

*République Algérienne Démocratique et Populaire*  
*Ministère de l'Enseignement Supérieur et de la Recherche*  
*Scientifique*

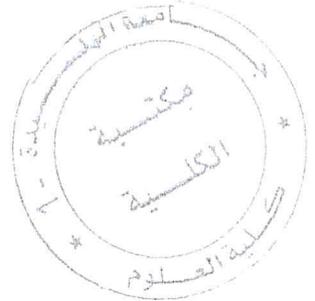
*Université Saad Dahlab Blida1*



*Faculté des sciences*  
*Département d'Informatique*

*Pour l'obtention du diplôme de Master en Informatique*

*Option : Ingénierie des logiciels*



**Thème :**

*Développement d'un système de classification des arythmies cardiaques en utilisant les réseaux de neurones artificiels.*



**ORGANISME D'ACCUEIL :**

**Réalisé par :**

- Mellas Chahinez
- Bouarioua Hiba Sabriya

**Président du Jury :** Mr Chi Khi.

**Promoteur :** Mme TO

- Mr Kameche

**Encadreur :**

- Mr Bengherabi Messaoud
- Mme Toubaline.

MA-004-374-1

# *Remerciements*

*Louange à Dieu le tout puissant de nous avoir permis de réaliser dans de très bonnes conditions, ce modeste travail en tonifiant toute l'énergie dont il a bien voulu nous investir.*

*A notre co-encadreur,  
M' Touazi Azzedine,*

*Pour votre disponibilité, votre gentillesse et votre confiance,  
Pour votre aide précieuse dans la réalisation de ce travail,  
Veuillez accepter ce travail comme le témoignage de notre reconnaissance, de notre admiration et de notre profond respect.*

*A notre promoteur,  
M' Kameche Hicham ,*

*Pour l'honneur que vous nous avez fait en acceptant de nous encadrer pour la réalisation de ce travail,*

*Pour l'intérêt particulier que vous nous avez accordé,  
Pour votre confiance et vos encouragements,*

*Veuillez recevoir l'expression de notre sincère reconnaissance.*

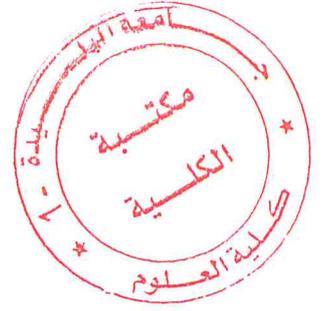
*Aux membres du jury,*

*Pour nous avoir fait l'honneur d'accepter de siéger dans ce jury et d'examiner cette thèse,  
Pour vos enseignements et vos encouragements au début de notre cursus,  
Soyez assuré de notre très sincère gratitude et notre profond respect.*

*A notre encadreur Mr Bengherabi Messaoud et à tout le personnel du CDTA, en particulier ceux de la division Telecom,*

*Pour leur contribution à la réalisation de ce travail,*

*Veuillez recevoir notre gratitude et nos sincères remerciements.*



## *Je dédie ce mémoire à*

### *Mes parents,*

*Ma mère, qui a œuvré pour ma réussite, par son amour, son soutien, tous les sacrifices consentis et ses précieux conseils, pour toute son assistance et sa présence dans ma vie, qu'elle reçoit à travers ce modeste travail, l'expression de mes sentiments et de mon éternelle gratitude.*

*Mon père, qui peut être fier de trouver ici le résultat de longues années de sacrifices et de privations pour m'aider à avancer dans la vie. Puisse Dieu faire en sorte que ce travail porte son fruit ; Merci pour les valeurs nobles, l'éducation et le soutien permanent venu de toi.*

*A mes frères et sœur Nassim, Anis et Nassima qui n'ont cessé d'être pour moi des exemples de persévérance, de courage et de générosité.*

*A mon fiancé Walid, aucun mot ne saurait t'exprimer mon profond attachement et ma reconnaissance pour l'amour, la tendresse et la gentillesse dont tu m'as toujours entouré.*

*J'aimerais bien que tu trouves dans ce travail l'expression de mes sentiments de reconnaissance les plus sincères car grâce à ton aide et à ta patience avec moi que ce travail a pu voir le jour... Que Dieu le tout puissant nous accorde un avenir meilleur.*

*A mon promoteur M<sup>r</sup> Kameche et mon co-encadreur M<sup>r</sup> Touazi Azzedine.*

*A tous mes amis, plus particulièrement ; Wassila, Oussama et Meriem en Témoignage de mon amitié sincère.*

*À celle qui a su m'écouter, supporter ma mauvaise humeur, mes angoisses et mon caractère, ma meilleure amie IHCENE, que je remercie infiniment pour sa patience, sa gentillesse, son aide et sa grande générosité.*

**Chahinez**

# Dédicace

Je dédie ce modeste travail tout d'abord à mes chers parents,  
qui m'ont soutenu pendant tout le parcours,

Ainsi qu'à ma sœur Doha et mon frère Omar

Je le dédie aussi à tous mes amis, en particulier Asma,  
Sofia, Imene, Nouredine, Fatma, Riad, Adlene, Karima,  
Meriem, Mounir, Sana... et tant d'autre

A Ma famille et particulièrement à mes cousine Zineb et  
Meriem, mes grand mères pour qui j'ai une forte pensée.

Et une dédicace particulière à une personne très cher à mon  
cœur et pour qui je porte beaucoup d'estime et beaucoup  
d'amour « Abd-Elbasset » .

Aussi à notre promoteur Monsieur Kamech, à notre co-  
encadreur Mr Touazi.

Et enfin à tous ceux qui ont contribué de près ou de loin

A cette réussite inchallah .

Hiba

## **Résumé :**

L'électrocardiogramme (ECG) est l'examen le plus couramment effectué, ce dernier est rapide à mettre en place, peu coûteux et surtout non invasif donc très peu contraignant pour le patient, facilite le diagnostic de certaines arythmies cardiaques. Il représente les variations de l'activité électrique du cœur en fonction du temps.

La classification des battements du signal ECG en différents cas pathologiques est une tâche de reconnaissance très complexe. Ce document présente un système performant pour la classification des arythmies cardiaques en utilisant les réseaux de neurones artificiels.

Dans le système développé, pour la phase prétraitement, nous avons utilisé deux filtres médians ainsi qu'un filtre passe-bas. Ensuite, nous avons segmenté le signal à l'aide d'un expert ou d'un algorithme de détections des pics R. Pour la phase de l'extraction des caractéristiques, nous avons utilisé une approche hybride tel que le vecteur R extrait de la phase précédente sera concaténé avec l'une des transformées suivantes : la transformée en ondelette discrète (DWT pour Discrete Wavelet Transform) ou la transformée en cosinus discrète (DCT pour Discrete Cosine Transform).

Enfin nous avons classifié ces signaux en entraînant un réseau de neurones artificiel (ANN pour Artificial Neural Networks) sur quatre classes (N, A, V ou R).

Notre système est développé en MATLAB R2015a et a été validé sur des signaux réels de la base de données MIT\_BIH Arrhythmia qui est considérée comme une base de référence dans l'étude des signaux ECG

**Mots-clés :** L'électrocardiogramme, la classification des battements du signal ECG, les réseaux de neurones artificiels, filtres médians, filtre passe-bas, détections des pics R, l'extraction des caractéristiques, la transformée en ondelette discrète, la transformée en cosinus discrète.

**Abstract:**

The electrocardiogram (ECG) is the most commonly performed examination, the latter is quick to set up, inexpensive and above all non-invasive and therefore very little constraining for the patient, facilitates the diagnosis of certain cardiac arrhythmias. It represents the variations of the electrical activity of the core as a function of time.

The classification of the beats of the ECG signal in different pathological cases is a task of recognition very complex. This paper presents an efficient system for the classification of cardiac arrhythmias using artificial neural networks.

In the developed system, for the pretreatment phase, we used two middle filters as well as a low-pass filter. We then segmented the signal using an expert or a R-peak detection algorithm. For the extraction phase of the characteristics, we used a hybrid approach such as the R vector extracted from Phase will be concatenated with one of the following transforms: the Discrete Wavelet Transform (DWT) or the discrete Cosine Transform (DCT).

Finally, we classified these signals by training an Artificial Neural Network (ANN) for four classes (N, A, V or R).

Our system is developed in MATLAB R2015a and has been validated on real signals from the MIT\_BIH Arrhythmia database which is considered as a reference base in the study of ECG signals

**Keywords:** electrocardiogram, classification of ECG signal beats, artificial neural networks, median filters, low-pass filter, R-peak detections, characteristic extraction, discrete wavelet transform, transform Cosine discreet.

## ملخص:

تخطيط القلب (ECG) هو الفحص الأكثر شيوعاً، وهذا الأخير هو سريع لاقامة، وغير مكلفة وقبل كل شيء غير الغازية، وبالتالي تقييد جداً للمريض، ويسهل تشخيص عدم انتظام ضربات القلب معينة. وهو يمثل الاختلافات في النشاط الكهربائي من جوهر كدالة من الزمن.

تصنيف يديق إشارة ECG في الحالات المرضية المختلفة هي مهمة الاعتراف معقدة للغاية. تقدم هذه الورقة نظام فعال لتصنيف عدم انتظام ضربات القلب باستخدام الشبكات العصبية الاصطناعية.

في النظام المتقدم، لمرحلة المعالجة المسبقة، استخدمنا اثنين من المرشحات المتوسطة فضلاً عن مرشح تمريرة منخفضة. ثم قمنا بتقسيم الإشارة باستخدام خوارزمية الكشف أو خوارزمية الكشف عن الذروة R. وبالنسبة لمرحلة الاستخلاص من الخصائص، استخدمنا نهجاً هجيناً مثل ناقلات R المستخرجة من المرحلة سوف تكون متسلسلة مع واحدة من التحويلات التالية: تحويل الموجة المنفصلة (DWT) أو تحويل جيب التمام منفصلة (DCT). وأخيراً، قمنا بتصنيف هذه الإشارات من خلال تدريب الشبكة العصبية الاصطناعية (ANN) لأربع فئات (A، N، V أو R). تم تطوير نظامنا في ماتلاب R2015a وتم التحقق من صحة على إشارات حقيقية من قاعدة بيانات MIT\_BIH عدم انتظام ضربات القلب التي تعتبر قاعدة مرجعية في دراسة إشارات تخطيط القلب

**كلمات البحث:** تخطيط القلب الكهربائي، تصنيف نبضات إشارة تخطيط القلب، الشبكات العصبية الاصطناعية، المرشحات المتوسطة، مرشح التمرير المنخفض، الكشف عن الذروة، الاستخلاص المميز، تحويل الموجات المنفصلة، التحويل جيب التمام سرية.

## Table des matières

### Introduction Générale

### Chapitre 1 : Généralités sur le signal ECG

1. Introduction .....	1
2. Le cœur .....	1
2.1. Anatomie et activité musculaire du cœur .....	1
3. L'électrocardiographie .....	2
3.1 Définition.....	2
3.2 Principe de fonctionnement.....	3
3.2 Enregistrement de l'électrocardiogramme et dérivations .....	4
3.3 L'ECG de Holter .....	6
4. Tracé électrique du cœur .....	7
5. Intervalles temporels .....	9
6. A quoi sert l'électrocardiogramme ?.....	10
7. Le traitement automatisé des signaux ECG.....	11
8. Conclusion.....	12

### Chapitre 2 : Apprentissage

1. Introduction .....	13
2. L'apprentissage .....	13
2.1 Les éléments de l'apprentissage connexionniste .....	13
2.2 Qu'est-ce qu'un algorithme d'apprentissage ?.....	14
3. Méthodes d'apprentissage supervisé.....	16
3.1 Les arbres de décision .....	16
3.2 SVM : Machines à Vecteurs de Support .....	19
3.3 La méthode K-ppv.....	20
3.4 Les Réseaux de neurones artificiels .....	22
3.4.5 Types de neurones .....	26
4. Conclusion.....	38

### Chapitre 3 : Etat de l'art

1. Introduction .....	39
-----------------------	----

2.	Les travaux antérieurs .....	39
2.1	Prétraitement .....	39
2.2	Segmentation .....	41
2.3	Extraction des paramètres.....	42
2.3.1	Extraction de caractéristiques.....	43
2.3.2	Sélection de fonctionnalité .....	47
2.4	Classification .....	49
3.	Tableau comparatif.....	50
4.	Conclusion.....	51

## **Chapitre 4 : Conception**

1.	Introduction .....	53
2.	Conception globale.....	53
2.1	Description .....	53
2.2	Organigramme global.....	54
3.	Conception des différentes phases.....	54
3.1	Conception de la phase « Prétraitement » .....	54
3.1.1	Algorithme de la phase « Prétraitement » .....	55
3.2	Conception de la phase « Segmentation ».....	56
3.2.1	Algorithme de la phase « Segmentation » .....	57
3.3	Conception de la phase « Classification ».....	57
3.3.1	Algorithme de la phase « Classification ».....	59
3.3.2	Conception de la phase « Extraction des paramètres ».....	59
1.1.1	Algorithme de la phase « Extraction des données ».....	61
4.	Le traitement automatique du signal ECG .....	62
4.1	Phase 1 « Le prétraitement » .....	62
4.2	Phase 2 « La segmentation » .....	63
4.3	Phase 3 « Extraction des caractéristiques » .....	66
4.4	Phase 4 « La Classification ».....	69
5.	Conclusion.....	70

## **Chapitre 5 : Implémentation et expérimentation**

1.	Introduction .....	71
----	--------------------	----

2.	Présentation de la base de données.....	<b>Error! Bookmark not defined.</b>
3.	Standards AAMI.....	71
4.	Présentation de l'environnement de travail : .....	72
4.1	Matlab.....	72
5.	Choix et paramétrages des fonctions : .....	72
5.1	Fonctions utilisées pour le Prétraitement : .....	72
5.2	Fonctions utilisées pour la Segmentation : .....	73
5.3	Fonctions utilisées pour l'Extraction des caractéristiques : .....	74
5.4	Fonctions utilisées pour la Classification : .....	75
6.	Test.....	76
7.	Les mesures de performance .....	86
7.1	Évaluation des performances d'un classifieur : .....	86
7.2	Indicateurs de performance en classification.....	86
8.	Conclusion : .....	89

## Liste des figures :

Figure 1. La structure anatomique du cœur.....	2
Figure 2. Principe de fonctionnement de l'ECG.....	4
Figure 3. Les dérivation bipolaires et unipolaires des membres.....	5
Figure 4. Les dérivation précordiales.....	6
Figure 5. Illustration d'un homme portant un Holter.....	7
Figure 6. L'onde électrique d'un battement de cœur.....	8
Figure 7 Différents intervalles dans l'ECG.....	10
Figure 8. Les éléments de l'apprentissage.....	13
Figure 9. Schéma bloc d'apprentissage non-supervisé.....	14
Figure 10. Schéma bloc de l'apprentissage supervisé.....	16
Figure 11. La situation en début d'un match de football est décrite par deux attributs binaires : <i>Match à domicile et Mauvaises conditions climatiques</i> . L'attribut classe prend deux valeurs : <i>gagné et perdu</i> . Un exemple d'arbre de décision.....	17
Figure 12. Schéma montrant un hyperplan.....	20
Figure 13. le principe du fonctionnement d'un classifieur.....	21
Figure 14. Représentation d'un neurone artificiel.....	23
Figure 15. Plusieurs types de voisinages entre neurones. Les neurones en gris représentent les 'voisinage' de celui du milieu.....	25
Figure 16. Modèle du neurone biologique.....	26
Figure 17. Structure détaillée d'un neurone artificiel.....	26
Figure 18. Différentes fonctions d'activation.....	28
Figure 19. La fonction Signe.....	28
Figure 20. La fonction Gaussienne.....	29
Figure 21. Exemple courbe sigmoïde.....	29
Figure 22. Réseau de neurones bouclé.....	31
Figure 23. Réseau de Jordan.....	31
Figure 24. Réseau d'Elman.....	32
Figure 25. Module RNN.....	32
Figure 26. Exemple d'architecture d'un ANN.....	34
Figure 27. Réseau de neurones non bouclé.....	34
Figure 28. Perceptron à une seule couche avec fonction seuil.....	36
Figure 29. Perceptron multicouche.....	37
Figure 30. Organigramme Global.....	54
Figure 31. Organigramme du processus de « Prétraitement ».....	55
Figure 32. Description du processus de « Segmentation ».....	56
Figure 33. Description du processus de Classification.....	59
Figure 34. Description du processus « Extraction des paramètres ».....	60
Figure 35. Distribution des battements dans les différentes classes. Les classes sont, comme attendu, fortement déséquilibrées.....	63
Figure 36. Les paramètres de caractérisation sur un battement cardiaques d'un sujet sain [ $RR_{pré1}$ , $RR_{pré2}$ , $RR_{post1}$ , $RR_{post2}$ ].....	65
Figure 37. Fenêtre de Hamming à 500 échantillons.....	65
Figure 38. Principe de l'algorithme de Mallat.....	67

Figure 39. Décomposition en ondelettes.....	67
Figure 40. Signal ECG du patient 100 filtré par la transformée DCT.....	68
Figure 41. Architecture de l'ANN.....	69
Figure 42. Signal ECG du patient '100' sur l'intervalle [1000,1400] de la base ML.....	76
Figure 43. Signal ECG du patient '100' sur l'intervalle [1000,1400] de la base V.....	77
Figure 44. Signal ECG du patient '100' sur l'intervalle [4000,9000] de la base ML.....	77
Figure 45. Signal ECG du patient '100' sur l'intervalle [4000,9000] de la base V.....	78
Figure 46. Résultat après application du 1er filtre médian sur le signal du patient '100'.....	78
Figure 47. Résultat après application du 2 <sup>ème</sup> filtre médian sur le signal du patient '100'.....	79
Figure 48. Filtre passe-bas d'une fréquence de coupure à 35Hz.....	79
Figure 49. Résultat après application du filtre passe-bas sur le signal du patient '100'.....	80
Figure 50. Fenêtre de Hamming à 500 échantillons.....	80
Figure 51. Résultat de la décomposition en ondelette du signal du patient '100', avec une fenêtre de Haar (1 <sup>er</sup> niveau).....	81
Figure 52. Résultat de la décomposition en ondelette du signal du patient '100', en appliquant une seconde fenêtre de Haar (2 <sup>ème</sup> niveau).....	81
Figure 53. Résultat de l'application de la DCT sur le signal du patient '100'.....	82
Figure 54. Signal résultant de l'application de la DCT sur le signal du patient '100'; tronqué à la fréquence 100.....	82
Figure 55. Signal ECG du patient '116' sur l'intervalle [1000,1400] de la base ML.....	83
Figure 56. Signal ECG du patient '116' sur l'intervalle [1000,1400] de la base V.....	83
Figure 57. Signal ECG du patient '116' sur l'intervalle [4000,9000] de la base ML.....	83
Figure 58. Signal ECG du patient '201' sur l'intervalle [1000,1400] de la base ML.....	83
Figure 59. Signal ECG du patient '201' sur l'intervalle [1000,1400] de la base V.....	83
Figure 60. Signal ECG du patient '201' sur l'intervalle [4000,9000] de la base ML.....	83
Figure 61. Résultat de la décomposition en ondelette du signal du patient '116', avec une fenêtre de Haar (1 <sup>er</sup> niveau).....	84
Figure 62. Résultat de la décomposition en ondelette du signal du patient '116', en appliquant une seconde fenêtre de Haar (2 <sup>ème</sup> niveau).....	84
Figure 63. Résultat de la décomposition en ondelette du signal du patient '201', avec une fenêtre de Haar (1 <sup>er</sup> niveau).....	84
Figure 64. Résultat de la décomposition en ondelette du signal du patient '201', en appliquant une seconde fenêtre de Haar (2 <sup>ème</sup> niveau).....	84
Figure 65. Résultat de l'application de la DCT sur le signal du patient '116'.....	85
Figure 66. Signal résultant de l'application de la DCT sur le signal du patient '116'; tronqué à la fréquence 100.....	85
Figure 67. Résultat de l'application de la DCT sur le signal du patient '201'.....	85
Figure 68. Signal résultant de l'application de la DCT sur le signal du patient '201'; tronqué à la fréquence 100.....	85

## Liste des tableaux :

Tableau 1. La correspondance entre neurone biologique et neurone artificiel.....	30
<b>Tableau 2. Base d'apprentissage DS1 et base de test DS2 de la base de donnée MIT-BIH.....</b>	<b>Error!</b>
<b>Bookmark not defined.</b>	
Tableau 3. Matrice de confusion .....	86
Tableau 4. Un tableau comparatif résumant les tests fait sur notre étude .....	89

***Introduction***  
***Générale***

## INTRODUCTION

Les maladies cardiovasculaires constituent un problème majeur de santé publique, elles sont la première cause de mortalité en Algérie, avec un taux de 41%. Les facteurs de risques sont multiples : tabac, sédentarité, obésité, hypertension artérielle, diabète, facteurs génétiques aussi parfois.

Le cœur est l'organe central du système cardiovasculaire : il peut être affecté de nombreuses pathologies qui peuvent soit être bénignes, comme certaines tachycardies par exemple, soit s'avérer très sérieuses, comme l'infarctus du myocarde. Avec l'évolution des techniques, les médecins disposent aujourd'hui d'outils performants pour observer le fonctionnement du muscle cardiaque et dresser ainsi leur diagnostic. Parmi les examens cardiologiques possibles, l'électrocardiogramme (ECG) qui est l'examen le plus couramment effectué, car il est rapide à mettre en place, peu coûteux et surtout non invasif donc très peu contraignant pour le patient.

A travers ce mémoire, nous allons aborder un sujet d'actualité qui est l'analyse et la modélisation non linéaire du signal électrocardiogramme (ECG) avec des techniques basés sur les réseaux de neurones artificiels qui sont des agents de traitement et d'approximation très performants.

Normalement effectué sur un patient au repos en cabinet ou en milieu hospitalier, pendant quelques secondes, l'ECG est très souvent complété par un examen similaire d'une durée de 24 heures appelé «Holter»[1], examen au cours duquel le patient peut vaquer à ses occupations habituelles. Le principal avantage de l'enregistrement Holter par rapport à l'ECG est qu'il permet la détection d'événements sporadiques qui n'interviennent pas nécessairement au cours des quelques secondes de l'enregistrement ECG lorsque le patient est au repos.

Pour assurer une meilleure présentation du travail effectué et garantir la clarté du mémoire, outre cette introduction générale, ce manuscrit se compose de cinq chapitres. Chacun met en évidence une contribution particulière du travail :

- Le premier chapitre de ce mémoire, sera consacré à l'introduction de l'élément principal du système cardiovasculaire qui est le cœur, au principe du signal électrocardiogramme (ECG), ainsi que les différentes étapes du traitement automatiques des signaux ECG.
- Le deuxième chapitre est dédié à l'apprentissage supervisé et à ses différentes approches et nous présentons aussi quelques notions de base sur les réseaux de neurones artificiels.
- Le troisième chapitre est consacré à une étude de synthèse sur les différents travaux antérieurs.
- Le quatrième chapitre est dédié à l'étude conceptuelle de notre solution proposée. Nous présentons les différents organigrammes et algorithmes utilisés et nous décrivons les différentes étapes suivies, pour le traitement automatiques d'un signal ECG.
- Le cinquième chapitre décrit l'implémentation de notre solution réalisée. Nous retrouvons la présentation des outils et des langages utilisés dans la programmation ainsi les différentes fonctions, nous évaluons aussi la performance du système proposé.

Nous avons terminé ce modeste travail par une conclusion générale.

***Chapitre 1 :***  
***Généralités sur***  
***le signal ECG***



## 1. Introduction

Dans ce chapitre nous présentons dans une première partie le fonctionnement de l'élément principal du système cardiovasculaire; le cœur, puis dans une seconde nous traitons d'une manière plus détaillée, le principe de l'électrocardiogramme (ECG) qui désigne l'enregistrement de l'activité électrique du cœur.

## 2. Le cœur

Elément principal du système cardiovasculaire, qui est un muscle appelé myocarde, d'un volume de poignet sert à propulser le sang vers tout le corps humain à travers les vaisseaux sanguins.

Dans le corps humain, le cœur se situe dans le médiastin. C'est la partie médiane de la cage thoracique délimitée par les deux poumons, le sternum et la colonne vertébrale. Il se trouve un peu à gauche du centre du thorax, en arrière du sternum, sur le diaphragme. C'est un organe creux constitué par un muscle, le myocarde, et enrobé du péricarde (péricardique) ; il est entouré par les poumons.

Les vaisseaux sanguins sont décomposés en deux grands systèmes, le système artériel et le système veineux. Le premier système assure l'acheminement du sang oxygéné vers les organes, et le deuxième sert à ramener le sang pauvre en oxygène au cœur. [1]

### 2.1. Anatomie et activité musculaire du cœur

Le cœur est divisé en deux parties par une cloison, une partie droite et une partie gauche. Chaque partie est divisée elle-même en deux parties, une partie haute qui est les oreillettes et une partie basse qui sont les deux ventricules. La Figure 1 illustre la structure anatomique détaillée du cœur humain. [2]

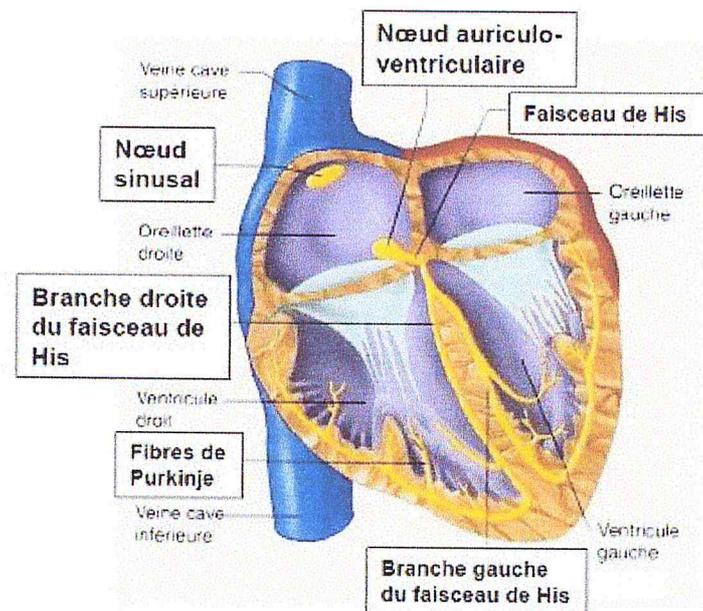


Figure 1. La structure anatomique du cœur. [2]

Le sang pauvre en oxygène arrive au cœur par la veine cave. Il y entre par l'oreillette droite, et en est chassé par sa contraction appelée systole auriculaire qui le déplace dans le ventricule droit. La contraction ventriculaire (systole ventriculaire) propulse le sang du ventricule droit vers les poumons où il va se charger en oxygène. De retour au cœur par les veines pulmonaires, le sang s'accumule dans l'oreillette gauche puis, lors de la contraction auriculaire, passe dans le ventricule gauche qui lors de la systole ventriculaire l'envoie vers les organes par l'artère Aorte.

Du fait que le muscle cardiaque est myogénique, les contractions rythmiques se produisent spontanément et sont coordonnées par une impulsion électrique qui le stimule. [1]

### 3. L'électrocardiographie

#### 3.1 Définition

L'électrocardiographie (ECG) est la représentation graphique du potentiel électrique qui commande l'activité musculaire du cœur. Ce potentiel est recueilli par des électrodes mis sur la surface de la peau.

L'électrocardiographie est constitué en général de :



- Un ensemble d'électrodes destinées à être appliquées en contact direct du patient.
- Un système d'amplification des signaux issus des électrodes.
- Un appareil enregistreur.
- Un système d'enregistrement graphique.

L'ECG est né en 1887 avec les travaux de Waller[4], révélé à la communauté médicale par l'invention du galvanomètre à cordes en 1901, L'invention de l'ECG a valu à Willem Einthoven le prix Nobel de médecine en 1924[5], l'électrocardiographie est devenue une technique incontournable en pratique cardiologique.

Les dérivations précordiales sont utilisées pour le diagnostic médical à partir de 1932 et les dérivations frontales unipolaires à partir de 1942, ce qui permet à Emanuel Goldberger de réaliser le premier tracé sur 12 voies. [6][8]

### 3.2 Principe de fonctionnement

Une cellule vivante, lors des transferts ionique entre ses parois, peut être considérée comme un dipôle électrique. Au repos aucune différence de potentiel n'existe, alors il n'y a pas de représentation vectorielle du potentiel électrique, le vecteur est donc nul, Figure 2.a. [1][4]

Après une stimulation, la polarité des parois se change induisant ainsi une différence de potentiel qui se propage tout au long de la paroi marquée par un vecteur positif(b) qui atteint son maximum lorsque l'impulsion électrique arrive au milieu(c). La fin de la dépolarisation est marquée par un vecteur positif de faible amplitude. Une fois la cellule est dépolarisée, le vecteur est nul (d). La re-polarisation de la cellule se manifeste par un vecteur négatif (e), qui suit les mêmes étapes que le premier dans le sens opposé (f), Figure 2. [1]

Aujourd'hui l'électrocardiographie est une technique relativement peu coûteuse, permettant à l'aide d'un examen indolore et sans danger, de surveiller l'appareil cardio-circulatoire, notamment pour la détection des troubles du rythme et la prévention de l'infarctus du myocarde.

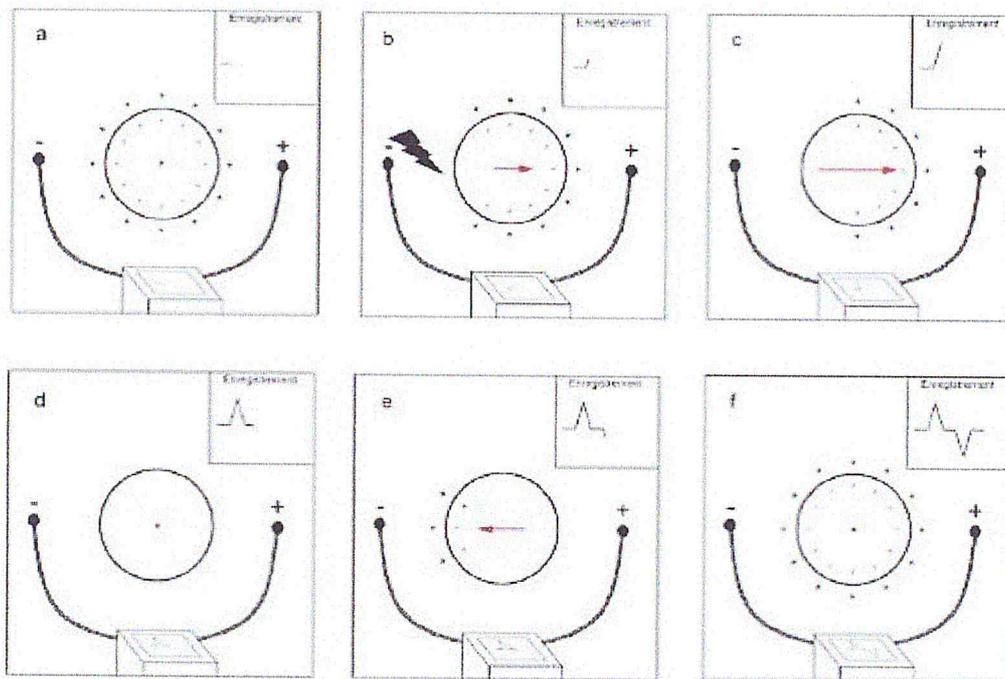


Figure 2. Principe de fonctionnement de l'ECG. [1]

### 3.2 Enregistrement de l'électrocardiogramme et dérivations

L'électrocardiogramme est le tracé obtenu grâce à l'électrocardiographie. L'acquisition du signal ECG est assurée par des électrodes de surface, dont leur emplacement sur le thorax du patient définit un type de dérivation. Les emplacements des électrodes sur le thorax du patient sont choisis de manière à explorer la quasi-totalité du champ électrique cardiaque. [1]

En cardiologie, l'examen le plus pratiqué est l'ECG, il comporte 12 dérivations, chaque dérivation renvoie une image particulière de l'activité électrique du cœur, en fonction de la position des électrodes et de la morphologie du cœur visualisé comme suit :

- 6 déviations périphériques, lecture sur le plan frontal du cœur :

Les trois dérivations bipolaires DI, DII, DIII elles sont dites bipolaires car elles proviennent de la différence de potentiel électrique entre deux membres (dérivations de Einthoven). La différence de potentiel est lue du négatif(-) au positif(+). (Figure 3.b)

- DI : enregistre les différences de potentiel électrique entre le poignet droit(-) et le poignet gauche(+).



- DII : enregistre les différences de potentiel électrique entre le poignet droit(-) et la jambe gauche(+).
- DIII : enregistre les différences de potentiel électrique entre le poignet gauche(-) et la jambe gauche(+).

Plus les dérivations unipolaires (de Wilson) aVR, aVL, aVF elles sont dites unipolaire car plutôt que de mesurer la différence de potentiel entre deux électrodes, elles renvoient l'activité électrique de l'électrode par rapport à un point central qui correspond en quelque sorte à un cœur.[4] (Figure 3.a)

- aVL : a= augmenter (amplifié) V= Voltage L= Left pour l'avant-bras gauche
- aVR : a= augmenter (amplifié) V= Voltage R= Right pour l'avant-bras droit
- aVF : a= augmenter (amplifié) V= Voltage F= Foot pour la jambe gauche

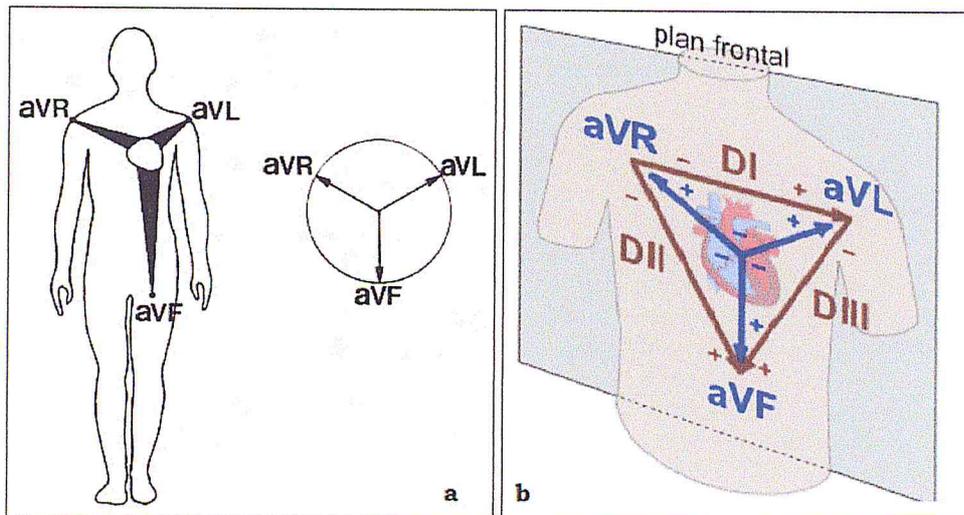


Figure 3. Les dérivations bipolaires et unipolaires des membres. [4]

- 6 déviations précordiales, lecture de l'activité sur le plan horizontal du cœur (dérivations unipolaires de V1 à V6 dites de Kossman) :

V1 : 4ème espace intercostal, à droite du sternum.

V2 : 4ème espace intercostal, à gauche du sternum.



V3 : à mi-chemin entre V2 et V4.

V4 : 5ème espace intercostal, sur la ligne médio-claviculaire.

V5 : même hauteur que V4, à mi-chemin entre V4 et V6 ou sur la ligne axillaire antérieure (LAA).

V6 : même hauteur que V4, sur la ligne médio-axillaire (LMA).[1][4]

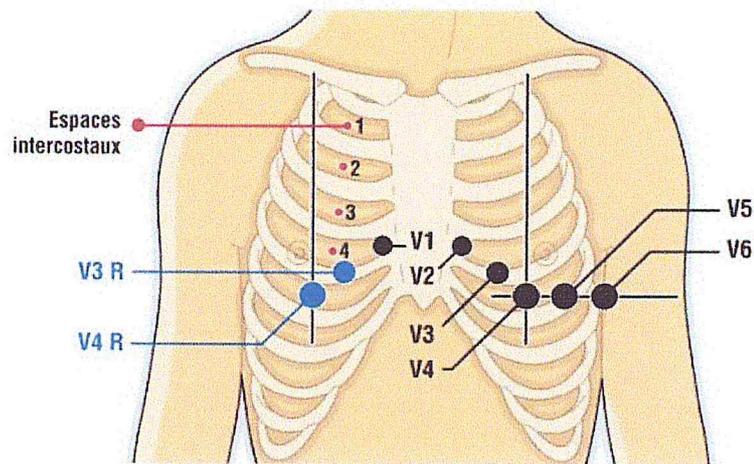


Figure 4. Les dérivations précordiales. [4]

La différence de potentiel enregistrée entre chaque paire d'électrodes constitue le signal qui représente l'activité électrique du cœur depuis plusieurs points de vue. La fréquence d'échantillonnage de tels ECG modernes se situe entre 250 et 500 Hz [14]. Néanmoins, ce type de procédures est uniquement utilisé pour des mesures très courtes (typiquement 10 secondes) pour observer des anomalies structurelles du cœur.

Malheureusement, une mesure de l'ECG de courte durée peut ne pas permettre de diagnostiquer certaines pathologies comme des arythmies cardiaques, des épisodes ischémiques transitoires ou des ischémies silencieuses du myocarde [15], [16]. Dans ce genre de situations, les médecins ont recours à un enregistrement ECG de long terme et utilisant moins d'électrodes (seulement deux ou trois) : le Holter.

### 3.3 L'ECG de Holter

Un Holter est un enregistreur d'ECG portable qui permet de mesurer l'activité cardiaque sur de longues périodes (de 24 à 48h) [9][10]. La Figure 5 représente un homme portant un



Holter. Cette mesure se fait avec un nombre restreint de paires d'électrodes (deux à trois) [11]. L'analyse est effectuée par un battement ECG annotés. Ils ont été obtenus artificiellement car dans la réalité le signal est beaucoup plus bruité [11]. De par la durée de l'enregistrement, il peut y avoir plus de 100 000 battements par jour et par paire d'électrodes à examiner [12][13]. Malheureusement, le diagnostic peut reposer sur un petit nombre d'entre eux et on ne peut donc pas en ignorer. En effet, on retrouve seulement quelques battements «anormaux» parfois dispersés dans tout l'enregistrement [12][13].

De nos jours, des progrès remarquables sont faits dans les domaines du sansfil et des senseurs portables miniatures qui peuvent remplacer les électrodes. La société IMEC, implantée en Belgique, a par exemple réussi à faire d'un GSM un véritable ECG portable grâce à des senseurs sans-fil de la taille d'une pièce de monnaie [13].

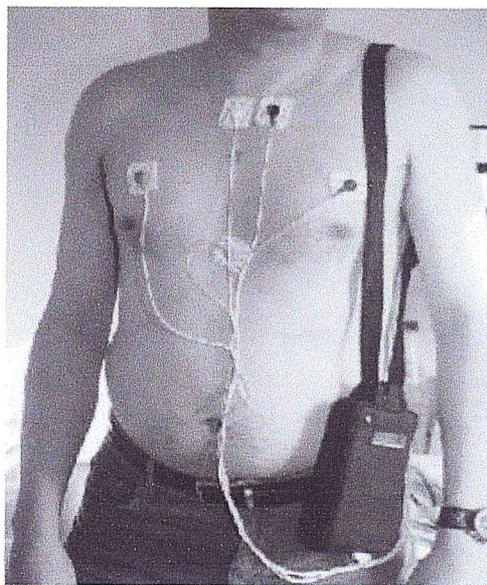


Figure 5. Illustration d'un homme portant un Holter. [12]

#### 4. Tracé électrique du cœur

La visualisation de l'activité électrique du cœur pour un seul battement donne un tracé constitué de trois ondes successives, Figure 6.

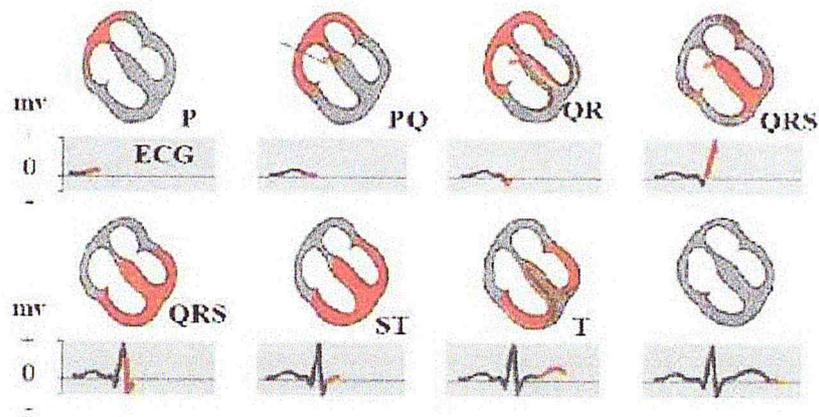


Figure 6. L'onde électrique d'un battement de cœur. [8]

- L'onde P : Au cours du rythme sinusal normal, la dépolarisation du myocarde auriculaire produit une onde positive dans les dérivations DI et DII et négative en AVR. [1]

Voici les valeurs normales des paramètres de l'onde P :

- Durée < 0,11 dans la dérivation DII.
- Amplitude < 0,25 mV (2,5 mm) dans la dérivation DII.
- Orientation dans le plan frontal entre 0 et +75°.

- L'onde QRS : La dépolarisation ventriculaire se traduit par un complexe polyphasique, le complexe QRS. L'onde négative initiale est appelée onde Q, sa durée est généralement inférieure à 0,04 seconde et son amplitude dépasse rarement 1 à 2 mm. La première onde positive est appelée onde R. L'onde négative qui suit l'onde R est appelée l'onde S.

- L'onde T : Elle correspond à la re-polarisation des ventricules. Dans l'état normal du cœur, cette onde présente une amplitude moins faible que celle du complexe QRS et une durée plus longue.[1][8]

#### - Les artefacts de l'ECG

Divers bruits sont présents dans l'ECG de routine. Parmi les plus importants, on peut citer : La dérive de la ligne de base (fréquence < 5Hz), les artefacts dus aux mouvements (fréquence 1-10Hz), le secteur et ses harmoniques (fondamental 50 ou 60Hz), et L'EMG (fréquence 25-100Hz).[17]



## 5. Intervalles temporels

L'analyse de l'électrocardiogramme comprend la mesure des amplitudes, les durées ainsi que l'examen de la morphologie de l'onde P, du complexe QRS, de l'onde T, de l'intervalle PR, du segment ST et de l'intervalle QT. Les valeurs normales citées ci-dessous sont appliquées sur une tranche d'âge moyenne et données à titre indicatif car il existe un chevauchement parfois important entre les valeurs normales et pathologiques.

### - L'Intervalle PR ou PQ

L'intervalle PR ou PQ, mesuré du début de l'onde P au début du complexe QRS, représente le temps de propagation de l'influx par les oreillettes, le nœud auriculo-ventriculaire, le faisceau de His, ses branches, le réseau de Purkinje jusqu'au début de l'activation ventriculaire. La durée de l'intervalle PR varie de 0,12 à 0,20 secondes en fonction de la fréquence cardiaque et de l'âge.[17]

### - L'Intervalle QRS

La durée de cet intervalle représente le temps de dépolarisation ventriculaire.

### - L'Intervalle ST

Le segment ST est la partie du tracé comprise entre la fin du complexe QRS et le début de l'onde T. Il correspond à la phase 2, en plateau, du potentiel d'action transmembranaire. Le segment ST normal peut être légèrement décalé, vers le haut au repos, ou vers le bas à l'effort. [17][1]

### - L'Intervalle QT

Il s'agit de la distance entre le début du complexe QRS et la fin de l'onde T, englobant la dépolarisation et la re-polarisation ventriculaires. La durée de l'intervalle QT varie en fonction de la fréquence cardiaque, de l'âge et du sexe.

### - L'Intervalle RR

Cet intervalle désigne le temps entre deux ondes R successives. La facilité de la détection de l'onde R donne l'importance de cet intervalle qui sert à mesurer la fréquence cardiaque.

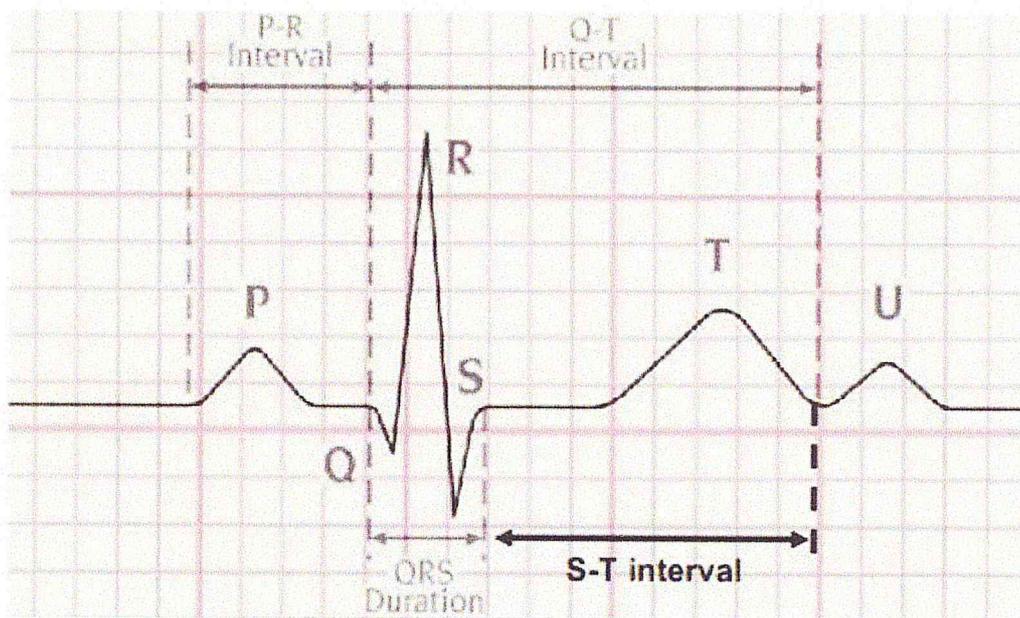


Figure 7 Différents intervalles dans l'ECG. [17]

## 6. A quoi sert l'électrocardiogramme ?

L'ECG peut constituer un marqueur indépendant d'affection myocardique; il peut refléter des atteintes anatomiques, électrophysiologiques, métaboliques et hémodynamiques. Il procure une information qui, souvent s'avère essentielle pour le diagnostic et le traitement de diverses anomalies cardiaques; et il est sans égal pour le diagnostic des arythmies. [18]

L'électrocardiographie est une procédure de premier choix chez des patients se plaignant de précordialgies, lipothymies ou syncopes, symptômes qui peuvent être annonciateurs d'infarctus myocardique ou de mort subite.

Des anomalies électriques peuvent être les premiers signes indiquant l'existence d'effets secondaires potentiellement désastreux de certains médicaments, ou de sévères déséquilibres métaboliques ou électrolytiques, et parfois le seul signe d'atteinte myocardique, tel que l'infarctus "silencieux" chez le sujet âgé. [17]

L'échocardiographie et la résonance magnétique nucléaire, montrant directement la morphologie et la dynamique des structures anatomiques, domaines où l'électrocardiogramme est moins performant. Par contre, l'électrocardiogramme est le premier



et parfois le seul témoin des modifications qui se produisent à l'étage moléculaire et cellulaire. Il peut de la sorte constituer un outil de diagnostic essentiel, par exemple pour la détection de l'ischémie myocardique (pathologie fréquente), pour la reconnaissance des atteintes myocardiques précoces comme dans certaines cardiopathies et certaines dystrophies musculaires (pathologies rares) où les tracés électrocardiographiques peuvent être perturbés avant que les anomalies échocardiographiques apparaissent. [1][18]

Enfin l'électrocardiogramme est le seul examen couramment utilisé dans l'étude des troubles de conduction et des troubles du rythme. C'est un excellent outil de diagnostic.

## 7. Le traitement automatisé des signaux ECG

Le traitement automatisé des signaux ECG a gagné un large intérêt dans les derniers ans tant dans les milieux médicaux que dans ceux qui s'occupent des traitements du signal. Le défi est bien intéressant : étant donnée la " sensibilité " du domaine, le but final du traitement automatique (de compléter où même substituer l'apport du médecin) reste une tâche particulièrement délicate.

Une chaîne complète pour le traitement du signal ECG doit comprendre les suivantes étapes :

- **L'acquisition des signaux ECG** et leur transformation dans un format qui soit utilisable pour le traitement automatique. L'acquisition sert ultérieurement à la constitution des bases de données. [13]

- **Le prétraitement** : Lors du processus d'acquisition, les signaux ECG sont affectés par de multiples sources de distorsions. L'étape de pré-traitement doit diminuer le plus possible l'effet de ces interférences perturbatrices, tout en conservant avec beaucoup d'attention les composantes utiles du signal. Parmi les perturbations les plus communes, on retrouve les interférences avec le réseau électrique (les « 50 Hz » ), les fluctuations de la ligne de base (à cause de la respiration où des mouvements du patient) et l'ainsi nommé « bruit électromyographique » (EMG) provoqué par l'activité des muscles. Tandis que des méthodes bien efficaces ont été conçues pour éliminer les premiers deux types de bruit, le plus troublant reste le résidu EMG, à cause du fait que son spectre est superposé sur le spectre du signal ECG utile.[11]



- **La segmentation** : étape importante et délicate du traitement automatique, dont le résultat est la fragmentation du signal en trames successives homogènes, en isolant ainsi les principales ondes utiles du point de vue clinique : les ondes P et T et le complexe QRS. [13][14]

- **L'extraction des paramètres** : Il s'agit de trouver, à partir des ondes élémentaires résultées de la phase de segmentation, les paramètres qui puissent prédire le mieux l'état du patient, et c'est cette phase qui nous intéresse le plus dans notre étude, et que l'on verra par la suite en détail.

- **La classification** : En utilisant les paramètres relevants, la classification doit être capable de " donner le diagnostique ", en substituant le rôle du médecin. La classification consiste à partir d'un ensemble d'objets de classes connues appelé ensemble d'apprentissage, à produire un modèle de classe caractérisant ces données et surtout, pouvant être généralisé à un ensemble de données plus large. Chaque étape est particulièrement délicate et nécessite une qualité quasi parfaite. Le succès de la chaîne automatique est assuré seulement dans le cas d'un fonctionnement irréprochable de chacune de ses parties composantes.[17]

Le présent travail s'intéresse à l'étude d'un classificateur supervisé appelé les réseaux de neurones artificiels.

## 8. Conclusion

L'électrocardiographie est une technique largement utilisée, elle remplit bien sa fonction et fourni de façon fiable un signal auquel nous pouvons appliquer des méthodes appropriées du traitement de signal.

Ce chapitre a pour but de sensibiliser le lecteur de l'importance d'étudier les différentes caractéristiques du signal ECG, tels que les amplitudes des ondes P, Q, R, S et T, leurs formes, leurs durées ainsi que les intervalles qui les séparent afin de faire un bon diagnostic.

# ***Chapitre 2 :***

# ***Apprentissage***

## 1. Introduction

L'apprentissage désigne un ensemble de méthodes et d'algorithmes permettant d'extraire de l'information pertinente de données ou d'apprendre un comportement à partir de l'observation d'un phénomène. En général, ce processus est associé à la possibilité de mesurer en un certain sens la qualité et la précision des résultats.

Dans ce chapitre nous traitons les notions de base pour la compréhension de l'apprentissage, en particulier l'apprentissage supervisé et ses différentes techniques.

## 2. L'apprentissage

Un réseau de neurones nécessite une phase d'apprentissage par laquelle le réseau construit les liens qui lui permettent d'effectuer la mémorisation, la classification et la prédiction du type de données présentées.

### 2.1 Les éléments de l'apprentissage connexionniste

L'apprentissage d'un processus par une architecture connexionniste peut se résumer succinctement à un échange d'information entre trois éléments principaux : l'environnement (c'est-à-dire le processus à contrôler), l'élève (le contrôleur proprement dit) et le superviseur d'apprentissage, qui constitue le professeur (Figure 8).

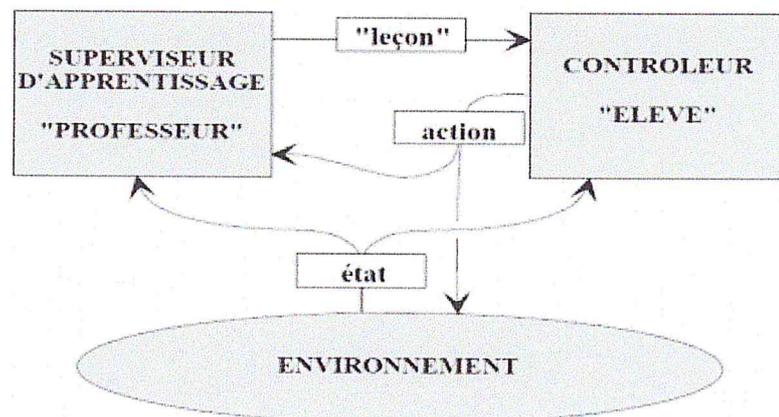


Figure 8. Les éléments de l'apprentissage

## 2.2 Qu'est-ce qu'un algorithme d'apprentissage ?

L'algorithme d'apprentissage est l'opération qui permet de modifier les poids selon l'évolution de l'erreur entre la sortie obtenue et la sortie désirée. Il contrôle tout le comportement futur du réseau de neurones. La capacité de mémorisation et de généralisation du réseau réside dans la configuration de ses poids. On trouve trois types d'algorithme d'apprentissage : l'apprentissage supervisé, l'apprentissage non-supervisé et l'apprentissage par renforcement.

### ➤ Apprentissage par renforcement

L'apprentissage par renforcement constitue un modèle dont on ne dispose pas de l'information nécessaire à la construction d'une base d'apprentissage complète. On ne dispose souvent que d'une information qualitative permettant l'évaluation de la réponse calculée, sans pour autant connaître la réponse la plus adaptée. Les algorithmes d'apprentissage par renforcement, essentiellement développés depuis le début des années quatre-vingt, permettent alors d'entraîner le réseau pour qu'il fournisse, à chaque stimulus entrant, la sortie la plus adéquate, autrement dit le système étant capable de savoir si la réponse qu'il fournit est correcte ou non, mais il ne connaît pas la bonne réponse.[1]

### ➤ Apprentissage non-supervisé

Contrairement aux modes supervisés, seule une base d'entrée est ici fournie au réseau. Ce dernier doit donc déterminer lui-même ses sorties en fonction des similarités détectées entre les différentes entrées, c'est-à-dire en fonction d'une règle d'auto-organisation.[1]

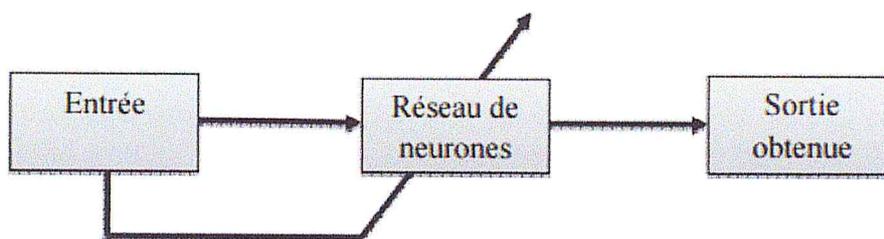


Figure 9. Schéma bloc d'apprentissage non-supervisé

### ➤ Apprentissage supervisé

C'est le cadre d'apprentissage statistique qui nous intéresse ici c'est actuellement le mode d'apprentissage le plus utilisé. Son principe est élémentaire : on soumet au réseau un grand nombre d'exemple pour lesquels l'entrée et la sortie associée sont connues et les poids sont modifiés de façon à corriger l'erreur commise par le réseau (Figure 10), c'est-à-dire la différence entre la sortie désirée et la réponse du réseau à l'entrée correspondante. [1]

En ce qui concerne l'apprentissage supervisé, une première distinction est à faire entre les méthodes estimant des probabilités pour en déduire la fonction de décision et les méthodes estimant directement la fonction de décision sans passer, du moins explicitement, par les probabilités [19]. Parmi les approches probabilistes, les plus utilisées se distinguent suivant la nature du modèle sous-jacent. La méthode de Bayes naïve permet d'estimer des probabilités discrètes alors que les modèles de mélange associés à l'algorithme EM sont utilisés pour l'estimation de densités et de lois mixtes. Les méthodes à noyaux ont aussi été utilisées dans le cadre bayésien sous différentes formes : processus gaussiens, relevance vector machines ou Bayes point machines. [21][20]

Une manière de présenter les méthodes d'apprentissage supervisé dites « directes » consiste à les classer suivant la nature de leur ensemble d'hypothèses. Conceptuellement, cet ensemble d'hypothèses peut être vu comme l'ensemble de combinaisons linéaires de fonctions de référence [19][20]. On distingue trois catégories selon la nature des fonctions de références. Soit elles sont fixées indépendamment de l'échantillon en prenant une base (d'ondelettes par exemple). Soit elles ne dépendent que des observations  $x_i$  et pas des étiquettes. C'est le cas des méthodes à base de noyaux et notamment des séparateurs à vaste marge (SVM), des  $k$  plus proches voisins, des arbres de décisions, des méthodes additives et celles d'agrégation comme le boosting. [19]

Enfin les fonctions de références peuvent dépendre à la fois les observations et des étiquettes comme pour les réseaux de neurones de type « perceptron multicouche » ou « fonctions de base radiales ». Les méthodes du deuxième type conduisent à des algorithmes d'apprentissage rapides et souvent bien posés alors que les réseaux de neurones sont connus pour être associés à des algorithmes d'apprentissage au comportement chaotique. En revanche ils donnent souvent des modèles plus concis que les algorithmes de la

deuxième catégorie. Une des problématiques de recherche dans le domaine de l'apprentissage est donc de trouver des modèles parcimonieux facilement identifiables.

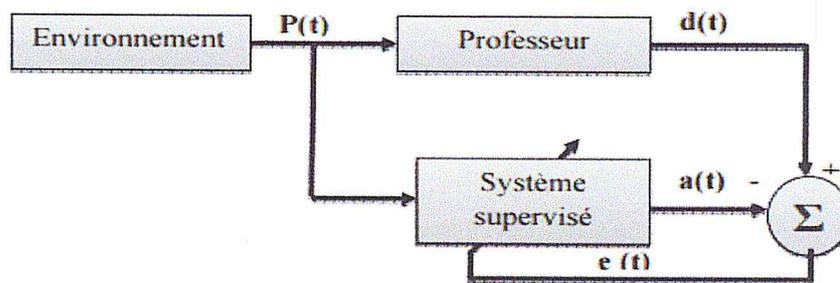


Figure 10. Schéma bloc de l'apprentissage supervisé

### 3. Méthodes d'apprentissage supervisé

En apprentissage automatique, différents types de classificateurs ont été mis au point, et cela dont le but d'atteindre un degré maximal de précision et d'efficacité, chacun ayant ses avantages et ses inconvénients. Mais, ils partagent toutefois des caractéristiques communes. Parmi la panoplie de classificateurs existants, on peut faire des regroupements et distinguer des grandes familles.

Dans ce qui suit, nous allons exposer quelques méthodes et leurs algorithmes tels que les machines à support vectoriel (SVM) et l'algorithme des k-voisins les plus proches, qui représentent vraisemblablement à l'heure actuelle les deux meilleurs choix en catégorisation de textes, les arbres de décision ainsi que les réseaux de neurones.

#### 3.1 Les arbres de décision

##### 3.1.1 Définition

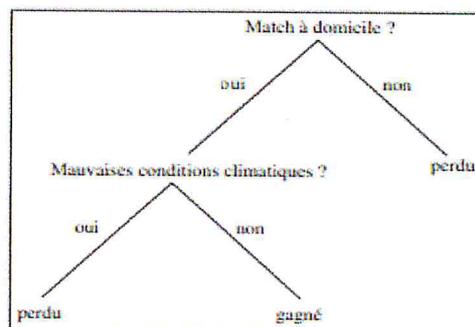
Etant donné  $n$  attributs  $A_1, \dots, A_n$ , l'espace de description  $X$  est le produit cartésien des domaines  $X_i$  de chaque attribut  $A_i$ .

$$X = \prod_{i=1}^n X_i \text{ où } X_i = \text{Dom}(A_i).$$

Les attributs peuvent être :

- binaires,
- n-aires,
- réels.

Les arbres de décision sont des règles de classification qui basent leur décision sur une suite de tests associés aux attributs, les tests étant organisés de manière arborescente.



**Figure 11.** La situation en début d'un match de football est décrite par deux attributs binaires : *Match à domicile* et *Mauvaises conditions climatiques*. L'attribut classe prend deux valeurs : *gagné* et *perdu*. Un exemple d'arbre de décision.

Un arbre de décision est un arbre au sens informatique du terme. Les nœuds internes sont appelés nœuds de décision. Chaque nœud de décision est étiqueté par un test qui peut être appliqué à toute description d'un individu de la population. En général, chaque test examine la valeur d'un unique attribut de l'espace des descriptions. Les réponses possibles au test correspondent aux étiquettes des arcs issus de ce nœud. Les feuilles sont étiquetées par une classe appelée classe par défaut. Chaque nœud interne ou feuille est repéré par sa position : la liste des numéros des arcs qui permettent d'y accéder depuis la racine. Les positions des nœuds de l'arbre de décision de la *Figure.8* sont :  $\varepsilon$ , 1, 2, 1 · 1, 1 · 2.

A tout arbre de décision, on associe de façon naturelle une procédure de classification. En effet, à toute description complète est associée une et une seule feuille de l'arbre de décision. Cette association est définie en commençant à la racine de l'arbre et en descendant dans l'arbre selon les réponses aux tests qui étiquettent les nœuds internes. La classe associée est alors la classe par défaut associée à la feuille qui correspond à la description. Cette procédure de classification a une traduction immédiate en termes de règles de décision (une

règle par branche). Les systèmes de règles qu'on obtient ainsi ont la particularité que l'ordre dans lequel on examine les attributs est fixé et que les règles de décision sont mutuellement exclusives.

Les arbres de décision ont deux qualités appréciables :

- les décisions sont aisément interprétables.
- la classification est très rapide.

### 3.1.2 Algorithmes d'apprentissage par arbres de décision

Les principaux algorithmes d'apprentissage par arbres de décision sont CART (Breiman) et C4.5 (Quinlan). Nous présentons ci-dessous quelques une de leurs caractéristiques. La première étape consiste à construire un petit arbre consistant avec la plupart des données.

**Idée centrale** : Diviser récursivement et le plus efficacement possible les exemples de l'ensemble d'apprentissage par des tests définis à l'aide des attributs jusqu'à ce que l'on obtienne des sous-ensembles d'exemples ne contenant (presque) que des exemples appartenant à une même classe. Cette idée débouche sur des méthodes de construction Top-Down, c'est-à-dire construisant l'arbre de la racine vers les feuilles, gloutonnes et récursives. Dans toutes les méthodes, on trouve les trois opérateurs suivants :

1. Décider si un nœud est terminal, c'est-à-dire décider si un nœud doit être étiqueté comme une feuille ou porter un test.
2. Si un nœud n'est pas terminal, sélectionner un test à lui associer.
3. Si un nœud est terminal, lui affecter une classe.

On peut alors définir un schéma général d'algorithme, sans spécifier comment seront définis les 3 opérateurs décrits plus haut

### 3.1.3 Algorithme d'apprentissage générique

```
entrée : échantillon S
début
    Initialiser l'arbre courant à l'arbre vide ; la racine est le nœud courant
répéter
    Décider si le nœud courant est terminal
    Si le nœud est terminal alors
        Lui affecter une classe
    sinon
        Sélectionner un test et créer autant de nouveaux nœuds fils
        qu'il y a de réponses possibles au test
    FinSi
    Passer au nœud suivant non exploré s'il en existe
Jusqu'à obtenir un arbre de décision
Fin
```

## 3.2 SVM : Machines à Vecteurs de Support

### 3.2.1 Généralités sur l'approche SVM

Parmi les méthodes à noyaux, inspirées de la théorie statistique de l'apprentissage de Vladimir Vapnik, les SVM constituent la forme la plus connue. SVM est une méthode de classification binaire par apprentissage supervisé, elle fut introduite par Vapnik en 1995. Cette méthode est donc une alternative récente pour la classification. Cette méthode repose sur l'existence d'un classificateur linéaire dans un espace approprié. Puisque c'est un problème de classification à deux classes, cette méthode fait appel à un jeu de données d'apprentissage pour apprendre les paramètres du modèle. Elle est basée sur l'utilisation de fonction dites noyau (kernel) qui permettent une séparation optimale des données.

Dans le schéma qui suit, on détermine un hyperplan qui sépare les deux ensembles de points

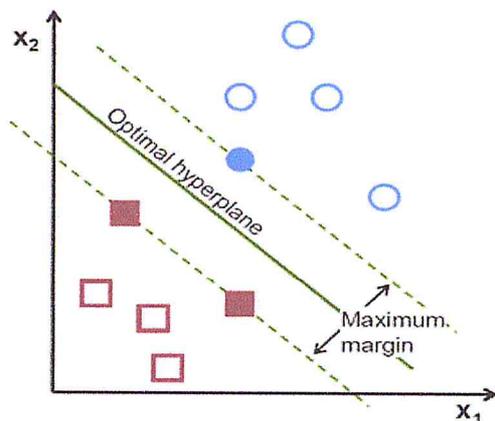


Figure 12. Schéma montrant un hyperplan

Les points les plus proches, qui seuls sont utilisés pour la détermination de l'hyperplan, sont appelés vecteurs de support. L'hyperplan séparateur optimal est celui qui maximise la marge. Si on cherche à maximiser cette marge, on parlera de séparateurs à vaste marge.

### 3.2.2 Principe de l'algorithme

L'algorithme se base principalement sur 3 astuces pour obtenir de très bonnes performances tant en qualité de prédiction qu'en complexité de calcul.

- On cherche l'hyperplan comme solution d'un problème d'optimisation sous-contrainte. La fonction à optimiser intègre un terme de qualité de prédiction et un terme de complexité du modèle.
- Le passage à la recherche de surfaces séparatrices non linéaires est introduit en utilisant un noyau kernel qui code une transformation non linéaire des données.
- Numériquement, toutes les équations s'obtiennent en fonction de certains produits scalaires utilisant le noyau et certains points de la base de données (ce sont les Support Vectors).

## 3.3 La méthode K-ppv

### 3.3.1 Définition

K-ppv en abrégé k-NN ou KNN, de l'anglais K-nearest neighbor, c'est une approche très simple et directe, elle ne nécessite pas d'apprentissage mais simplement le stockage des données d'apprentissage. Son principe est le suivant: étant donnée une base d'apprentissage d'images étiquetées correctement et un entier  $k$ , le classifieur k-ppv détermine la classe d'un nouvel objet en lui attribuant la classe majoritaire des  $k$  objets lui ressemblant le plus dans la

base d'apprentissage au sens d'une distance choisie. Les figures suivantes illustrent le principe de fonctionnement de ce classifieur.

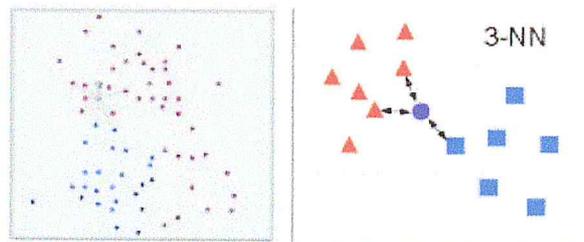


Figure 13. le principe du fonctionnement d'un classifieur

### 3.3.2 Quelle distance ?

Afin de trouver les  $K$  plus proches d'une donnée à classer, on peut choisir la distance euclidienne. Soient deux données représentées par deux vecteurs  $x_i$  et  $x_j$ , la distance entre ces deux données est donnée par :

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^d (x_{ik} - x_{jk})^2}$$

### 3.3.3 K-ppv : classifieur « paresseux »

L'algorithme k-ppv est un algorithme de la famille des algorithmes dits « paresseux » : à l'inverse de beaucoup d'autres méthodes d'apprentissage automatique (tels que la régression logistique, les réseaux de neurones artificiels, les méthodes à noyaux, etc.) aucun apprentissage ne prend réellement place, c'est-à-dire qu'il n'y a pas de phase de détermination de paramètres d'une fonction par le biais d'une optimisation mathématique.

On note deux aspects importants de l'algorithme k-ppv : d'une part, à chaque nouvelle classification il est nécessaire de parcourir l'ensemble de la base d'apprentissage, ce qui en fait un algorithme qui n'est pas nécessairement très efficace (surtout que, habituellement, on cherche à avoir la base d'apprentissage la plus grande possible afin d'avoir un meilleur classifieur), et d'autre part, un point crucial de cet algorithme est la fonction de distance utilisée pour mesurer la proximité des objets. Il n'existe pas de distance/similarité universellement optimale et une bonne connaissance du problème traité guide généralement le choix de cette distance/similarité.

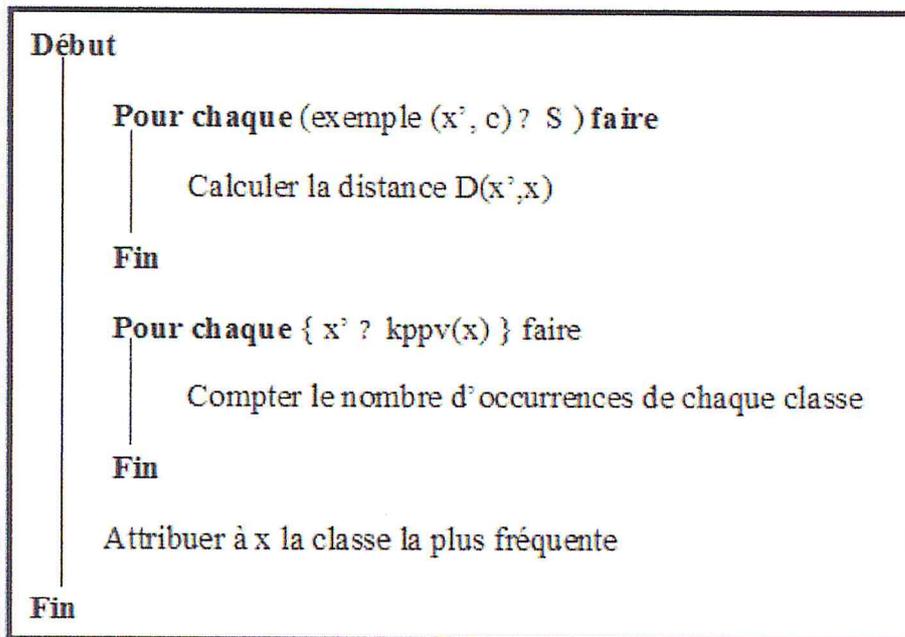
### 3.3.4 Algorithme de K-ppv

**Notion :**

Soit  $S = \{ (x', c) \mid x' \in \mathbb{R}^d, c \in C \}$  l'ensemble d'apprentissage

Soit  $x$  l'exemple dont on souhaite déterminer la classe.

**Algorithme :**



## 3.4 Les Réseaux de neurones artificiels

### 3.4.1 Définition

Les réseaux de neurones artificiels ou réseaux neuromimétiques, sont des techniques d'apprentissage numérique. Leurs structures sont inspirées du système nerveux humain. Les réseaux neuromimétiques sont composés des éléments de calcul qui s'appellent les neurones (processing units), ces neurones sont interconnectés par des lignes ou à chaque ligne est associée une valeur numérique ( $w$ ) qui s'appelle poids (weight). De plus, chaque neurone possède une règle de propagation  $Net_k$  (valeur net), et une fonction d'activation  $F_k$  et éventuellement une entrée libre ou biais  $w_0$ . Le réseau doit se doter d'une technique qui lui assure la récolte des informations à partir du monde extérieur ou simplement d'une règle d'apprentissage qui permettent au réseau de s'adapter à l'environnement par l'ajustement et

l'actualisation de ses poids (weight updating), et cela d'une manière synchrone ou asynchrone selon le cas.

Les réseaux de neurones peuvent être classés comme des modèles de calcul possédant des caractéristiques spécifiques telles que la capacité d'apprentissage et d'adaptation, la capacité de généralisation et la capacité de classification dans un environnement de traitement parallèle. Parallèle signifie que la plupart des unités de calculs produisant leur résultat en même temps.

### 3.4.2 Les neurones

Un réseau connexionniste est constitué d'éléments extrêmement simples qui interagissent pour donner au réseau son comportement global. Dans les modèles connexionnistes, ces éléments sont des processeurs élémentaires dont la définition est faite en analogie avec les cellules nerveuses, les neurones.

Ces unités de base reçoivent des signaux provenant de l'extérieur ou d'autres neurones du réseau. Ils calculent une fonction, simple en général, de ces signaux et envoient à leur tour des signaux vers un ou plusieurs autres neurones ou vers l'extérieur. La Figure 14 montre un schéma comportant les organes principaux d'un neurone artificiel.

Nous caractérisons un neurone par trois concepts : son état, ses connexions avec d'autres neurones et sa fonction de transition. Les sections suivantes décrivent ces concepts. Nous détaillerons ensuite la propagation des états des neurones à l'intérieur d'un réseau.

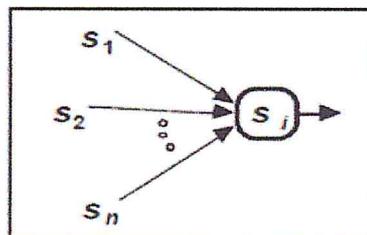


Figure 14. Représentation d'un neurone artificiel

L'état  $S_j$  du neurone est en fonction des entrées  $S_1 \dots \dots S_n$ . Le neurone produit une sortie qui sera transmise aux neurones reliés ou à l'extérieur.

### 3.4.3 L'état des neurones

Un neurone artificiel est un élément qui possède un état interne. Il reçoit des signaux qui lui permettent éventuellement de changer d'état.

Nous noterons  $S$  l'ensemble des états possibles d'un neurone.  $S$  pourra être par exemple  $\{0, 1\}$  où 0 sera interprété comme l'état inactif et 1 l'état actif.  $S$  pourra également prendre un nombre plus grand de valeurs  $\{0, 1, \dots, P\}$  pour une image en  $P + 1$  niveaux de gris ou même, par extension, un continuum de valeurs  $[-1, 1]$  ou  $\mathbb{R}$  tout entier. Dans une application en télédétection les valeurs correspondant aux signaux écho-radar peuvent être représentées à l'aide de neurones à valeurs continues. L'état d'un neurone peut alors être défini dans l'intervalle  $S = [-1, 1]$ , où -1 représente la valeur minimum du signal, et 1 le maximum.

Un neurone possède une fonction qui lui permet de changer d'état en fonction des signaux qu'il reçoit : c'est sa fonction de transition.

L'état d'un neurone est fonction des états des neurones auxquels il est relié. Pour calculer l'état d'un neurone il faut donc considérer les connexions entre ce neurone et d'autres neurones. Nous définirons par la suite les connexions entre neurones et leur poids. Puis, nous parlerons du calcul de l'état d'un neurone.

### 3.4.4 Les connexions entre neurones

En 1943, Warren S. McCulloch et Walter Pitts [McCulloch et Pitts 43] ont introduit la notion de réseaux de neurones artificiels. Leur but était de représenter l'activité électrique des cellules nerveuses du cerveau. Les réseaux qu'ils ont proposés, appelés réseaux neurologiques, étaient composés par l'interconnexion des petites unités élémentaires : les neurones formels.

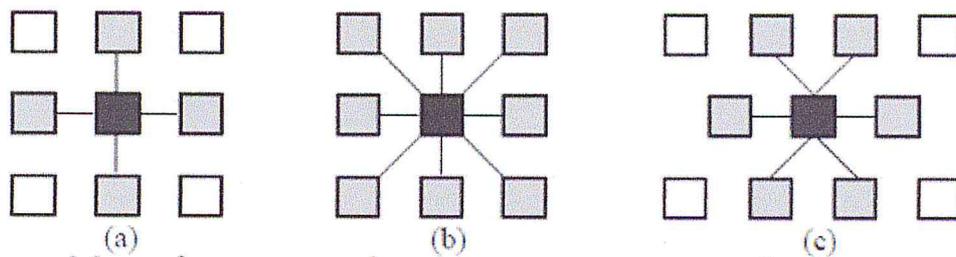
Leur modèle était inspiré en partie des nouvelles théories mathématiques des automates à états finis de l'époque. Dans ce modèle, les neurones étaient arrangés d'une telle façon que le tout formait une machine capable, en particulier, de "reconnaître" des formes. L'organisation des neurones dans les réseaux, autrement-dit l'architecture des réseaux, a été ici un facteur déterminant pour l'obtention de résultats intéressants.

Architecture est le terme le plus général pour désigner la façon dont sont disposés et connectés les différents neurones qui composent un réseau. On parle également de topologie (terme emprunté de la théorie des graphes). Au niveau des neurones on parle plutôt de voisinage. Ce terme fait allusion à la façon dont un neurone est connecté à d'autres neurones. Il est donc en rapport direct avec l'architecture du réseau. Voyons de plus près la signification du mot voisinage dans une architecture de réseaux de neurones.

➤ **Voisinage :**

Le voisinage d'un neurone est l'ensemble des neurones connectés à ce neurone. On parle de voisinage d'ordre  $n$  pour un neurone  $i$ , s'il y a  $n$  neurones connectés à ce neurone. Les connexions entre neurones ont souvent un sens.

Dans la Figure 15 nous présentons des neurones avec des voisinages d'ordre 4, 8 et 6 respectivement. Les connexions utilisées ici n'ont pas de sens particulier, elles sont bidirectionnelles. Ces types de voisinages sont très utilisés, notamment dans les modèles à base d'automates cellulaires. D'autres types de voisinage plus complexes sont possibles. On peut par exemple envisager des connexions complètes entre neurones, on aura alors un voisinage d'ordre  $N$ ,  $N$  étant le nombre total de neurones du réseau.



**Figure 15. Plusieurs types de voisinages entre neurones. Les neurones en gris représentent les 'voisinage' de celui du milieu**

### 3.4.5 Types de neurones

- **Le neurone biologique**

L'unité de base de l'organisation du système nerveux est la cellule nerveuse ou le neurone. Cette cellule, bien qu'on en ait observé de nombreuses variantes, présente toujours la même fonctionnalité de transfert d'un signal électrique. Sa structure est d'ailleurs parfaitement adaptée à cette tâche, nous pouvons, grossièrement, la diviser en trois parties : les dendrites, le corps cellulaire qui porte le noyau et l'axone. (Figure 16)

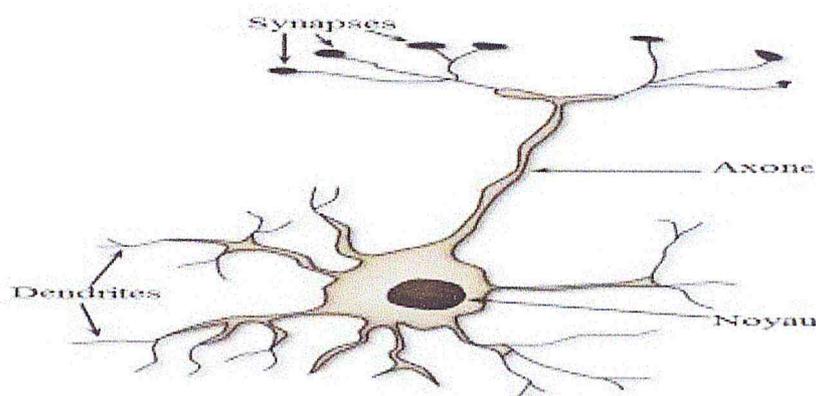


Figure 16. Modèle du neurone biologique

- **Le neurone artificiel (formel)**

Un neurone est un automate indépendant MISO (multi inputs, single output), dont l'état de sortie, est une valeur scalaire  $Y_k$ . En générale, on considère que chaque neurone fournit une information additive aux unités de calcul (neurones) qui lui sont connectés. La valeur nette ou règle de propagation de neurone  $k$ ,  $Net_k$  est simplement la somme pondérée des sorties des différents neurones en amont avec lesquels il est connecté, plus une valeur d'offset (biais interne). La figure 10 résume la structure détaillée du neurone.

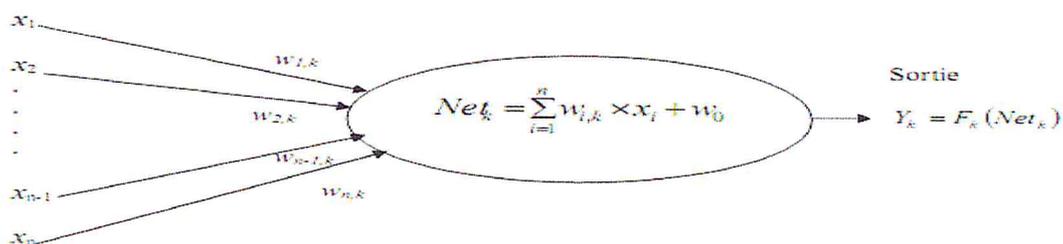


Figure 17. Structure détaillée d'un neurone artificiel

- $x_n$  : l'entrée n du k<sup>ème</sup> neurone.
- $w_{jk}$  : poids associé au j<sup>ème</sup> entrée du neurone k.
- $Net_k = \sum_j w_{jk} Y_j + w_0$  : règle de propagation ou valeur net.
- $w_0$  : valeur d'offset ou biais interne.
- $F_k$  : fonction d'activation.
- $Y_k$  : sortie du neurone k.

- **Activation et règle de propagation**

La règle de propagation définit l'effet des neurones en amont exercé sur le neurone actuel.

La fonction d'activation définit l'effet du neurone actuel sur les neurones avec lesquels il est connecté.

- **Règles de propagation**

La règle de propagation usuelle est définie par :

$$Net_k(t) = \sum_j w_{jk}(t) y_j(t) + \Theta_k(t)$$

Feldman et Ballard [6], ont introduit une autre règle appelée SIGMA-PI UNIT donnée par la relation suivante :

$$Net_k(t) = \sum_j w_{jk}(t) \prod_m y_{jm}(t) + \Theta_k(t)$$

- **Fonction d'activation**

La fonction d'activation des neurones est généralement l'une des caractéristiques principales d'un type de réseau particulier. En effet l'état d'un neurone peut être à valeurs binaires ou réelles et la fonction d'activation peut fortement varier d'un type de réseau à l'autre. Les deux familles principales sont la fonction signe, pour les neurones à états binaires, et la fonction sigmoïde pour les neurones à états réels (Figures 12 et 14). D'autres fonctions sont cependant utilisables telles que les fonctions gaussiennes (Figure 13) ou les fonctions hyperboliques.

$$Y_k = F(Net_k) = \frac{1}{1 + \exp\left(\frac{-Net_k}{T}\right)}$$

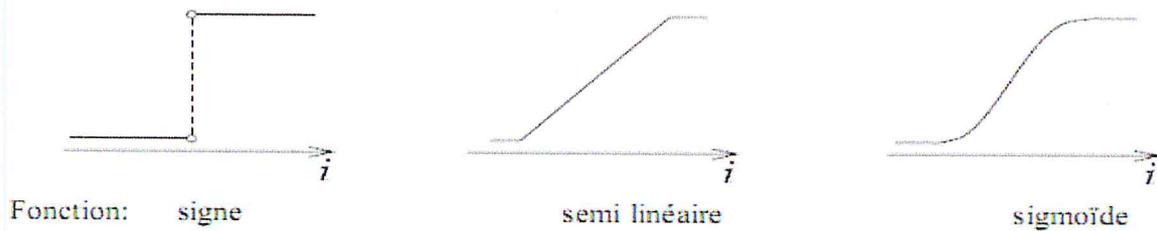


Figure 18. Différentes fonctions d'activation

❖ **Fonction Signe:**

Fonction *Signe*

$f(x) = a(2H(x) - 1)$  Avec  $H(x)$  fonction de

Heaviside:

$H(x) = 1$  si  $x > 0$ ,

$H(x) = 0$  sinon

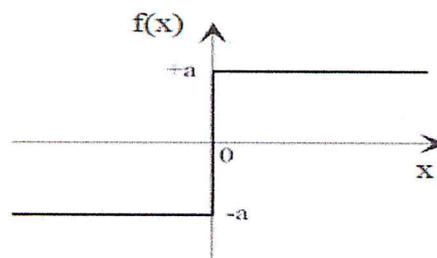


Figure 19. La fonction Signe

❖ **Fonction gaussienne:**

$$f(x) = \exp\left(-\frac{(x-m)^2}{2\sigma}\right)$$

Avec :  $m$  est la moyenne.  
 $\sigma$  est la variance.

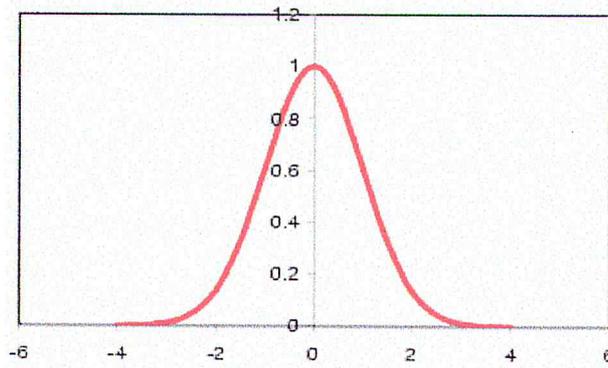


Figure 20. La fonction Gaussienne

Dans notre modèle, nous utilisons la fonction sigmoïde implémentée sous Matlab comme fonction d'activation dans le réseau de neurones, car nos entrées sont réelles.

❖ **Fonction sigmoïde**

Dans un neurone réel, les signaux sont envoyés entre les neurones quand la combinaison des données d'entrée dépasse un certain seuil : le seuil d'activation. Le comportement n'est pas linéaire car la réponse ne dépend pas linéairement de l'incrément de la stimulation.

La fonction d'activation la plus commune est la **fonction sigmoïde** :

$$y = 1 / (1 + e^{-x})$$

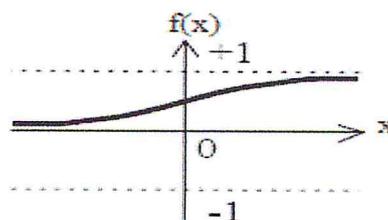


Figure 21. Exemple courbe sigmoïde

Dans certaines applications, la sortie du neurone peut être une fonction aléatoire (ex : réseaux RBF), l'activation dans ce cas n'est pas déterministe.

❖ **La fonction de sortie :**

L'une des plus importantes particularités du réseau de neurones est de n'avoir qu'une

sortie pour un grand nombre d'entrées binaires ou réelles, la sortie  $S$  est en général du même type que les entrées.

Ce tableau récapitule la transition entre le neurone biologique et le neurone formel.

Neurone biologique	Neurone artificiel
Synapses	Poids de connexions
Axone	Signal de sortie
Dendrite	Signal d'entrée
Corps cellulaire (Somma)	Fonction d'activation

**Tableau 1. La correspondance entre neurone biologique et neurone artificiel**

### 3.4.6 Topologies des réseaux de neurones formels

Généralement, un réseau neuromimétique est constitué de trois couches. Couche d'entrée, représentée par tous les neurones qui reçoivent directement le signal d'entrée, la couche de sortie constituée par les neurones qui délivrent la sortie du réseau, les neurones existants entre ces deux couches représentent la couche cachée. La façon avec laquelle les neurones et les couches sont interconnectés définit la topologie des réseaux. On distingue deux types de réseaux de neurones : les réseaux non bouclés appelés aussi feed-forward et les réseaux bouclés, dit aussi récurrents.

#### a) Les réseaux récurrents

Par opposition aux réseaux feed-forward, les réseaux récurrents peuvent contenir des chemins bouclés, passant plusieurs fois par un même neurone (figure 22). Grâce à cette structure cyclique, un stimuli entrant peut être partiellement ou totalement remis en question par l'état antérieur du réseau ou par l'arrivée de stimuli postérieurs. Ce type de réseau a donc des capacités théoriques supérieures à celles des réseaux non-récurrents. Les réseaux récurrents présentent donc une dynamique complexe dûe aux multiples rétroactions internes.

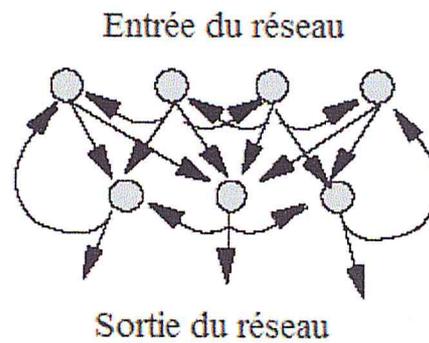


Figure 22. Réseau de neurones bouclé.

- **Topologie récurrente ou dynamique (recurrent neural network RNN)**

Dans cette catégorie, les neurones reçoivent le signal en provenance des neurones en aval et en amont ou de lui-même. Chaque couche reçoit des signaux à partir de n'importe quelle couche. Trois grandes classes existent [7]:

- réseaux à compétitions (VLQ, ART, ..., etc.).
- réseaux à connexions symétriques (Hopfield, machine de Boltzmann, ..., etc.).
- réseaux récurrents temporels (Jordan, Elman, PRNN, ..., etc.).

➤ **Réseaux de Jordan**

Parmi les plus anciennes approches utilisées, on trouve les réseaux dynamiques de Jordan.

Dans ce type de réseau, la sortie est réinjectée dans l'entrée via un ensemble de neurones appelés, neurones d'états, Figure 23

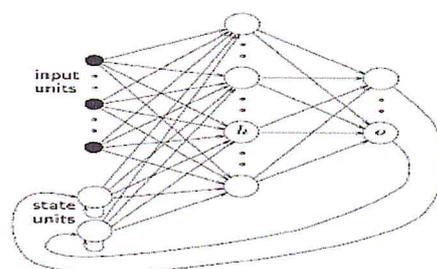


Figure 23. Réseau de Jordan

➤ Réseau d'Elman

Le réseau d'Elman a le même principe que le réseau de Jordan. Sauf que le feedback est en provenance de la couche cachée réinjectée dans l'entrée via une couche appelée couche de contexte, Figure 24.

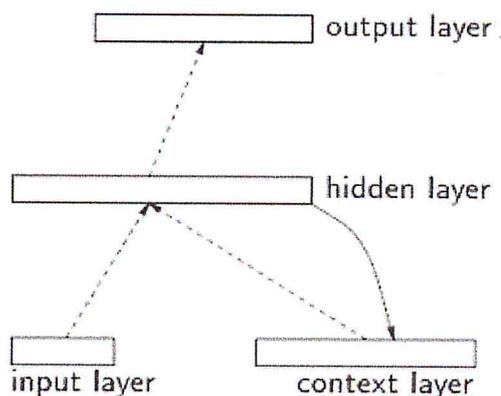


Figure 24. Réseau d'Elman

• Réseau PRNN (Pipeline Recurrent Neural Network)

Fut introduite par S. Haykin et Liang li en 1995[8], l'approche PRNN, est un réseau neuromimétique modulaire, contient M modules dynamiques. Chaque module est constitué par un réseau récurrent RNN, possédant (N) neurones.

Le réseau PRNN sert à la linéarisation du signal d'entrée, en lui appliquant une transformation non linéaire. Le PRNN effectue un filtrage sur un segment d'échantillons du signal d'entrée  $s(t)$ . Chaque module est un sous modèle dynamique possédant son propre comparateur. Relie au signal d'entrée via P échantillons, en plus de ces P d'entrées, il y en a N signaux de feedback.

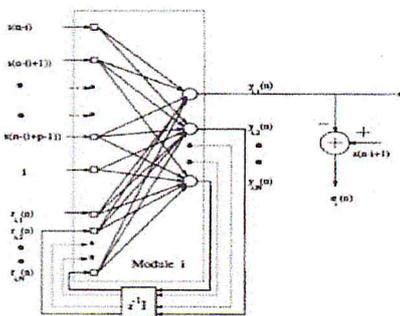


Figure 25. Module RNN.

- **Les Réseaux de neurones convolutionnels– (CNN)**

Cette architecture de réseau inventée par Léon O. Chua est similaire aux automates cellulaires. Il s'agit d'un réseau où chaque cellule est connectée à ses voisins (au sens de la notion de voisinage que l'on définit pour un problème donné). [1]

Ils sont des réseaux de neurones multi-couches qui sont spécialisés dans des tâches de reconnaissance de forme. Ils sont réputés pour leur robustesse aux faibles variations d'entrée, le faible taux de prétraitement nécessaires à leur fonctionnement, et ne requièrent aucun choix d'extracteur de caractéristiques spécifiques. L'architecture proposée repose sur plusieurs réseaux de neurones profonds alternant entre couches de convolution et couches d'agrégation (pooling). Ces réseaux de neurones profonds appartiennent à une classe de modèles s'inspirant des travaux de Hubel et Wiesel sur le cortex visuel primaire du chat [2]. Le début de l'architecture consistant en une succession de couches de convolution et d'agrégation est dédiée à l'extraction automatique de caractéristiques, tandis que la seconde partie, composée de couches de neurones complètement connectés, est dédiée à la classification.

**b) Les réseaux feed-forward**

Il s'agit de réseaux appelés aussi réseaux de type Perceptron ou statique, ce sont des réseaux dans lesquels l'information se propage de couche en couche sans retour en arrière. On peut alors regrouper les neurones en couches selon la longueur de ce chemin (figure 26). On parle alors de réseaux à deux couches « Perceptron monocouche » dans lesquels les neurones de sorties sont directement reliés aux neurones d'entrées, et le perceptron multi-couches comprend en plus des deux couches de base une ou plusieurs couches intermédiaires appelées couches cachées. Dans ce type de réseau le temps n'intervient pas comme variable fonctionnelle c-à-d que sa sortie ne dépend pas de son passé.

Comme la Figure 27 le montre, Un réseau de neurones (ANN) ou feed-forward neural network est composé de trois couches comme présenté dans la figure : une couche d'entrée (x), une ou plusieurs couche(s) cachée(s) ( $\theta$ ) et une couche de sortie (y).

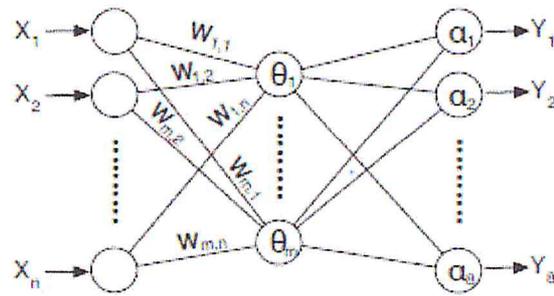


Figure 26. Exemple d'architecture d'un ANN.

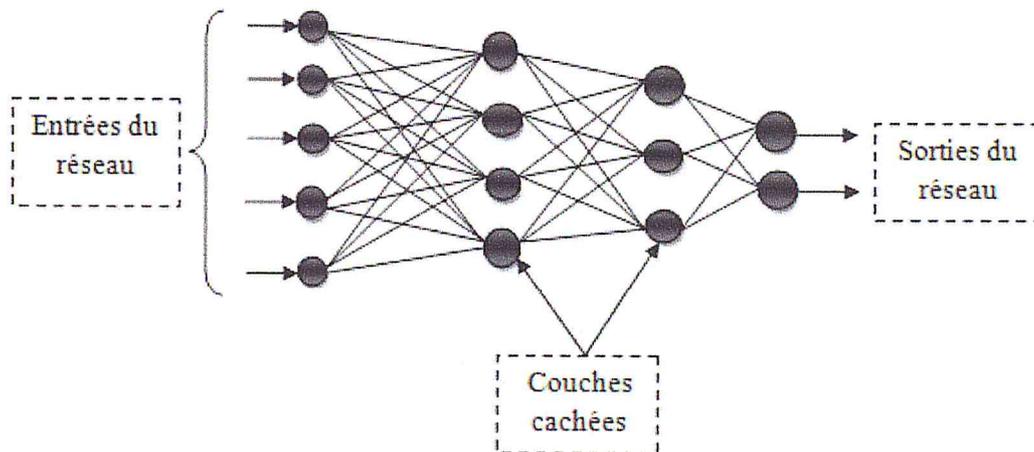


Figure 27. Réseau de neurones non bouclé.

- Concepts de base d'un réseau de neurones artificiels (ANN)

- Fonction d'activation

La fonction d'activation utilisée durant les expérimentations est la fonction classique de tangente hyperbolique :

$$\alpha(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

- **Algorithme d'apprentissage du « feed-forward »**

Trois étapes sont nécessaires : Calcul de la sortie, Rétro-propagation de l'erreur et mise-à-jour des poids et biais.

Phase de calcul des sorties : Soit  $N_l$  le nombre de neurones contenus dans la couche  $l$  ( $1 \leq l \leq M$ ) et  $M$  le nombre de couches du ANN.  $\theta_{n,l}$  est le biais du neurone  $n$  ( $1 \leq n \leq N_l$ ) de la couche  $l$ . Soit un ensemble de  $p$  exemples d'entrée  $x_i$  ( $1 \leq i \leq p$ ) et un ensemble de classes  $y_i$  associées à chacun des  $x_i$ . La sortie  $\gamma_{n,l}$  du neurone  $n$  de la couche  $l$  est donnée par :

$$\gamma_{n,l} = \alpha_{n,l} = \alpha \left( \sum_{m=0}^{N_{l-1}} w_{nm}^l \times \gamma_{m,l-1} \right) + \theta_{n,l}$$

Phase d'apprentissage : L'erreur  $e$  observée entre la sortie attendue  $y$  et le résultat de la phase de calcul des sorties est évaluée comme suit :

$$e_n^l = y_n - \gamma_{n,M}$$

$$e_n^l = \sum_{m=1}^{N_{l+1}} w_{m,n} \times \delta_{m,l+1}$$

Phase de mise-à-jour : Lorsque les erreurs entre la sortie attendue et le résultat sont calculées, les poids  $w_{n,m}^l$  et les biais  $\theta_{n,l}$  doivent alors être respectivement mis-à-jour :

$$w_{n,m}^{l*} = w_{n,m}^l + \epsilon \delta_{n,l} \times \alpha_{n,l}$$

$$\theta_{n,l}^* = \theta_{n,l} + \epsilon \delta_{n,l}$$

c) topologie statique ou réseau à couche

Les réseaux neuromimétique statique ou réseaux à couches, sont de réseaux dont le signal d'entrée se propage d'une couche à l'autre, aucun feedback n'est nécessaire. De plus une couche ne reçoit de signal que de la couche qui la précède, et ainsi de suite jusqu'à la couche de sortie.

On distingue dans ce type de réseaux, les réseaux d'une seule couche (perceptron), l'adaline et le perceptron multicouche (PMC).

- **Perceptron simple +**

Le perceptron simple est illustré dans la figure 28 .Il s'agit d'une seule couche de S neurones totalement connectée sur un vecteur p de R entrées. La matrice

$W = [w_1 w_2 \dots w_S]^T$  de dimension  $S \times R$  représente l'ensemble des poids de la couche, avec les vecteur-rangées  $iw$  (dimension  $R \times 1$ ) représentant les  $R$  poids des connexions reliant le neurone  $i$  avec ses entrées. Le vecteur  $b$  (dimension  $S \times 1$ ) désigne l'ensemble des  $S$  biais de la couche. Les niveaux d'activation  $n = Wp - b = [n_1 n_2 \dots n_S]^T$  des neurones de la couche servent d'argument a la fonction d'activation qui applique un seuil au niveau 0 pour produire le vecteur des sorties  $a = [\alpha_1 \alpha_2 \dots \alpha_S]^T$ , ou :

$$a_i = \begin{cases} +1 & \text{si } n_i \geq 0 \\ -1 & \text{autrement} \end{cases}$$

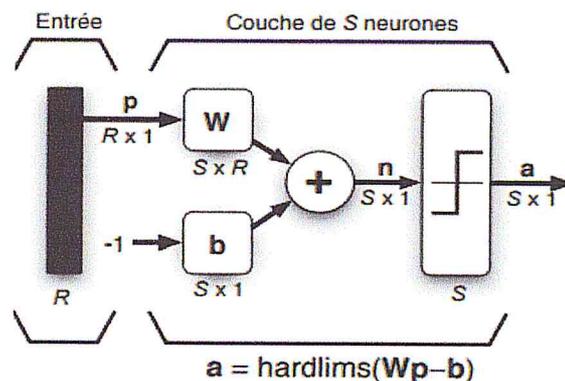


Figure 28. Perceptron à une seule couche avec fonction seuil

- **Perceptron multicouche**

Les réseaux multicouches permettent de lever la limitation de classification linéairement séparable. On peut même démontrer qu'avec un réseau de trois couches (deux couches cachées + une couche de sortie), on peut construire des frontières de décision de complexité quelconque, ouvertes ou fermées, concaves ou convexes, à condition d'employer une fonction de transfert non linéaire et de disposer de suffisamment de neurones sur les couches cachées.

Un réseau multicouche n'est rien d'autre qu'un assemblage de couches concaténées les unes aux autres, de la gauche vers la droite, en prenant les sorties d'une couche et en les injectant comme les entrées de la couche suivante. Une chose que l'on peut déjà remarquer est qu'il ne sert à rien d'assembler plusieurs couches ADALINE car la combinaison de plusieurs couches linéaires peut toujours se ramener à une seule couche linéaire équivalente. C'est pourquoi, pour être utile, un réseau multicouche doit toujours posséder des neurones avec fonctions de transfert non-linéaires sur ses couches cachées. Sur sa couche de sortie, selon le type d'application, il pourra comporter des neurones linéaires ou non-linéaires.

Minsky et Papert [10], ont montré en 1969, qu'un réseau multicouche, peut dépasser les limitations présentés par le perceptron à une seule couche et l'adaline. En 1986 Rumhart et Hinton & Williams ont développé une technique d'apprentissage au profit de ces réseaux qui d'après [11], et avec une seule couche cachée, peuvent approximer n'importe quelle fonction dans la nature, étant donné que les fonctions d'activations sont non linéaires.

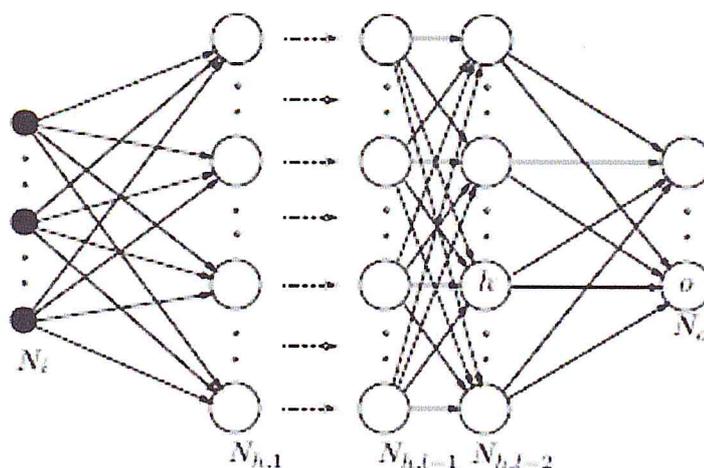


Figure 29. Perceptron multicouche.

➤ **Différence entre la fonction sigmoïde et le perceptron :**

La fonction sigmoïde présente l'avantage d'être dérivable ainsi que de donner des valeurs intermédiaires (des réels compris entre 0 et 1) par opposition à la fonction de Perceptron qui elle renvoie soit 0 soit 1. Toutefois, les deux fonctions possèdent un seuil. Celui de la fonction de perceptron est en  $x = 0$  et vaut 1 alors que celui de la fonction sigmoïde est en 0 également mais vaut  $1/2$ .

#### **4. Conclusion**

L'objectif de ce chapitre est de se familiariser avec les concepts liés à l'apprentissage. Nous avons, à cet effet, essayé de donner un aperçu général sur les différentes méthodes de l'apprentissage supervisé en se basant sur les réseaux de neurones artificiels.

***Chapitre 3 :***  
***Travaux***  
***antérieurs***



## 1. Introduction

Diverses méthodes sont développées et mises en œuvre pour le processus des systèmes de classification des arythmies cardiaques.

Dans ce contexte, nous allons citer quelques travaux qui ont contribué au succès du système.

## 2. Les travaux antérieurs

### 2.1 Prétraitement

Parmi toutes les propositions pour réduire le bruit dans les signaux ECG, la plus simple et la plus utilisée est la mise en œuvre de filtres numériques récurrents de la réponse impulsive finie (FIR) [22], ce qui a été rendu possible en calcul avec l'avance dans les microcontrôleurs et les microprocesseurs. Ces méthodes fonctionnent bien pour l'atténuation des bandes de fréquences connues, telles que le bruit provenant du réseau électrique (50 Hz ou 60 Hz), car elles permettent une application rapide et simple du filtre à bande de rejet. Le problème avec cette approche est que la fréquence du bruit n'est pas toujours connue, ce qui peut être résolu en appliquant des filtres pour diverses bandes de fréquences au signal. Cependant, l'utilisation indiscriminée des filtres, à savoir, passe-haut et passe-bas, déforme la morphologie du signal, et à plusieurs reprises, le rend inutilisable pour diagnostiquer des maladies cardiaques. Des architectures avec des filtres adaptatifs [23, 24] ont également été utilisées pour l'élimination du bruit à partir des signaux ECG. Cependant, selon Thakor et Zhu [25], cette technique a des contraintes et ne présente pas d'avantages importants par rapport aux filtres numériques FIR. Xue et al. [26] surmonter certaines de ces difficultés en utilisant des filtres adaptatifs basés sur des réseaux neuronaux de sorte que la réduction du bruit a été considérablement améliorée. Cette stratégie a permis une meilleure détection du complexe QRS, comparée à la même méthode en utilisant des filtres linéairement adaptatifs.

Au cours de la dernière décennie, de nombreuses méthodes basées sur des transformations en ondelettes ont été utilisées pour éliminer le bruit, car elles conservent les propriétés du signal ECG en évitant la perte de ses détails physiologiques importants et sont simples d'un



point de vue computationnel [27-29]. Sayadi et Shamsollahi [2] ont proposé une modification de la transformée en ondelettes appelée transformée en ondelettes bioniques multi-adaptatives et elles ont été appliquées pour réduire le bruit et la variation de référence du signal ECG. Cette méthode a présenté des résultats supérieurs par rapport à ceux basés sur la transformée en ondelettes traditionnelle.

D'autres méthodes ont également présenté des résultats intéressants sur l'atténuation du bruit. Sameni et al. [30] ont proposé l'utilisation de filtres bayésiens non linéaires pour la réduction du bruit de signal ECG, présentant des résultats prometteurs. Un nouvel algorithme basé sur le Filtre Kalman étendu [3], qui intègre les paramètres du modèle dynamique ECG pour la réduction du bruit et la compression du signal ECG, a donné une contribution significative car la méthode a montré la plus grande efficacité à ce jour. Notez que les travaux dans [2,3,30] rapportent leurs résultats en termes de rapport signal sur bruit.

Les techniques de prétraitement du signal ECG sont largement explorées, mais le choix de la méthode à utiliser est intrinsèquement lié à l'objectif final de la recherche. Les méthodes axées sur la segmentation des battements cardiaques à partir du signal ECG (c.-à-d. La détection du complexe QRS, d'autres ondes ou des points finaux visant la délimitation des battements cardiaques) ont tendance à nécessiter un prétraitement différent des méthodes axées sur la classification automatique des arythmies. Ces méthodes suivent les instructions AAMI et le même protocole pour signaler les résultats, mais différentes techniques de prétraitement sont utilisées. De Chazal et al. [7] ont utilisé deux filtres médians pour éliminer l'errance de base. Un filtre médian de largeur de 200 ms pour enlever les complexes QRS et les ondes P et autres de 600 ms de largeur pour éliminer les ondes T. Le signal résultant est ensuite filtré à nouveau avec un filtre FIR à 12 ordres passe-bas avec un point de 3 dB à 35 Hz. Le même prétraitement est utilisé dans [31-35, 8,36]. Dans [37], le signal est prétraité avec un filtre FIR à bas débit de 10ème ordre. Ye et al. [38] a utilisé une approche basée sur les ondelettes pour éliminer la distance de base [39], puis un filtre passe-bande à 0,5-12 Hz est appliqué pour maximiser l'énergie complexe QRS. Bazi et al. [40] a proposé l'utilisation d'un filtre passe-haut pour les artefacts sonores et un filtre d'échappement pour le bruit du réseau électrique. Lin et Yang [41] utilisent un filtre passe-bas de deuxième ordre et deux filtres médians. Dans [42], le signal est soustrait par sa moyenne et ensuite normalisé. Escalona-Moran et al. [43] ont utilisé l'onde brute, c'est-à-dire qu'aucun prétraitement n'est appliqué.

Les méthodes d'état de l'art considérées n'appliquent même pas le prétraitement sur le signal. Bien que certaines études existent concernant les techniques de prétraitement avec la performance finale de la classification automatique des arythmies, telles que le travail présenté dans [44], elles sont insuffisantes en nombre et d'autres recherches dans ce domaine sont encouragées. Il convient de noter que les méthodes de pointe pour la classification automatisée de l'arythmie n'utilisent pas les méthodes de prétraitement à la fine pointe de la technologie pour améliorer le rapport signal / bruit.

## 2.2 Segmentation

Les méthodes de segmentation du rythme cardiaque (c'est-à-dire la détection du pic R ou du complexe QRS) ont été étudiées pendant plus de trois décennies [49,53,46,54,55] et les générations de ces algorithmes et les nouveaux procédés de développement reflètent l'évolution du pouvoir de traitement des ordinateurs. Avec la possibilité d'utiliser des ordinateurs de traitement plus rapides, les auteurs ont cessé de s'inquiéter des coûts de calcul et ont commencé à se concentrer sur la précision de la segmentation des battements cardiaques.

Pour une comparaison équitable des méthodes axées sur la segmentation coeur-battement, une base de données standard doit être utilisée. Le plus utilisé et recommandé par ANSI / AAMI pour la validité du matériel médical [10], est la base de données MIT-BIH pour l'analyse de l'arythmie [56] - dans ce cas, utilisé pour la segmentation du rythme cardiaque, bien que d'autres bases de données soient également utilisés. Cependant, selon Kohler et al. [59], bon nombre des méthodes présentées dans la littérature n'utilisent pas une base de données standardisée ou utilisent une partie seulement de celle-ci, ce qui rend difficile la comparaison équitable des méthodes.

Une approche largement utilisée pour la segmentation, en raison de sa simplicité et de ses résultats prometteurs, est basée sur des filtres numériques pour l'atténuation du bruit et l'élimination de la ligne de base fluctuante, des traductions non linéaires qui améliorent le seuil de détection de crête et de protection R ont été proposées Par Pan et Tompkins [49]. Des méthodes plus sophistiquées ont également été utilisées, telles que des méthodes basées sur des réseaux de neurones [53], des algorithmes génétiques [50], des transformées en ondelettes [60,61,4], des banques de filtres [46], Quad Level Vector [62], entre autres. Certains algorithmes proposent également d'identifier d'autres ondes associées à des battements

cardiaques, telles que l'onde P et l'onde T [4,63-65], ce qui peut être utile pour les méthodes de classification de l'arythmie, car on peut obtenir plus d'informations sur les battements cardiaques.

Bien que la segmentation des battements cardiaques ne soit pas l'objet principal de cette enquête, notez que cette étape est d'une importance primordiale dans le processus de classification cardiaque de l'arythmie, car certaines erreurs se propagent aux étapes suivantes et ont un fort impact dans la classification finale du système d'arythmie. Cependant, une grande majorité des recherches examinées utilisent des bases de données dans lesquelles les événements liés à la segmentation du battement de cœur, c'est-à-dire la détection du pic R ou du complexe QRS, sont identifiés et précédemment étiquetés, ce qui réduit le stade de segmentation à une recherche simple d'un événement marqué dans la base de données. De cette façon, les résultats rapportés par ces travaux ne tiennent pas compte de l'impact de l'étape de segmentation même si l'étiquetage de la base de données est sujet à des erreurs humaines. Par conséquent, l'évaluation de l'impact de différents algorithmes de segmentation sur les méthodes automatiques de classification de l'arythmie peut être une direction de recherche prometteuse.

Ye et al. [66] ont proposé un test pour étudier la robustesse de leur méthode d'extraction de fonctionnalités par rapport à une question de segmentation, l'erreur de mise au point de R-peak. Une gigue artificielle distribuée par Gauss a été utilisée pour ajouter une erreur sur les annotations de pointe R. Nous suggérons à d'autres auteurs d'intégrer ce test dans des travaux futurs visant à classifier automatiquement le rythme cardiaque.

## 2.3 Extraction des paramètres

L'étape d'extraction des caractéristiques est la clé du succès de la classification de l'arythmie à l'aide du signal ECG. Toute information extraite des battements cardiaques utilisés tout au long de son type est peut-être considérée comme une caractéristique. Les caractéristiques peuvent être extraites sous diverses formes directement à partir de la morphologie du signal ECG dans le domaine temporel et / ou dans le domaine fréquentiel, ou du rythme cardiaque. Les méthodes les plus populaires proposées dans la littérature sont discutées dans la section 2.3.1.



Même si certains travaux considèrent l'extraction des fonctionnalités et la sélection des fonctionnalités comme deux termes interchangeables, ces deux procédés sont en fait différents. Bien que l'extraction des fonctions soit définie comme étape qui implique la description d'un battement cardiaque, la sélection des fonctionnalités consiste à choisir un sous-ensemble présentant les caractéristiques les plus représentatives dans le but d'améliorer la phase de classification. La section 4.2 est consacrée à décrire les approches de sélection des fonctionnalités.

### 2.3.1 Extraction de caractéristiques

La caractéristique la plus commune trouvée dans la littérature est calculée à partir du rythme cardiaque (ou intervalle de battement cardiaque), également connu sous le nom de l'intervalle RR. L'intervalle RR est le temps entre le pic R d'un battement de cœur par rapport à un autre battement cardiaque, qui pourrait être son prédécesseur ou son successeur. À l'exception des patients qui utilisent un stimulateur cardiaque, les variations perçues dans la largeur de l'intervalle RR sont corrélées avec les variations de la morphologie de la courbe, souvent provoquée par les arythmies [1]. Ainsi, les caractéristiques de l'intervalle RR ont une grande capacité de discriminer les types de battements cardiaques et certains auteurs ont basé leurs méthodes uniquement sur l'utilisation des caractéristiques de l'intervalle RR [67,69]. Les variations de cette fonction sont utilisées pour réduire les interférences de bruit et sont très fréquentes, par exemple, la moyenne de l'intervalle RR dans un patient pendant un certain intervalle de temps [70]. Lin et Yang [41] ont montré que l'utilisation d'un intervalle RR normalisé améliore significativement les résultats de classification. Seuls les intervalles RR normalisés sont utilisés dans ce travail et les résultats sont comparables aux méthodes à la fine pointe de la technologie, même dans le cadre du paradigme inter-patient. Doquire et al. [71] a confirmé l'efficacité des intervalles RR normalisés au moyen de techniques de sélection de caractéristiques.

D'autres caractéristiques extraites des intervalles cardiaques se retrouvent également dans la littérature, comme d'autres distances entre les points finaux d'un battement cardiaque (ici appelés intervalles ECG ou segments ECG). Parmi ces intervalles, l'intervalle QRS, ou la durée du complexe QRS, est le plus utilisé. Certains types d'arythmies provoquent des variations dans l'intervalle QRS, ce qui en fait une bonne caractéristique discriminante [7,72]. Il convient de mentionner qu'il existe d'autres algorithmes disponibles pour déterminer ces points finaux, comme celui proposé par Laguna et al. [63]. Le tableau 2 (voir annexe) présente



les valeurs standard pour ces intervalles, compte tenu d'un être humain sain sans anomalies cardiaques.

Les fonctionnalités extraites du domaine de temps / fréquence en combinaison avec les caractéristiques de l'intervalle RR apparaissent comme les méthodes qui ont produit les précisions les plus élevées dans la littérature à ce jour. Le moyen le plus simple d'extraire des fonctionnalités dans le domaine temporel est d'utiliser les points de la courbe ECG segmentée, c'est-à-dire les battements cardiaques, en tant que caractéristiques [73,74]. Cependant, l'utilisation d'échantillons de la courbe en tant que caractéristiques est une technique qui n'est pas très efficace, car en plus de produire un vecteur des caractéristiques à haute dimension (selon la quantité d'échantillons utilisés pour représenter le rythme cardiaque), il souffre de plusieurs problèmes liés à l'échelle ou au déplacement du signal par rapport au point central (pic R). Viser à réduire la dimension de la caractéristique, de nombreuses techniques vectorielles ont été appliquées directement sur les échantillons qui représentent le battement cardiaque (dans le voisinage du pic R) en tant qu'analyse des composants principaux (PCA) [75-77], ou une analyse indépendante des composants (ICA) [78-80], dans lequel de nouveaux coefficients sont extraits pour représenter le rythme cardiaque. Chawla [81] présente une étude comparative entre l'utilisation de PCA et ICA pour réduire le bruit et les artefacts du signal ECG et a montré que l'ACP est une meilleure technique pour réduire le bruit, tandis que l'ICA est mieux pour extraire des fonctionnalités. La technique ICA permet de séparer statistiquement les différentes sources d'un signal de mélange.

L'ECG est un mélange de plusieurs potentiels d'action et chaque potentiel d'action pourrait être fortement lié à une classe d'arythmie. La raison d'être de ICA pour la classification des battements cardiaques ECG consiste à séparer les sources d'actions potentielles ainsi que les sources de bruit. La technique PCA sépare les sources en fonction de la contribution énergétique au signal. L'étude présentée dans [81] suggère que les sources de bruit sur cette base ont une faible énergie et sont difficiles à isoler et que les sources individuelles isolées par l'ICA sont des caractéristiques prometteuses pour la classification de l'ECG. En outre, il a été démontré que la combinaison de ces deux techniques, c'est-à-dire PCA pour la réduction du bruit et ICA pour l'extraction des fonctionnalités, peuvent offrir de meilleurs avantages par rapport à l'utilisation d'un seul d'entre eux. Une autre technique basée sur PCA, The Kernel Principal Component Analysis (KPCA), a été utilisée par Kanaan et al. [82]. Dans ce travail, une comparaison entre PCA et KPCA a été effectuée et il a été conclu que KPCA est supérieur à la technique PCA pour classer les battements cardiaques du signal

ECG. Selon Kallas et al. [83], KPCA fonctionne mieux, en raison de sa structure non linéaire. Özbay et al. [84] ont utilisé des techniques de regroupement directement dans des points échantillonnés à partir de la courbe pour réduire de 106 échantillons à 67 grappes / points. Les auteurs ont également utilisé une technique de regroupement pour augmenter le nombre de fonctionnalités à 212, mais il n'y avait pas de différences significatives dans les résultats. Asl et al. [85] a utilisé l'Analyse Discriminante Généralisée (GDA) pour réduire les dimensions des caractéristiques du type d'intervalle du rythme cardiaque pour classer les arythmies. Ils ont signalé une précision proche de 100% pour ce type d'arythmie à l'aide de la base de données MIT-BIH. Cependant, les auteurs n'ont pas pris soin de séparer les battements cardiaques du même patient utilisés lors de la formation et des tests (paradigme intra-patient), ce qui est une préoccupation sérieuse abordée plus avant. Le paradigme inter-patient devrait être considéré comme un scénario plus réaliste. Des techniques plus simples, telles que l'interpolation, ont également été utilisées pour réduire le nombre de points représentant les battements cardiaques. Un exemple de cette technique est présenté par de Chazal et al. [7], dans lequel le battement de cœur, initialement représenté par 250 échantillons (environ 600 ms de la courbe, échantillonné à 360 Hz), a été subdivisé et présenté dans 18 échantillons. Dans la littérature, l'onde ECG sous échantillonnée est également appelée morphologie ou caractéristiques morphologiques.

Récemment, des projections aléatoires ont également été utilisées pour un tel but, comme dans [86,42]. Huang et al. [42] montrent que les caractéristiques extraites avec des projections aléatoires ont produit des résultats comparables aux méthodes à la fine pointe de la technologie, même si l'on considère le paradigme inter-patient. D'autres techniques ont également été utilisées, telles que le codage prédictif linéaire [87], l'ordre élevé s'accumule [88,89], le regroupement [84,90,91], la dimension de corrélation et le plus grand exposant de Lyapunov [92,93], la transformation d'Hermite [94], Dimension fractale locale [95]. Bien que diverses techniques aient été considérées, la plupart des études présentées dans la littérature utilisent des transformations d'ondelettes et les chercheurs affirment que c'est la meilleure méthode pour extraire des caractéristiques du signal ECG [44,96,97]. La transformée en ondelettes permet l'extraction de l'information à la fois dans les domaines de la fréquence et du temps, ce qui est différent de ce qui est généralement réalisé par la transformée de Fourier traditionnelle [98], ce qui permet d'analyser uniquement le domaine fréquentiel. Dans les types de transformée en ondelettes, la transformée en ondelettes discrète (DWT) est la plus populaire pour la classification des signaux ECG en raison de sa mise en œuvre facile. Outre

DWT, la transformation en ondelettes continue (CWT) a également été utilisée pour extraire des caractéristiques des signaux ECG [99], car elle surmonte certains des inconvénients du DWT, tels que la grossièreté de la représentation et de l'instabilité. Cependant, le CWT n'est pas largement utilisé en raison du fait que sa mise en œuvre et son inverse ne sont pas disponibles dans les boîtes à outils standard (comme MATLAB wavelet Toolbox) et CWT doit être soigneusement discrétisé pour l'utiliser comme analyseur CWT. En outre, même si Addison [99] met l'accent sur le coût de calcul élevé comme un inconvénient pour l'utilisation de CWT, il a été utilisé avec succès même sur des équipements médicaux simples pendant au moins une décennie.

Enfin, Addison [99] défend l'utilisation de DWT, avec CWT, car ils offrent un gain sur les méthodologies utilisées aujourd'hui, dans lesquelles les auteurs utilisent une seule des transformées. Selon Güler et Übeyli [44], le choix de la fonction de la fonction mère est utilisé pour l'extraction des caractéristiques est crucial pour la performance finale du modèle de classification. Ce choix devrait être soigneusement analysé afin de ne pas perdre des détails importants sur le signal ECG. Outre le choix de la fonction de l'ondelette mère, l'ordre du filtre et le niveau de décomposition sont des paramètres qui influent sur les résultats finaux de la classification de l'arythmie. Daamouche et al. [100] a proposé l'utilisation de la technique d'optimisation des essences de particules (PSO) pour optimiser ces paramètres et a conclu que ce processus améliorerait les résultats finaux. Dans la littérature, on propose diverses caractéristiques statistiques extraites des coefficients de transformée en ondelettes, telles que la moyenne, l'écart type, l'énergie [44] et la variance coefficient [101]. Ces caractéristiques présentent un grand avantage car elles sont à l'abri des variations du marquage de point final. Certains auteurs ont utilisé des techniques pour réduire l'espace des caractéristiques après l'application de la transformée en ondelettes, comme dans le travail de Song et al. [102] qui a comparé les techniques d'analyse PCA et d'analyse discriminante linéaire (LDA) pour la réduction dimensionnelle après l'utilisation de la transformation en ondelettes. Wang et al. [103] et Polat & Günes , [104] ont également utilisé PCA pour réduire les caractéristiques formées par les coefficients d'ondelettes et ont également signalé une amélioration significative de leurs résultats. Selon Güler et Übeyli [44], les ondelettes de Daubechies sont les listes de voix principales les plus appropriées pour la classification des battements cardiaques ECG. Parmi eux, les Daubechies de l'ordre 2 offrent la meilleure précision. Bien que de nombreuses techniques aient été proposées pour extraire et réduire les caractéristiques

des signaux ECG visant à classifier les battements cardiaques, seuls quelques-uns ont considéré le paradigme inter-patient.

Par conséquent, il est difficile d'évaluer si les caractéristiques extraites avec PCA, ICA, GDA et autres sont utiles pour discriminer les patients ou les battements cardiaques. La variance de la fonction d'auto-corrélation est considérée comme une mesure de similitude ou de cohérence entre un signal et sa version décalée [101]. Cette technique est utilisée pour l'extraction de caractéristiques à partir de coefficients d'ondelettes [101, 37] et s'est révélée efficace dans la discrimination des battements cardiaques arythmiques. Le cardiogramme vectoriel (VCG) est une représentation du signal ECG en deux dimensions qui intègre l'information à partir de deux.

Les caractéristiques extraites avec VCG ont été utilisées dans [105, 31, 106, 37]. Selon Goldberger et al. [107], la classification des battements cardiaques classés comme battement ectopique supra-ventriculaire (SVEB) et le battement ectopique ventriculaire (VEB) (battements cardiaques arythmiques) peut être favorisée par des informations provenant de pistes de type V1, V2 ou V4. Pour cette raison, on pense que les fonctionnalités extraites par VCG (combinées avec les pistes II et V1) peuvent aider à mieux discriminer les classes arythmiques minoritaires et importantes telles que SVEB et VEB.

### 2.3.2 Sélection de fonctionnalité

Selon Llamedo et Martinez [37], de nombreux auteurs ont utilisé des techniques qui réduisent l'espace caractéristique, mais peu ont étudié les techniques de sélection des fonctionnalités dans le contexte de la classification des arythmies. Llamedo et Martinez [37] ont employé, pour la première fois dans la littérature, un algorithme pour la sélection de fonctionnalités en utilisant la recherche séquentielle flottante pour la classification de l'arythmie. Cette méthode échange des algorithmes exécutant des recherches vers l'avant et vers l'arrière pour obtenir un ensemble avec les fonctionnalités les plus robustes et éviter l'optimisation locale dans l'espace des fonctionnalités. La méthode proposée a obtenu de meilleurs résultats que la méthode de l'état de l'art en utilisant seulement huit caractéristiques sélectionnées.

Récemment, Mar et al. [34] a également effectué une sélection de fonctionnalités en utilisant la recherche séquentielle flottante [108]. Dans cette étude, les auteurs ont analysé un ensemble de possibilités de sélection des fonctionnalités, en recherchant un compromis entre le nombre de fonctionnalités et la précision. L'objectif de cette recherche était de mettre une méthode spécialement développée pour la surveillance ambulatoire; C'est-à-dire être particulièrement utile dans les applications du monde réel. Pour un tel objectif, une fonction objective optimisée par une méthode de sélection de fonctionnalité a été spécialement développée pour être un indicateur de la qualité des classifications d'arythmie à partir d'un signal ECG. En plus du classificateur linéaire discriminant (LD) utilisé dans les travaux antérieurs, Mar et al. [34] ont utilisé un perceptron multicouche. Cependant, aucun de ces résultats n'a été meilleur que ceux proposés par de Chazal et al. [7] et le travail de Llamedo et Martinez [37] en termes d'exactitude. Néanmoins, l'accent de Mar et al. [34] le travail portait sur la maintenance de la précision avec l'utilisation d'un nombre réduit de fonctionnalités. Les techniques de sélection de fonctionnalités peuvent apporter divers avantages aux méthodes de classification, telles que l'augmentation de la puissance de généralisation des algorithmes de classification et la réduction du coût de calcul, en raison du fait qu'ils utilisent un nombre plus petit de fonctionnalités pour construire le modèle final [34]. Cependant, dans les travaux analysés dans cette enquête, ces techniques ont été peu explorées. Doquire et al. [71] compare la technique de sélection des fonctionnalités de l'enveloppe contre une technique de sélection de fonctionnalités de filtre et plus de 200 types de caractéristiques (dimensions) sont pris en compte pour la tâche. La sélection des fonctionnalités de l'enveloppe est utilisée avec le modèle LD pondéré en utilisant une stratégie de recherche vers l'avant - vers l'arrière (forward-backward). La technique de filtration utilisée est l'information mutuelle en conjonction avec l'approche de classement et la SVM pondérée (Support Vector Machines). Selon les auteurs, les résultats ont montré que des chiffres plus élevés sont obtenus lorsqu'un très petit nombre de fonctionnalités sont sélectionnées. Ils ont souligné que les caractéristiques les plus importantes sont les intervalles R-R, l'amplitude et la longueur de l'onde T et les statistiques de 2ème ordre. Ils ont également affirmé que le critère de l'information mutuelle est un outil puissant pour la sélection de fonctionnalités dans ce scénario. Selon Zhang et al. [35], de nombreuses caractéristiques sont associées à une interprétation mathématique et n'ont pas de sens clair pour les médecins.

Habituellement, les auteurs utilisent plusieurs fonctionnalités combinées et la compréhension de cette fonction contribue à la détection de la classe de battements de cœur

qui n'est pas non plus claire dans la littérature. Pour ce faire, Zhang et al. [35] a proposé un schéma de sélection de caractéristique spécifique à la classe cardiaque pour permettre l'étude de la contribution de caractéristique pour chaque classe d'arythmie / battement de cœur. Ainsi, nous suggérons l'incorporation de cette approche sur les travaux visant à classifier les battements cardiaques. Cela pourrait apporter une contribution importante à la littérature en permettant une meilleure compréhension de la corrélation entre les maladies cardiaques et les caractéristiques extraites de l'ECG. Les techniques de pointe pour la sélection des attributs, telles que les Algorithmes génétiques (GA) [109, 110] et l'optimisation des essaims de particules (PSO) [111, 112] peuvent également fournir des résultats prometteurs et devraient être mieux étudiées dans les travaux futurs.

## 2.4 Classification

Une fois que l'ensemble des fonctionnalités a été défini par les battements cardiaques, des modèles peuvent être construits à partir de ces données en utilisant des algorithmes d'intelligence artificielle à partir des domaines de l'apprentissage par machine et de l'exploration de données [113-115] pour la classification des battements de l'arythmie.

Les quatre algorithmes les plus populaires utilisés pour cette tâche et trouvés dans la littérature sont: les machines de vecteurs de soutien (SVM) [40, 38,66], les réseaux de neurones artificiels (ANN) [34,116,69], le discriminant linéaire (LD) [7, 37,17], et Reservoir Computing With Logistic Regression (RC) [43]. Notez que la méthode à la fine pointe de la technologie de classement cardiaque utilise l'algorithme RC.

En raison de leur importance pour la classification de l'arythmie cardiaque, ces quatre classificateurs (SVM, ANN, LD et RC) sont discutés en détail dans la littérature mais nous prenons en compte que les réseaux de neurones que nous entamerons dans la section suivante.

### ❖ Artificial neural networks(ANN)

Les architectures ANN, principalement utilisées pour la classification de l'arythmie, sont les microscopes multicouches (MLP) et les réseaux neuronaux probabilistes (PNN). Selon Yu et Chen [101], les modèles construits avec PNN sont calculés de manière plus robuste et efficace que le MLP traditionnel. Cependant, dans [121,84,122,88], on a proposé des méthodes de réseau hybrides neuro-floues afin de minimiser les problèmes de MLP, en augmentant sa généralisation et en réduisant son temps de formation.

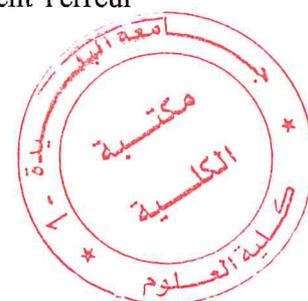
Beaucoup d'autres approches basées sur ANN ont été proposées. Güler et Übeyli [44] ont utilisé des réseaux de neurones combinés afin d'obtenir une méthode plus générique à partir d'une forme de validation croisée plus sophistiquée. Cependant, de tous les articles mentionnés dans cette étude, seule celle de Mar et al. [34] a utilisé MLP avec un protocole d'évaluation plus équitable en appliquant le schéma de division des patients proposé par de Chazal et al. [7]. Ainsi, en utilisant les résultats déclarés dans les travaux des méthodologies qui utilisent ANN comme classificateur, il est impossible de faire une comparaison équitable. Enfin, Mar et al. [34] a comparé MLP avec des Discriminants linéaires et a constaté que MLP était significativement supérieur.

La combinaison des classificateurs avait été peu explorée pour la tâche en question. Selon Osowski et al. [91], une combinaison de classificateurs réduit non seulement l'erreur globale dans les réseaux neuronaux, mais aussi réduit l'incidence des faux négatifs.

### 3. Tableau récapitulatif

Pour la partie de l'extraction des caractéristiques, qui est la partie la plus importante de notre étude, nous avons fait un résumé des travaux antérieurs par article, date, auteur et la méthode utilisée ; présenté dans le tableau ci-dessus :

Article	Date	Auteur	Méthode
Investigation et classification des battements d'ECG en utilisant les entrées sorties des réseaux de neurones artificiels feed forward.	2013	R.G. Kumar et Y.S. Kumaraswamy	L'utilisation des caractéristiques de l'intervalle RR.
Classification des battements cardiaques en utilisant des intervalles RR normalisés et des caractéristiques morphologiques.	2014	C. Lin et M. Yang	L'utilisation d'un intervalle RR normalisé améliore significativement les résultats de classification.



Sélection de caractéristiques pour la classification de la fréquence cardiaque surveillée inter-patients	2011	G. Doquire et D. François	L'efficacité des intervalles RR normalisés au moyen de technique de sélection de caractéristique
Classification des battements ECG à l'aide de l'optimisation des essais de particules et de la fonction radiale des réseaux de neurones	2010	M.Korürek et B.Dogan	La durée du complexe QRS
Classification des battements ECG en utilisant un nouveau réseau neuronal hybride.	2001	Z. Dokur et T. Ölmez	La transformée de Fourier traditionnelle,
Réseau adaptatif d'ondelettes pour la reconnaissance multiple des arythmies cardiaques.	2006	C.Lin, Y. Du, et T. Chen	La transformée en ondelettes
L'ECG et les transformées en ondelettes	2005	P.S. Addison	la transformé en ondelette continu pour l'extraction des caractéristiques

#### 4. Conclusion

Sur les travaux mentionnés ci-dessus, de nombreuses méthodes ont été citées dans chacune des phases du traitement de signal ECG, le présent travail s'intéresse à la phase extraction des paramètres, nous avons donc élaboré par la suite un tableau comparatif en se basant sur cette phase.

***Chapitre 4 :***  
***Conception***

## **1. Introduction**

Suite aux notions de base présentées dans les chapitres précédents, ce chapitre consiste au développement de l'activité de conception, qui représente une étape importante dans l'élaboration de notre projet de fin d'étude, il propose une modélisation du système développé.

En premier lieu, nous allons présenter une vision descriptive des différentes étapes et techniques de traitement d'images de l'ECG, le prétraitement, l'extraction des paramètres, la segmentation et la classification.

A la fin ce chapitre, une description détaillée est donnée sur les différentes phases considérées dans ce travail.

## **2. Conception globale**

### **2.1 Description**

L'électrocardiographie (ECG) est l'étude et l'analyse des variations de l'enregistrement de l'activité électrique du cœur. C'est un domaine privilégié des applications d'analyse et de reconnaissance automatique des signaux biomédicaux

Afin d'arriver au résultat demandé, notre système consiste à suivre différentes étapes, qui sont le prétraitement, l'extraction des paramètres, la segmentation et la classification. Dans chacune de ces étapes le signal subit des traitements qui sont un ensemble d'opérations le transformant en un signal facile à exploiter.



## 2.2 Organigramme global

Une chaîne complète pour le traitement du signal ECG doit comprendre les suivantes étapes :

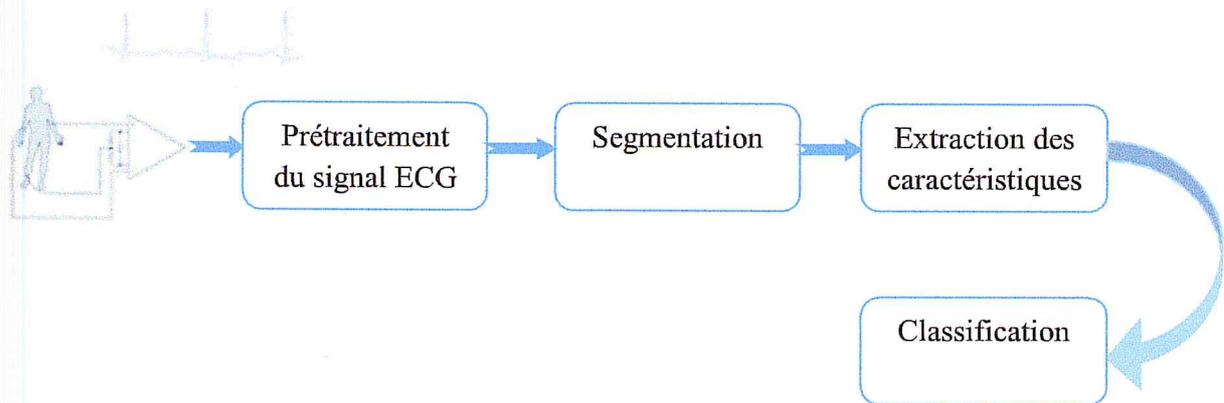


Figure 30. Organigramme Global

## 3. Conception des différentes phases

En se basant sur l'organigramme cité ci-dessus, nous allons détailler les étapes les plus importantes :

### 3.1 Conception de la phase « Prétraitement »

A ce stade, notre but est de réduire le bruit se trouvant sur le signal. Lors du processus d'acquisition, les signaux ECG sont affectés par de multiples sources de distorsions. L'étape de prétraitement doit diminuer le plus possible l'effet de ces interférences perturbatrices, tout en conservant avec beaucoup d'attention les composantes utiles du signal. Pour traiter ce problème des méthodes bien efficaces ont été conçues pour éliminer ce type de bruit.

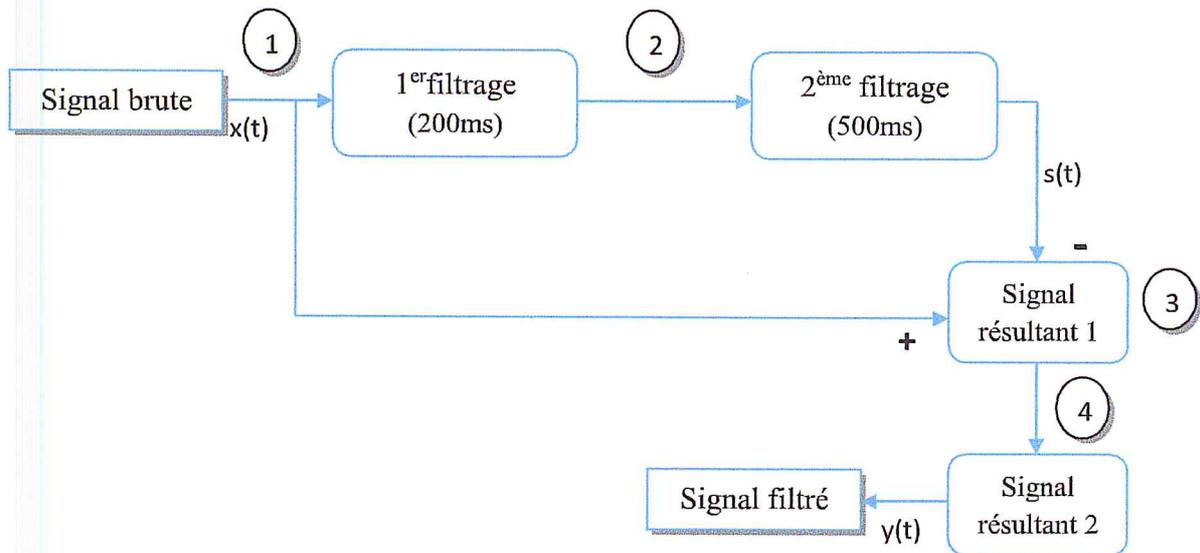


Figure 31. Organigramme du processus de « Prétraitement »

### 3.1.1 Algorithme de la phase « Prétraitement »

Debut

Lire  $x(t)$

- ① Appliquer sur le signal bruité un premier filtre médian sur une fenêtre coulissante de 200ms (72 échantillons).
  - ② Appliquer sur le signal un second filtre médian sur une fenêtre coulissante de 500ms (216 échantillons).
  - ③ Soustraire les deux filtres résultants du signal d'origine pour produire un signal ECG corrigé :  $y(t) = x(t) - s(t)$
  - ④ Appliqué sur le signal résultant un filtre passe-bas
- Obtenir un signal filtré  $y(t) = f(x(t))$

Fin.



### 3.2 Conception de la phase « Segmentation »

Etape importante et délicate du traitement automatique, dont le résultat est la fragmentation du signal en trames successives homogènes, en isolant ainsi les principales ondes utiles du point de vue clinique : les ondes P et T et le complexe QRS.

La segmentation est tout à fait essentielle à l'extraction des paramètres et à la classification. C'est l'une des étapes les plus importantes dans les systèmes de reconnaissance automatique des signaux biomédicaux. Dans notre cas, on a supposé que la détection des pics R est parfaite, on prend le cas idéal ' l'avis d'un expert' ou d'un algorithme de détection performant, afin d'avoir toutes les annotations de la base de donnée.

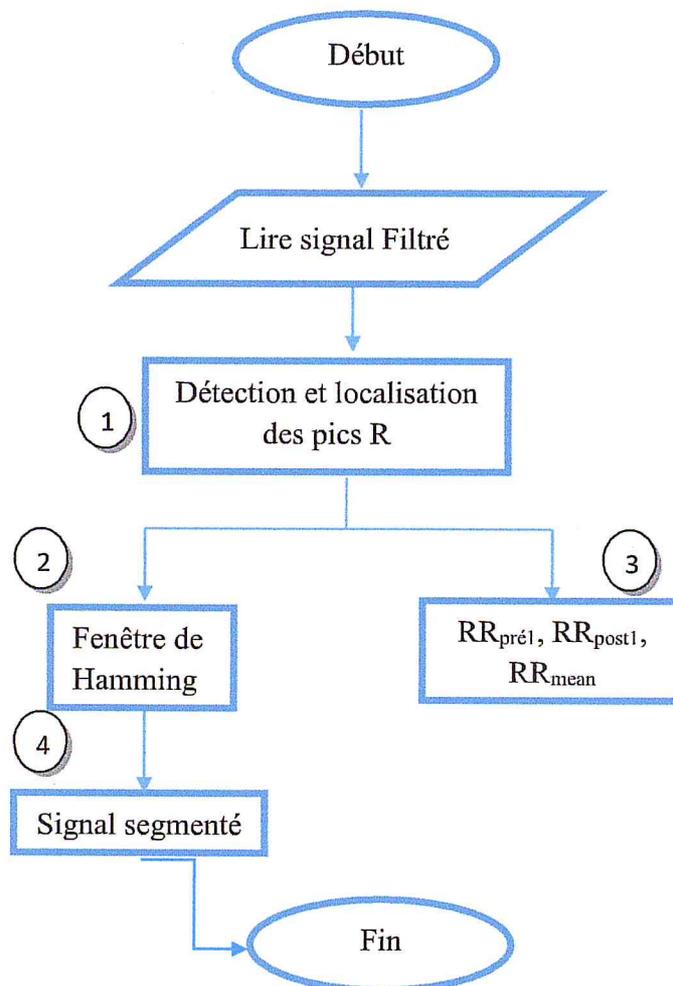


Figure 32. Organigramme du processus de « Segmentation »



### 3.2.1 Algorithme de la phase « Segmentation »

Debut

Signal filtré

- ① Détection et localisation des pics R selon l'avis d'un expert ou selon une fonction de détection des pics R performante.
- ② Appliquer la fenêtre de Hamming sur le signal.
- ③ Extraire les paramètres propres au signal ECG
  - Sélectionner les 4 premiers plus proches RR intervalles du pic R courant  $RR_{pré1}$ ,  $RR_{pré2}$ ,  $RR_{post1}$ ,  $RR_{post2}$
  - Calculer l'intervalle  $RR_{pré1}$  et  $RR_{pré2}$  qui est la distance entre un pic R actuel et son pic R précédant (Ses deux prédécesseurs)
  - Calculer l'intervalle  $RR_{post1}$ ,  $RR_{post2}$  représentant la distance entre le pic R actuel et le prochain pic R (Ses deux successeurs)
  - Calculer l'intervalle  $RR_{mean}$ , qui est la moyenne des intervalles  $RR_{pré1}$ ,  $RR_{pré2}$ ,  $RR_{post1}$ ,  $RR_{post2}$
  - Construire le vecteur  $R = [RR_{pré1}, RR_{post1}, RR_{mean}(RR_{pré1}, RR_{pré2}, RR_{post1}, RR_{post2})]$
- ④ Obtenir un signal segmenté

Fin

### 3.3 Conception de la phase « Classification »

En utilisant les paramètres pertinents, la classification doit être capable de " donner le diagnostique ", en substituant le rôle du médecin. La classification consiste à partir d'un ensemble d'objets de classes connues appelé ensemble d'apprentissage, à produire un modèle de classe caractérisant ces données et surtout, pouvant être généralisé à un ensemble de

données plus large. Chaque étape est particulièrement délicate et nécessite une qualité quasi parfaite. Le succès de la chaîne automatique est assuré seulement dans le cas d'un fonctionnement irréprochable de chacune de ses parties composantes.

Le présent travail s'intéresse à l'étude d'un classificateur supervisé appelé les réseaux de neurones artificiels.

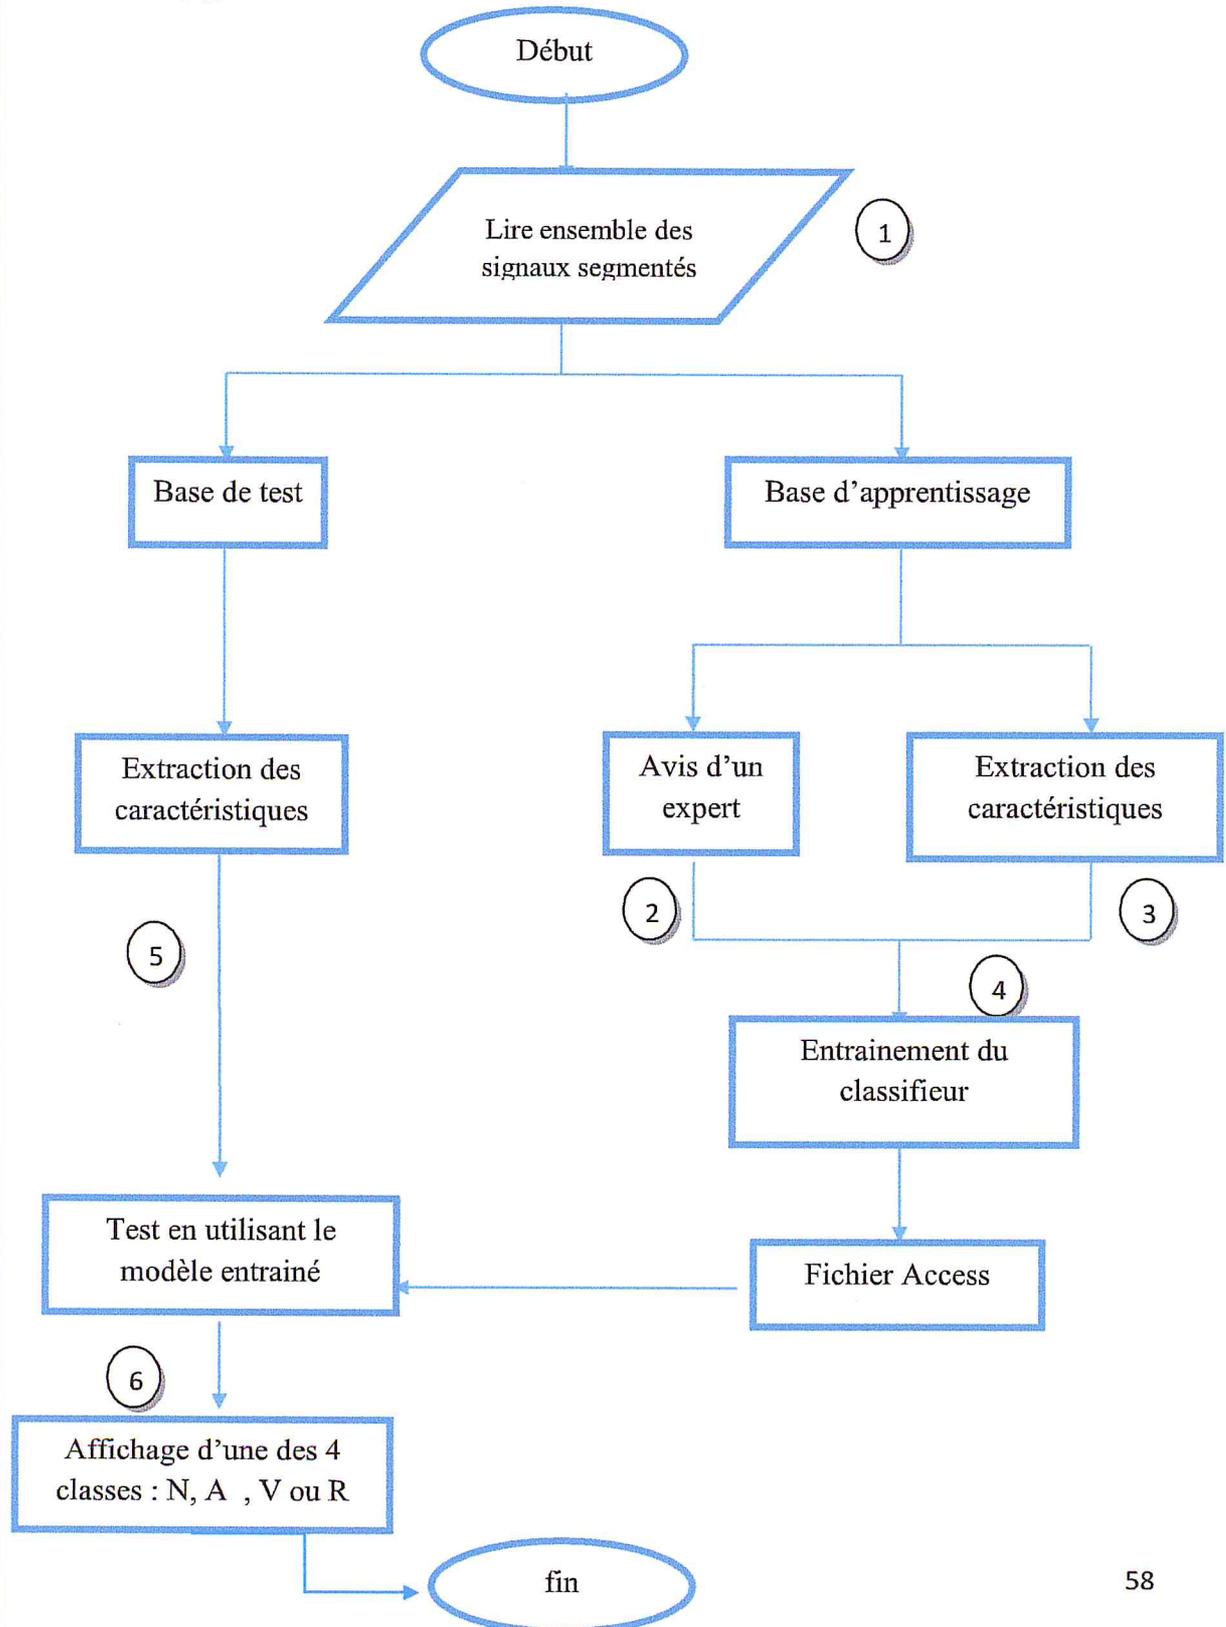


Figure 33. Organigramme du processus de Classification

### 3.3.1 Algorithme de la phase « Classification »

Debut

- ① Diviser la dataset en deux groupes de 22 signaux
  - Le premier groupe constitue l'ensemble d'apprentissage et est utilisé pour bâtir le modèle.
  - Le second groupe quand à lui constitue l'ensemble de test et est utilisé pour mesurer les performances du modèle
- ② Extraire le vecteur de caractéristiques. Cette phase sera détaillée dans la section 3.3.2
- ③ Avoir l'avis d'un expert.
- ④ Entraîner le classifieur 'Réseaux de neurones artificiels ' d'une seule couche cachée composée de 10 neurones puis de 2 couches cachées composées de 10 neurones chacune.
- ⑤ Extraire le vecteur de caractéristiques.
- ⑥ Classifier les signaux en utilisant le modèle entraîné.

Fin

### 3.3.2 Conception de la phase « Extraction des paramètres »

Il s'agit de trouver, à partir des ondes élémentaires résultées de la phase de segmentation, les paramètres qui puissent prédire le mieux l'état du patient.

Dans notre travail, nous avons testé deux transformées : la DWT et la DCT qu'on verra en détail par la suite et avec les quelles on a concaténé le vecteur  $R = [RR_{pré1}, RR_{post1}, RR_{mean}(RR_{pré1}, RR_{pré2}, RR_{post1}, RR_{post2})]$

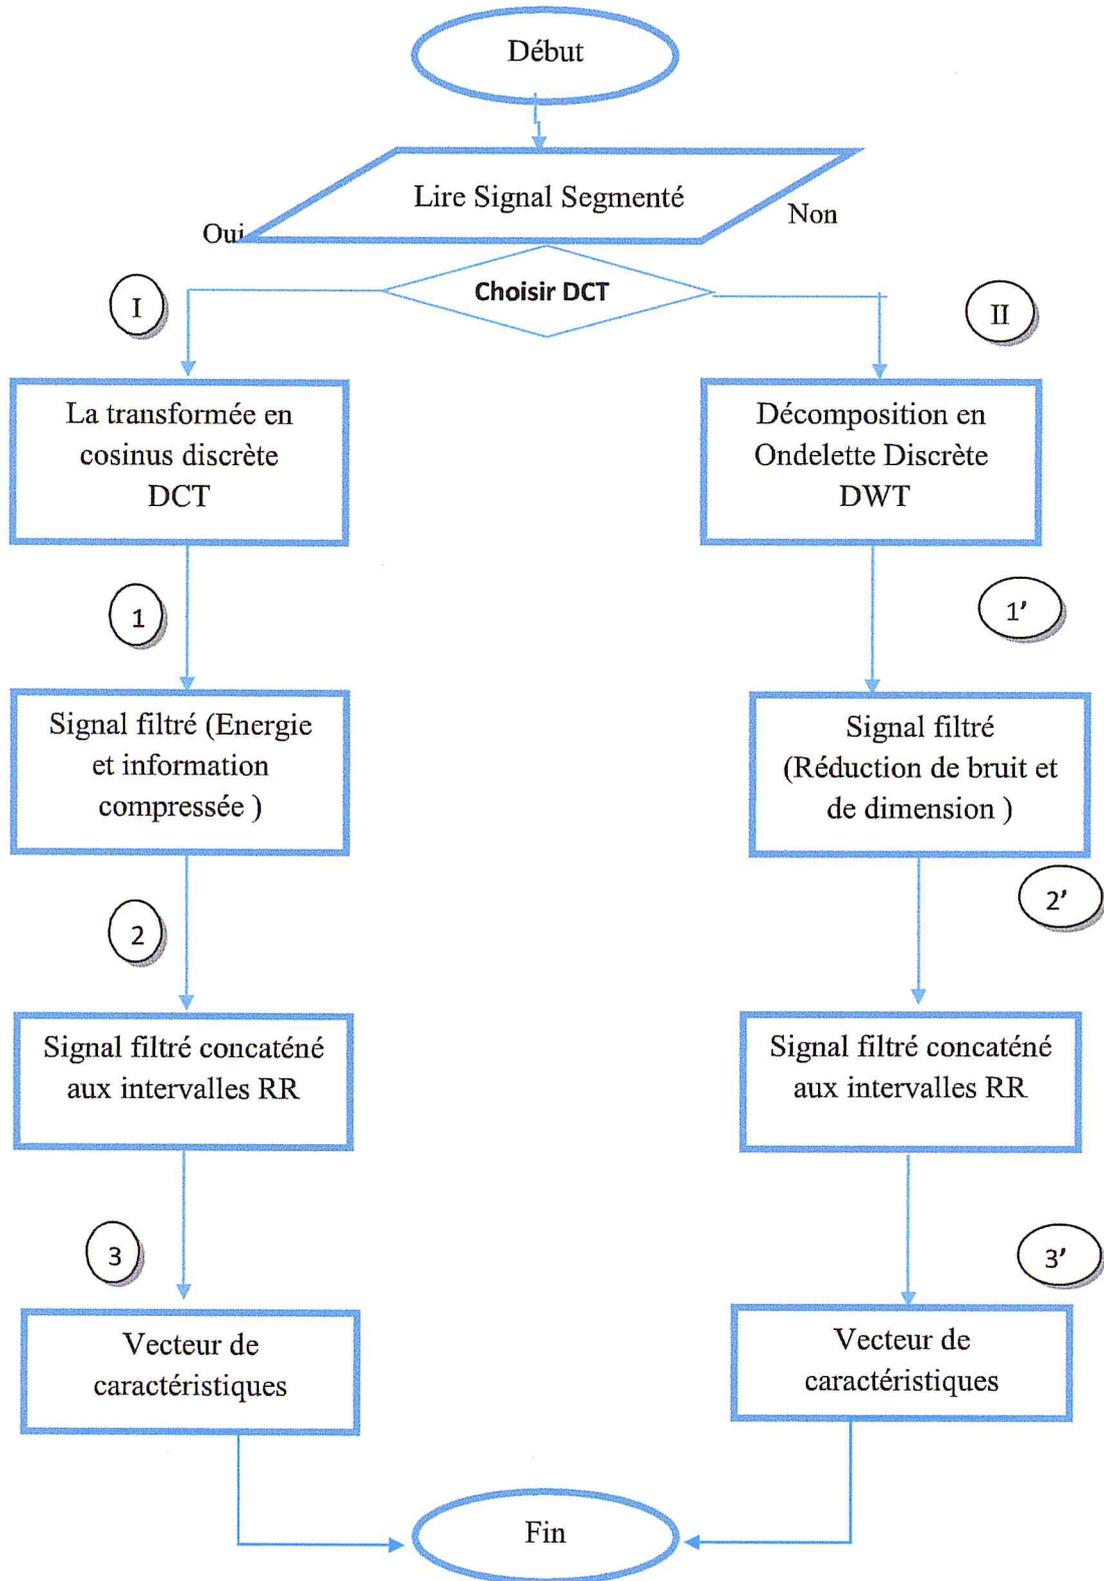


Figure 34. Organigramme du processus « Extraction des paramètres »



### 1.1.1 Algorithme de la phase « Extraction des données »

Debut

- I** Si choisir DCT
- Appliquer DCT sur le signal segmenté.
  - Changement d'espace du temporel au fréquentiel.
  - 1** - Compacter l'énergie, compresser le signal et tronquer les 100 premiers échantillons.
  - 2** - Concaténé le signal résultant avec les intervalles RR précédemment calculés dans la phase « Segmentation ».
  - 3** - Extraction du vecteur de caractéristiques.

**II** Sinon

Si choisir DWT

- Appliquer DWT sur le signal segmenté.
- Espace temporel.
- 1'** - Réduction de bruit et de dimension.
- 2'** - Concaténé le signal résultant avec les intervalles RR précédemment calculés dans la phase « Segmentation ».
- 3'** - Extraction du vecteur de caractéristiques.

Fin



## 4. Le traitement automatique du signal ECG

L'enregistrement de l'activité électrique du cœur au moyen d'un électrocardiogramme (ECG) est omniprésent dans les milieux de santé, ainsi que dans les environnements quotidiens. Le traitement du signal ECG fournit une mine d'informations sur la fonction cardiaque et la santé cardiovasculaire globale. Alors que les enregistrements ECG multiconducteurs sont nécessaires pour une évaluation correcte des rythmes cardiaques, plus souvent, les enregistrements à un seul fil sont disponibles pour l'analyse, ce qui complique la délimitation des points fiduciaires (P, Q, R, S, T). Ceci est particulièrement important dans la surveillance du rythme cardiaque. De nombreux systèmes de surveillance ambulatoire et des appareils mobiles modernes sont également des ECG à un seul conducteur et ont généralement une configuration de plomb peu commune en raison de l'emplacement du périphérique. Pour notre étude, les enregistrements ont été faits à partir de 2 fils.

Il existe 4 phases principales pour le traitement automatique des signaux ECG :

### 4.1 Phase 1 « Le prétraitement »

La base de données « MIT-BIH arrhythmia database » sera utilisée. Celle-ci contient 48 heures d'enregistrement issues de 48 patients, pour un total d'approximativement 110 000 battements. Quatre patients possédant un pace maker ont été écartés 102, 104, 107 et 217, suivant les recommandations de l'AAMI. Les 44 tracés restants sont divisés en deux groupes de 22. Le premier groupe constitue l'ensemble d'apprentissage et est utilisé pour bâtir le modèle, regroupé dans  $DS1 = \{100, 103, 105, 111, 113, 117, 121, 123, 200, 202, 210, 212, 213, 214, 219, 221, 222, 228, 231, 232, 233, 234\}$ . Le second groupe quant à lui constitue l'ensemble de test et est utilisé pour mesurer les performances du modèle, regroupé dans  $DS2 = \{101, 106, 108, 109, 112, 114, 115, 116, 118, 119, 122, 124, 201, 203, 205, 207, 208, 209, 215, 220, 223, 230\}$ . Les tracés ECG des deux groupes sont ensuite filtrés et débarrassés de leurs artefacts en utilisant un premier filtre médian de 200ms de largeur, de 72 échantillons, ce dernier est un filtre non linéaire qui enlève le complexe composé des ondes Q, R et S et l'onde P. Le résultat est ensuite soumis à un second filtre médian de 600ms de largeur de 216 échantillons pour enlever l'onde T. Le signal en résultant est soustrait du signal original. L'artefact issu du secteur est ensuite enlevé avec un filtre passe-bas à 12 ordres avec une fréquence de coupure de 35 Hz pour éliminer les bruits de ligne et de haute fréquence.



Les échantillons sont obtenus avec à l'opération suivante :

$$1s \rightarrow 360 \text{ échantillons}$$

$$0.2s \rightarrow x$$

$$x = 0.2 * \frac{360}{1} = 72 \text{ échantillons}$$

$$1s \rightarrow 360 \text{ échantillons}$$

$$0.6s \rightarrow x$$

$$x = 0.6 * \frac{360}{1} = 216 \text{ échantillons}$$

class	N	A	V	R	#REC
Training	36444	1736	3220	3476	22
Test	38102	810	3683	3783	22
Total	74546	2546	6903	7259	44

**Figure 35. Distribution des battements dans les différentes classes. Les classes sont, comme attendu, fortement déséquilibrées.**

#### 4.2 Phase 2 « La segmentation »

Il existe de nombreuses méthodes dans la littérature pour la segmentation automatique de l'ECG. La plupart des méthodes traitent de la détection d'un nombre limité de points fiduciaires dans l'ECG. L'utilisation de la même méthode pour détecter tous les points fiduciaires pourrait être plus difficile en raison des différentes caractéristiques des différentes ondes ECG en termes de forme, de fréquence, d'amplitude et de durée.

Généralement, les algorithmes de segmentation automatique d'ECG se composent de deux étapes. Dans la première étape, le signal d'entrée est conditionné ou transformé et les caractéristiques principales de chaque onde sont améliorées. Dans la deuxième étape, les points fiduciaires sont identifiés, souvent en appliquant des règles heuristiques utilisant un seuil adaptatif. Initialement, le pic du complexe QRS est détecté comme point de référence, car il est le point le plus important au sein du battement d'ECG. Le reste des points d'intérêt se

retrouve par un dépistage en avant et en arrière dans les fenêtres délimitées autour du QRS- de pointe (Les T se trouvent à droite, et les P à gauche) . Les positions des points fiduciaires sont déterminées par des seuils adaptatifs. Il existe plusieurs algorithmes qui permettent de détecter le complexe QRS, tel que le SQRS, GQRS, WQRS. Dans notre étude, et afin d'avoir des résultats fiables, nous avons supposé que la détection des pics R est parfaite, on prend le cas idéal ' l'avis d'un expert' ou d'un algorithme de détection performant, afin d'avoir toutes les annotations de la base de donnée.

Le choix du vecteur d'entrée d'un classifieur est très important pour la bonne reconnaissance des pathologies cardiaques. En effet, la qualité de la classification dépend énormément de la pertinence des paramètres du vecteur d'entrée. Notre choix de caractérisation des différents battements cardiaques est établi en fonction des pathologies ciblées. La caractéristique la plus commune trouvée dans la littérature est calculée à partir du rythme cardiaque (ou intervalle cardiaque), également appelé intervalle RR. L'intervalle RR est le temps entre le pic R d'un battement cardiaque par rapport à un autre battement cardiaque, qui pourrait être son prédécesseur ou son successeur. À l'exception des patients qui utilisent un stimulateur cardiaque, les variations perçues dans la largeur de l'intervalle RR sont corrélées avec les variations de la morphologie de la courbe, souvent provoquées par les arythmies. Ainsi, les caractéristiques de l'intervalle RR ont une grande capacité à discriminer les types de battements cardiaques.

Les paramètres de caractérisation choisis dans notre étude sont :

➤ **L'intervalle  $RR_{pré}$**

Nous appelons  $RR_{pré}$  la distance entre le pic R du présent battement et le pic R du battement précédent. Ce paramètre est un indicateur de prématurité du battement (Voir figure 36)

➤ **L'intervalle  $RR_{post}$**

Nous appelons  $RR_{post}$  la distance entre le pic R du présent battement et le pic R du battement suivant. (Voir figure 36)

➤ **L'intervalle  $RR_{mean}$**

Nous appelons  $RR_{mean}$  la moyenne des 4 premiers plus proche RR intervalles du pic R courant  $RR_{pré1}$ ,  $RR_{pré2}$ ,  $RR_{post1}$ ,  $RR_{post2}$ . (Voir figure 36)

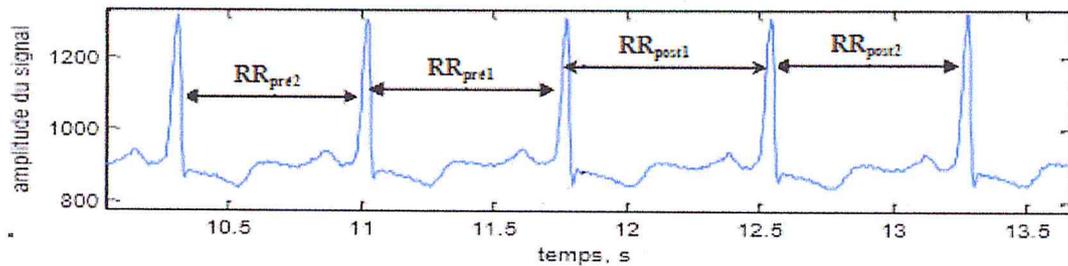


Figure 36. Les paramètres de caractérisation sur un battement cardiaques d'un sujet sain [RR<sub>pré1</sub>, RR<sub>pré2</sub>, RR<sub>post1</sub>, RR<sub>post2</sub>]

Dans une première partie, et après avoir fixé les différents RR intervalles, nous avons calculé les intervalles RR de quelques échantillons pour passer au fenêtrage et on a obtenu une moyenne de 500 échantillons approximativement.

Dans une seconde partie, nous avons appliqué une fenêtre de Hamming à 500 échantillons sur le signal pour éliminer les effets de bords, elle tend à adoucir la transition (Voir figure37). Cette fenêtre est une généralisation de la fenêtre de Hann qui permet de parcourir l'ensemble des fenêtresde forme trigonométrique. Partant de la fenêtre rectangulaire pour  $\alpha= 1$  jusqu'à la fenêtre de Hann avec  $\alpha=0.5$ , elle est défini par :

$$w_n = \begin{cases} \alpha - (1 - \alpha) \cos \frac{2\pi n}{N} & n = 0, 1, \dots, N-1 \\ 0 & \text{ailleurs} \end{cases}$$

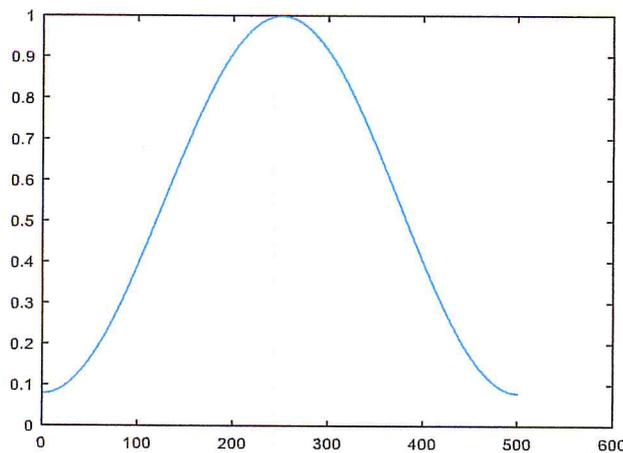


Figure 37. Fenêtre de Hamming à 500 échantillons



### 4.3 Phase 3 « Extraction des caractéristiques »

L'étape d'extraction des caractéristiques est la clé du succès de la classification du rythme cardiaque de l'arythmie à l'aide du signal ECG. Toute information extraite des battements cardiaques utilisés pour discriminer son type peut être considérée comme une caractéristique. Les caractéristiques peuvent être extraites sous diverses formes directement à partir de la morphologie du signal ECG dans le domaine temporel et / ou dans le domaine fréquentiel ou du rythme cardiaque.

Dans cette étude, nous avons fait une extraction des caractéristiques hybride ; c'est-à-dire on a implémenté deux transformées pour l'extraction des caractéristiques à savoir : La DWT et la DCT pour réduire la dimension et le bruit et surtout garder que les informations pertinentes, qu'on a concaténé avec le vecteur  $R = [RR_{\text{pré1}}, RR_{\text{post1}}, RR_{\text{mean}}(RR_{\text{pré1}}, RR_{\text{pré2}}, RR_{\text{post1}}, RR_{\text{post2}})]$  déjà construit dans la phase « Segmentation ».

- **La Transformée en ondelettes ( Discret Wavelet Transform)**

La transformée en ondelettes est une méthode puissante qui permet d'effectuer une analyse des structures locales d'un signal avec un zoom en fonction de l'échelle considérée. Deux des plus courantes ondelettes sont les ondelettes de Haar et le jeu d'ondelettes de Daubechies, pour notre cas, nous avons opté pour les ondelettes de Haar.

$$\psi(t) = \begin{cases} 1 & , 0 \leq t < \frac{1}{2} \\ -1 & , \frac{1}{2} \leq t < 1 \\ 0 & \text{si non} \end{cases}$$

Cette ondelette est définie par :

La transformée en ondelette d'un signal  $x(t)$  est définie comme suit :

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

Où :  $\Psi(t)$ ,  $a, b \in \mathbb{R}$  et  $a \neq 0$ , sont l'ondelette mère, le facteur de dilatation et de translation respectivement. Le facteur de translations et de dilatation sont utilisés dans la transformée en ondelettes afin d'obtenir une famille d'éléments temps-fréquence.

Chaque signal est constitué des composantes basses fréquences : appelées approximations et des composantes hautes fréquences : appelées détails.

Selon Mallat, nous pouvons séparer les détails et les approximations en faisant appel à une paire de filtre H et G, appelées aussi filtres a miroirs quadratique, qui sont un filtre passe bas et un filtre passe haut complémentaires (ils ont la même fréquence de coupure) et dont les réponses impulsionnelles doivent satisfaire certaines conditions. Le processus de cet algorithme de Mallat à son premier niveau est illustré dans la figure 38

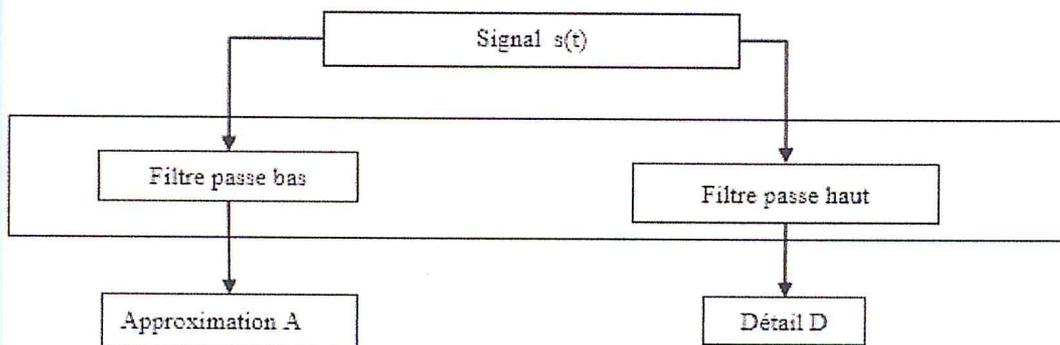


Figure 38. Principe de l'algorithme de Mallat.

Pour passer au niveau suivant de la décomposition, on applique la même opération à l'approximation A. le processus est par la suite itéré à chaque fois qu'on obtient une approximation (figure 39). Dans notre cas, nous avons appliqué 2 niveaux de décompositions pour chaque battement cardiaque.

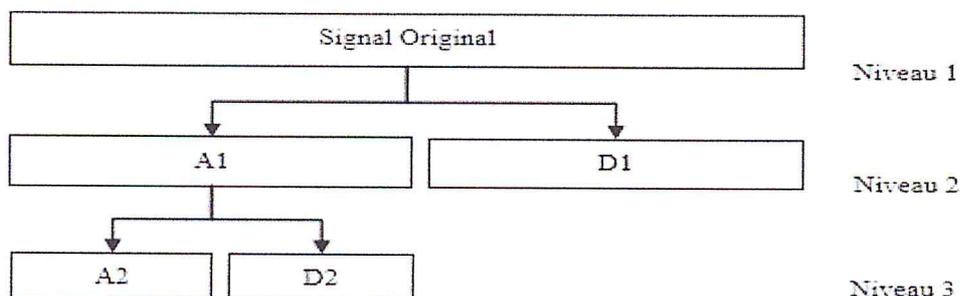
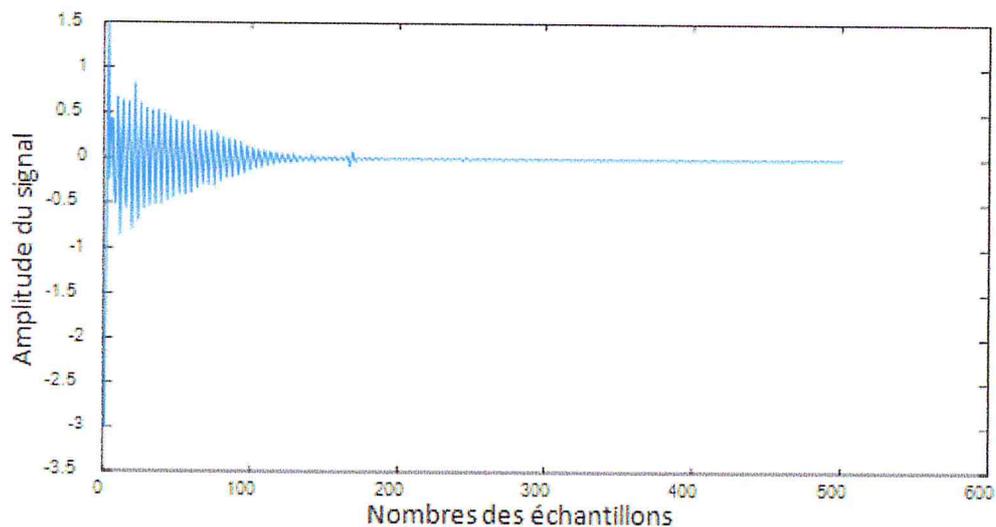


Figure 39. Décomposition en ondelettes.



- **La transformée en cosinus discrète (DCT)**

La transformée en cosinus discrète, utilisée pour la compression d'un signal ( voir figure 11), est un cas particulier de la transformée de Fourier. Nous allons décomposer le signal en somme de cosinus, comme son nom l'indique.[3]



**Figure 40. Signal ECG du patient 100 filtré par la transformée DCT**

Pour chacune des méthodes présentées précédemment, un vecteur de caractéristique est résulté dont les caractéristiques sont :

L'ensemble des composants de la DCT ou la DWT après une réduction de dimension, concaténé avec les composants des RR intervalles tel que les deux RR intervalles représentent les deux premiers proches RR intervalles du pic R, et le  $RR_{mean}$  est la moyenne des 4 premiers plus proches RR du pic courant.

$$\text{Vecteur}_{\text{caractéristiques}} = \{\text{Composants DCT /DWT}\} + [R = [RR_{pré1}, RR_{post1}, RR_{mean}(RR_{pré1}, RR_{pré2}, RR_{post1}, RR_{post2})]]$$

#### 4.4 Phase 4 « La Classification »

La performance du classificateur a été évaluée en termes de taux d'exactitude dans la reconnaissance des arythmies par signal ECG et par taux d'exactitude par classe de battements cardiaques.

Dans le cadre de ce travail, on utilise un réseau de neurones (ANN) qui est composé en premier lieu d'une seule couche cachée de 10 neurones, ensuite de deux couches cachées 10 neurones chacune, afin de tester notre programme. On prend en entrée un ensemble de signaux, qui sera divisé en 2 groupes : base d'apprentissage et base de test. Pour la phase d'apprentissage, nous allons extraire les vecteurs de caractéristique de chaque signal qui seront classifiés selon l'avis d'un expert afin d'entraîner le réseau de neurone artificiel, en utilisant la fonction suivante :

$$y = x * w + b$$

Inputs      Weight (poids)

Biais (erreur)

Quant à la phase de test, nous allons extraire les vecteurs de caractéristique de chaque signal qui seront classifiés en 4 classes (N, A, R, V), en utilisant le modèle entraîné.

Nous avons aussi appliqué la normalisation Z-score, afin de réduire le phénomène de disparité (Le mismatching) entre les données de la base de test et de la base d'apprentissage.

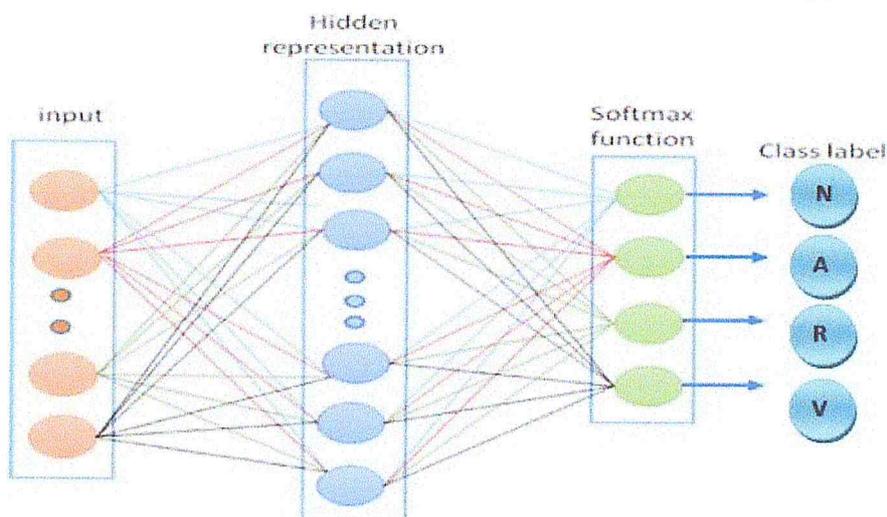


Figure 41. Architecture de l'ANN

## **5. Conclusion**

Dans ce chapitre, nous avons montré en détails l'architecture de notre système, nous avons présenté ainsi la conception de notre travail à travers différents organigrammes et algorithmes utilisés pour son développement.

L'implémentation de l'expérimentation fera l'objet du prochain chapitre.

***Chapitre 5 :***  
***Implémentation***  
***et***  
***expérimentation***

## 1. Introduction

Nous allons présenter dans ce chapitre, les outils de développement que nous avons utilisés pour la réalisation de notre application, cette dernière est programmée en Matlab sous MATLAB R2015a.

Nous allons parler aussi des tests qui ont été faits ainsi que les mesures et les filtres utilisés, et enfin quelques interfaces et scénarios d'utilisations seront présentés afin d'illustrer les différentes fonctionnalités de l'application réalisée sur la base de donnée « MIT-BIH arrhythmia database » définie sur la chapitre précédent.

## 2. Standards AAMI

Pour pouvoir classifier les battements cardiaques, il faut commencer par définir des classes. De nombreuses classifications différentes peuvent être trouvées dans la littérature. Dans ce mémoire, c'est la classification recommandée par l'AAMI « Association for the Advancement of Medical Instrumentation » [124], [17] qui a été choisie.

Les classes sont au nombre de quatre (N, A, V ou R) :

- Classe N : Ce sont les battements « normaux ». Ce sont de loin les battements les plus fréquents.
- Classe A : Ce sont les battements « anormaux » d'origine Supra-ventriculaire (dont ceux originaires des oreillettes).
- Classe V : Ce sont les battements « anormaux » d'origine Ventriculaire (ceux originaires des ventricules).
- Classe R : Ce sont les battements « anormaux » d'origine du bloc de branche droite.

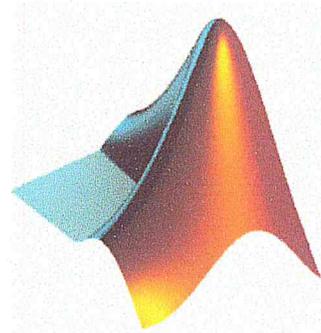


### 3. Présentation de l'environnement de travail :

#### 3.1 Matlab

Le logiciel Matlab constitue un système interactif et convivial de calcul numérique et de visualisation graphique.

Destiné aux ingénieurs, aux techniciens et aux scientifiques, c'est un outil très utilisé, dans les universités comme dans le monde industriel, qui intègre des centaines de fonctions mathématiques et d'analyse numérique visualisations graphiques, il est utilisé dans les domaines de l'apprentissage



automatique, calcul matriciel —le MAT de Matlab—, le traitement du signal, traitement d'images, la vision par ordinateur, les communications, la finance computationnelle, la conception de contrôleurs, la robotique et bien plus. [125]

### 4. Choix et paramétrages des fonctions :

Le rendement défini par les fonctions dépend des valeurs des paramétrages configurées. On définit ici les différents paramètres utilisés :

#### 4.1 Fonctions utilisées pour le Prétraitement :

- *Filtre médian :*

```
% % median filter 200 ms = 72 echantillons avec Fs=360Hz
A1=medfilt1(signal, 72);
% % median filter 500 ms = 216 echantillons avec Fs=360Hz
B=medfilt1(A1, 216);
% % subtraction
AA=signal;
signal=signal-B;
```



- *Filtre passe-bas :*

```

% low pass filter design order=12 cutoff frequency at 3dB = 35Hz fs=360Hz
d = fdesign.lowpass('N,F3db',12,35,360);
% pour visualiser le filtre
Hd = design(d);
% fvtool(Hd);
% % Filtrage pass bas
signal = filter(Hd,signal);
  
```

#### 4.2 Fonctions utilisées pour la Segmentation :

Après détection et localisation des pics R nous avons procédé comme suit :

- *Extraction des paramètres propres au signal ECG :*

```

[RR, TM]=ann2rr(['mitdb/',num2str(AdrTest(i))'],'atr');
LLL=length(RR);
RM=ones(LLL,1);

for j=4:LL-4

PM=RM*ann(j);
TTM=abs(PM-TM);
[a,b]=sort(TTM);
RRR=mean([RR(b(1)),RR(b(2)),RR(b(3)),RR(b(4))]);
RRF=[RR(b(1));RR(b(2));RRR];
  
```

- *Fenêtre de Hamming :*

```

% Parametrage
LDCT=250;
TDCT=100;
CL=2;
% Fenetre de hamming pour éliminer les effets de boards
w = hamming(LDCT*2+1);
  
```



### 4.3 Fonctions utilisées pour l'Extraction des caractéristiques :

- Transformée en cosinus discrète DCT :

```
if type(j)=='V'  
    TestLabel_V=[TestLabel_V,V];  
    AA1=signal(ann(j)-LDCT:ann(j)+LDCT,CL);  
    AA1=AA1.*w;  
    BB=dct(AA1);  
    BB=BB(1:TDCT);
```

- Décomposition en ondelettes discrètes DWT :

```
if type(j)=='R'  
    TestLabel_V=[TestLabel_V,R];  
    AA1=signal(ann(j)-LDCT:ann(j)+LDCT,CL);  
    AA1=AA1.*w;  
    [BB,DD]=dwt(AA1,'haar');  
    [BB,DD]=dwt(BB,'haar');
```

- Concaténation du vecteur RRF avec DCT ou DWT :

```
BB=[BB;RRF];  
TestData_V=[TestData_V,BB];
```

#### 4.4 Fonctions utilisées pour la Classification :

- *Normalisation*

```
LLTS=size(TestData_V);
LLTR=size(TrainData_V);

for i=1:LLTS(1)
    TestData_V(i,:)=(TestData_V(i,:)-mean(TestData_V(i,:)))/std(TestData_V(i,:));
    TestData_ML(i,:)=(TestData_ML(i,:)-mean(TestData_ML(i,:)))/std(TestData_ML(i,:));
end

for i=1:LLTR(1)
    TrainData_V(i,:)=(TrainData_V(i,:)-mean(TrainData_V(i,:)))/std(TrainData_V(i,:));
    TrainData_ML(i,:)=(TrainData_ML(i,:)-mean(TrainData_ML(i,:)))/std(TrainData_ML(i,:));
end
```

- *Entraînement du classifieur*

```
% training MLII
netML = patternnet(NETPAR);
netML.trainParam.max_fail = VAL;
netML.divideFcn='divideint';
netML = train(netML,TrainData_ML,TrainLabel_ML);

% training V1
netV = patternnet(NETPAR);
netV.trainParam.max_fail = VAL;
netV.divideFcn='divideint';
netV = train(netV,TrainData_V,TrainLabel_V);
```



## 5. Test

Afin d'évaluer l'efficacité de notre système, plus de 22 échantillons des signaux réels de la base de données MIT-BIH Arrhythmia (base de référence dans l'étude des signaux ECG) ont été testés.

Nous présentons dans ce qui suit, les différents résultats des tests effectués sur ces signaux.

Nous allons commencer par présenter différents tests sur un même patient, et sur différents intervalles de la base ML et de la base V.

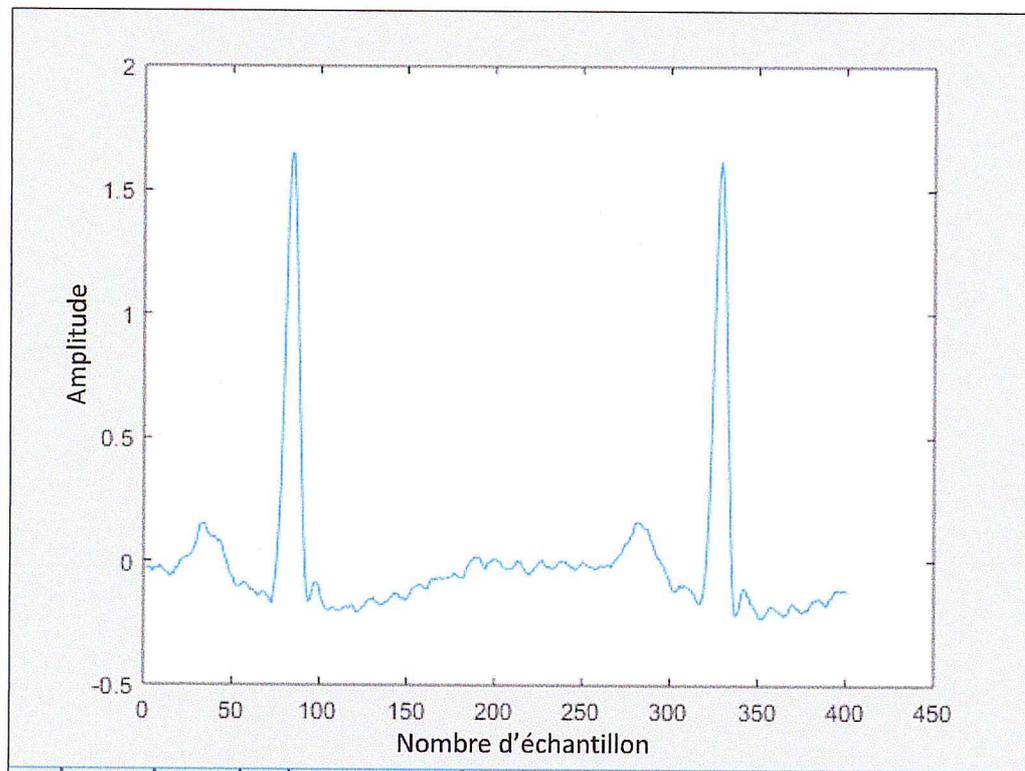


Figure 42. Signal ECG du patient '100' sur l'intervalle [100,1400] de la base ML

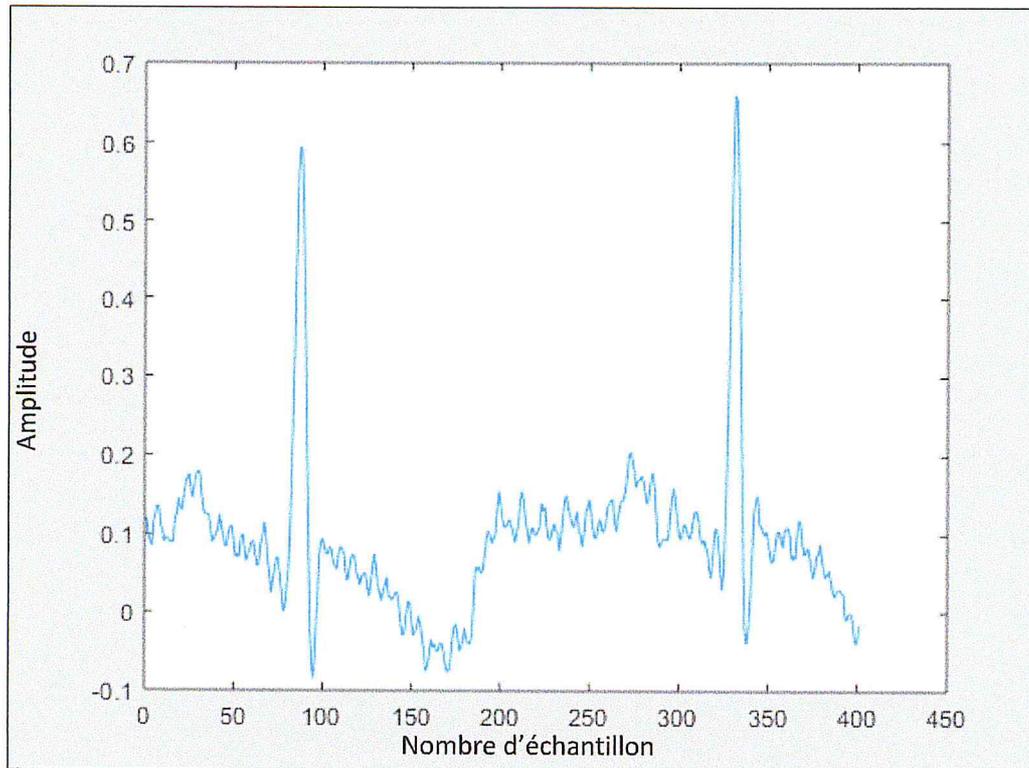


Figure 43. Signal ECG du patient '100' sur l'intervalle [1000,1400] de la base V

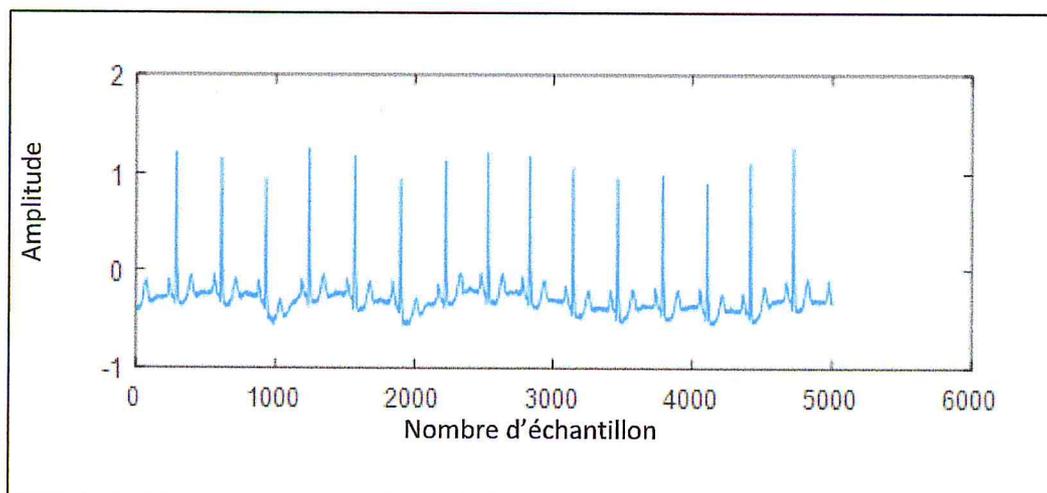
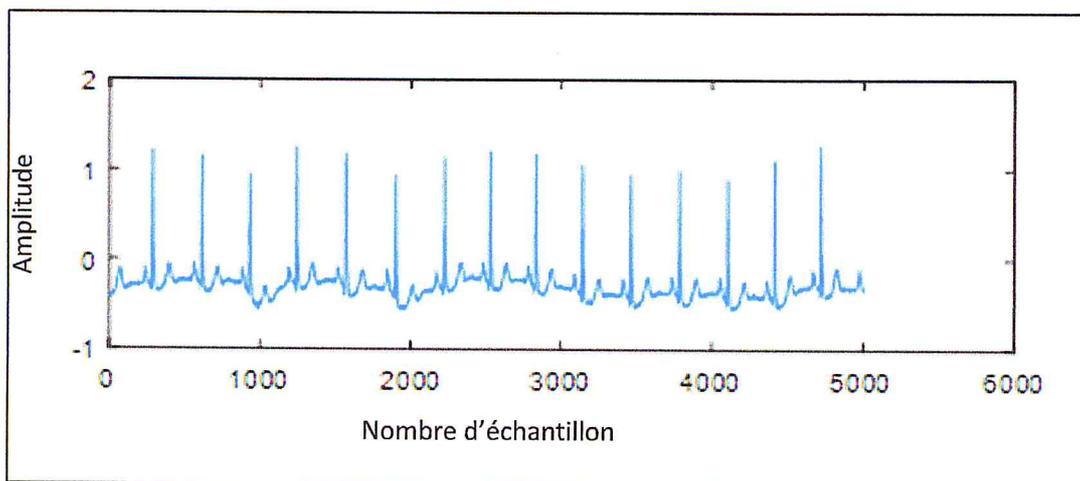
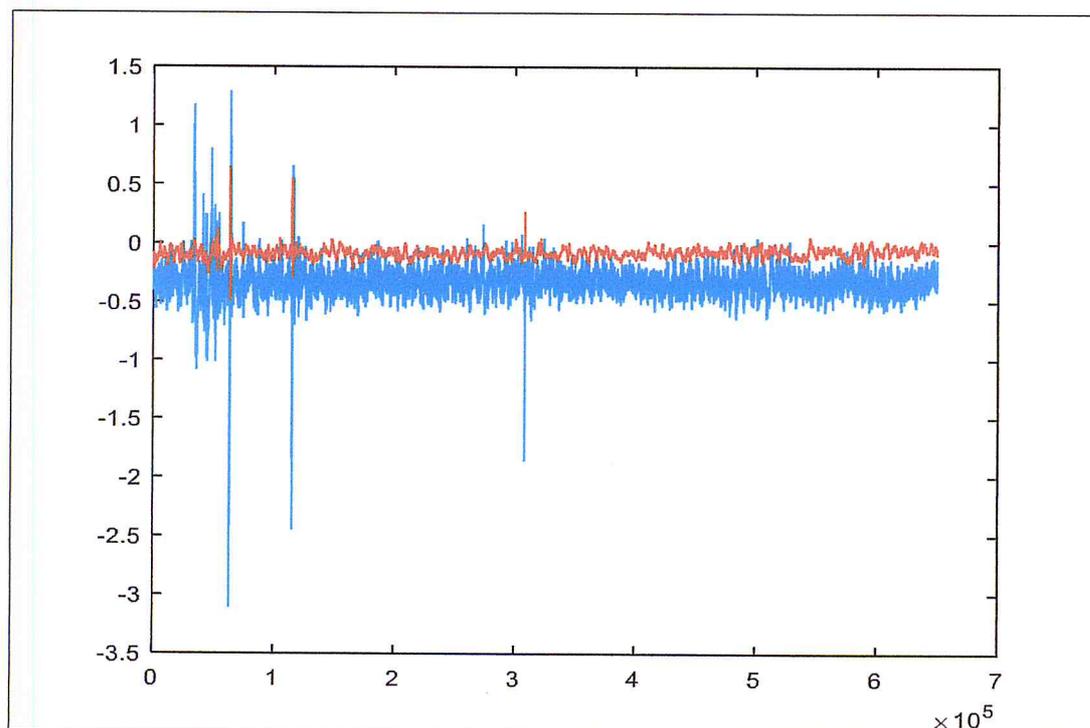


Figure 44. Signal ECG du patient '100' sur l'intervalle [4000,9000] de la base ML



**Figure 45. Signal ECG du patient '100' sur l'intervalle [4000,9000] de la base V**

Un signal ECG, contient habituellement des bruits indésirables causés lors de son acquisition, ces derniers doivent être réduits ou éliminés par des prétraitements. Pour cela, nous avons appliqué le filtre médian ainsi que le filtre passe-bas, les résultats obtenus sont présentés dans les figures ci-dessous :



**Figure 46. Résultat après application du 1er filtre médian sur le signal du patient '100'**

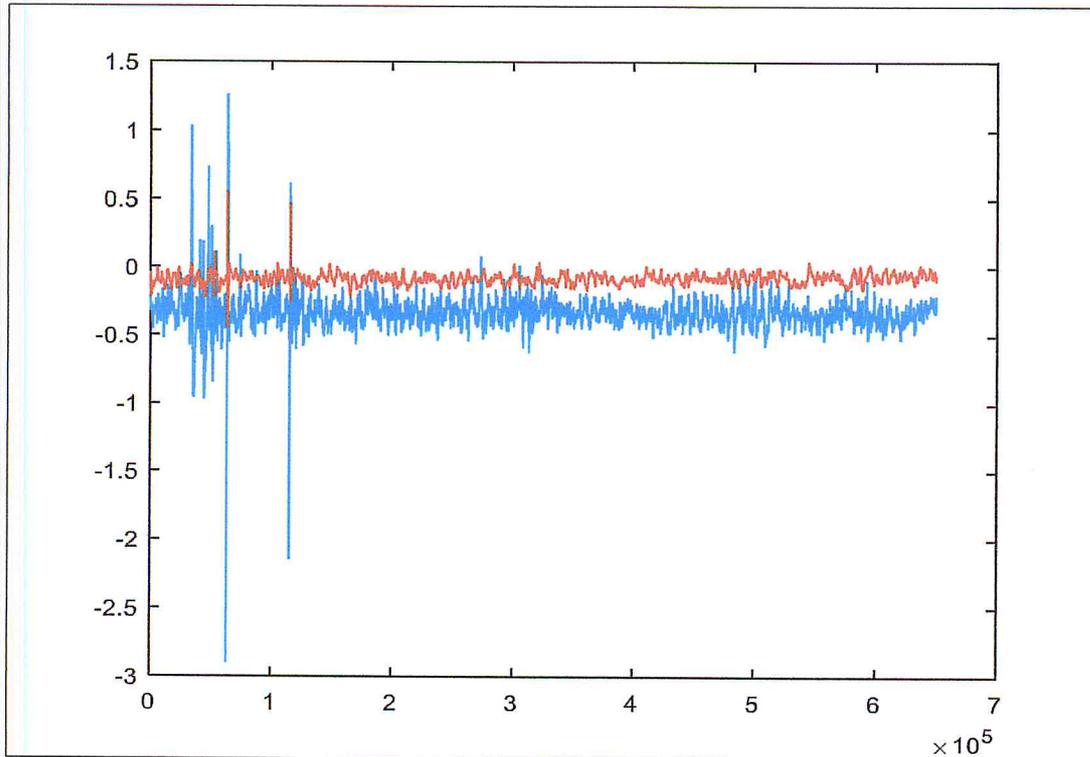


Figure 47. Résultat après application du 2<sup>ème</sup> filtre médian sur le signal du patient '100'

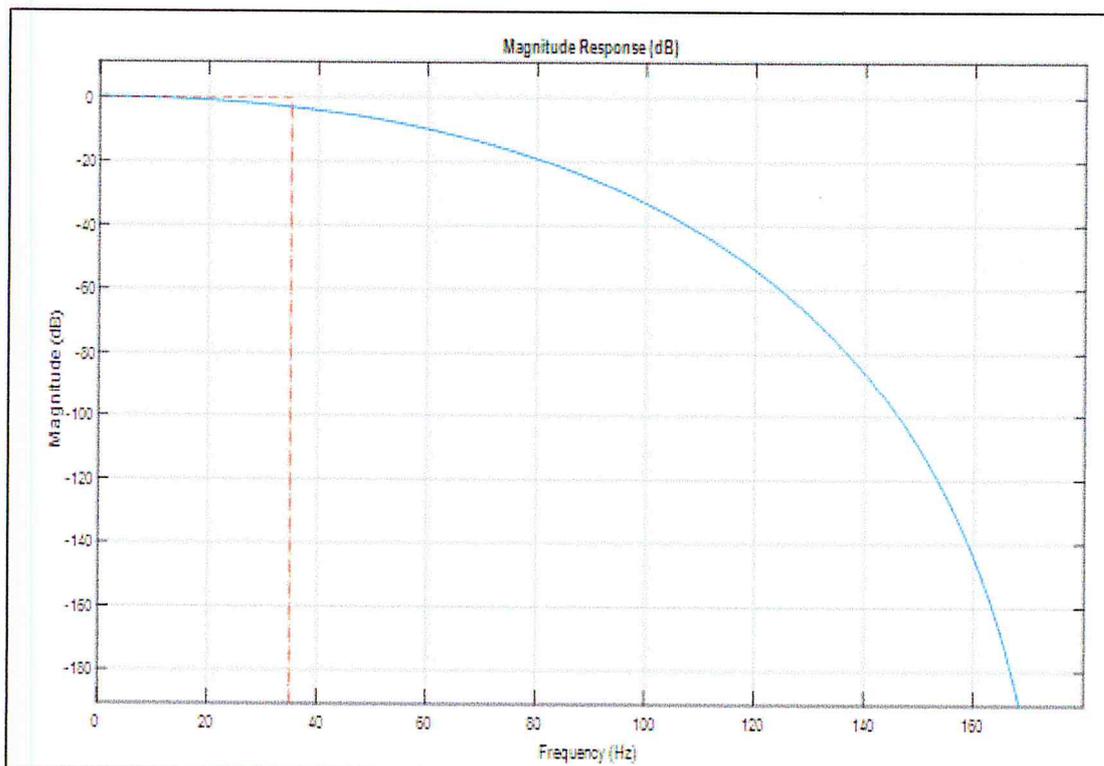


Figure 48. Filtre passe-bas d'une fréquence de coupure à 35Hz

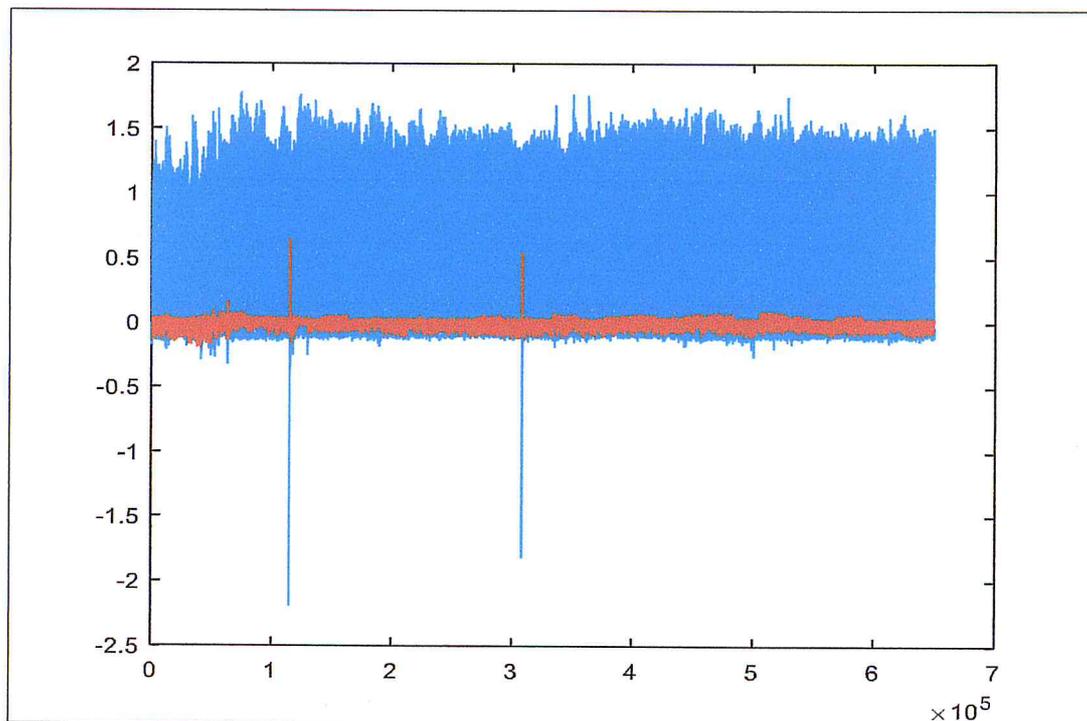


Figure 49. Résultat après application du filtre passe-bas sur le signal du patient '100'

Après avoir détecté les pics R du le signal dé-bruité, nous appliquons sur ce dernier une fenêtre de Hamming à 500 échantillons (voir figure 50), pour éliminer les effets de bords, cette fenêtre tend à adoucir la transition.

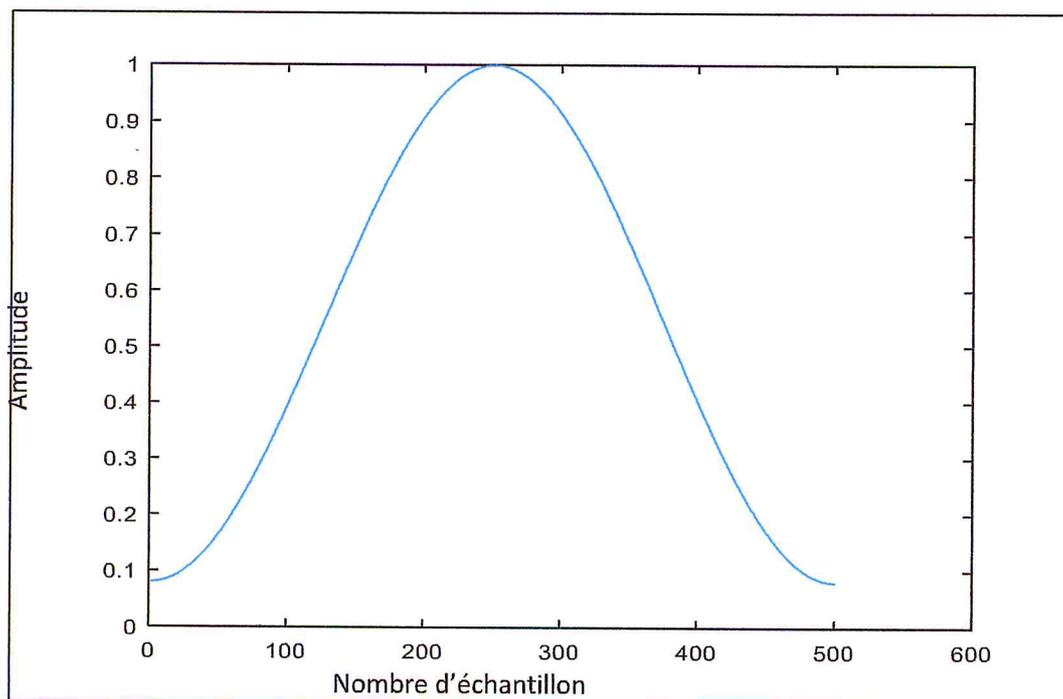
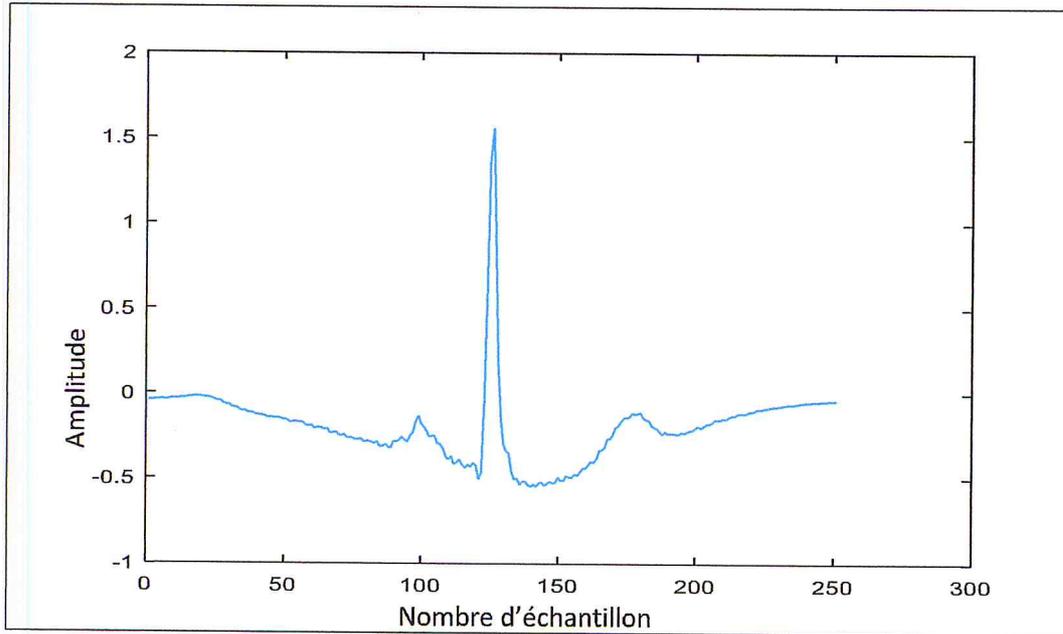


Figure 50. Fenêtre de Hamming à 500 échantillons

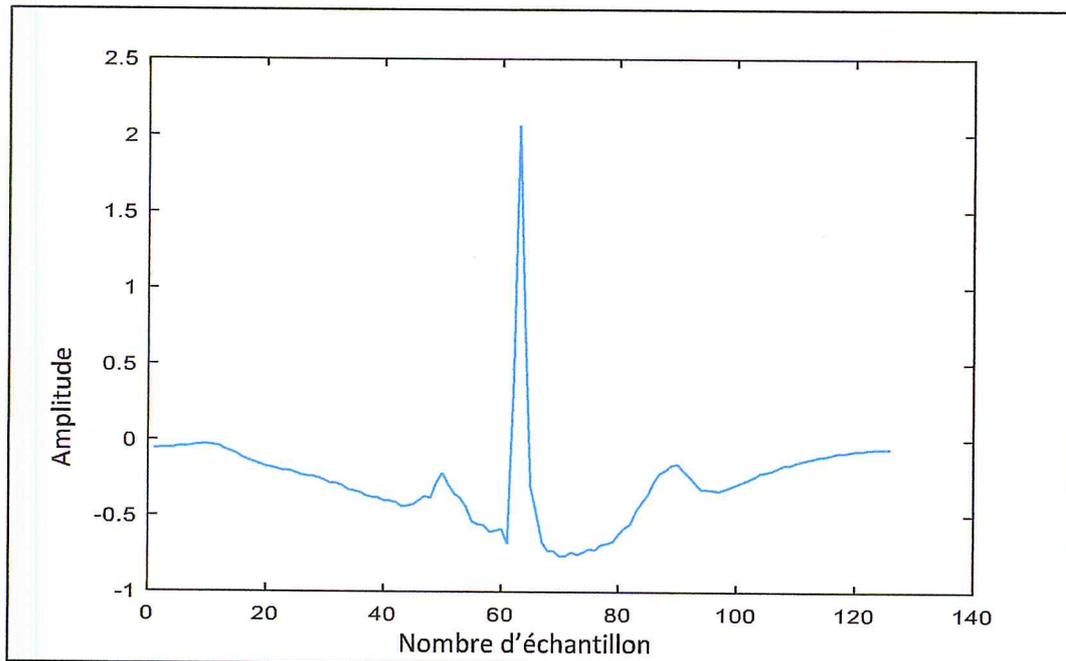


L'extraction des paramètres étant l'étape la plus importante dans tout processus de classification. Nous avons testé à ce stade deux méthodes : la DWT et la DCT.

Les résultats de leurs applications sont présentés dans ce qui suit :



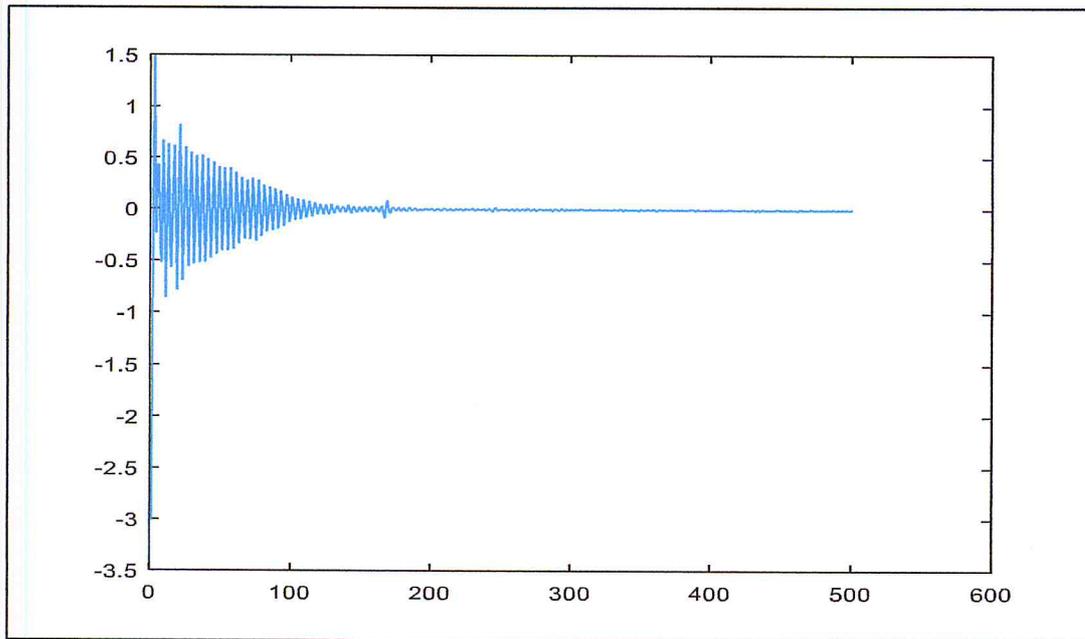
**Figure 51. Résultat de la décomposition en ondelette du signal du patient '100', avec une fenêtre de Haar (1<sup>er</sup> niveau)**



**Figure 52. Résultat de la décomposition en ondelette du signal du patient '100', en appliquant une seconde fenêtre de Haar (2<sup>ème</sup> niveau)**

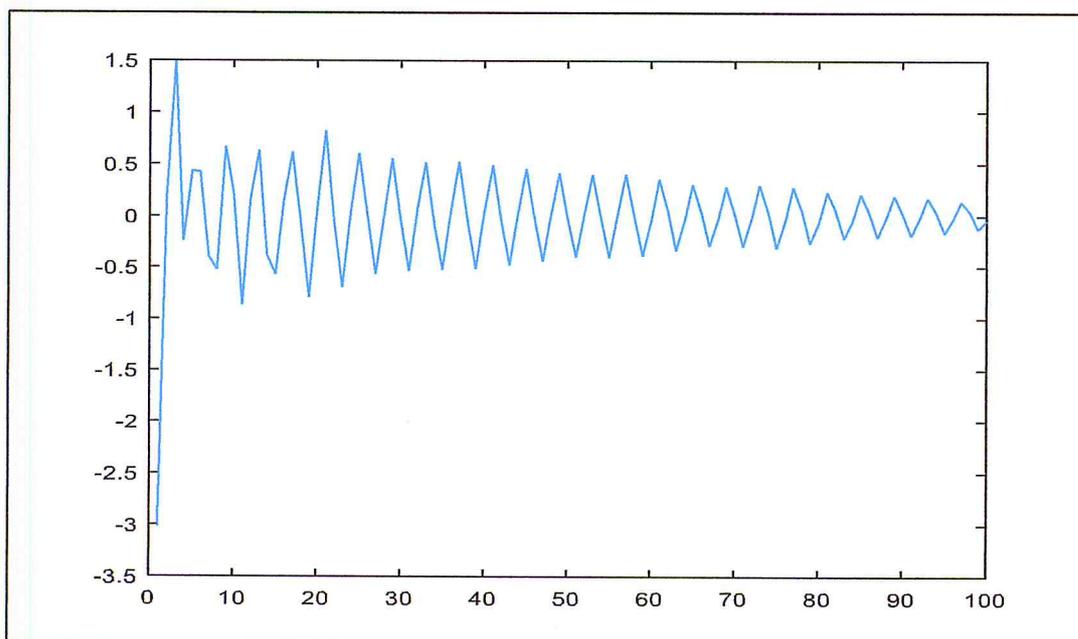


La figure 53 présente le résultat de l'opération de décomposition en ondelettes à partir d'un segment du signal ECG de patient '100'. Il est illustré que le signal résultant est d'une meilleure qualité.



**Figure 53. Résultat de l'application de la DCT sur le signal du patient '100'**

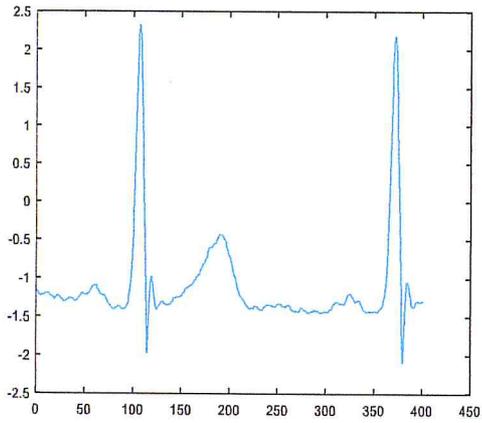
Nous remarquons dans la figure 54 que la plupart de l'énergie utile du signal est concentrée sur les 100 premières fréquences, pour cela nous prenons seulement en considération le signal présenté dans la figure suivante:



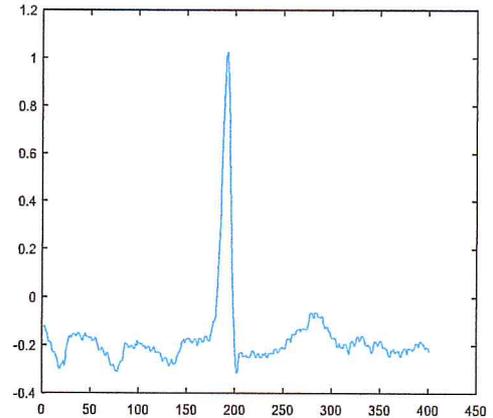
**Figure 54. Signal résultant de l'application de la DCT sur le signal du patient '100'; tronqué à la fréquence 100**



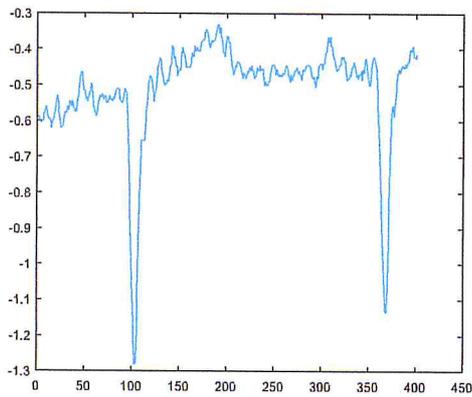
Nous présentons dans ce qui suit ; une série de tests sur différentes parties du signal ECG, de deux patients 116 et 201.



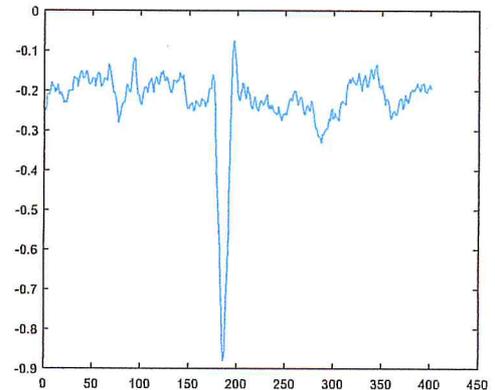
**Figure 55. Signal ECG du patient '116' sur l'intervalle [1000,1400] de la base ML**



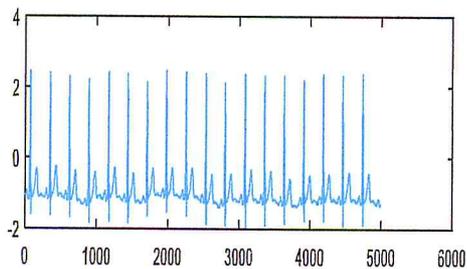
**Figure 58. Signal ECG du patient '201' sur l'intervalle [1000,1400] de la base ML**



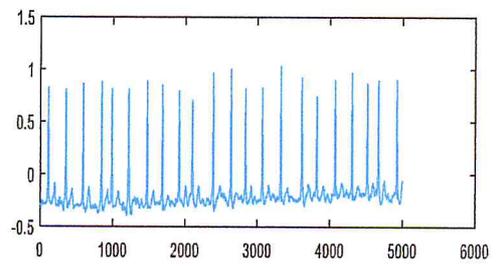
**Figure 56. Signal ECG du patient '116' sur l'intervalle [1000,1400] de la base V**



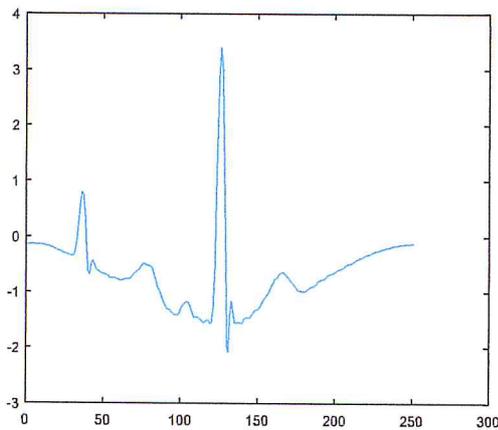
**Figure 59. Signal ECG du patient '201' sur l'intervalle [1000,1400] de la base V**



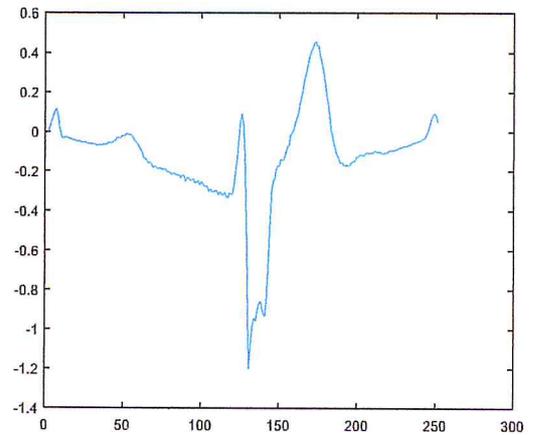
**Figure 57. Signal ECG du patient '116' sur l'intervalle [4000,9000] de la base ML**



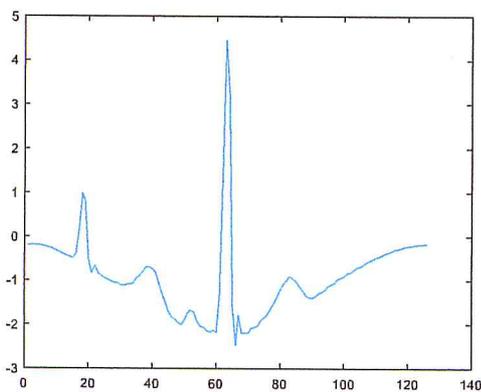
**Figure 60. Signal ECG du patient '201' sur l'intervalle [4000,9000] de la base ML**



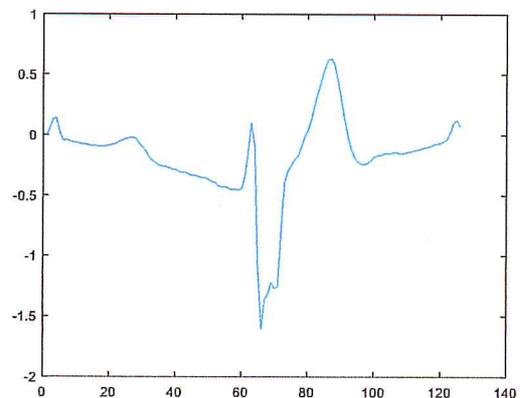
**Figure 61. Résultat de la décomposition en ondelette du signal du patient '116', avec une fenêtre de Haar (1<sup>er</sup> niveau)**



**Figure 63. Résultat de la décomposition en ondelette du signal du patient '201', avec une fenêtre de Haar (1<sup>er</sup> niveau)**



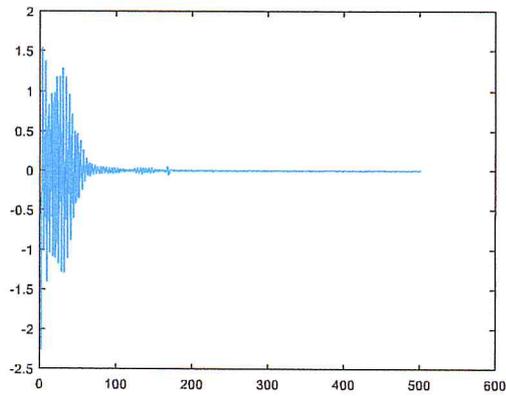
**Figure 62. Résultat de la décomposition en ondelette du signal du patient '116', en appliquant une seconde fenêtre de Haar (2<sup>ème</sup> niveau)**



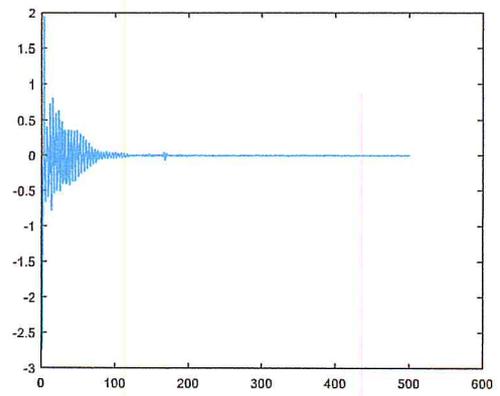
**Figure 64. Résultat de la décomposition en ondelette du signal du patient '201', en appliquant une seconde fenêtre de Haar (2<sup>ème</sup> niveau)**

Nous remarquons que la présence du bruit dans le signal filtré est fortement réduite sur les figures 22 et 24.

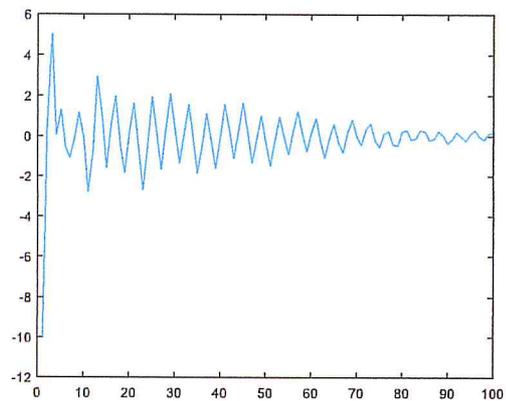
Nous remarquons aussi une réduction d'amplitude sur ces figures et cela après application d'une décomposition de Haar.



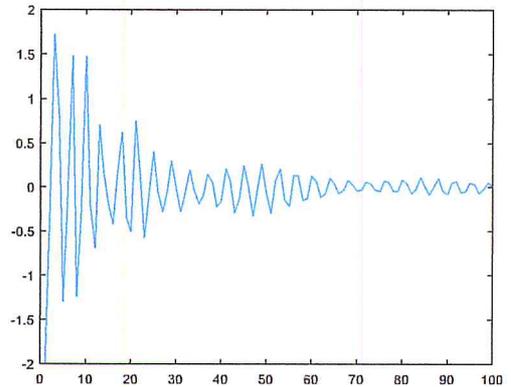
**Figure 65. Résultat de l'application de la DCT sur le signal du patient '116'.**



**Figure 67. Résultat de l'application de la DCT sur le signal du patient '201'.**



**Figure 66. Signal résultant de l'application de la DCT sur le signal du patient '116'; tronqué à la fréquence 100.**



**Figure 68. Signal résultant de l'application de la DCT sur le signal du patient '201'; tronqué à la fréquence 100.**

L'application du DCT permet une compression d'information et d'énergie du signal (voir figures 65 et 67). Nous constatons que la plupart de l'énergie utile est concentrée au début du signal, c'est pour cela que ce dernier est tronqué à 100 (illustré dans les figures 66 et 68).

## 6. Les mesures de performance

### 6.1 Évaluation des performances d'un classifieur :

Évaluer les performances d'un système de classification est un enjeu de grande importance car ces performances peuvent être utilisées pour l'apprentissage en tant que tel ou pour optimiser les valeurs des hyper paramètres du classifieur. Pendant longtemps, le critère retenu pour évaluer ces performances a été le taux de bonne classification, c'est-à-dire le nombre d'éléments d'une base de test correctement classés. Le problème d'un tel critère est qu'il n'est pas adapté à des environnements mal définis. Dans de nombreuses situations, toutes les erreurs n'ont pas les mêmes conséquences. Certaines erreurs ont un coût plus important que d'autres, par exemple, pour les diagnostics médicaux. Un mauvais diagnostic ou traitement peut, en effet, avoir différents coûts ou dangers selon le type d'erreur commise. [5]

A ce point de notre parcours sur l'apprentissage automatique (Machine Learning), nous allons nous intéresser aux indicateurs qui permettent de mesurer la qualité d'un modèle.

### 6.2 Indicateurs de performance en classification

Pour mesurer les performances de ce classifieur, il est d'usage de distinguer 4 types d'éléments classés pour la classe voulue, on utilise la matrice de confusion ( tableau 2), qui permet la différenciation des erreurs selon chaque classe en vue d'évaluer un classifieur. Définissons maintenant plusieurs mesures de manière formelle.[96]

	Décision positif	Décisions Négatif	
Etiquette positif	Vrai positif TP	Faux négatif, FN	Pos <sup>a</sup>
Etiquette négatif	Faux positifs FP	Vrai négatif TN	Neg <sup>b</sup>
	PPos <sup>c</sup>	PNeg <sup>d</sup>	N

Tableau 2. Matrice de confusion

Avec:

a: Nombre d'éléments étiquetés positifs dans la base.

b: Nombre d'éléments étiquetés négatifs dans la base.

c: Nombre d'éléments classés positifs.

d: Nombre d'éléments classés négatifs

- Le taux de vrais positifs ("True positive rate"):

$$tpr = \frac{TP}{Pos} = \frac{TP}{TP + FN}$$

- Le taux de vrais négatifs ("True negative rate"):

$$tnr = \frac{TN}{Neg} = \frac{TN}{TN + FN}$$

- Le taux de faux positifs ("False positive rate"):

$$fpr = \frac{FP}{Neg} = \frac{FP}{FP + TN}$$

- Le taux de faux négatifs ("False negative rate"):

$$fnr = \frac{FN}{Pos} = \frac{FN}{FN + TN}$$

- Le taux de bonne classification ou l'exactitude (accuracy):

$$acc = tbc = Pos * tpr + Neg * (1 - fpr)$$

- **La précision:**

$$prec = \frac{TP}{PPos} = \frac{TP}{TP + FP}$$

- Le rappel (recall) :

$$rec = tpr = \frac{TP}{Pos} = \frac{TP}{TP + FN}$$

- F-measure :

La F-mesure correspond à une moyenne harmonique de la précision et du rappel. Le paramètre b permet de pondérer la précision ou le rappel et vaut généralement 1, la mesure devient :

$$F = \frac{(2 * Precision * Rappel)}{(Precision + Rappel)}$$

Voici un tableau comparatif résumant les tests fait sur notre étude en prenant compte des différentes mesures citées ci-dessus :

Mesures Méthodes	Précision	Recall	F <sub>measure</sub>
<i>Sans prétraitement DTC (une seule couche)</i>	91%	84%	88%
<i>Sans prétraitement DWT (une seule couche)</i>	92%	83%	90%
<i>Avec prétraitement DTC (une seule couche)</i>	96%	95%	96%
<i>Avec prétraitement DWT (une seule couche)</i>	93%	92%	93%
<i>Sans prétraitement DTC (deux couches)</i>	91%	79%	88%

<i>Sans prétraitement DWT (deux couches)</i>	90%	84%	87%
<i>Avec prétraitement DTC (deux couches)</i>	96%	95%	96%
<i>Avec prétraitement DWT (deux couches)</i>	93%	93%	93%

**Tableau 3. Un tableau comparatif résumant les mesures et les méthodes de notre étude**

Les valeurs représentées dans ce tableau, sont le résultat de la moyenne des cas étudiés qui ont été arrondis

Nous constatons que les meilleurs résultats sont obtenus grâce au DCT avec la mesure de précision.

## **7. Conclusion :**

Nous avons présenté dans ce chapitre les détails techniques liés à la mise en œuvre de notre application. Nous avons commencé par présenter les différentes technologies utilisées pour la réalisation de l'application. Ensuite nous avons cité les fonctions et filtres appliqués la dernière partie été consacré à la présentation des différents interfaces.

# ***Conclusion Générale***



## Conclusion Générale

Dans notre travail mené tout au long de ce mémoire, nous avons abordé le problème de classification et de modélisation non linéaire du signal électrocardiogramme. Le premier chapitre de ce mémoire a été dédié complètement à l'introduction et l'étude de l'élément principal du système cardiovasculaire et au principe de l'électrocardiogramme et une petite brèche a été ouverte sur le signal ECG de Holter.

Dans le deuxième chapitre nous avons traité le domaine d'apprentissage en particulier les réseaux de neurones qui seront notre partenaire primordial pour le traitement du signal ECG. Leur capacité d'adaptation à l'environnement non linéaire et leur puissance d'approximation ont permis leur application avec succès dans beaucoup de domaines très complexes. La détection du complexe QRS constitue l'élément clé de l'analyse du signal ECG. Une fois détecté beaucoup d'informations qui seront utilisées pour des fins diagnostiques, peuvent être décelées et différents traitements supplémentaires peuvent être appliqués. Nous avons abordé ensuite dans le troisième chapitre les travaux antérieurs qui ont été faits avant puis nous avons conclu ce chapitre avec un tableau comparatif des différents travaux réalisés. Nous avons consacré le quatrième chapitre pour présenter notre algorithme de détection de l'onde R ainsi que la chaîne du le traitement du signal ECG qui comprends : l'acquisition des signaux ECG, le prétraitement, la segmentation, l'extraction des caractéristiques et enfin la classification.. L'utilisation des filtres médian et passe-bas dans l'étape de prétraitement, a pour but le rejet du bruit en vue d'améliorer la qualité du rapport signal sur bruit. Dans l'étape de détection des pics, nous avons pris l'avis d'un expert ou selon une fonction de détection des pics R performante afin d'avoir toutes les annotations de la base de données, ce qui a permis la fiabilité de détection des complexe QRS. On a utilisé pour l'extraction du vecteur de caractéristique une approche hybride; c'est-à-dire on a implémenté deux transformées pour l'extraction des caractéristiques à savoir : La DWT et la DCT pour réduire la dimension et le bruit et surtout garder que les informations pertinentes, qu'on a concaténé avec le vecteur R extrait durant la phase de segmentation. Finalement, nous avons exposé les résultats des tests effectués sur les signaux de la base MIT/BIH.

Il est bien évident que l'algorithme développé dans ce travail peut avoir beaucoup d'amélioration, en introduisant des techniques nouvelles tel que la validation du complexe QRS par sa morphologie, l'utilisation d'autres architectures neuronales, les transformés en ondelettes, l'apprentissage basé sur les algorithmes génétiques et l'algorithme de Levenberg–Marquardt,..., etc.

# ***Bibliographie***

- [1] M. Arbatni Khaled. Réseaux de neurones appliqués à l'analyse et à la modélisation non linéaire du signal ECG. Thèse de l'université de Constantine, decembre 2007.
- [2] Jérôme Declerck. Etude de la dynamique cardiaque par analyse d'images tridimensionnelles. Thèse de l'université de Nice Sophia-Antipolis, novembre 1997.
- [3] F. Kiss and J. Szentagothai Atlas d'anatomie du corps humain. Masson, 1974.
- [4] A.D. Waller, "A demonstration on man of electromotive changes accompanying the heart beat", in : *Physiol.* 8, 229-234, 1887.
- [5] I.E.W. Einthoven : "The man. The string galvanometer electrocardiograph", in: *Arch. Intern. Med.*, 148, 453-455, 1988.
- [6] C. Fisch, "The clinical electrocardiogram", A classic, in: *Circulation* 62 (Suppl. III), 1-4, 1980.
- [7] H.J.J. Wellens, "The electrocardiogram 80 years after Einthoven", in : *J. Am. Coll. Cardiol.* Vol.07, pp. 484-491, 1986.
- [8] D.M. Krikler, "Electrocardiography then and now. Where next?", in *Br. Heart J.* 57, 113.
- [9] N. J. Holter. New methods for heart studies. *Science* 134, 1214, 1961.
- [10] E. Jovanov and al. Real time holter monitoring of biomedical signals. DSP technology and education conference (DSPS-99), 1999.
- [11] G. de Lannoy. Automated modeling and processing of long-term electrocardiogram signals. PhD thesis, Université Catholique de Louvain, 2011.
- [12] D. Cuesta-Frau, J. C. Perez-Cortes, and G. Andreu-Garcia. Clustering of electrocardiograph signals in computer-aided holter analysis. *Computer Methods and Programs in Biomedicine* 72, 179-196, 2003.
- [13] B. Lebichot. Traitement automatique du signal ECG pour l'aide au diagnostic de pathologies cardiaques. Thèse de l'université catholique de Louvain, 2011.
- [14] G. de Lannoy. Automated modeling and processing of long-term electrocardiogram signals. PhD thesis, Université Catholique de Louvain, 2011.
- [15] R. Jafari, H. Noshadi, S. Ghiasi, and M. Sarrafzadeh. Adaptive electrocardiogram feature extraction on distributed embedded systems. *IEEE transaction on parallel and distributed systems*, 17 :1-11, 2006.
- [16] M. Paoletti and C. Marchesi. Discovering dangerous patterns in long-term ambulatory ecg recording using a fast qrs detection algorithm and explorative analysis. *Computer Methods and programs in biomedicine*, 82 :20-30, 2006.
- [17] C. Patrick. Projet Traitement du Signal : Analyse de Signaux ECG. Université de Lille 2012.

- [18] Cliord, Azuaje, and McSharry. *Advanced Methods and Tools for ECG Data Analysis*. Artech House, 2006.
- [19] HASTIE T., TIBSHIRANI R., FRIEDMAN J., *The Elements of Statistical Learning*, Springer, 2001.
- [20] Gaëlle Loosli. al. *Perception d'états affectifs et apprentissage*. PSI, CNRS FRE2645, INSA de Rouen, FRANCE
- [21] C. Pater, *Methodological considerations in the design of trials for safety assessment of new drugs and chemical entities*, *Trials* 6 (1) (2005) 1–13.
- [22] P. Lynn, *Recursive digital filters for biological signals*, *Med. Biol. Eng. Comput.* 9 (1) (1979) 37–43.
- [23] E.R. Ferrara, B. Widrow, *Fetal electrocardiogram enhancement by time-sequenced adaptive filtering*, *IEEE Trans. Biomed. Eng.* 29 (6) (1982) 458–460.
- [24] M. Yelderian, B. Widrow, J.M. Cioffi, E. Hesler, J.A. Leddy, *ECG enhancement by adaptive cancellation of electrosurgical interference*, *IEEE Trans. Biomed. Eng.* 30 (7) (1983) 392–398.
- [25] N.V. Thakor, Y.-S. Zhu, *Applications of adaptive filtering to ECG analysis: noise cancellation and arrhythmia detection*, *IEEE Trans. Biomed. Eng.* 38 (8) (1991) 785–794.
- [26] Q. Xue, Y.H. Hu, W.J. Tompkins, *Neural-network-based adaptive matched filtering for QRS detection*, *IEEE Trans. Biomed. Eng.* 39 (4) (1992) 317–329.
- [27] B.N. Singh, A.K. Tiwari, *Optimal selection of wavelet basis function applied to ECG signal denoising*, *Digit. Signal Process.* 16 (3) (2006) 275–287.
- [28] S.-W. Chen, H.-C. Chen, H.-L. Chan, *A real-time QRS detection method based on moving-averaging incorporating with wavelet denoising*, *Comput. Method Programs Biomed.* 82 (3) (2006) 187–195.
- [29] A.E. Zadeh, A. Khazaei, V. Ranaee, *Classification of the electrocardiogram signals using supervised classifiers and efficient features*, *Comput. Method Programs Biomed.* 99 (2) (2010) 179–194.
- [30] R. Sameni, M.B. Shamsollahi, C. Jutten, G.D. Clifford, *A nonlinear Bayesian filtering framework for ECG denoising*, *IEEE Trans. Biomed. Eng.* 54 (12) (2007) 2172–2185.
- [31] M.L. Soria, J.P. Martinez, *Analysis of multidomain features for ECG classification*, in: *Comput. Cardiol.*, 2009, pp.561–564.
- [32] G. de Lannoy, D. Francois, J. Delbeke, M. Verleysen, *Weighted SVMs and feature relevance assessment in supervised heart beat classification*, in: *Biomedical Engineering Systems and Technologies (BIOSTEC)*, 2010, pp. 212–223.
- [33] K.S. Park, B.H. Cho, D.H. Lee, S.H. Song, J.S. Lee, Y.J. Chee, I.Y. Kim, S.I. Kim, *Hierarchical support vector machine based heartbeat classification using higher order statistics and hermite basis function*, in: *Comput. Cardiol.*, 2008, pp.229–232.

- [34] T. Mar, S. Zaunseder, J.P. Martínez, M. Llamedo, R. Poll, Optimization of ECG classification by means of feature selection, *IEEE Trans. Biomed. Eng.* 58 (8) (2011) 2168–2177.
- [35] Z. Zhang, J. Dong, X. Luo, K.-S. Choi, X. Wu, Heartbeat classification using disease-specific feature selection, *Comput. Biol. Med.* 46 (2014) 79–89.
- [36] Z. Zhang, X. Luo, Heartbeat classification using decision level fusion, *Biomed. Eng. Lett.* 4 (4) (2014) 388–395.
- [37] M. Llamedo, J.P. Martínez, Heartbeat classification using feature selection driven by database generalization criteria, *IEEE Trans. Biomed. Eng.* 58 (3) (2011) 616–625.
- [38] C. Ye, B.V.K. Kumar, M.T. Coimbra, Combining general multi-class and specific two-class classifiers for improved customized ECG heartbeat classification, in: *International Conference on Pattern Recognition (ICPR)*, 2012, pp. 2428–2431.
- [39] D. Zhang, Wavelet approach for ECG baseline wander correction and noise reduction, in: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2005, pp. 1212–1215.
- [40] Y. Bazi, N. Alajlan, H. AlHichri, S. Malek, Domain adaptation methods for ECG classification, in: *International Conference on Computer Medical Applications (ICMA)*, 2013, pp. 1–4.
- [41] C.-C. Lin, C.-M. Yang, Heartbeat classification using normalized RR intervals and morphological features, *Math. Problem Eng.* 2014 (2014) 1–11.
- [42] H. Huang, J. Liu, Q. Zhu, R. Wang, G. Hu, A new hierarchical method for inter-patient heartbeat classification using random projections and RR intervals, *Biomed. Eng. Online* 13 (2014) 1–26.
- [43] M.A. Escalona-Moran, M.C. Soriano, I. Fischer, C.R. Mirasso, Electrocardiogram classification using reservoir computing with logistic regression, *IEEE J. Biomed. Health Inform.* 19 (3) (2015) 892–898.
- [44] I. Güler, E.D. Übeyli, ECG beat classifier designed by combined neural network model, *Pattern Recogn.* 38 (2) (2005) 199–208.
- [45] G.B. Moody, R.G. Mark, Development and evaluation of a 2-lead ECG analysis program, in: *Comput. Cardiol.*, 1982, pp. 39–44.
- [46] V.X. Afonso, W.J. Tompkins, T.Q. Nguyen, S. Luo, ECG beat detection using filter banks, *IEEE Trans. Biomed. Eng.* 46 (2) (1999) 192–202.
- [47] J. Lee, K. Jeong, J. Yoon, M. Lee, A simple real-time QRS detection algorithm, in: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Vol. 4, 1996, pp. 1396–1398.
- [48] P.S. Hamilton, W.J. Tompkins, Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmia database, *IEEE Trans. Biomed. Eng.* 33 (12) (1986) 1157–1165.

- [49] J. Pan, W.J. Tompkins, A real-time QRS detection algorithm, *IEEE Trans. Biomed. Eng.* 32 (3) (1985) 230–236.
- [50] R. Poli, S. Cagnoni, G. Valli, Genetic design of optimum linear and nonlinear QRS detectors, *IEEE Trans. Biomed. Eng.* 42 (11) (1995) 1137–1141.
- [51] J.C.T.B. Moraes, M.M. Freitas, F.N. Vilani, E.V. Costa, A QRS complex detection algorithm using electrocardiogram leads, in: *Comput. Cardiol.*, 2002, pp. 205–208.
- [52] P. Hamilton, Open source ECG analysis, *Comput. Cardiol.* (2002) 101–104.
- [53] Y.H. Hu, W.J. Tompkins, J.L. Urrusti, V.X. Afonso, Application of artificial neural networks for ECG signal detection and classification, *J. Eletrocardiol.* 26 (Suppl.) (1990) 66–73.
- [54] Y.-C. Yeh, W.-J. Wang, QRS complexes detection for ECG signal: the difference operation method, *Comput. Method Program Biomed.* 91 (3) (2008) 245–254.
- [55] O. Sayadi, M.B. Shamsollahi, A model-based Bayesian framework for ECG beat segmentation, *Physiol. Meas.* 30 (3) (2009) 335–352.
- [56] Massachusetts Institute of Technology, MIT-BIH ECG database, 2011, Available at: <http://ecg.mit.edu/>.
- [57] American Heart Association, AHA database, 1998, Available at: <http://www.ahadata.com/>.
- [58] J.H. van Bommel, J.L. Williams, Standardisation and validation of medical decision support systems: the CSE project, *Method Inf. Med.* 29 (4) (1990) 261–262.
- [59] B.-U. Kohler, C. Hennig, R. Orglmeister, The principles of software QRS detection, *IEEE Eng. Med. Biol. Mag.* 21 (1) (2002) 42–57.
- [60] S. Kadambe, R. Murray, G.F. Boudreaux-Bartels, Wavelet transform-based QRS complex detector, *IEEE Trans. Biomed. Eng.* 46 (7) (1999) 838–848.
- [61] Y. Jung, W.J. Tompkins, Detecting and classifying life-threatening ECG ventricular arrhythmias using wavelet decomposition, in: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Vol. 3, 2003, pp. 2390–2393.
- [62] H. Kim, R.F. Yazicioglu, P. Merken, C. van Hoof, H.-J. Yoo, ECG signal compression and classification algorithm with quad level vector for ECG holter system, *IEEE Trans. Inf. Technol. Biomed.* 14 (1) (2010) 93–100.
- [63] P. Laguna, R. Jané, P. Caminal, Automatic detection of wave boundaries in multilead ECG signals: validation with the CSE database, *Comput. Biomed. Res.* 27 (1) (1994) 45–60.
- [64] B. Celler, P. de Chazal, Selection of parameters from power spectral density, wavelet transforms and other methods for the automated interpretation of the ECG, in: *IEEE International Conference on Digital Signal Processing (ICDSP)*, 1997, pp. 71–74.
- [65] J.S. Sahambi, S.N. Tandon, R.K.P. Bhatt, DSP based ST-segment analysis: the wavelet approach, in: *Southern Biomedical Engineering Conference*, 1997, pp. 455–457.

- [66] C. Ye, V. Bhagavatula, M.T. Coimbra, Heartbeat classification using morphological and dynamic features of ECG signals, *IEEE Trans. Biomed. Eng.* 59 (10) (2012) 2930–2941.
- [67] T.P. Exarchos, M.G. Tsipouras, D. Nanou, C. Bazios, Y. Antoniou, D.I. Fotiadis, A platform for wide scale integration and visual representation of medical intelligence in cardiology: the decision support framework, *Comput. Cardiol.* (2005) 167–170.
- [68] T.P. Exarchos, M.G. Tsipouras, C.P. Exarchos, C. Papaloukas, D.I. Fotiadis, L.K. Michalis, A methodology for the automated creation of fuzzy expert systems for ischaemic and arrhythmic beat classification based on a set of rules obtained by a decision tree, *Artif. Intell. Med.* 40 (3) (2007) 187–200.
- [69] R.G. Kumar, Y.S. Kumaraswamy, Investigation and classification of ECG beat using input output additional weighted feed forward neural network, in: *International Conference on Signal Processing, Image Processing & Pattern Recognition (ICSIPR)*, 2013, pp. 200–205.
- [70] C. Ye, M.T. Coimbra, B.V.K.V. Kumar, Arrhythmia detection and classification using morphological and dynamic features of ECG signals, in: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2010, pp. 1918–1921.
- [71] G. Doquire, G. de Lannoy, D. Francois, M. Verleysen, Feature selection for interpatient supervised heart beat classification, *Comput. Intell. Neurosci.* 2011 (2011) 1–9.
- [72] M. Korürek, B. Dog˘ an, ECG beat classification using particle swarm optimization and radial basis function neural network, *Expert Syst. Appl.* 37 (12) (2010) 7563–7569.
- [73] C. Wen, T.-C. Lin, K.-C. Chang, C.-H. Huang, Classification of ECG complexes using self-organizing CMAC, *Measurement* 42 (3) (2009) 399–407.
- [74] Y. Özbay, G. Tezel, A new method for classification of ECG arrhythmias using neural network with adaptive activation function, *Digit. Signal Process.* 20 (4) (2010) 1040–1049.
- [75] F. Castells, P. Laguna, L. Sörnmo, A. Bollmann, J.M. Roig, Principal component analysis in ECG signal processing, *EURASIP J. Appl. Signal Process.* 2007 (1) (2007) 98.
- [76] R. Ceylan, Y. Özbay, Comparison of FCM, PCA and WT techniques for classification ECG arrhythmias using artificial neural network, *Expert Syst. Appl.* 33 (2) (2007) 286–295.
- [77] J. Kim, H.S. Shin, J. Shin, M. Lee, Robust algorithm for arrhythmia classification in ECG using extreme learning machine, *BioMed. Eng. OnLine* 8 (1) (2009) 1–12.
- [78] M. Sarfraz, A.A. Khan, F.F. Li, Using independent component analysis to obtain feature space for reliable ECG arrhythmia classification, in: *IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 2014, pp. 62–67.
- [79] S.-N. Yu, K.-T. Chou, Integration of independent component analysis and neural networks for ECG beat classification, *Expert Syst. Appl.* 34 (4) (2008) 2841–2846.
- [80] S.-N. Yu, K.-T. Chou, Selection of significant independent components for ECG beat classification, *Expert Syst. Appl.* 36 (2) (2009) 2088–2096.

- [81] M. Chawla, A comparative analysis of principal component and independent component techniques for electrocardiograms, *Neural Comput. Appl.* 18 (6) (2009) 539–556.
- [82] L. Kanaan, D. Merheb, M. Kallas, C. Francis, H. Amoud, P. Honeine, PCA and KPCA of ECG signals with binary SVM classification, in: *IEEE Workshop on Signal Processing Systems (SiPS)*, 2011, pp. 344–348.
- [83] M. Kallas, C. Francis, L. Kanaan, D. Merheb, P. Honeine, H. Amoud, Multi-class SVM classification combined with kernel PCA feature extraction of ECG signals, in: *International Conference on Telecommunications (ICT)*, 2012, pp. 1–5.
- [84] Y. Özbay, R. Ceylan, B. Karlik, A fuzzy clustering neural network architecture for classification of ECG arrhythmias, *Comput. Biol. Med.* 36 (4) (2006) 376–388.
- [85] B.M. Asl, S.K. Setarehdan, M. Mohebbi, Support vector machine-based arrhythmia classification using reduced features of heart rate variability signal, *Artif. Intell. Med.* 44 (1) (2008) 51–64.
- [86] I. Bogdanova, F. Rincón, D. Atienza, A multi-lead ECG classification based on random projection features, in: *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2012, pp. 625–628.
- [87] F.M. Ham, S. Han, Classification of cardiac arrhythmias using fuzzy ARTMAP, *IEEE Trans. Biomed. Eng.* 43 (4) (1996) 425–429.
- [88] S. Osowski, T.H. Linh, ECG beat recognition using fuzzy hybrid neural network, *IEEE Trans. Biomed. Eng.* 48 (11) (2001) 1265–1271.
- [89] S. Osowski, L.T. Hoai, T. Markiewicz, Support vector machine-based expert system for reliable heartbeat recognition, *IEEE Trans. Biomed. Eng.* 51 (4) (2004) 582–589.
- [90] R. Ceylan, Y. Özbay, B. Karlik, A novel approach for classification of ECG arrhythmias: type-2 fuzzy clustering neural network, *Expert Syst. Appl.* 36 (3) (2009) 6721–6726.
- [91] S. Osowski, T. Markiewicz, L.T. Hoai, Recognition and classification system of arrhythmia using ensemble of neural networks, *Measurement* 41 (6) (2008) 610–617.
- [92] M.I. Owis, A.H. Abou-Zied, A.B.M. Youssef, Y.M. Kadah, Study of features based on nonlinear dynamical modeling in ECG arrhythmia detection and classification, *IEEE Trans. Biomed. Eng.* 49 (7) (2002) 733–736.
- [93] E.D. Übeyli, Adaptive neuro-fuzzy inference system for classification of ECG signals using Lyapunov exponents, *Comput. Method Program Biomed.* 93 (3) (2009) 313–321.
- [94] W. Jiang, G.S. Kong, Block-based neural networks for personalized ECG signal classification, *IEEE Trans. Neural Netw.* 18 (6) (2007) 1750–1761.
- [95] A.K. Mishra, S. Raghav, Local fractal dimension based ECG arrhythmia classification, *Biomed. Signal Process. Control* 5 (2) (2010) 114–123.

- [96] C. Lin, Y. Du, T. Chen, Adaptive wavelet network for multiple cardiac arrhythmias recognition, *Expert Syst. Appl.* 34 (4) (2008) 2601–2611.
- [97] Y. Kutlu, D. Kuntalp, Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients, *Comput. Method Program Biomed.* 105 (3) (2012) 257–267.
- [98] Z. Dokur, T. Ölmez, ECG beat classification by a novel hybrid neural network, *Comput. Method Program Biomed.* 66 (2-3) (2001) 167–181.
- [99] P.S. Addison, Wavelet transforms and the ECG: a review, *Physiol. Meas.* 26 (5) (2005) 155–199.
- [100] A. Daamouche, L. Hamami, N. Alajlan, F. Melgani, A wavelet optimization approach for ECG signal classification, *Biomed. Signal Process. Control* 7 (4) (2012) 342–349.
- [101] S.-N. Yu, Y.-H. Chen, Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network, *Pattern Recogn. Lett.* 28 (10) (2007) 1142–1150.
- [102] M.H. Song, J. Lee, S.P. Cho, K.J. Lee, S.K. Yoo, Support vector machine based arrhythmia classification using reduced features, *Int. J. Control Autom. Syst.* 3 (4) (2005) 509–654.
- [103] J.-S. Wang, W.-C. Chiang, Y.-L. Hsu, Y.-T.C. Yang, ECG arrhythmia classification using a probabilistic neural network with a feature reduction method, *Neurocomputing* 116 (20) (2013) 38–45.
- [104] K. Polat, S. Güneş, Detection of ECG arrhythmia using a differential expert system approach based on principal component analysis and least square support vector machine, *Appl. Math. Comput.* 186 (1) (2007) 898–906.
- [105] G. Bortolan, I.I. Christov, W. Pedrycz, Hyperbox classifiers for ECG beat analysis, in: *Comput. Cardiol.*, 2007, pp.145–148.
- [106] I. Christov, G. Bortolan, Ranking of pattern recognition parameters for premature ventricular contractions classification by neural networks, *Physiol. Meas.* 25 (5) (2004) 1281–1290.
- [107] A.L. Goldberger, L.A.N. Amaral, L. Glass, J.M. Hausdorff, P.C. Ivanov, R.G. Mark, J.E. Mietus, G.B. Moody, C.-K. Peng, H.E. Stanley, Physiobank, physiotoolkit, and physionet: Components of a new research resource for complex physiologic signals, *Circulation* 101 (23) (2000) 215–220, database and tools available at: <http://www.physionet.org/>.
- [108] P. Pudil, J. Novovicova, J. Kittler, Floating search methods in feature selection, *Pattern Recogn. Lett.* 15 (11) (1994) 1119–1125.
- [109] I.-S. Oh, J.-S. Lee, B.-R. Moon, Hybrid genetic algorithms for feature selection, *IEEE Trans. Pattern Anal. Mach. Intell.* 26 (11) (2004) 1424–1437.
- [110] J. Yang, V. Honavar, Feature subset selection using a genetic algorithm, *IEEE Intell. Syst. Appl.* 13 (2) (1998) 44–49.

- [111] X. Wang, J. Yang, X. Teng, W. Xia, R. Jensen, Feature selection based on rough sets and particle swarm optimization, *Pattern Recogn. Lett.* 28 (4) (2007) 459–471.
- [112] S.-W. Lin, K.-C. Ying, S.-C. Chen, Z.-J. Lee, Particle swarm optimization for parameter determination and feature selection of support vector machines, *Expert Syst. Appl.* 35 (4) (2008) 1817–1824.
- [113] R.O. Duda, P.E. Hart, D.G. Stork, *Pattern Classification*, 2nd ed., Wiley-Interscience, 2000.
- [114] C.M. Bishop, *Pattern Recognition and Machine Learning*, 1st ed., Springer, 2006.
- [115] S. Theodoridis, K. Koutroumbas, *Pattern Recognition*, 4th ed., Elsevier, 2009.
- [116] E.D. Übeyli, Combining recurrent neural networks with eigenvector methods for classification of ECG beats, *Digit. Signal Process.* 19 (2) (2009) 320–329.
- [117] N. Özcan, F. Gurgen, Fuzzy support vector machines for ECG arrhythmia detection, in: *IEEE International Conference on Pattern Recognition (ICPR)*, 2010, pp. 2973–2976.
- [118] J.A. Nasiri, M. Naghibzadeh, H.S. Yazdi, B. Naghibzadeh, ECG arrhythmia classification with support vector machines and genetic algorithm, in: *IEEE European Symposium on Computer Modeling and Simulation (EMS)*, 2009, pp. 187–192.
- [119] M. Moavenian, H. Khorrami, A qualitative comparison of artificial neural networks and support vector machines in ECG arrhythmias classification, *Expert Syst. Appl.* 37 (4) (2010) 3088–3093.
- [120] N.V. Chawla, K.W. Bowyer, W.P. Kegelmeyer, Smote: synthetic minority over-sampling technique, *J. Artif. Intell. Res.* 16 (1) (2002) 321–357.
- [121] Y.P. Meau, F. Ibrahim, S.A.L. Narainasamy, R. Omar, Intelligent classification of electrocardiogram (ECG) signal using extended kalman filter (EKF) based neuro fuzzy system, *Comput. Method Program Biomed.* 82 (2) (2006) 157–168.
- [122] E. Mehmet, ECG beat classification using neuro-fuzzy network, *Pattern Recogn. Lett.* 25 (15) (2004) 1715–1722.
- [123] A. Rodan, P. Tinˆo, Minimum complexity echo state network, *IEEE Trans. Neural Netw.* 22 (1) (2011) 131–144.
- [124] P. De Chazal, M. O’Dwyer, R.B. Reilly, Automatic classification of heartbeats using ECG morphology and heartbeat interval features, *IEEE Trans. Biomed.Eng.* 51 (2004) 1196–1206.
- [125] K. R. Coombes, B. R. Hunt, R. L. Lipsman, J. E. Osborn, and G. J. Stuck. *Differential Equations with MATLAB*. John Wiley and Sons, 2000.

