques en acquérant des informations biométriques telles que les caractéristiques physiologiques et comportementales du corps humain.

Agrawal et al. (2020), présentent une architecture basée sur le réseau de neurones à convolution (CNN) pour la reconnaissance faciale dans un environnement sans contrainte. Pour protéger les informations médicales, un système de partage d'informations médicales robuste et sans perte utilisant la méthode de crypto-filigranage est proposé par (Aparna et al., (2019)). Dans (Betouaf et al., 2020), les auteurs proposent un algorithme de vérification d'identité automatique basé sur la structure du réseau vasculaire de la rétine humaine. Plus précisément, le gabarit biométrique est constitué des coordonnées géométriques des points de bifurcation et des croisements des branches du réseau vasculaire. L'objectif principal de ce travail est de parvenir à un système performant tout en minimisant le temps de traitement et la taille des données manipulées.

Il existe différents types d'informations biométriques dans le corps; par exemple, la reconnaissance faciale, les empreintes digitales, l'iris, la main, la voix....etc. Jain et al. (2004) sont parmi les premiers à décrire c'est quoi la reconnaissance biométrique, ou simplement la biométrie, faisant référence à la reconnaissance automatique des individus en fonction de leurs caractéristiques physiologiques et/ou comportementales. En utilisant la biométrie, il est possible de confirmer ou d'établir l'identité d'un individu en se basant sur "qui elle est", plutôt que sur "ce qu'elle possède".

Dans notre contexte, nous allons parler sur l'utilisation des signaux physiologiques et plus particulièrement le signal ECG pour l'identification des individus. En effet, l'utilisation des enregistrements ECG a dépassé le domaine médical en tant que diagnostic clinique pour devenir un outil biométrique potentiellement intéressant.

Comme expliqué dans le chapitre I, le cœur est un organe musculaire qui assure l'activité électrique liée aux variations du potentiel électrique des cellules spécialisées dans la contraction (myocarde) et des cellules spécialisées dans l'automatisation et la conduction des impulsions. Chaque personne a une forme de cœur différente et un corps approprié, où le signal ECG se propage sur la surface de la peau à travers les tissus conjonctifs du corps. Ces différences morphologiques se reflètent dans les signaux ECG, grâce auxquels nous pouvons confirmer la biométrie.

Depuis 2001, les chercheurs qui ont étudié le contrôle d'accès au système, ont confirmé que les signaux ECG sont un type d'information biométrique qui satisfait les conditions mentionnées ci-dessus. Wübbeler et al. (2007) ont effectué une étude de faisabilité sur le potentiel de l'électrocardiogramme (ECG) pour des applications biométriques est présentée. La méthode proposée a été testé sur 234 enregistrements ECG de 74 sujets en utilisant des mesures courtes de 10 s de longueur.

De nombreuses méthodes utilisant l'ECG pour l'identification humaine ont été proposées. Par exemple, Fratini et al (2015) ont réalisé une étude visait à fournir une enquête sur les techniques utilisées dans l'identification humaine basée sur l'ECG. Plus précisément, une perspective de reconnaissance de formes a été proposée, fournissant un cadre unificateur pour apprécier les études antérieures et, espérons-le, guider les recherches futures. Wang et al. (2006) ont identifié des sujets humains à partir de signaux d'électrocardiogramme (ECG). Les enregistrements ECG sont segmentés en battements cardiaques individuels en fonction de la localisation des pics d'onde R. Deux types de caractéristiques sont pris, à savoir les caractéristiques analytiques et d'apparence. Elles sont extraites pour représenter les caractéristiques du signal de battement cardiaque de différents sujets. La sélection des fonctionnalités est effectuée pour découvrir les attributs significatifs.

D'après les travaux scientifiques cités ci-dessus, nous pouvons remarquer que le signal ECG est largement utilisé comme information permettant d'identifier les personnes. Ces systèmes biométriques basés sur l'ECG peuvent être classés selon des techniques d'acquisition de données, de prétraitement, l'extraction de caractéristiques et de classification. L'étape d'extraction de caractéristiques peut avoir un impact considérable sur les performances du système biométrique comme montré dans de nombreuses recherches. Tantawi et (2012) ont développé une étude afin d'évaluer l'applicabilité et/ou la pertinence des données PhysioNet ECG pour les applications biométriques. Les données sont collectées auprès de sujets dans un cadre médical, dans le but d'acquérir des informations cliniquement pertinentes auprès des patients. En raison de la commodité offerte par Internet, des milliers d'enregistrements ECG peuvent être téléchargés et utilisés à des fins non médicales, telles que la biométrie. Dans Rezki et al. (2015), les auteurs ont présenté

une nouvelle approche pour l'identification personnelle à partir des signaux d'électrocardiogramme. Après un prétraitement du signal ECG, des points de repères ont été détectés pour chaque battement de cœur. Trois types de caractéristiques sont ensuite extraits, à savoir les attributs temporels, les attributs d'amplitude et les descripteurs morphologiques. Le modèle de Markov caché a été utilisé pour l'analyse des paramètres et la reconnaissance personnelle. Une combinaison entre 21 caractéristiques et 10 paramètres morphologiques a été effectuée dans un seul système afin d'apporter une amélioration plus significative en termes de reconnaissance. Dans un autre travail, des chercheurs ont proposé une nouvelle approche pour l'identification de personnes et l'authentification de nouvelles personnes à l'aide d'un électrocardiogramme humain à une seule dérivation. Neuf paramètres de caractéristique ont été extraits de l'ECG dans le domaine spatial pour la classification (Venkatesh et al., 2010).

Bassioni et al. (2016) présentent une technique d'apprentissage automatique pour l'identification de personnes à l'aide d'électrocardiogrammes (ECG). La technique proposée consiste en quatre processus ; à savoir, l'acquisition de données, le prétraitement, l'extraction de caractéristiques et la classification. L'ensemble de données a été collecté à partir de la base de données MIT-BIH Arrhythmia travaillant sur 30 sujets utilisant la sonde II (MLII) obtenue en plaçant les électrodes sur la poitrine. Le deuxième processus concerne la réduction du bruit dans l'ECG en supprimant la dérive de la ligne de base, les interférences de la ligne électrique et le bruit à haute fréquence.

Dans (Hejazi et al., 2016), les auteurs proposent un nouveau cadre non fiducial pour la vérification biométrique ECG utilisant des méthodes de noyau pour réduire à la fois la dimensionnalité et le système de reconnaissance des vecteurs d'autocorrélation élevés après le débruitage des signaux de 52 sujets avec la transformée discrète en ondelettes (DWT).

Dans notre travail, nous avons Développé une nouvelle application en télémédecine pour l'identification des patients en utilisant la transformée en ondelettes continue (CWT) et les réseaux de neurones convolutifs (CNN). La méthode proposée est très prometteuse et offre des résultats d'identification très satisfaisante.



## **V.2. Schéma fonctionnel du système**

La Figure V.1 représente le schéma fonctionnel du système. L'objectif à travers le schéma présenté est de développer un nouveau système flexible qui permet l'identification d'un patient en détresse en vue d'obtenir de meilleurs soins médicaux. Le système se compose principalement de deux parties :

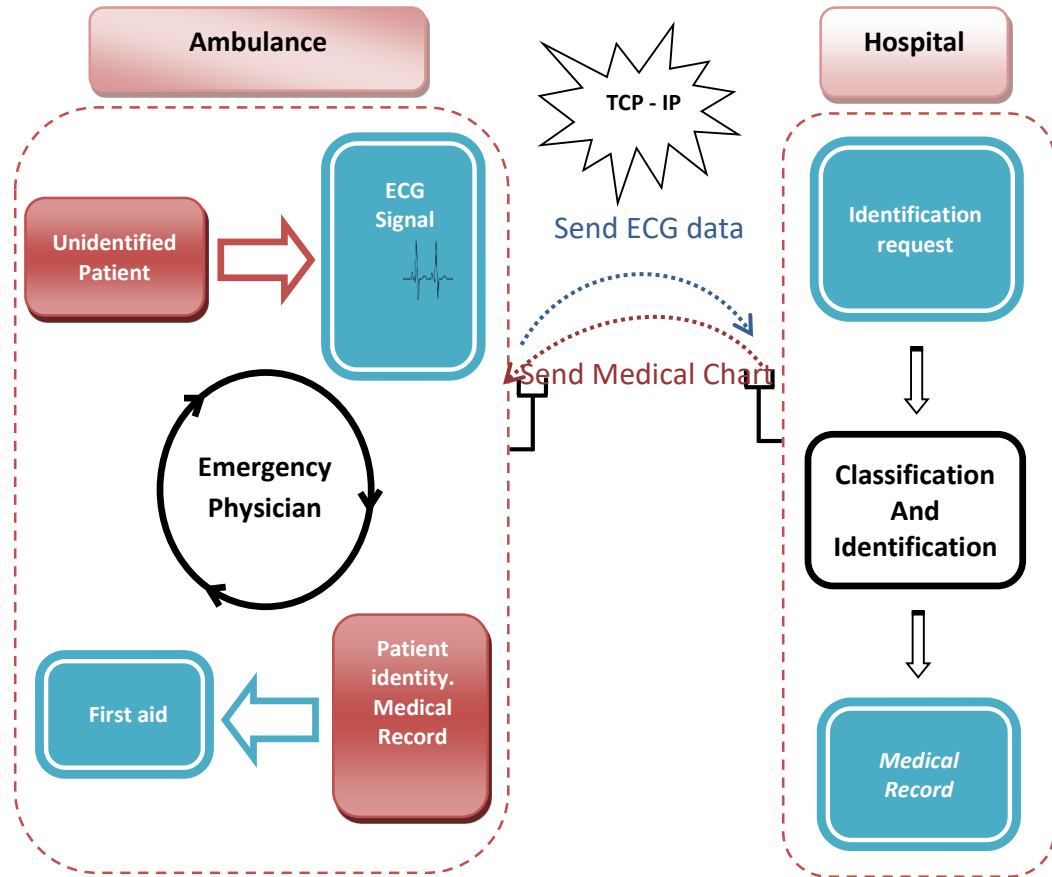
1- Au niveau de l'ambulance : Dans un premier temps le médecin urgentiste effectue un enregistrement de l'ECG relevé du patient non identifié (inconnu).

2- L'unité hospitalière va recevoir les données ECG afin d'identifier le patient. Les résultats d'identification ainsi que le dossier médical vont être transmis au médecin urgentiste dans l'Ambulance.

Dans la majorité des cas, on retrouve des patients inconscients en détresse dans les rues sans aucune identité. A ce stade, la population a l'habitude d'utiliser le Smartphone sécurisé par un code comme pièce d'identité. En pensant à cette situation, nous avons proposé un nouveau système.

Les ambulances sont souvent équipées d'un ECG mobile. Le personnel qui y travaille effectue un examen régulier de l'ECG obtenu à partir d'un patient. Les informations enregistrées seront envoyées à l'hôpital via le protocole TCP/IP. Comme rappel, la plupart des protocoles de communication à travers le monde sont bâtis autour du TCP/IP : Transmission Control Protocol/Internet Protocol. Ces protocoles ont des spécifications qui permettent à plusieurs machines de communiquer entre elles. Le TCP/IP représente l'ensemble des règles de communication sur internet et se base sur la notion d'adressage IP qui représente une adresse unique attribuée à chaque ordinateur.

À l'hôpital, le personnel reçoit les données ECG et les examine pour identifier le patient. L'identité et le dossier médical seront envoyés à l'Ambulance pour que le médecin urgentiste connaisse les antécédents médicaux du patient. Les informations transmises permettent d'éviter les erreurs médicales.



**Figure V.1 :** L'Architecture du système d'indentification proposé

### V.3. Base de données utilisées

Les différents tests ont été effectués sur la base de données Fantasia, disponible gratuitement sur Physionet (*PhysioBank database*, 2016 ; Goldberger et al, 2000). La base de données utilisée comprend 40 signaux simultanément enregistrés (20 vieux de 68 à 85 ans et 20 jeunes de 20 à 34 ans). La fréquence d'échantillonnage est de 250 Hz. Tous les sujets sont dans un état de repos regardant le film Fantasia (Disney, 1940) pour aider à maintenir les personnes en vigilance. Chaque enregistrement comprend des signaux ECG et respiratoire. 20 enregistrements (f1y01, f1y02, ..... f1y10 et f2y01, f2y02, ...f2y10) sont obtenus à partir des sujets jeunes, et 20 autres (f1o01, f1o02, ..... f1o10 et f2o01, f2o02, .....f2o10) sont obtenus à partir des sujets âgés.

Dans notre étude, nous avons utilisé 11 sujets parmi les 20 sujets. Pour chaque sujet, nous avons extrait un segment de 100 secondes puis nous avons divisé chaque segment en 10 segments de 10 secondes. Les enregistrements sont stockés dans un tableau avec deux champs : Données et Étiquettes. Le champ Données est une matrice de 110 x 2500 où chaque ligne est un enregistrement ECG échantillonné à 250 hertz. Les étiquettes sont représentées dans un tableau de cellules de 110 par 1 d'étiquettes de diagnostic, une pour chaque ligne de données.

Les catégories de classification sont représentées dans le **tableau V.1**.

Categories (Labels)	Inscription dans la base de données	Informations	Nombre de segments extraits
P1	f1o01	Age : 77 Sex: F	10
P2	f1o02	Age: 73 Sex: F	10
P3	f1o03	Age: 73 Sex: M	10
P4	f1y04	Age: 31 Sex: M	10
P5	f1o05	Age: 76 Sex: M	10
P6	f1o06	Age: 74 Sex: F	10
P7	f1o07	Age: 68 Sex: M	10
P8	f1o08	Age: 73 Sex: F	10
P9	f1o09	Age: 71 Sex: M	10
P10	f1o010	Age: 71 Sex: F	10
P11	f1y01	Age: 23 Sex: F	10

**Tableau V.1** : Représentation des données en catégories de classification

La figure V.2 montre un aperçu des signaux ECG de chaque personne {p1, p2, p3, p4, p5, p6, p7, p8, p9, p10, p11} pendant quatre secondes ou 1000 points.




Figure V.2 : L'ensemble des signaux ECGs pour les différentes personnes

#### V.4. Présentation de la méthode proposée

Dans l'étape suivante, nous créons des représentations temps-fréquence des signaux ECG. Ces représentations sont appelées scalogrammes. Un scalogramme est la valeur absolue des coefficients CWT d'un signal. Pour les créer, nous précalculons une banque de filtres CWT, chaque image RVB est un tableau de taille 224-by-224-by-3. Enfin, nous chargeons les images des scalogrammes en tant qu'images d'entrée.

La figure V.3 montre un schéma fonctionnel de notre détecteur biométrique utilisant GoogleNet pré-entraîné pour la reconnaissance d'images, afin de classer les formes d'onde ECG en fonction d'une représentation temps-fréquence :

Étape (1) Appliquez le CWT aux signaux ECGs pour générer une représentation semblable à une image.

Étape (2) Extraction des caractéristiques.

Étape (3) Classification.

Étape (4) Utiliser les informations biométriques dans les services de sécurité et les urgences hospitalières.




Figure V. 3 : Schéma bloc de la méthode proposée

### Extraction de caractéristiques à l'aide d'un GoogLeNet pré-entraîné

GoogLeNet est composé de plusieurs couches appelées couches d'inception. L'idée de base est d'avoir des filtres en parallèle avec des champs récepteurs de taille multiple (pyramide spatiale). Cette architecture contient 9 modules 'inception'. Elle consiste à la concaténation des cartes de caractéristiques obtenus à la sortie des quatre modules de convolution de taille  $1 \times 1$ ,  $3 \times 3$  et  $5 \times 5$  mises en parallèle. GoogLeNet comprend 22 couches de profondeur en ne comptant que les couches avec paramètres (ou 27 couches si on compte aussi le pooling) et nécessite des images d'entrée d'une taille de  $224 \times 224 \times 3$  (voir chapitre III).

A l'origine, GoogLeNet est conçu pour classer les images dans 1000 catégories. Nous le réformons pour notre problème de classification ECG pour éviter le surajustement.

Une couche de décrochage est utilisée. Une couche d'abandon définit de manière aléatoire les éléments d'entrée à zéro avec une probabilité donnée. La probabilité par défaut est de 0,5. Nous avons remplacé la dernière couche de décrochage du réseau par une couche de décrochage de probabilité 0,6.

Les couches de convolutions du réseau extraient les caractéristiques de l'image, et la couche de classification finale est utilisée pour classer l'image d'entrée.

### **Classification ECG (Fully-connected layer)**

La couche finale est la couche entièrement connecté (en anglais fully connected layer), dont la sortie est utilisée pour effectuer la classification. Après un nombre spécifique de convolutions, ReLU and Max pooling, la couche fully-connected s'applique sur une entrée préalablement aplatie où chaque entrée est connectée à tous les neurones. Cette couche fonctionne exactement de la même manière qu'un réseau feed-forward traditionnel (voir chapitre III).

Nous avons utilisé 100 secondes de données ECG divisées en segment de 10 secondes pour chaque personne, qui donne un nombre total de segments de 110. Au hasard, nous avons divisé les images en deux groupes, un pour l'apprentissage et l'autre pour la validation. Nous avons utilisé 60% = 66 des images pour la phase d'apprentissage, et le reste 40% = 44 pour la validation.

## **V.5. RÉSULTATS ET DISCUSSION**

Dans cette partie, une présentation des différents résultats obtenus sera faite. La méthode proposée est testé sur les différents enregistrements ECG de la base de données Fantasia.

Comme mentionner ci-avant, le CNN accepte les images RVB (red, green, blue). Ainsi, il est nécessaire dans un premier temps de convertir les données ECG en images en utilisant la transformée en ondelettes continue (CWT). Le CWT appliqué aux formes d'onde ECG donne des images dans le plan temps-fréquence.

Le CWT est donné par :

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \Psi\left(\frac{t-b}{a}\right) x(t) dt$$

Où:  $\psi(t)$  représente l'ondelette mère.

$a$  et  $b$  sont respectivement les facteurs d'échelle (ou de dilatation) et de translation.

Les images obtenues seront ensuite envoyées au réseau GoogleNet.

Pour qu'elle soit compatible avec l'architecture GoogLeNet, chaque image RGB est configuré en images de taille 224/224/3.

En les transmettons au CNN pré-entraîné pour le test, nous avons utilisé 110 images présentant le CWT des signaux ECG, divisé aléatoirement les images en deux groupes.

Le tableau V.2 et la figure V.4 montrent les résultats de classification et les paramètres de performance de CNN pendant les séries d'entraînement et de test. Ces résultats sont très satisfaisants avec une validation à 97,75%.

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Validation Accuracy	Mini-batch Loss	Validation Loss	Base Learning Rate
1	1	00:00:19	0.00%	11.36%	2.6278	2.3565	1.0000e-04
3	10	00:01:14	13.33%	29.55%	2.4453	2.0973	1.0000e-04
5	20	00:02:14	46.67%	81.82%	1.6814	1.6573	1.0000e-04
8	30	00:03:14	73.33%	95.45%	1.2731	1.2064	1.0000e-04
<b>10</b>	<b>40</b>	<b>00:04:18</b>	<b>100.00%</b>	<b>97.73%</b>	<b>0.6813</b>	<b>0.8067</b>	<b>1.0000e-04</b>
<b>13</b>	<b>50</b>	<b>00:05:26</b>	<b>93.33%</b>	<b>97.73%</b>	<b>0.5741</b>	<b>0.5273</b>	<b>1.0000e-04</b>
<b>15</b>	<b>60</b>	<b>00:06:26</b>	<b>100.00%</b>	<b>97.73%</b>	<b>0.3091</b>	<b>0.3269</b>	<b>1.0000e-04</b>
<b>18</b>	<b>70</b>	<b>00:07:26</b>	<b>86.67%</b>	<b>97.73%</b>	<b>0.2689</b>	<b>0.2377</b>	<b>1.0000e-04</b>
<b>20</b>	<b>80</b>	<b>00:08:29</b>	<b>100.00%</b>	<b>97.73%</b>	<b>0.1615</b>	<b>0.2032</b>	<b>1.0000e-04</b>

**Tableau V.2** : Analyse des résultats de la classification CNN (architecture GoogLeNet)




Figure V.4 : Analyse des résultats de la classification CNN (GoogLeNet architecture)

Le tableau V.3 résume la performance de notre méthode par rapport à d'autres méthodes utilisant la même base de données. Dans notre travail, les méthodes proposées sont basées sur des signaux ECG à dérivation unique qui peuvent être utilisés comme méthode peu coûteuse d'identification et non invasive par rapport aux méthodes les plus conventionnelles.

Method	Classifier	Accuracy (%)
<b>Our method</b>	<b>CWT-CNN(GoogLeNet)</b>	<b>97.75%</b>
Chantaf et al., (2010)	Wavelet networks	92.00%
Bassiouni et al., (2016)	(AC/DCT) and artificial neural network (ANN)	97.00%
Bak et al., (2020)	Temporal-Amplitude CombinedFeatureVectors	>94%
Zhao et al., (2013)	Ensemble empirical mode decomposition, and the K-nearest neighbors (K-NN)	95%
Louis et al. (2016)	Multi-Resolution Local Binary Patterns (1DMRLBP)	92.11%

**Tableau V.3 :** Comparaison des résultats obtenus par rapport à d'autres méthodes existantes dans la littérature



## V.6. Conclusion

Nous avons présenté un travail utilisant les réseaux de neurones convolutifs avec une analyse par ondelettes continue (CWT) pour l'identification biométrique par le signal électrocardiogramme (ECG). La méthode proposée est testée sur la base de données Fantasia disponible gratuitement sur Physionet. Pour créer des scalogrammes, des représentations temps-fréquence basées sur une analyse en ondelettes continue des signaux ECGs (CWT) est obtenues. Des images RVB des scalogrammes sont générées qui sont ensuite été utilisées comme entrées du réseau de neurones convolutif (CNN). Les activations de différentes couches du réseau ont également été explorées.

Les résultats obtenus montrent des performances plus intéressantes par rapport aux méthodes ANN, K-NN, 1DMRLBP, Temporal-Amplitude CombinedFeatureVectors et réseaux d'ondelettes.

## Bibliographie

- Agrawal, A.K and Singh, Y. N. (2020) 'Unconstrained face recognition using deep convolution neural network', *International Journal of Information and Computer Security*, Vol.12, No.2/3, pp.332 – 348.
- Aparna, P. and Kishore, P.V.V. (2019) 'A Blind Medical Image Watermarking for Secure E-Healthcare Application Using Crypto-Watermarking System', *Journal of Intelligent Systems*, Vol.29, No.1, pp.1558 – 1575.
- Bak, E., Choi, G. and Pan, S. B. (2020) 'ECG-Based Human Identification System by Temporal-Amplitude Combined Feature Vectors', *IEEE Access*, Vol.8, pp.42217 - 42230.
- Bassiouni, M., Khalefa, W., El-Dahshan, E. A. and Salem, A. M. (2016) 'A Machine Learning Technique for Person Identification Using ECG Signals', *International Journal of Applied Physics*, Vol.1, pp.37-41.
- Betaouaf, T. H., Decencièrre, E. and Bessaid, A. (2020) 'Automatic biometric verification algorithm based on the bifurcation points and crossovers of the retinal vasculature branches', *International Journal of Biomedical Engineering and Technology*, Vol.32, No.1, pp.66 – 82.
- Chantaf, S., Nait-Ali, A., Karasinski, P. and Khalil, M. (2010) 'ECG modelling using wavelet networks: application to biometrics', *International Journal of Biometrics*, Vol.2, No.3, pp.236-249.
- Fratini, A., Sansone, M., Bifulco, P. and Mario Cesarelli (2015) 'Individual identification via electrocardiogram analysis', *BioMed Eng OnLine*, Vol. 14, No.78,pp.1-23.
- Goldberger, A., Amral, L., Glass, L., Hausdorff, J., Ivanov, P., Mark, R., Mietus, J., Moody, G., Peng, C., and Stanley, H. (2000) 'Physiobank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals', *Circulation*, Vol. 101, No. 23, pp.215–220
- Hejazia, M., Al-Haddada, S.A.R., Shaiful, Y. P. S. and Abdul Aziz J. H. A. F. (2016) 'ECG biometric authentication based on non-fiducial approach using kernel methods', *Digital Signal Processing*, Vol.52, pp.72-86.

- Jain, A.K., Ross, A. and Prabhakar, S. (2004) 'An introduction to biometric recognition', IEEE Transactions on Circuits and Systems for Video Technology, Vol. 14, No.1, pp.4-20.
- Louis, W., Komeili, M. and Hatzinakos, D. (2016) 'Continuous Authentication Using One-Dimensional Multi-Resolution Local Binary Patterns (1DMRLBP) in ECG Biometrics', IEEE Transactions on Information Forensics and Security, Vol.11, No.12, pp. 2818 - 2832.
- PhysioBank database.* (2016) [online] <https://physionet.org/physiobank/database/fantasia/>
- Rezgui, D. and Lachiri, Z. (2015) 'Human identification system based on ECG features', International Journal of Biomedical Engineering and Technology, Vol. 19, No.1, pp.99-103.
- Tantawi, M. M., Revett, K., Tolba, M. F. and Salem, A. (2012) 'An evaluation of the generalisability and applicability of the PhysioNet electrocardiogram (ECG) repository as test cases for ECG-based biometrics', International Journal of Cognitive Biometrics, Vol.1, No.1, pp.66-97.
- Venkatesh, N. and Jayaraman, S. 'Human Electrocardiogram for Biometrics Using DTW and FLDA', 20th International Conference on Pattern Recognition, 23-26 August 2010, Istanbul, Turkey.
- Wang, Y., Plataniotis, K.N. and Hatzinakos, D. (2006) 'Integrating Analytic and Appearance Attributes for Human Identification from ECG Signals', Biometrics Symposium: Special Session on Research at the Biometric Consortium Conference.
- Wübbeler, G., Stavridis, M., Kreiseler, D., Bousseljot, R. and Elster, C. (2007) 'Verification of humans using the electrocardiogram', Vol.28, No.10, pp.1172-1175.
- Zhao, Z., Yang, L., Chen, D. and Luo, Y., (2013) 'A Human ECG Identification System Based on Ensemble Empirical Mode Decomposition', Sensors (Basel), Vol.13, No.5, pp.6832–6864.

## **CONCLUSION GENERALE**

Cette thèse a été consacrée à réalisation d'un système de surveillance cardiaque et respiratoire à distance.

Comme première étape, une nouvelle conception d'électrocardiographe portable sans fil a été réalisée. Le prototype conçu permet de garder un contact permanent entre les patients et leurs médecins traitants. Les différentes informations sont transmises à distance grâce à un Smartphone. Il s'agit d'enregistrer le signal ECG et d'extraire le signal respiratoire à partir du signal ECG à partir d'un programme rédigé sur Smartphone dans un langage approprié.

La deuxième étape de notre travail nous a amené à développer un prototype spécifiquement dédié aux patients atteints de la maladie d'apnée du sommeil. Dans cette étape de travail, nous avons utilisé la transformée en ondelette continue (CWT) et le réseau neuronal convolutionnel (CNN) pour classer les signaux en deux catégories 'Apnée' et 'normal'. Les architectures CNN, GoogLeNet et SqueezeNet ont été choisis. Le signal utilisé est l'ECG obtenu à partir d'une seule dérivation. Les informations obtenues seront transmises au médecin. Le prototype proposé va permettre une surveillance continue et à distance des patients atteints de la maladie d'apnée du sommeil. L'application peut être généralisée sur d'autres maladies qui nécessitent une surveillance continue du malade.

Les résultats obtenus vont sans doute servir à aider le médecin dans son diagnostic. Elle peut aussi être utilisée pour aider à déterminer la présence d'une apnée du sommeil et de détecter les troubles dans le signal ECG causés par le signal respiratoire sans les considérer comme étant des pathologies cardiaques.

L'étape suivante de notre travail consistait à trouver un algorithme performant en vue d'une identification biométrique basé sur les paramètres du signal ECG. L'avantage de la méthode proposée est d'extraire les informations à partir d'un seul signal. L'application développée utilise la transformée en ondelettes continue (CWT) et les réseaux de neurones convolutifs

(CNN). La méthode proposée est très prometteuse et offre des résultats d'identification très satisfaisante.

En perspective, il serait intéressant d'approfondir les recherches sur les différentes techniques (technologies) de l'information et de la communication (TIC). Ces technologies recouvrent tous les nouveaux moyens et outils qui permettent de traiter (matériels et logiciels de traitement), transmettre (réseaux et moyens de transmission et d'échange), de conserver (les supports de stockage) l'information électronique. Nous espérons qu'à travers le développement du réseau d'internet à travers le monde, profiter des différentes technologies qui en ressortent pour améliorer la qualité des informations transmises.

Des améliorations peuvent être aussi faites au niveau du processus de classification. Nous pouvons par exemple utiliser des architectures plus appropriés de réseaux de neurones convolutionnels (CNN).

Les différents algorithmes développés dans le cadre de cette thèse, après des tests de validation à grande échelle, vont servir à l'élaboration d'un prototype très fiable pour une surveillance à distance des malades.