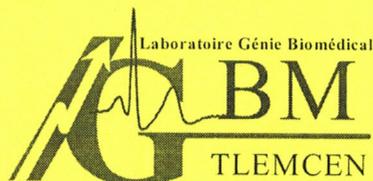


UNIVERSITE ABOU BEKR BELKAID

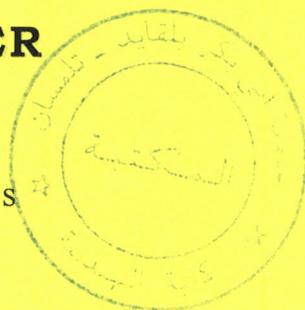


Faculté
des Sciences
de l'Ingénieur



**THESE DE MAGISTER
EN ELECTRONIQUE**

Option Signaux et Systèmes



THEME

**DETECTION ET CLASSIFICATION DES ARYTHMIES
CARDIAQUES PAR APPLICATION DES RESEAUX DE NEURONES**

Présentée par :

Mr BELGACEM *Noureddine*

Soutenu en juin 2002.

Directeur de la thèse :

Mr BEREKSI-REGUIG Fethi *Professeur (Univ. de Tlemcen).*

Membres de jury :

Président :

Mr. CHERKI Brahim

Maître de conférences (Univ. de Tlemcen).

Examineurs :

Mr. BENDIMERAD Fethi Tarik

Maître de conférences (Univ. de Tlemcen).

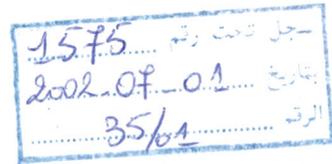
Mr. GHAF FOUR Kheireddine

Maître de conférences (Univ. de Tlemcen).

Mr. MEZIANE TANI Abderrahim

Maître Assistant (C.H.U. Tlemcen).

DEDICACES



A mes parents,
A tous ceux qui me semblent très chers,



REMERCIEMENTS

Je remercie mon seigneur d'avoir donné à l'homme le pouvoir de raisonner
et d'exploiter les vérités de l'univers.

En premier lieu, je tiens à remercier le professeur F. BEREKSI-REGUIG, Directeur de ma thèse et Directeur du laboratoire où celle-ci s'est déroulée (GBM), pour m'avoir permis d'effectuer une étude aussi intéressante. Je pense que le fait d'avoir eu à traiter les différentes phases de développement d'un tel système apporte énormément sur le plan intellectuel comme sur le plan pratique.

Je remercie également M.A.CHIKH, F.MEGHNEFI et A.DJEBBARI, membres de ce laboratoire, pour le soutien qu'ils m'ont apporté en me faisant part de leurs expériences, ainsi que pour leurs précieux conseils, leurs critiques constructives et pertinentes.

Je teins à remercier respectueusement Monsieur Brahim CHERKI d'avoir accepter la présidence du jury.

Ma gratitude va aussi aux membres du jury : Mr Fethi Tarik BENDIMERAD, Kheireddine GHAFfour et Abderrahim MEZIANE TANI qui ont accepté d'être examinateurs de mes travaux.

Je voudrais aussi remercier toutes les personnes que j'ai côtoyées, bibliothécaires, documentalistes, responsables et agents de laboratoires ainsi que les cardiologues du C.H.U. de Tlemcen et qui m'ont apporté leur aide dans des domaines très variés.

Que mes chers parents trouvent dans ce travail ma reconnaissance et ma gratitude pour leur patience tout le long de ma scolarité.

TABLE DES MATIERES

| | | | |
|---------------|---|---|----|
| CHAPITRE I : | | Concepts Fondamentaux. | |
| I.1 | Introduction..... | | 7 |
| I.2 | Généralités sur le fonctionnement du cœur..... | | 8 |
| I.2.1 | <i>La conduction électrique du cœur.....</i> | | 8 |
| I.2.2 | <i>Caractéristiques du signal ECG.....</i> | | 9 |
| I.3 | Recueil du signal ECG de monitoring..... | | 10 |
| I.4 | Les arythmies cardiaques..... | | 12 |
| I.4.1 | <i>Les troubles du rythme sinusal.....</i> | | 14 |
| I.4.2 | <i>Les troubles du rythme auriculaire.....</i> | | 14 |
| I.4.3 | <i>Les troubles du rythme ventriculaire.....</i> | | 15 |
| I.5 | Bases de données..... | | 16 |
| I.6 | Base de données MIT BIH..... | | 17 |
| I.7 | Classification des arythmies cardiaques..... | | 18 |
| I.8 | Méthodes de classification..... | | 19 |
| I.8.1 | <i>Méthode des arbres.....</i> | | 19 |
| I.8.2 | <i>Approche statistique.....</i> | | 19 |
| I.8.3 | <i>Approche syntaxique.....</i> | | 20 |
| I.8.4 | <i>Intelligence artificielle et systèmes experts.....</i> | | 20 |
| I.8.5 | <i>Réseaux de neurones et systèmes connexionnistes.....</i> | | 21 |
| I.9 | Conclusion..... | | 22 |
| CHAPITRE II. | | Traitement Du Signal ECG. | |
| II.1 | Introduction..... | | 24 |
| II.2 | Lecture et chargement des signaux ECG..... | | 25 |
| II.3 | Prétraitement du signal cardiaque..... | | 25 |
| II.4 | Identification et détection des paramètres du signal ECG..... | | 25 |
| II.4.1 | <i>Détection du pic R.....</i> | | 29 |
| II.4.1.1 | <i>Détection d'un seuil de référence.....</i> | | 29 |
| II.4.1.2 | <i>Localisation du pic Pkn, Pka et Pkb.....</i> | | 29 |
| II.4.1.3 | <i>Localisation de la position du pic R (Rp).....</i> | | 30 |
| II.4.1.4 | <i>Mesure de la fréquence cardiaque.....</i> | | 30 |
| II.4.2 | <i>Détection des ondes Q et S.....</i> | | 31 |
| II.4.3 | <i>Détection de l'onde T.....</i> | | 32 |
| II.4.4 | <i>Détection de l'onde P.....</i> | | 33 |
| II.5 | Préparation des données en vue de la classification..... | | 37 |
| II.5.1 | <i>Réduction des données.....</i> | | 38 |
| II.5.2 | <i>Compression du complexe QRS et de l'onde P par la prédiction linéaire.....</i> | | 39 |
| II.5.3 | <i>Choix des paramètres.....</i> | | 40 |
| II.6 | Conclusion..... | | 41 |
| CHAPITRE III. | | Classification Des Arythmies Cardiaques Par Réseaux De Neurones. | |
| III.1 | Introduction..... | | 43 |
| III.2 | Les réseaux de neurones..... | | 45 |
| III.2.1 | <i>Historique.....</i> | | 45 |

| | | |
|-----------|---|----|
| III.2.2 | Principe de fonctionnement..... | 45 |
| III.2.3 | Le réseau de neurones..... | 46 |
| III.2.4 | Apprentissage : | 47 |
| III.2.5 | La rétropropagation..... | 48 |
| III.2.6 | Applications | 49 |
| III.2.7 | Procédures de développement d'un réseau de neurones : | 50 |
| III.3 | Performance d'un classificateur | 53 |
| III.4 | Structure du classificateur | 54 |
| III.4.1 | Première approche..... | 54 |
| III.4.1.1 | Classificateur des complexes QRS CLS1 | 54 |
| III.4.1.2 | Classificateur des ondes P CLS2..... | 55 |
| III.5 | Implémentation software du classificateur | 56 |
| III.5.1 | Apprentissage..... | 57 |
| III.5.2 | Algorithme de la rétropropagation..... | 57 |
| III.5.3 | Base de données | 58 |
| III.5.4 | Programmation..... | 59 |
| III.5.5 | Dimensionnement du réseau..... | 60 |
| III.6 | Conclusion | 61 |

CHAPITRE IV. **Synthèse de la Classification des Arythmies Cardiaques.**

| | | |
|------|------------------------------------|----|
| IV.1 | Introduction..... | 63 |
| IV.2 | Le logiciel : <i>ECG Pro</i> | 63 |
| IV.3 | Résultats..... | 67 |
| IV.4 | Intérêt | 71 |
| IV.5 | Conclusion..... | 72 |

| | |
|---------------------------------|-----------|
| Conclusion Générale..... | 74 |
|---------------------------------|-----------|

BIBLIOGRAPHIE.

ANNEXES :

Annexe A : Format des fichiers de MIT BIH.

Annexe B : Algorithmes d'apprentissage.

Annexe C : Contenu des fichiers de MIT.



Résumé

Le signal électrocardiogramme ECG est en grande partie utilisé comme outil de diagnostic de cas pathologiques cardiaques par l'ensemble des paramètres et ondes (P, QRS, T) qu'il regroupe, il traduit l'activité électrique du coeur. L'analyse du signal ECG et l'identification des ses paramètres constituent une étape primordiale pour le diagnostic. Cependant, des sources de bruits telles que les variations de la ligne de base, l'interférence électrique du réseau 50Hz, et d'autres artefacts, mettent en arène la mise en œuvre des techniques d'analyse et d'identification utilisées. Toutefois, un ensemble de méthodes et d'algorithmes sont développés compte tenu de l'importance de ce signal et son exploitation en routine clinique dans le diagnostic des cas pathologiques cardiaques

Parmi ces méthodes, l'approche basée sur des concepts de réseaux de neurones est très prometteuse dans le domaine d'aide au diagnostic et particulièrement dans la classification de cas pathologiques. Notre intérêt est porté à l'application de cette technique dans la classification des arythmies cardiaques. Pour aboutir à cette classification, l'approche qu'on a adoptée est basée sur trois critères qui sont :

- *Filtrage du signal ECG* des différents bruits par un filtre passe bande (0.15Hz-20Hz).
- *Détection des paramètres pertinents* dans le signal ECG en utilisant la technique de la dérivée.
- *Classification des cycles cardiaques en six classes*, à savoir : normal (N), extrasystole ventriculaire (V), fusion entre N et V (F), battement ectopique (P), extrasystole auriculaire (A), battement non classé (Q). L'algorithme utilisé pour l'apprentissage de notre classificateur est basé sur la rétropropagation de Gradient.

Le test et l'évaluation des performances du classificateur conçu, ont été effectués sur des signaux ECG réels disponibles dans la base de données de Physionet : MIT BIH Arrhythmia Database. Cette évaluation de performance est faite par la détermination de paramètres standard d'évaluation tel que la sensibilité, la spécificité et le taux de classification correct.

Les résultats obtenus sont comparés à d'autres travaux, ils ont montré la puissance de l'outil que nous avons développé : le logiciel "*ECG Pro*" pour le traitement du signal ECG et la classification des arythmies cardiaques.

Abstract

The most widely used signal in clinical practice is the ECG. ECG conveys information regarding the electrical activity of the heart, by altering the shape of its constituting waves, namely the P, QRS, and T waves. Thus, the required tasks of ECG processing are first the reliable recognition of these waves, then the accurate measurement of clinically important parameters from the temporal distribution of the ECG constituting waves. The recognition and analyzing of ECG signal is difficult, since their size and waveform may change eventually, introducing noise in the signal. Since the processing of ECG signal is a very important step in the examination done by physicians, many methods and algorithm procedures have been proposed, described and implemented. Artificial Neural Networks (ANN) is a new and promising technique for achieving this task. ANN have generated a tremendous interest in both theoretical and applied areas, especially over the past few years.

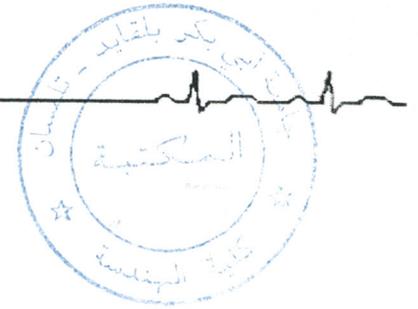
Our work focuses on the three main topics in the field of ECG processing: filtering (denoising, removal of baseline wandering, artifacts, etc), detection of the ECG signal parameters (P, QRS, T) and finally classification of waveforms according to pathologies cases. We proposed a classifier, based on ANN, of six classes: Normal, Premature Ventricular Contraction, Fusion of ventricular and normal beat, Paced beat, Atrial premature beat and Unclassifiable beat. This work is not intended to cover the neural network theory in details; it rather serves as a first reading and gives some basic properties and definitions.

The signals which are used to develop this work are available in the MIT BIH database, which covert a large set and variety of real pathological ECG signals.

Sensitivity, specificity, and total accuracy were the indices used for the assessment of the performance of the classifier. The study also contains a brief description of some recent applications of connectionist approaches to ECG interpretation. This study finally ends with a comparative assessment of performances of all above works and some hints about the future directions of work in this field.

Keywords: Biomedical signal processing, Automated ECG interpretation, cardiac arrhythmia, Connectionist approach, Artificial neural network, MIT BIH arrhythmia Database.

INTRODUCTION



INTRODUCTION

Ce travail, de nature technologique, a été élaboré au sein de laboratoire de Génie Biomédicale (GBM). [L'objectif de cette étude était de concevoir un système d'aide au diagnostic médicale dans les pathologies cardiaques en exploitant le signal électrocardiogramme ECG.] Cette étude vient à compléter les travaux déjà effectués par certains membres du laboratoire[1-4]. Il a été montré les possibilités d'utiliser des techniques de traitement du signal pour détecter les arythmies cardiaques sur des enregistrements de signaux ECG réels et simulés. Dans ce travail, nous sommes d'abord intéressé au développement d'un algorithme de détection et d'identification des différentes ondes constituant le signal ECG, [puis la conception d'un classificateur des arythmies cardiaques en exploitant les réseaux de neurones.]

[L'évolution de la médecine s'accélère, et la cardiologie, marquée comme d'autres disciplines par la technique, se transforme rapidement. Le nombre élevé de malades suivis quotidiennement et, par conséquent, la multitude de cas se présentant, rendent désormais indispensable l'utilisation de ces systèmes d'aide à la surveillance et au diagnostic. Leur utilité dans les hôpitaux, tant pour les médecins, les infirmiers et les étudiants en médecine que pour le malade lui-même, n'est plus à démontrer.]

Actuellement, le succès commercial remporté par les systèmes de reconnaissance automatique est beaucoup plus lié à leur possibilité de recherche, d'extraction et de stockage des données ECG, qu'à leur possibilité d'analyse et de diagnostic (classification). Cependant, de par le monde, des efforts de recherche considérables sont consentis afin de mettre en œuvre des classificateurs fiables.

Dans cet objectif, nos recherches se sont orientées d'une part vers le développement d'un algorithme d'extraction d'information contenu dans le signal électrocardiogramme ECG, et d'autre part vers la conception d'un classificateur des arythmies cardiaques. [Ce classificateur sera capable de gérer d'une façon efficace et

satisfaisante les différents aspects d'informations médicales nécessaires aux médecins pour la prise de décision en pathologie cardiaque.)

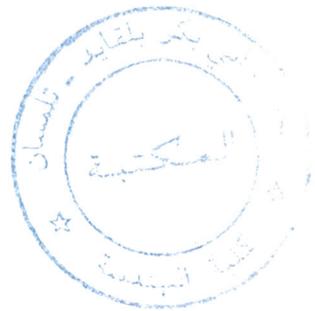
La première partie relative à l'extraction d'informations consiste en la mise au point d'une méthodologie de transformation des données en informations. Cette méthode s'appuie sur la richesse descriptive des données patient. Elle est basée sur des concepts issus des domaines de l'apprentissage, de la reconnaissance de formes et morphologies des ondes, de l'analyse de données et du traitement du signal. Cependant, il n'est pas toujours possible de disposer d'un ensemble de données (enregistrements ECG) suffisant. En particulier dans la domaine médical, il est souvent difficile d'associer une vérité médicale aux données patient. Dans le cadre de ce travail, la source des signaux ECG que nous avons traité est la base de données universelle « MIT BIH Arrhythmia Database ». Il est alors nécessaire de mettre au point des techniques améliorées capables de détecter, d'identifier et de localiser simultanément les différentes ondes constituant le signal ECG.

La deuxième partie est relative à la conception d'un système dédié à la classification des arythmies cardiaques. Ce système utilise une approche neuronale qui exploite les données et paramètres précédemment étudiés. En fait, dans le domaine de la classification, et plus particulièrement la classification de signaux ECG, les travaux de recherche montrent que les classificateurs à base de réseaux de neurones donnent des résultats meilleurs que les classificateurs classiques. Les réseaux de neurones, par leur propriété d'apprentissage et de généralisation, offrent les possibilités pour utiliser des modèles non linéaires, une habilité de lecture et d'auto organisation et la possibilité de lire des formes en réponse à de nouvelles formes.

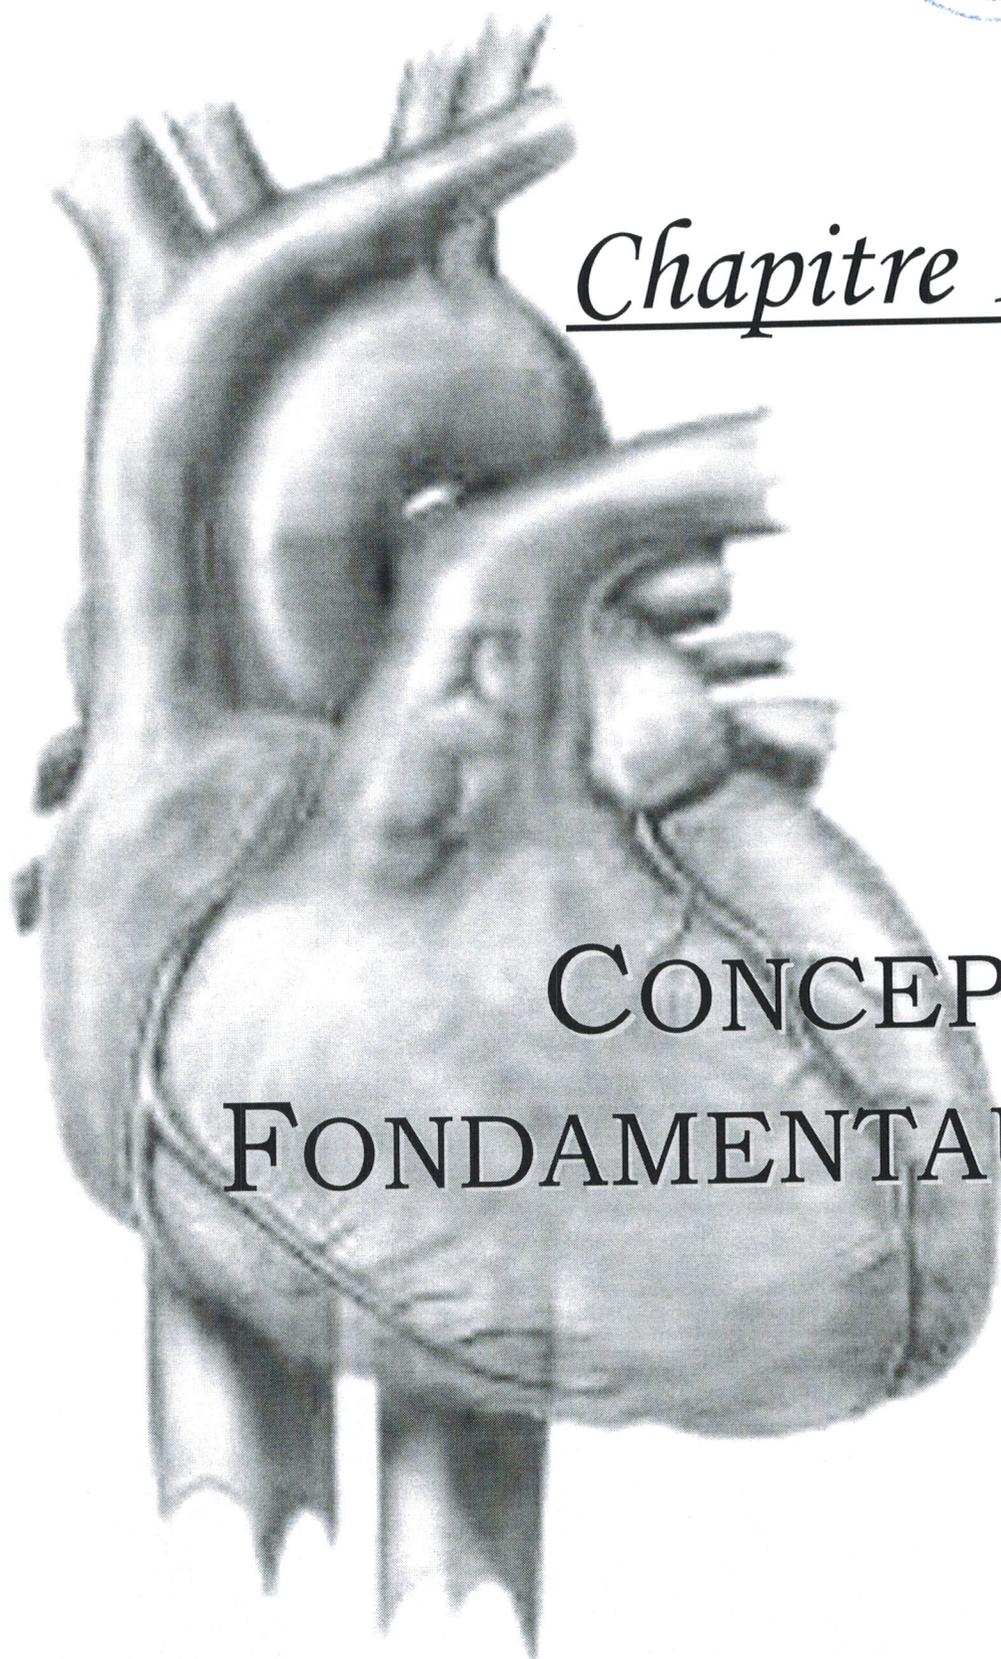
L'essentiel de la présente étude est consacré à la mise en œuvre d'un système fiable de détection et classification des cas pathologique. Nous commençons par une représentation de l'organe cible (chapitre 1) : le cœur. L'accent est mis sur d'autres concepts de base à savoir : le signal ECG, les arythmies cardiaques, les sources des signaux ECG et les méthodes de classification. Nous mettons également en évidence la nécessité de disposer de variables descriptives représentatives pour

résoudre un tel problème de classification. Le deuxième chapitre regroupe les techniques du traitement du signal ECG : détection et identification de ses différents paramètres, qui constituent les éléments du vecteur d'entrée du réseaux de neurones.

A travers cette étude, nous présentons dans le chapitre 3 un système de classification des arythmies cardiaques. Une utilisation originale des réseaux de neurones pour la conception de ce système basé sur l'algorithme de la rétropropagation de gradient est proposée. Enfin, le chapitre 4 présente les résultats obtenus sur les signaux ECG de MIT. Une évaluation des performances de notre classificateur est présentée. Cette évaluation est comparée aux résultats d'autres travaux.



Chapitre 1



CONCEPTS FONDAMENTAUX



I. CONCEPTS FONDAMENTAUX

I.1 Introduction

L'électrocardiographie, inventée par W. Einthoven, explore l'activité électrique du cœur par enregistrement des variations des ondes électriques de l'activité de polarisation et de dépolarisation ventriculaire et auriculaires du cœur [5]. L'activité cardiaque constitue l'un des plus importants paramètres déterminant l'état d'un sujet. Elle se traduit par l'apparition de plusieurs ondes sur le tracé de l'électrocardiogramme : c'est le signal cardiaque, l'électrocardiogramme : ECG. La figure I.1 montre la courbe caractéristique d'un signal cardiaque issue d'un électrocardiogramme.

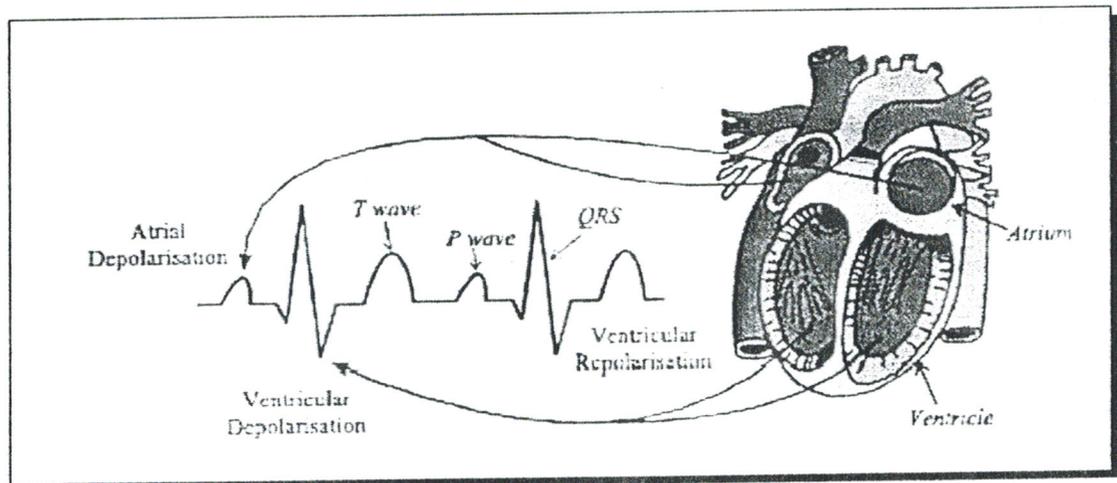


Fig. I.1. Courbe caractéristique d'un signal cardiaque.

I.2 Généralités sur le fonctionnement du cœur

Le cœur est situé au centre du thorax et sa pointe orientée vers la gauche. Il a approximativement la taille d'un poing fermé. Le cœur est un muscle qui a pour rôle de pomper le sang afin de le faire circuler à travers tout le corps pour nourrir les cellules. Il pompe environ 5 à 6 litres de sang par minute. Pour assurer son rôle de pompe, il doit se contracter, se décontracter et ainsi de suite. Ces mouvements correspondent au battement du cœur. Un cœur en bonne santé bat entre 60 et 100 cycles par minute au repos. Il peut augmenter ou diminuer sa fréquence selon le niveau d'activité de l'homme.

Le cœur est principalement composé de quatre cavités ou parties. Au niveau supérieur, on retrouve côte à côte l'oreillette droite et gauche et au niveau inférieur,

le ventricule droit et gauche. Chaque oreillette est reliée à un ventricule par une valve. Ces quatre cavités, dont les parois sont constituées de muscle, servent de réservoir au sang et c'est à partir de celles-ci que le sang est propulsé dans tout l'organisme.

I.2.1 La conduction électrique du cœur

Afin de pouvoir battre, le cœur est muni d'un système électrique que l'on appelle système de conduction électrique du cœur. En fait, on peut dire que le cœur est une pompe à deux temps qui produit un potentiel électrique. Celui-ci fait contracter les oreillettes et les ventricules (Fig. I.2).

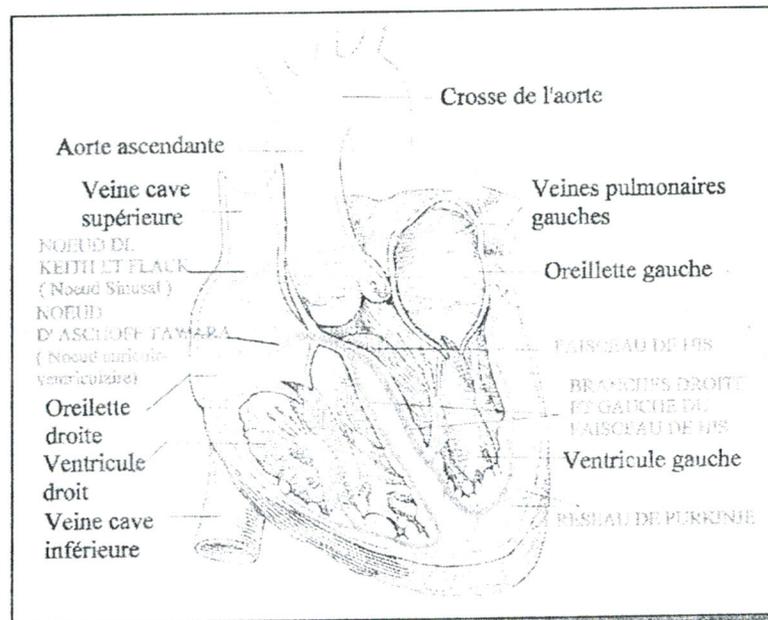


Fig. I.2. Le système de conduction électrique du cœur.

L'endocarde, tunique interne du cœur, est tapissé de cellules nerveuses. La dépolarisation d'une cellule nerveuse provoque la contraction de la cellule musculaire associée et la dépolarisation de la cellule nerveuse voisine, et de proche en proche, la contraction du muscle. Ceci engendre une onde de dépolarisation. Un second mode de propagation utilise des voies de conduction spécialisées : les branches gauche et droite de conduction. La dépolarisation prend naissance dans le (nœud sinusal), situé à la partie haute de l'oreillette droite. Ainsi, l'onde envoie et contrôle les impulsions pour que le cœur batte de 60 à 100 cycles par minute lorsqu'on est au repos.

Après avoir été engendrée dans le nœud sinusal, l'onde de dépolarisation parcourt les deux oreillettes, en active leur contraction, et favorise le passage du sang des oreillettes vers les ventricules. Puis, elle poursuit son chemin pour se rendre dans un autre site, le (nœud auriculo-ventriculaire). On l'appelle ainsi parce qu'il est situé entre les oreillettes et les ventricules. Sa fonction est de donner le temps aux oreillettes d'assurer une contraction complète, et au sang de passer complètement dans les ventricules.

1.2.2 Caractéristiques du signal ECG

On peut distinguer dans un ECG différentes ondes, différents segments ainsi que différents intervalles (Fig. 1.3) en corrélation directe avec l'activité cardiaque. Ces composantes réunies forment le cycle cardiaque complet [6], c'est ainsi que :

L'onde P : représente la déflexion produite par la dépolarisation des oreillettes. Dans les conditions normales la durée de l'onde P est inférieure ou égale à 0.11 seconde.

Le complexe QRS : représente l'ensemble des déflexions correspondantes à la dépolarisation des ventricules. La valeur normale du complexe QRS est inférieure à 0.1 seconde, habituellement entre 0.06 et 0.08 secondes.

L'onde T : représente la déflexion produite par la repolarisation ventriculaire.

L'onde U : est une déflexion habituellement positive que l'on rencontre après l'onde T et précède l'onde P suivante. Sa signification exacte est encore discutée.

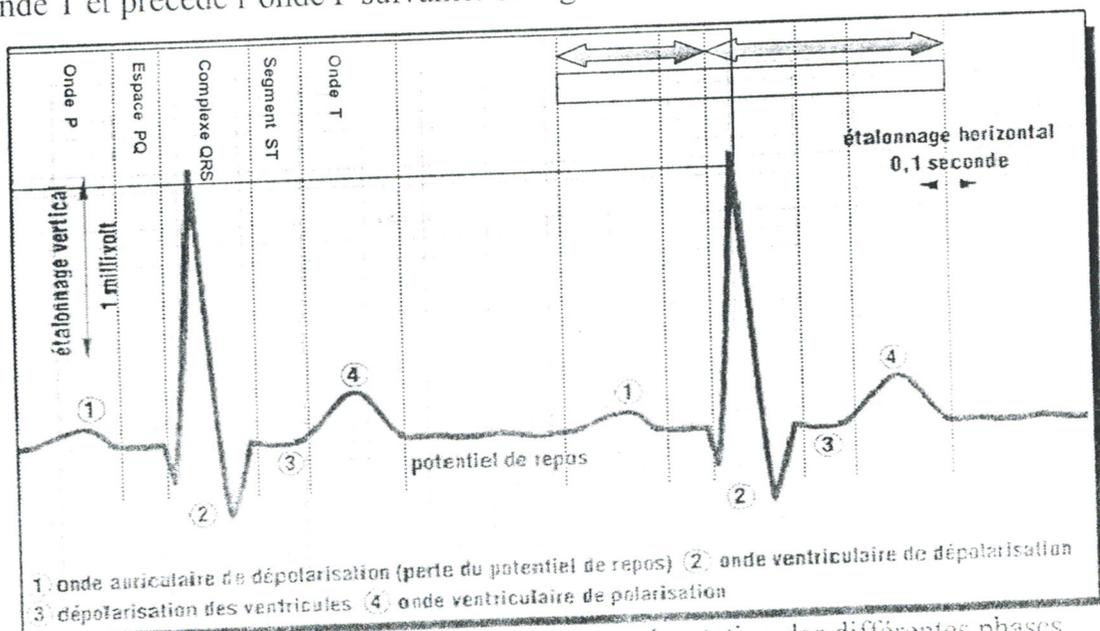


Fig. 1.3. Tracé d'un signal ECG normal et représentation des différentes phases.



Les caractéristiques d'un signal ECG normal sont représentées sur le tableau suivant :

Durées en secondes

| | | |
|--------------|------------------|---|
| Onde P | Jusqu'à 0,10 sec | |
| Espace PQ | Jusqu'à 0,20 sec | (début P jusqu'au début Q, dépendant de la fréquence) |
| Onde Q | Jusqu'à 0,02 sec | |
| Complexe QRS | Jusqu'à 0,10 sec | |
| Espace QT | | (du début Q jusqu'à la fin de T, correspondant à la systole électrique, env. 0,40 sec pour un rythme de 60 bat/min ou 0,35 sec pour un rythme de 80 bat/mn) |

Amplitude (valeur absolue en mV, par rapport à l'amplitude maximale)

| | |
|--------------|------------------|
| Onde P | Moins de 0,25 mV |
| Complexe QRS | plus de 0,6 mV |
| Onde T | 1/6 à 2/3 de R |

Tableau I-1 Caractéristiques d'un signal ECG normal.

I.3 Recueil du signal ECG de monitoring

Les variations du potentiel électrique induites par l'activité cardiaque et transmises à la surface corporelle sont captées à l'aide d'électrodes dites de surface placées sur la peau suivant des dérivations (Fig. I.4, I.5, I.6) qui représentent des différents angles de vue (points d'observations) d'où l'on examine un même phénomène. Les dérivations classiques sont au nombre de douze :

- Les Dérivations Bipolaires des membres d'Einthoven (D1, D2 et D3) ou (I, II, III) enregistrent les variations du potentiel entre deux électrodes :

- D1 : Poignet droit – Poignet gauche.
- D2 : Poignet droit – Jambe gauche.
- D3 : Poignet gauche – Jambe gauche.

Ces dérivations sont dites bipolaires car elles enregistrent une différence de potentiel entre deux électrodes par rapport à une référence.

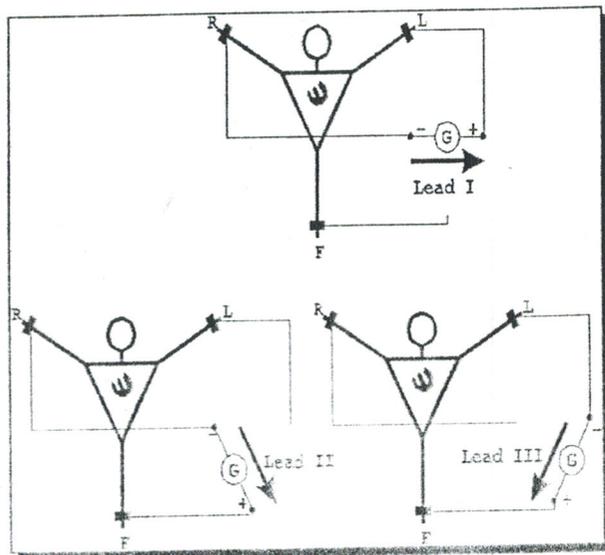
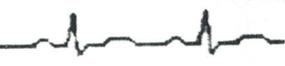


Fig. I.4. Dérivations Bipolaires



- Les Dérivations Unipolaires des membres de *Goldberger* (*aVR*, *aVL* et *aVF*), recueillent des potentiels artificiellement augmentés. Elles sont unipolaires car une seule électrode explore les variations de potentiel d'un des membres, tandis que l'autre est reliée soit à une borne de potentiel zéro, soit aux deux autres membres réunis :

aVR : Poignet droit.

aVL : Poignet gauche.

aVF : Jambe gauche.

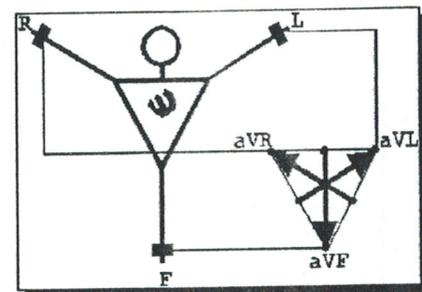


Fig. I.5. Dérivations *Unipolaires*

- Les Dérivations Thoraciques (précordiales) Unipolaires de *Wilson* (de *V1* à *V6*) sont placées de manière conventionnelle entre le bord droit du sternum au quatrième espace intercostal et la région axillaire au sixième espace, de manière à refléter de façon préférentielle l'activité du ventricule droit (*V1-V2*) et celle du ventricule gauche (*V5-V6*).

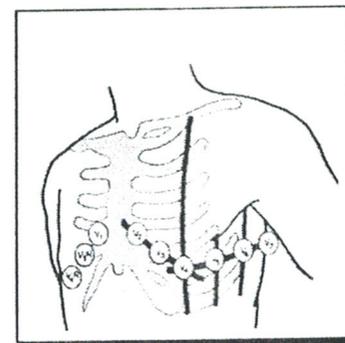


Fig. I.6. Dérivations *Thoraciques*

D'autres dérivations : *V3R*, *V4R*, *V7*, *V8*, *V9* sont très peu utilisées et permettent un diagnostic plus approfondi lors de la lecture de l'électrocardiogramme.

I.4 Les arythmies cardiaques

Les troubles du rythme cardiaque sont dus essentiellement à des défaillances de certaines zones du cœur. Le rythme cardiaque normal est appelé rythme sinusal. Sa naissance se fait au niveau du sinus Keith et Flack, appelé également nœud sinusal, sinu-atrial, ou sino-auriculaire. Il s'agit d'un regroupement de cellules nerveuses situées dans la paroi de l'oreillette droite. Grâce à ces cellules, le cœur crée une excitation qui va déclencher la contraction cardiaque. L'influx va progresser ensuite un peu plus loin, vers un autre nœud appelé Aschoff Tawara, puis vers le restant du cœur par l'intermédiaire du faisceau de His. Le tissu myocardique (du cœur) est spécialisé pour propager l'influx électrique et synchroniser les mouvements des différentes parties du cœur [7].

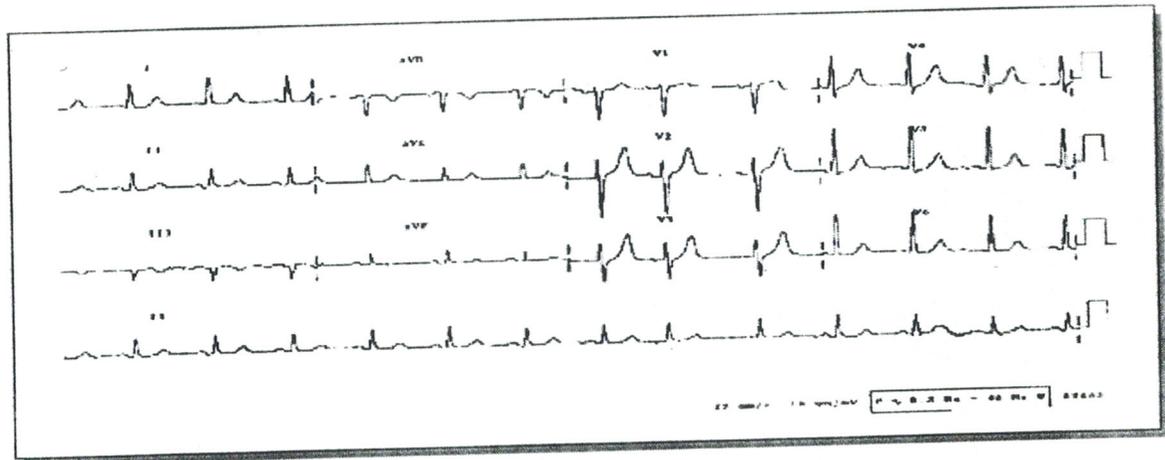


Fig. I.7. Exemple d'un cas pathologique (extrasystole auriculaire).

Chez certaines personnes, on peut observer des irrégularités dans le fonctionnement du système électrique du coeur. Ce trouble fréquemment rencontré s'appelle l'arythmie cardiaque (Fig.I.7). On pourrait définir l'arythmie comme étant un dérèglement dans le système de conduction électrique du coeur. Ces troubles ou arythmies peuvent causer des désagréments. Si le rythme est trop lent ou trop rapide, certains symptômes ou malaises apparaîtront tels que faiblesse, perte de conscience, fatigue, vertiges, palpitations, sensation de "souffle court", douleur à la poitrine. Il existe différentes variétés d'arythmie :

- Les bradycardies et les tachycardies.
- Les extrasystoles ventriculaires et auriculaires.
- Les flutters auriculaires.
- La fibrillation ventriculaire.
- Les blocs auriculo-ventriculaires, etc.

Causes :

- Stress
- Abus de tabac, d'alcool, de café ou tout autre excitant
- Artériosclérose (durcissement des parois des artères et du cœur) et athérosclérose (dépôts de corps gras à base de cholestérol sur les artères) susceptible d'entraîner une diminution du passage sanguin (ischémie).
- Broncho-pneumopathies (affections de l'appareil respiratoire)



- Embolie pulmonaire (obstruction d'une artère des poumons par un caillot sanguin ou graisseux)
- Déshydratation (par insuffisance d'apport d'eau, ou par perte excessive : sudation, urines importantes etc.)
- Insuffisance coronarienne (mauvais fonctionnement du sang à l'intérieur des artères irriguant le muscle cardiaque : le myocarde), à l'origine d'un défaut d'oxygénation du tissu cardiaque.
- Mauvais fonctionnement du tissu nodal (tissu contenant le nœud sinusal)

Traditionnellement, la méthodologie suivie par les médecins et cardiologues pour l'interprétation de l'ECG est basée sur l'observation, l'expérience et la mesure des données [8]. La méthodologie en question consiste à :

- Localiser les ondes **P**, les complexes **QRS**, les complexes **T** et les ondes **U**.
- Interpréter la morphologie (forme) des différentes ondes et complexes localisés.
- Calculer les amplitudes et caractéristiques temporelles entre les différentes ondes et complexes tel que l'intervalle RR, l'intervalle PP, l'intervalle PR, le segment QT et le segment ST.

Dans la terminologie médicale, un signal est dit normal si tous les paramètres cités ci-dessus sont normaux.

Dans le cas des troubles du rythme cardiaque et selon l'étage de leur origine : sinusal, auriculaire ou ventriculaire, on définit les classes suivantes :

- Les troubles du rythme sinusal.
- Les troubles du rythme auriculaire.
- Les troubles du rythme ventriculaire.

1.4.1 Les troubles du rythme sinusal

Ils sont définis par une onde P et un complexe QRS tous deux de morphologie normale, mais les intervalles PP et/ou RR présentent des valeurs différentes des valeurs du signal normal. Les troubles du rythme sinusal sont la tachycardie sinusale et la bradycardie sinusale. Exemple :



Les bradycardies : diminution brutale et passagère du rythme cardiaque.

Les tachycardies : accélération du rythme cardiaque.

1.4.2 Les troubles du rythme auriculaire

Ils sont définis par une onde P de morphologie anormale et un complexe QRS de morphologie normale. En plus de la morphologie anormale de l'onde P, les caractéristiques temporelles des différents intervalles : PP, PR et RR permettent de distinguer entre les extrasystoles auriculaires, la tachycardie auriculaire, le flutter auriculaire et la fibrillation auriculaire. Exemple :

Les extrasystoles auriculaires : Une extrasystole auriculaire (ou atriale) est une contraction prématurée des oreillettes en raison d'un foyer ectopique. Sur l'ECG, la régularité du rythme sinusal est interrompue par une onde P prématurée, le plus souvent suivie d'une dépolarisation ventriculaire. En fonction du site d'origine de l'extrasystole au sein des deux oreillettes, la dépolarisation de celles-ci se fait selon une direction parfois très différente de la normale : la morphologie de l'onde P sur l'ECG est donc modifiée, par exemple négative en D2, D3 et aVF lorsqu'elle prend naissance dans la partie basse de l'oreillette droite (dépolarisation ascendante des oreillettes, donc inverse du sens normale de la dépolarisation).

Les extrasystoles peuvent se répéter plusieurs fois de suite : lorsqu'elles sont nombreuses et successives, on parle de salve d'extrasystoles.

1.4.3 Les troubles du rythme ventriculaire

Ils sont définis par un complexe QRS de morphologie anormale et une onde P de morphologie normale. De plus, la connaissance des caractéristiques temporelles des différents intervalles PP, PR et RR permet de différencier entre les différentes anomalies affectant le rythme ventriculaire à savoir : l'extrasystole ventriculaire, la tachycardie ventriculaire et la fibrillation ventriculaire.

Remarque : Certaines anomalies affectent l'onde P et le complexe QRS en même temps, telle que la tachycardie supra-ventriculaire. Exemple :

Les extrasystoles ventriculaires : Les extrasystoles sont des contractions cardiaques anormales car prématurées. Les extrasystoles ventriculaires naissent en

dessous de la bifurcation hisienne. Elles apparaissent donc sur un tracé électrocardiographique comme un complexe QRS prématuré, non précédé d'une onde P et toujours large.

Les critères électrocardiographiques composent une triade :

- Absence d'onde P.
- Complexes QRS prématurés.
- Complexes QRS larges et déformés.

On notera aussi l'existence d'une pause compensatrice, et d'une onde T géante et souvent inverse au QRS.

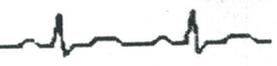
En résumé, il est clair que la morphologie de l'onde P, la morphologie du complexe QRS et les paramètres temporels RR, PR et PP de cycles cardiaques successifs sont des paramètres importants pour la classification des arythmies cardiaques.

En fait la détection des différentes ondes P, QRS, S et T ; ainsi que la mesure des paramètres temporels ne peuvent être accomplis qu'après un traitement adéquat du signal ECG. Le développement des différentes techniques de traitement et leurs validations sont dans la plupart des cas réalisés à travers l'exploitation de signaux ECG.

I.5 Bases de données

Plusieurs bases de données des enregistrements ECG sont généralement disponibles sur le marché. Ces bases de données sont exploitées pour permettre le développement et la validation de différents algorithmes de traitement et d'analyse de signal ECG. Elles représentent :

- Des signaux standard qui sont utilisés pour la comparaison des systèmes traitants l'ECG. Ces systèmes restent sans signification à moins que la performance de chaque système soit mesurée en utilisant la même base de données.



- Elles contiennent des signaux annotés. Typiquement chaque complexe QRS a été annoté manuellement par deux cardiologues ou plus qui travaillent indépendamment.
- Ceux sont des signaux représentatifs de larges variations cardiaques. Ces larges variations dans les caractéristiques temporelles et morphologiques du cœur permettent aux analyseurs de faire leurs tests.
- Elles contiennent des cas "rarement" observés mais qui sont d'une signification clinique, des signaux importants et représentatifs. Bien qu'il n'est pas difficile d'obtenir des enregistrements ECG qui présentent des caractères anormaux communs, mais souvent des enregistrements pareils sont rarement enregistrés. Les analyseurs et développeurs des systèmes de traitement du signal cardiaque ont toujours besoin de tels enregistrements.

I.6 Base de données MIT BIH

La source de nos signaux ECG est la base de données « MIT BIH Arrhythmia Database » [9], elle se compose de 48 enregistrements annotés, obtenus à partir de 47 sujets étudiés par le laboratoire des arythmies cardiaques à l'hôpital de Beth d'Israël à Boston entre 1975 et 1979. 60% des enregistrements ont été obtenus à partir des hospitalisés. Cette base contient 23 enregistrements (les séries 100) choisis au hasard d'un ensemble de plus de 4000 enregistrements de 24 heures de holter, et 25 enregistrements (les séries 200) choisis de même ensemble pour inclure une variété de phénomènes rares mais médicalement importants. Plusieurs enregistrements dans les séries 200 ont été choisis spécifiquement à cause des dispositifs de rythme, de la morphologie de QRS, ou de la qualité de signal qui peuvent être prévus pour présenter la difficulté significative aux détecteurs d'arythmies.

Les sujets (patients) sont 25 hommes âgés de 32 ans à 89 ans et 22 femmes âgées de 23 ans à 89 ans. La dérivation utilisée pour la plupart des signaux est MLII (Modified Limb lead II) obtenu par emplacement des électrodes sur la poitrine (dérivation bipolaire D2). Chaque enregistrement a légèrement plus de 30 minutes de longueur, il contient deux signaux prélevés à 360 Hz. Le premier signal est

obtenu par la dérivation MLII, le deuxième par V1, V2 ou V5. Les fichiers d'en-tête incluent les dérivations utilisées, l'âge de patient, le sexe et les médicaments pris par le patient. Les fichiers d'annotations incluent le battement, le rythme et les annotations de qualité de signal. Chacun des battements d'approximativement 109 000 battements a été manuellement annoté par au moins deux cardiologues travaillant indépendamment. Leurs annotations ont été comparées, le consensus sur des désaccords a été obtenu et réparé. IL est à noter que les différents cas pathologiques traités dans la base de données MIT BIH sont :

| | |
|---|--|
| N Battement normal. | V Bat. Ventriculaire prématuré. |
| L Bloc de branche gauche. | F Fusion entre V et N. |
| R bloc de branche droit. | e Bat. Atriale échappé. |
| A Battement atriale prématuré. | j Bat. Nodal (jonctionnel) échappé. |
| a Bat. Atriale prématuré (aberré). | E Bat. Ventriculaire échappé. |
| J bat. Nodale prématuré (jonctionnel). | P Bat. Ectopique. |
| S Bat. Supraventriculaire prématuré. | f Fusion entre P et N. |
| | Q Bat. Non classé. |

La base de données MIT BIH a été employée dans le monde à approximativement 200 emplacements. Depuis 1980 date de sa mise en vente, seize erreurs dans les annotations de battements ont été découvert et corrigé. Aucune erreur n'a été trouvé depuis 1987 [10].

1.7 Classification des arythmies cardiaques

Effectuer une classification, c'est mettre en évidence des relations entre des objets et entre ces objets et leurs paramètres. A partir de proximités ou de dissemblances, il s'agit de construire une partition de l'ensemble des objets en un ensemble de classes les plus homogènes possibles. Les travaux de recherches pour la classification du signal cardiaque remontent à 1957 où les premières approches étaient principalement basées sur l'utilisation de la méthode des arbres de décision et la méthode statistique [11]. Par la suite, de nouvelles approches ont été développées telles que l'approche syntaxique, les systèmes experts, la logique floue et les réseaux de neurones.

Nous avons résumé les principales approches dans la figure suivante (Fig. 1.8) :

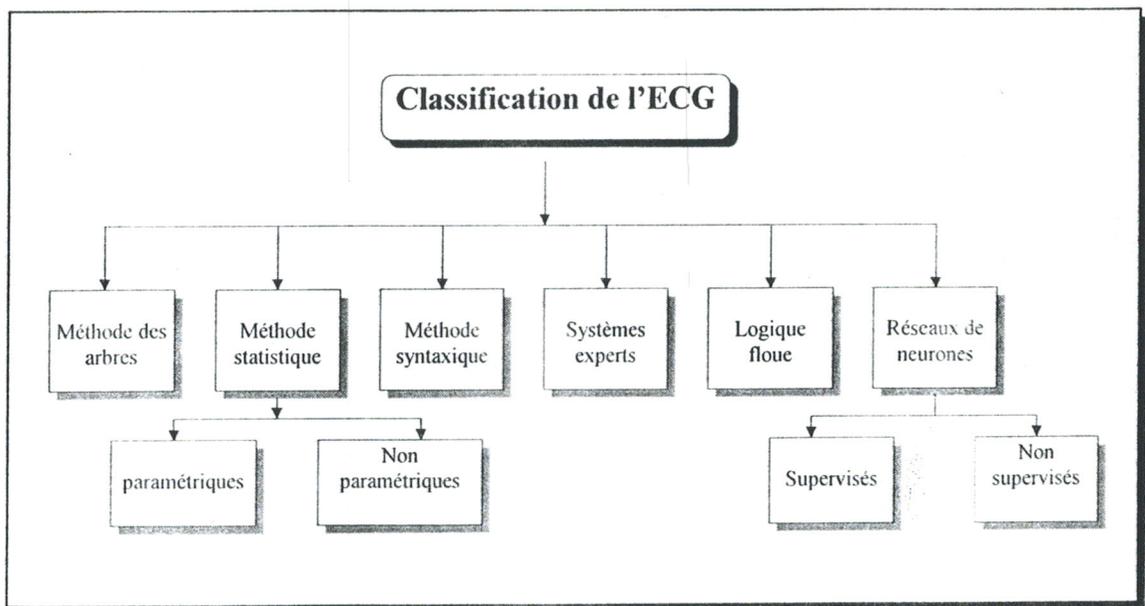


Fig. 1.8. Différentes approches utilisées pour la classification de l'ECG.

I.8 Méthodes de classification

I.8.1 Méthode des arbres

La méthode des arbres est basée sur l'utilisation d'un arbre de décision, les entrées de ces programmes sont les caractéristiques temporelles et les amplitudes des différentes ondes et complexes permettant la distinction d'un signal normal par rapport à un autre pathologique. L'avantage de ces programmes est que les critères de diagnostic utilisés sont familiers aux cardiologues et la logique est facile à suivre et à comprendre. De plus, ils sont flexibles à toute modification. Cependant, l'un des inconvénients majeurs de l'imitation humaine est que les critères de diagnostic diffèrent d'un médecin à un autre. Les études sur cette méthode [11] ont montré que le taux de classification correct ne dépasse pas 60 % vu que les caractéristiques temporelles ne suffisent pas à elles-mêmes pour classer les signaux cardiaques.

I.8.2 Approche statistique

Dans cette approche le signal ECG subit un traitement mathématique préalable pour extraire les paramètres les plus représentatifs de ce dernier. La règle de Bayes est utilisée par la suite dans le processus de classification. La décision Bayésienne

permet de reconnaître si un patient ayant un symptôme S est atteint d'une maladie Di parmi K maladies Dk. La règle de Bayes s'exprime comme suit :

$$Prob(D_i/S) = \frac{Prob(S/D_i)Prob(D_i)}{\sum Prob(S/D_j)Prob(D_j)}$$

Où les maladies Dk sont supposées indépendantes les unes des autres (classes séparables).

En utilisant cette approche, les performances ont été améliorées de 20 % jusqu'à 40 % par rapport à la méthode des arbres. Cependant, l'un des inconvénients majeurs de la méthode statistique est la nécessité d'une très large base de données pour tester les procédures de classification; de plus les paramètres statistiques qui sont préalablement estimés lors de l'apprentissage, diffèrent considérablement d'une population à une autre et sont fonction de la race, du sexe, de la taille et de l'âge du patient. La présence de plusieurs anomalies complique les méthodes de classification statistiques, il s'agit d'un problème de séparation des classes [12].

1.8.3 Approche syntaxique

L'approche syntaxique utilise des paramètres descriptifs liés à la nature des formes du signal cardiaque. Elle suppose que l'ECG est composé par l'agencement structuré de formes élémentaires ou primitives qui sont les pics et les segments. C'est ainsi que les pics sont combinés pour former les complexes et les pics et les segments sont combinés pour former le cycle cardiaque. L'approche syntaxique a été appliquée pour la reconnaissance de la forme de l'ECG, l'extraction et la mesure des paramètres et enfin pour la classification ; mais les primitives constituant le signal ECG varient légèrement pour un même patient et d'un patient à l'autre et dépendent de conditions de patient. Dans de tels cas, la méthode syntaxique ne donne pas de bons résultats [13].

1.8.4 Intelligence artificielle et systèmes experts

L'intelligence artificielle (IA) est « l'étude des idées et des techniques permettant de rendre les ordinateurs intelligents ». L'objectif est double :

- Pragmatique, rendre les ordinateurs plus utiles.
- Théorique, mieux comprendre les mécanismes de l'intelligence.

L' IA est au confluent de différentes disciplines :

L'informatique, la linguistique, la psychologie cognitive...l'une de ses retombées principales a été le développement des systèmes experts définis comme des programmes informatiques utilisant les connaissances spécialisées et des mécanismes d'inférences pour obtenir, dans un domaine particulier, des niveaux élevés de performances.

Les systèmes experts trouvent leur indication principale dans la résolution de problèmes bien individualisés, correspondant à des domaines médicaux spécialisés, pour lesquels l'absence de solutions algorithmiques et la disponibilité d'experts reconnus rendent possible la constitution et la mise à jour de base de connaissance. Ils restent limités par la complexité de constitution puis de maintenance des bases de connaissances. Ces connaissances, habituellement multiples et souvent inconstantes voire contradictoires peuvent mal se prêter au découpage en règles ou en objets structurés imposés par les systèmes experts. En l'absence de l'organe sensoriel, le système expert part d'une information déjà réinterprétée par l'utilisateur. Il lui est difficile d'intégrer une connaissance sur sa connaissance et de s'apercevoir qu'il sort de son domaine d'expertise [14].

• **Indications :**

- L'expertise risque d'être perdu.
- L'expertise est rare.
- L'expertise est utile dans de nombreuses situations.
- L'expertise est utile dans un environnement hostile.
- Les conséquences de décision sont importantes.

• **Faisabilité :**

- Tâches cognitives.
- Connaissances spécialisées.
- Pas de solution algorithmique.
- Il existe des experts reconnus.
- Les experts sont meilleurs que les amateurs.

- **Limites :**

- La connaissance est multiple
- La connaissance est infinie
- La connaissance est souvent contradictoire ou inconstante
- L'ordinateur est aveugle, il nécessite un intermédiaire
- La validation des connaissances est difficile

1.8.5 Réseaux de neurones et systèmes connexionnistes

Aucune méthode citée précédemment n'a pu résoudre le problème de la classification de l'ECG. Nous pouvons résumer les problèmes comme suit :

La morphologie et les caractéristiques temporelles du signal ECG varient au cours du temps pour le même patient et d'un patient à un autre.

L'efficacité de ces techniques dépend du choix des paramètres sélectionnés pour la classification et des seuils utilisés [15].

La nécessité de connaissance de règles (logiques floue et systèmes experts).

Les modèles utilisés pour le traitement de l'ECG étaient des modèles linéaires.

Alors que les premiers systèmes connexionnistes étaient conçus dès les années 40 et 50, leur essor et l'apparition d'applications pratiques sont beaucoup plus récents (fin des années 80) liés à l'augmentation de puissance des microprocesseurs permettant de simuler leur comportement puis des réseaux de microprocesseurs permettant de réaliser les premières machines matérielles (machines connexionnistes) [16].

L'architecture des réseaux de neurones est directement inspirée des structures et du fonctionnement du cerveau, d'où le nom de réseaux neuronaux habituellement utilisé (Fig I.9).

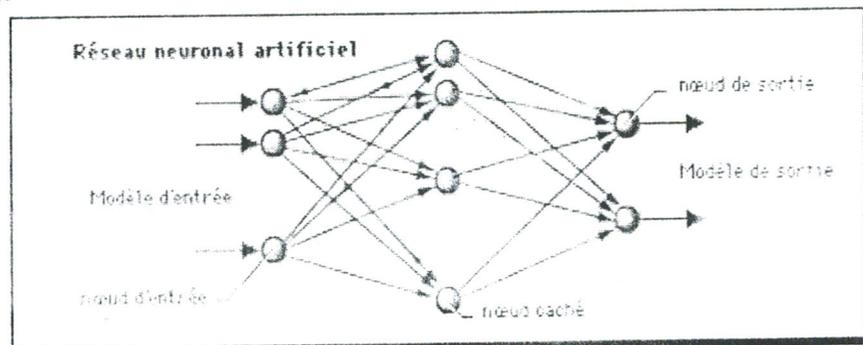


Fig. I.9. Architecture générale d'un réseau de neurones artificiels.



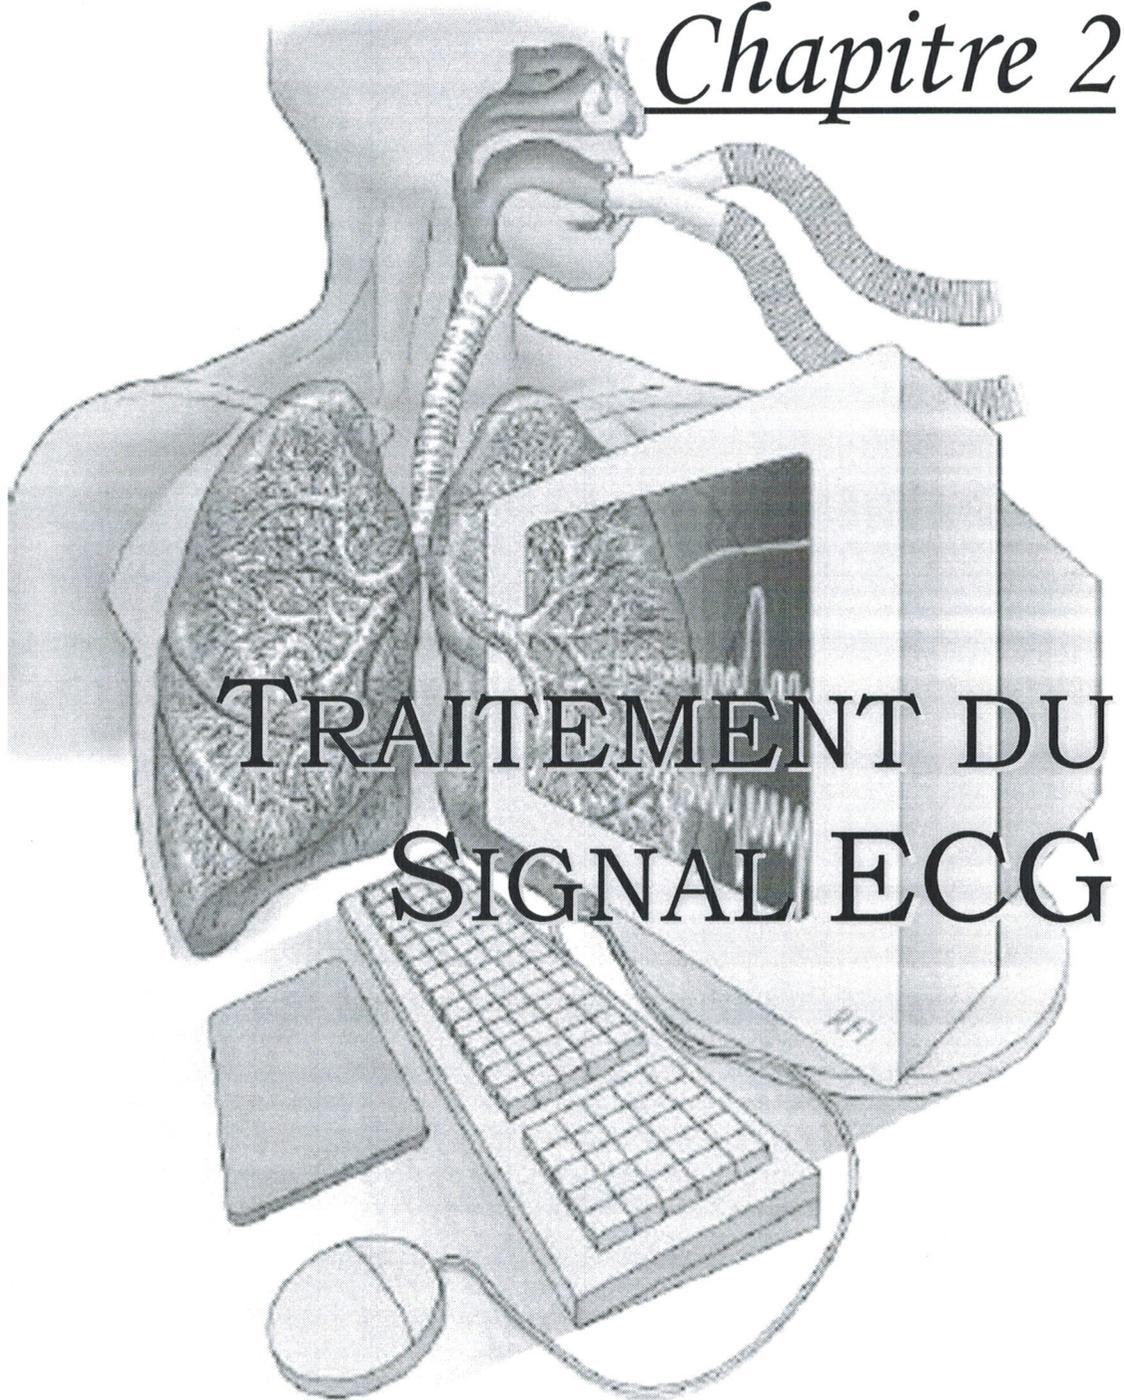
Durant ces dernières années, les réseaux de neurones ont été intensivement utilisés pour la classification des arythmies cardiaques, vu les avantages qu'ils présentent à savoir [17,18] :

- Habilité d'apprentissage et d'auto organisation à partir des exemples.
- Possibilité de lire des formes en réponse à de nouvelles formes.
- Non nécessité de la connaissance de règles.
- Possibilité d'utiliser des modèles non linéaires.

I.9 . Conclusion

On a montré dans ce chapitre que d'abord la classification des arythmies cardiaques ne peut avoir lieu qu'après une analyse et un traitement adéquat du signal ECG, en particulier la détection et l'identification des différentes ondes du signal ECG. Différentes approches de classification ont été ensuite décrites. Un intérêt particulier est porté aux réseaux de neurones compte tenu de leur efficacité dans le domaine de la classification.

Chapitre 2



TRAITEMENT DU
SIGNAL ECG



II. TRAITEMENT DU SIGNAL ECG

II.1 Introduction

Ce chapitre décrit une technique très efficace d'extraction pour la détection et l'identification des paramètres du signal cardiaque. Les signaux ECG à longue durée fournissent les informations qui peuvent être employées pour détecter les arythmies passagères, qui peuvent ne pas être présentées durant les essais cliniques réguliers. Un grand nombre de paramètres tels que les variations de fréquence cardiaque, la largeur de complexe QRS et la morphologies des ondes P et T de ce signal, sont nécessaires, et sont utilisés pour évaluer si le patient présente ou non des anomalies.

Pendant les dernières années, les systèmes de surveillance assistés par ordinateur ont été exploités dans divers domaines cliniques. La plupart de ces systèmes utilisent des systèmes conventionnels d'extraction, pour analyser le complexe QRS et pour classifier les cas anormaux. Nous présentons dans ce chapitre un algorithme efficace pour détecter et identifier les différentes ondes constituant un signal ECG.

II.2 Lecture et chargement des signaux ECG

Parce qu'il est un système interactif et convivial de calcul numérique et de visualisation graphique, Matlab 5.3 [19] était l'environnement sous lequel nous avons développé notre software de détection des ondes ECG. Cet environnement possède un langage de programmation à la fois puissant et simple d'utilisation, il permet d'exprimer les problèmes et solutions d'une façon aisée, contrairement aux autres langages.

Le chargement du signal cardiaque sous Matlab constitue une étape importante dans notre algorithme, il s'agit de convertir le signal ECG enregistré (codé) sous sa forme initiale (Le format 212 de MIT BIH Database) en un autre format compréhensif par Matlab. En effet, cela n'a été réalisé qu'après plusieurs tentatives compte tenu de la non disponibilité de documentation relative à la lecture du format avec lequel les signaux de MIT ont été enregistrés (voir annexe A).

La figure II.1 présente deux exemples des enregistrements ECG de la base de données MIT BIH.

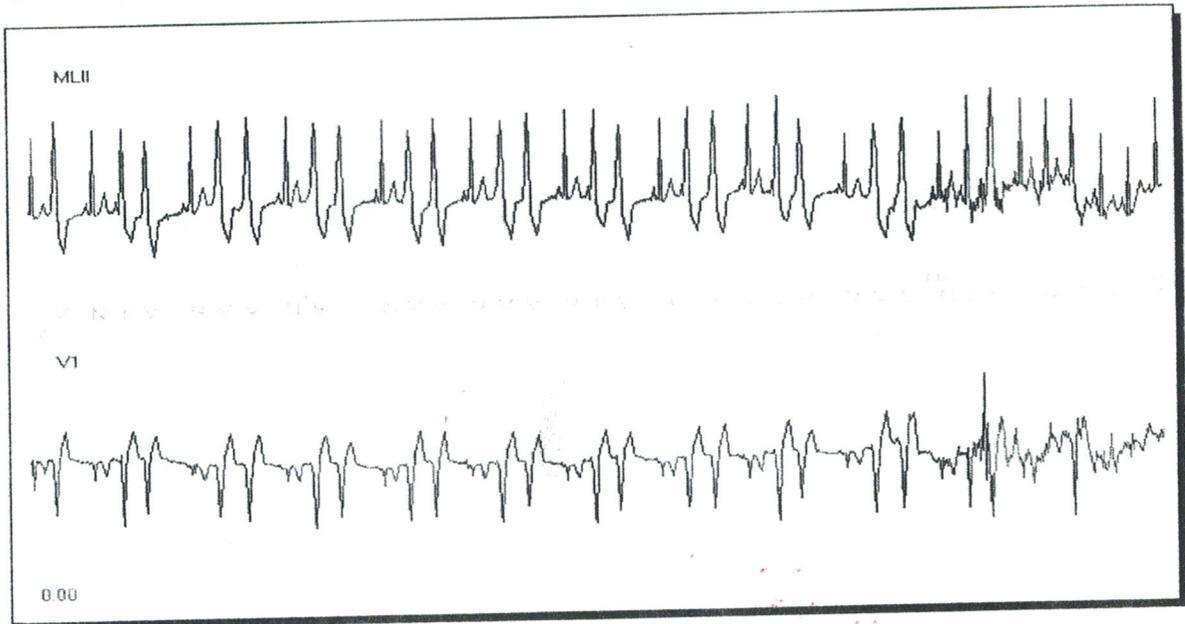


Fig. II.1: Exemple d'un enregistrement ECG de MIT BIH Database (Record : 208).

II.3 Prétraitement du signal cardiaque

J.Tompkins et J.Pan ont proposé une méthode permettant la détection en temps réel du complexe QRS [20]. Cette méthode permet une analyse numérique des pentes, amplitudes et intervalles des différentes ondes constituant le signal cardiaque. Elle est basée sur l'exploitation de la dérivée du signal ECG afin de détecter ses paramètres. Dans notre travail, nous utilisons une approche similaire mais plus généralisée.

Le signal ECG obtenu lors de l'enregistrement est généralement contaminé par différentes sources de bruits qui peuvent perturber les caractéristiques de phase et d'amplitude du signal utile d'où la nécessité d'un bon filtrage.

Le problème de filtrage a été intensivement étudié [21-24], nous nous intéressons aux travaux de Lo et al qui ont proposé un filtre passe bande capable d'éliminer les bruits causés par l'alimentation (50Hz), la respiration, les mouvements de muscles et la ligne de base [25]. Ce filtre est constitué par la combinaison d'un filtre passe bas et un autre passe haut. Les deux filtres numériques utilisent une fréquence d'échantillonnage de 360 Hz compte tenu que la



fréquence maximale du spectre du signal ECG ne dépasse pas les 150 Hz. La fonction de transfert de filtre passe bas (Fig. II. 2) est donnée par l'équation II. 1 :

$$H_L(z) = \frac{1 - 2z^{-6} + z^{-12}}{1 - 2z^{-1} + z^{-2}} \quad \text{Eq. II-1}$$

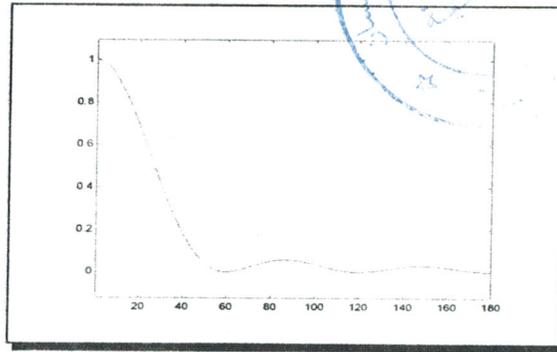


Fig. II.2. Fonction de transfert du filtre passe bas.

Le point -3dB est à 20 Hz, ce qui nous a permis d'éliminer les ondulations dues au réseau du 50Hz, et de minimiser les bruits de fréquence haute provoqués par le mouvement des muscles.

Le signal résultant est traité ensuite par un filtre passe haut de fonction de transfert, donnée par l'équation II.2 et est représentée sur la figure II.3.

$$H_H(z) = z^{-127} \frac{1}{2^{14}} \frac{1 - 2z^{-128} + z^{-256}}{1 - 2z^{-1} + z^{-2}} \quad \text{Eq. II-2}$$

Où $\frac{1}{2^{14}}$ est un facteur de normalisation. La fréquence de coupure de ce filtre est 1Hz, le gain est unitaire.

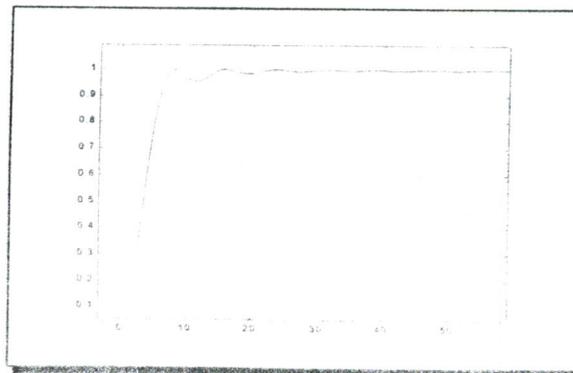
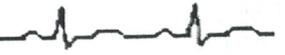
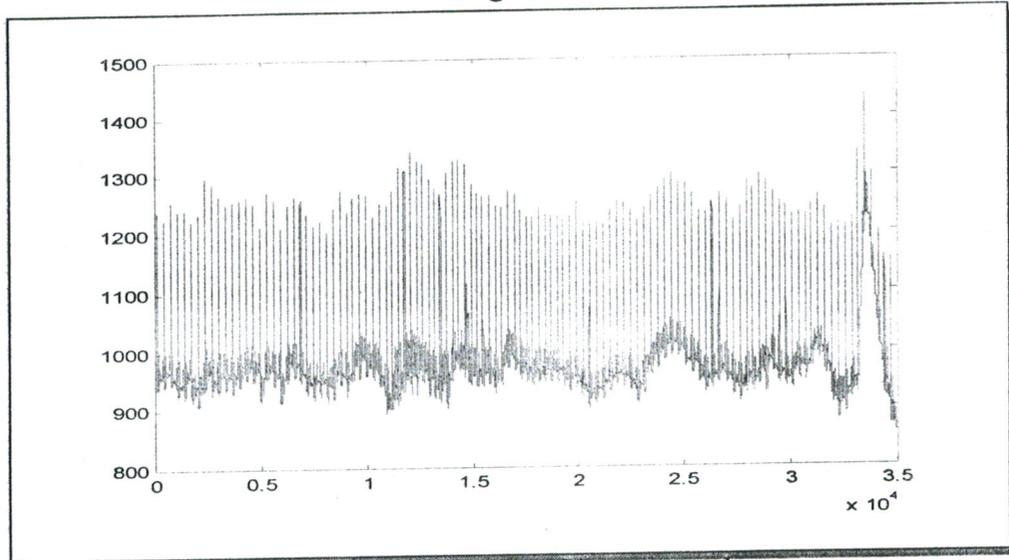


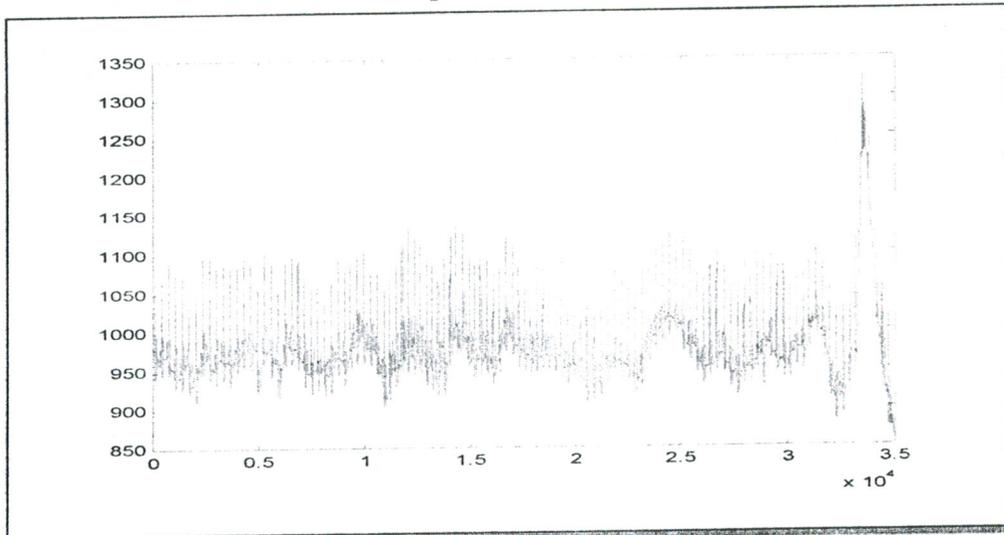
Fig. II.3. Fonction de transfert du filtre passe haut.



Signal ECG



L'ECG après un filtre passe bas



L'ECG après un filtre passe haut

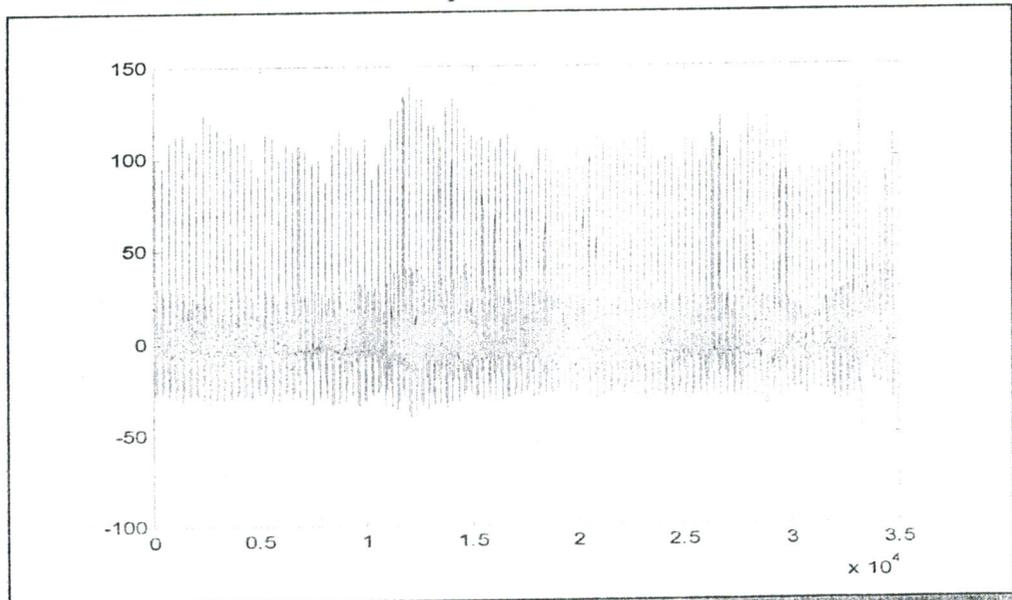


Fig. II.4. Filtrage de signal ECG.



Comme le montre la figure II.4 ce filtre a complètement éliminé les bruits relatifs à la variation de la ligne de base, la respiration, ainsi que tout autres artefacts liés à des mouvements du patient ou par d'autres signaux enregistrés simultanément.

Après filtrage, le signal est différentié pour faire apparaître les différents pics. La figure II.5 montre la dérivée du signal ECG.

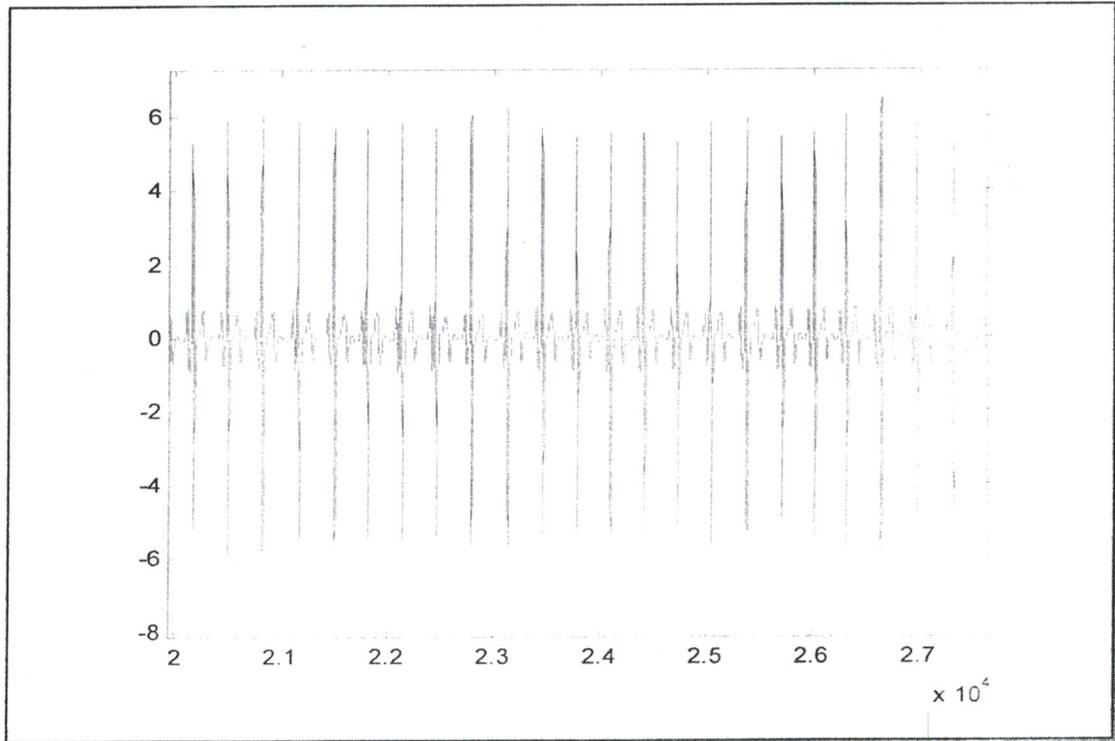


Fig. II.5. Signal ECG filtré et différentié.

II.4 . Identification et détection des paramètres du signal ECG

Après calcul de la dérivée du signal ECG, les différentes ondes et leurs pics respectifs sont identifiés et détectés selon l'approche proposée par P. Laguna [26,27]. Elle se résume dans les points suivants :

- Détecter le pic R.(pour mesurer de la fréquence cardiaque).
- Détecter les ondes Q et S (pour mesurer de la durée du complexe QRS).
- Détecter l'onde T (pour le calcul des l'intervalles QT et ST).
- Détecter l'onde P et sa morphologie (pour la mesure des intervalles PP et PR).



II.4.1 Détection du pic R

L'algorithme qui permet de détecter le pic R comporte quatre étapes :

II.4.1.1 Détection d'un seuil de référence

On définit P_k comme étant la valeur absolue de pic positif ou négatif le plus élevé par rapport à la ligne de base du signal ECG dérivé. Puis on fixe un seuil H_1 (fixé par P.Laguna à $0.8P_k$), mais après plusieurs tentatives en utilisant les signaux de MIT BIH, nous l'avons fixé à $0.3P_k$ pour une bonne détection. Lorsque H_1 est dépassé, la détection du pic R est déclenchée.

II.4.1.2 Localisation du pic P_{kn} , P_{ka} et P_{kb}

On définit pour chaque cycle cardiaque le pic maximal correspondant qu'on note par P_{kn} . La localisation de ce pic est déclenchée lorsque la valeur du seuil est dépassée. Ensuite, on cherche le pic P_{ka} et P_{kb} situés respectivement après et avant le pic P_{kn} .

II.4.1.3 Localisation de la position du pic R (R_p)

On définit ainsi la position de pic R (R_p) par le point d'intersection entre la ligne de base du signal ECG dérivé dans l'intervalle situé entre le pic P_{kn} et la position qui correspond à la valeur absolue la plus élevée entre P_{ka} et P_{kb} .

Remarque : Si la valeur du pic P_{ka} est supérieure à celle du pic P_{kb} , le complexe QRS est normal, si non il est inversé.

La figure II.6 montre les différents seuils détectés, et présente un complexe QRS normal ($P_{ka} > P_{kb}$).

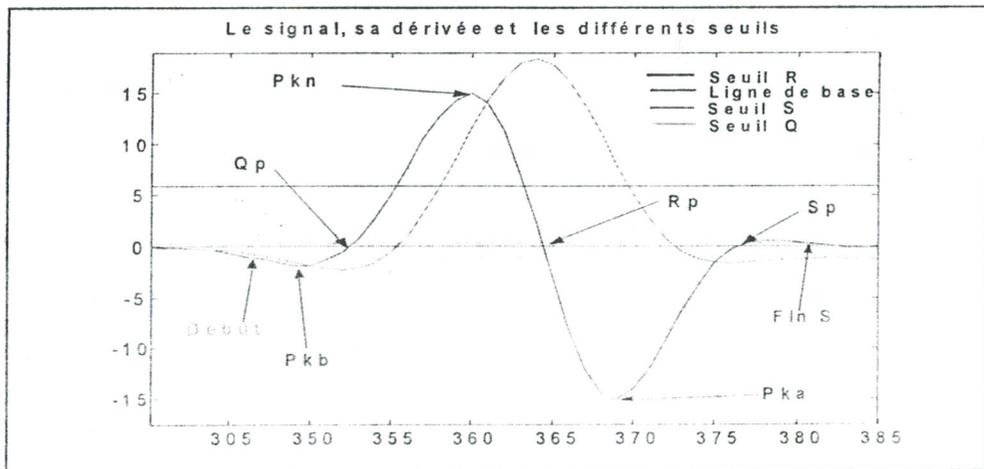


Fig. II.6. Différents seuils détectés dans un cycle.



II.4.1.4 Mesure de la fréquence cardiaque

II.4.1.4.1 Fréquence cardiaque

La fréquence cardiaque (Heart Rate) est le nombre d'impulsions sinusales par minute, les limites considérées comme normales sont entre 60 et 100 impulsions par minute [28]. Elle se calcule facilement en mesurant soit l'activité auriculaire (PP) soit l'activité ventriculaire (RR).

Dans notre algorithme, la fréquence cardiaque est mesurée à partir de l'intervalle de temps séparant deux ondes R-R. Elle est donnée par la relation suivante :

$$RR(n) = Rp(n) - Rp(n-1) \quad \text{Eq. II-3}$$

Où $Rp(n)$ représente la position du pic R du $n^{\text{ème}}$ cycle cardiaque.

Cela conduit à la mesure du nombre de battements de cœur par minute, ceci est donné par la relation II. 4 :

$$Bat(k) = \frac{60}{RR(k)} \quad \text{Eq. II-4}$$

La figure II.7 montre le résultat de la mesure de la fréquence cardiaque du sujet "100" de MIT BIH Database. Il représente un rythme sinusal variant entre 70 et 80 battements par minute.

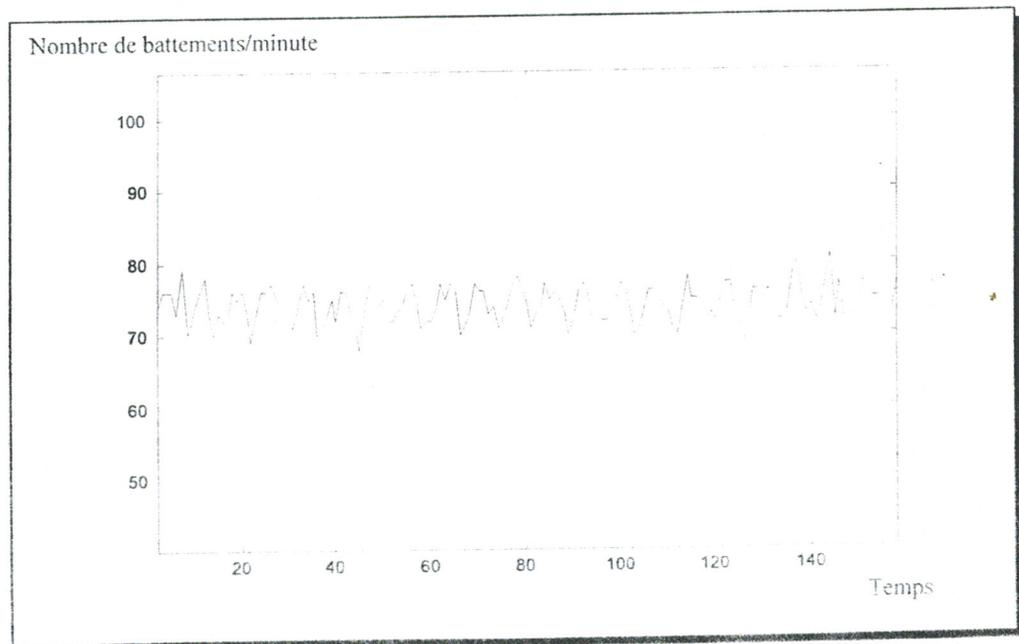


Fig. II.7. Variation de la fréquence cardiaque (sujet '100').

II.4.1.4.2 Fréquence cardiaque moyenne

L'ajustement de l'intervalle moyen RR_{av} est nécessaire pour éviter un changement brusque de l'intervalle RR due essentiellement à un repos cardiaque provisoire. Dans notre cas, le calcul de la fréquence cardiaque moyenne est déterminé sur huit cycles cardiaques précédents, il est donné par l'équation II.5 :

$$RR_{av} = 0.125(RR_{n-7} + RR_{n-6} + \dots + RR_n) \quad \text{Eq. II-5}$$

II.4.2 Détection des ondes Q et S

La position de l'onde Q notée Q_p est le point d'intersection situé juste avant le pic R_p du signal dérivé avec celui de la ligne de base (Fig. II.6). On mesure ensuite la durée de l'intervalle $[R_p Q_p]$, lorsque celui-ci dépasse une certaine limite (fixée à 80ms dans [26]), on considère que l'onde Q est absente. Le début de complexe QRS correspond au début de l'onde Q (ou l'onde R si l'onde Q est absente). On cherche le pic Q_i (ou R_i) situé avant le point Q_p (ou R_p), et on définit ensuite un seuil noté H_q (ou H_r) dont la valeur est donnée par l'équation II.6 :

$$H_q = \frac{\text{signal dérivé}(Q_i)}{K_q} \quad \text{Eq. II-6}$$

Dans le cas où l'onde Q est absente, on définit un autre seuil H_r donné par :

$$H_r = \frac{\text{signal dérivé}(R_i)}{K_r} \quad \text{Eq. II-7}$$

P. Laguna a montré en [27] qu'une meilleure performance de détection est obtenue pour : $K_q = 2$ et $K_r = 5$.

Le début de complexe QRS noté DQRS est le point d'intersection du signal dérivé et le seuil H_q (ou H_r).

L'opération de détection de l'onde S est semblable à celle de l'onde Q. Elle est définie comme étant le point d'intersection de la dérivée du signal ECG et la ligne de base.

On définit deux seuils notés TH_q (ou TH_r dans la cas de l'absence de l'onde S) et qui sont donnés par les équations II.8 et II.9 :



$$THq = \frac{\text{dérivée ECG}}{Kq} \quad \text{Eq. II-8,}$$

$$THr = \frac{\text{dérivée ECG}}{Kr} \quad \text{Eq. II-9}$$

Alors on détermine la fin du complexe QRS notée par FQRS par le point d'intersection de la dérivée et le seuil THq (ou THr).

Une fois le début DQRS et la fin FQRS du complexe QRS sont déterminés, on calcule la durée L(qrs) du complexe QRS par l'équation II.10 :

$$L(qrs) = FQRS - DQRS \quad \text{Eq. II-10}$$

II.4.3 Détection de l'onde T

A partir de la position du pic Rp, on définit une fenêtre de traitement dont les limites sont (Bwind, Ewind). Cette fenêtre dépend de la fréquence cardiaque, elle est définie par :

$$(Bwind, Ewind) = \begin{cases} (140, 500)ms & RR_{av} > 700ms \\ (100, 0.7RR_{av}) & RR_{av} < 700ms \end{cases} \quad \text{Eq. II-11}$$

On définit l'amplitude maximale (max) et minimale (min) de la dérivée de signal ECG, ainsi que leurs positions à l'intérieur de la fenêtre (Bwind, Ewind). Différents tests sont effectués entre ses positions afin de déterminer la morphologie de l'onde T. La fin de l'onde T notée T₂ correspond au point d'intersection entre le signal et le seuil Ht dont la valeur est donnée par la relation :

$$Ht = \frac{\text{Dérivé ECG}(Ti)}{2} \quad \text{Eq. II-12}$$

Où Ti est un pic qui peut prendre plusieurs positions (max, min...) suivant la morphologie de l'onde T.

Une fois la fin de l'onde T est définie, on peut alors mesurer les intervalles QT et ST. Ils sont donnés par :

$$QT(k) = T_2 - DQRS(k) \quad \text{Eq. II-13}$$

$$ST(k) = T_2 - FQRS(k) \quad \text{Eq. II-14}$$

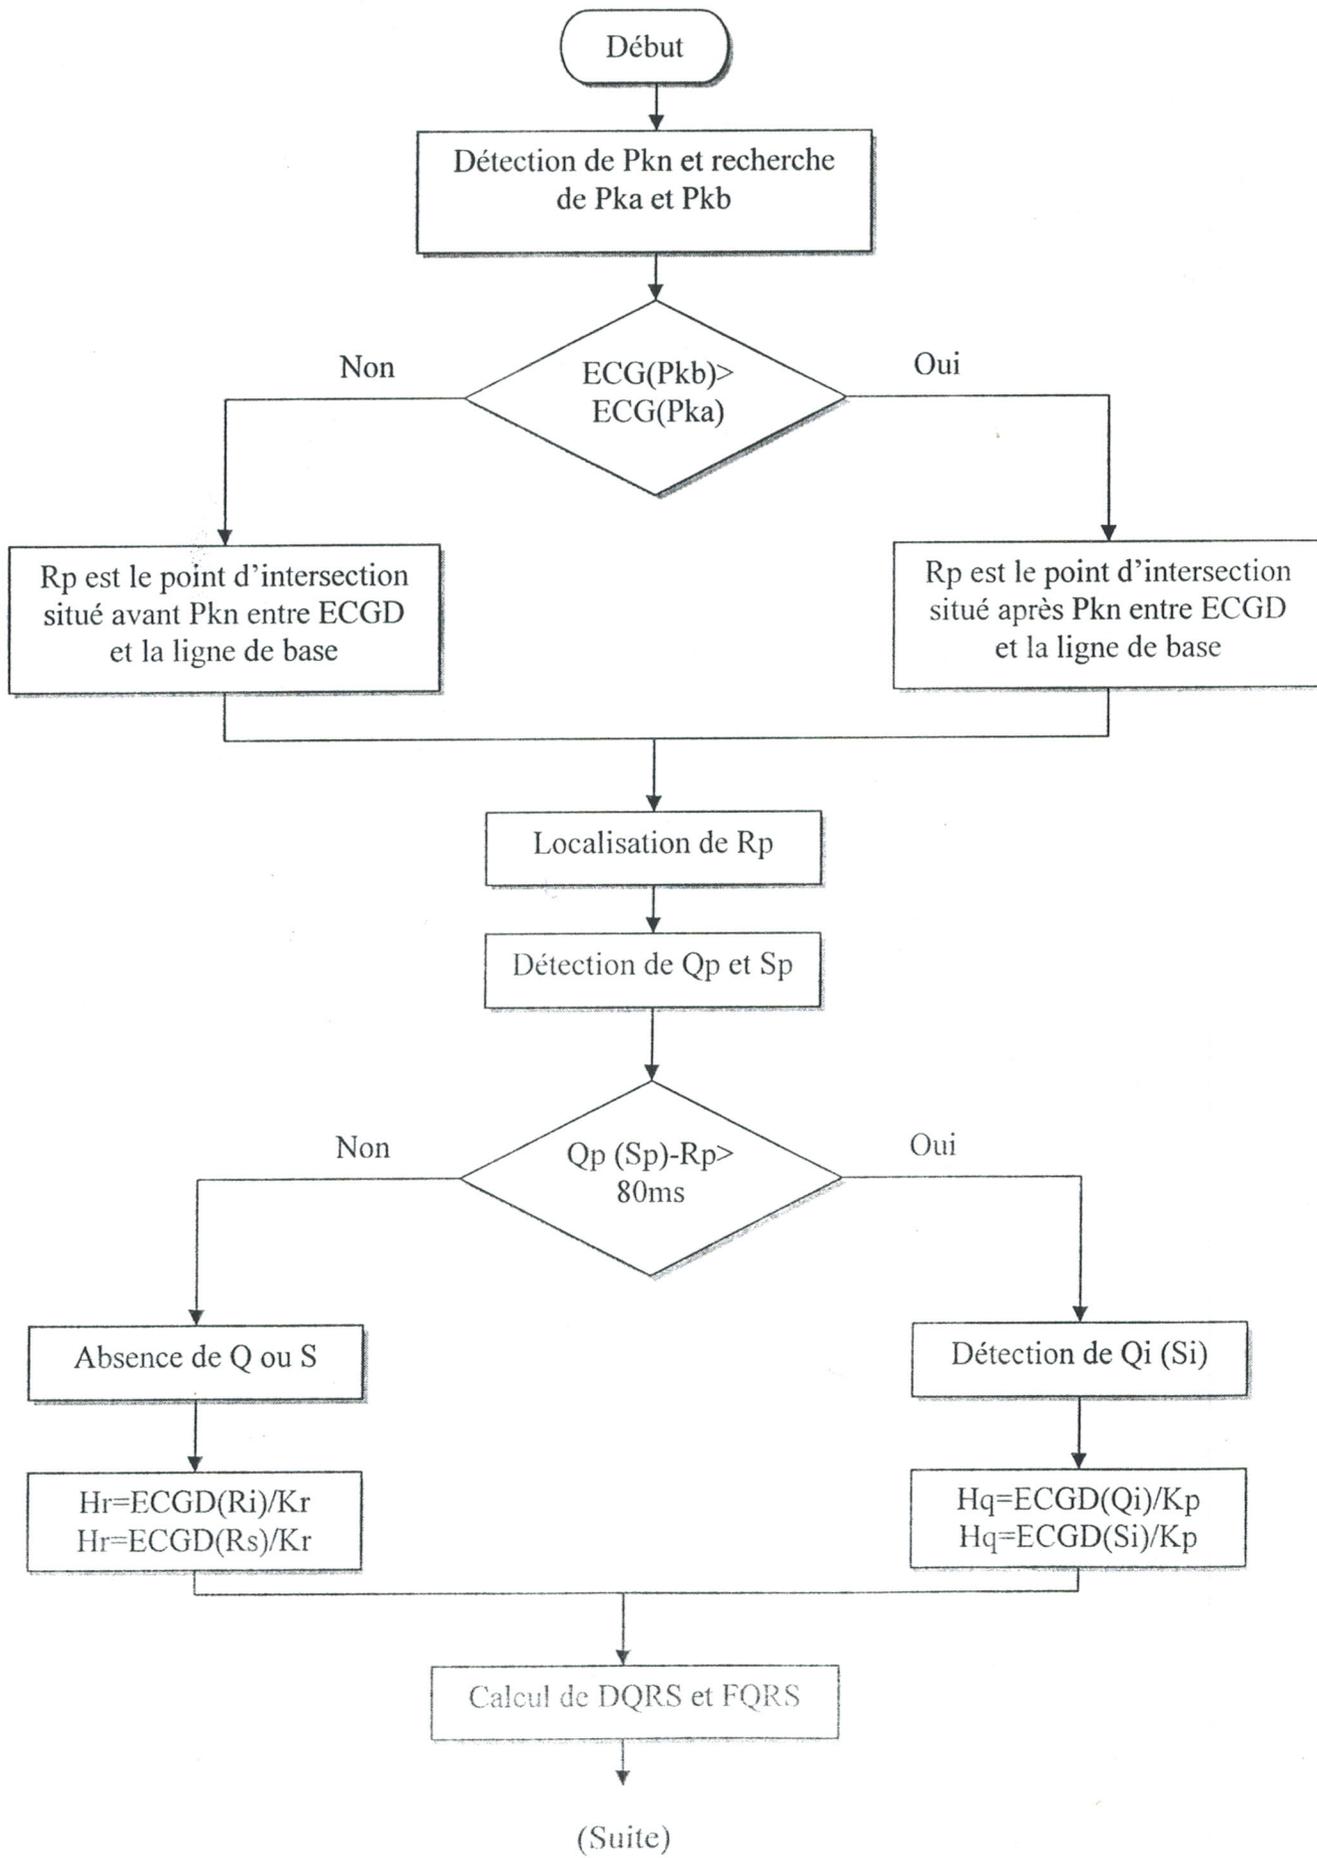


II.4.4 Détection de l'onde P

Une fois le début du complexe QRS et la fin de l'onde T situés, on peut localiser l'onde P par annulation de l'intervalle QT, comme suit :

$$\text{Onde } P(k) = \begin{cases} 0 & \text{si } DRQS \leq k < T_2(k) \\ ECG(k) & \text{si ailleurs} \end{cases} \quad \text{Eq. II-15}$$

Les étapes de détection et d'identification des paramètres du signal ECG, qui ont été implémentées, sont résumées sur l'organigramme ci-dessous :



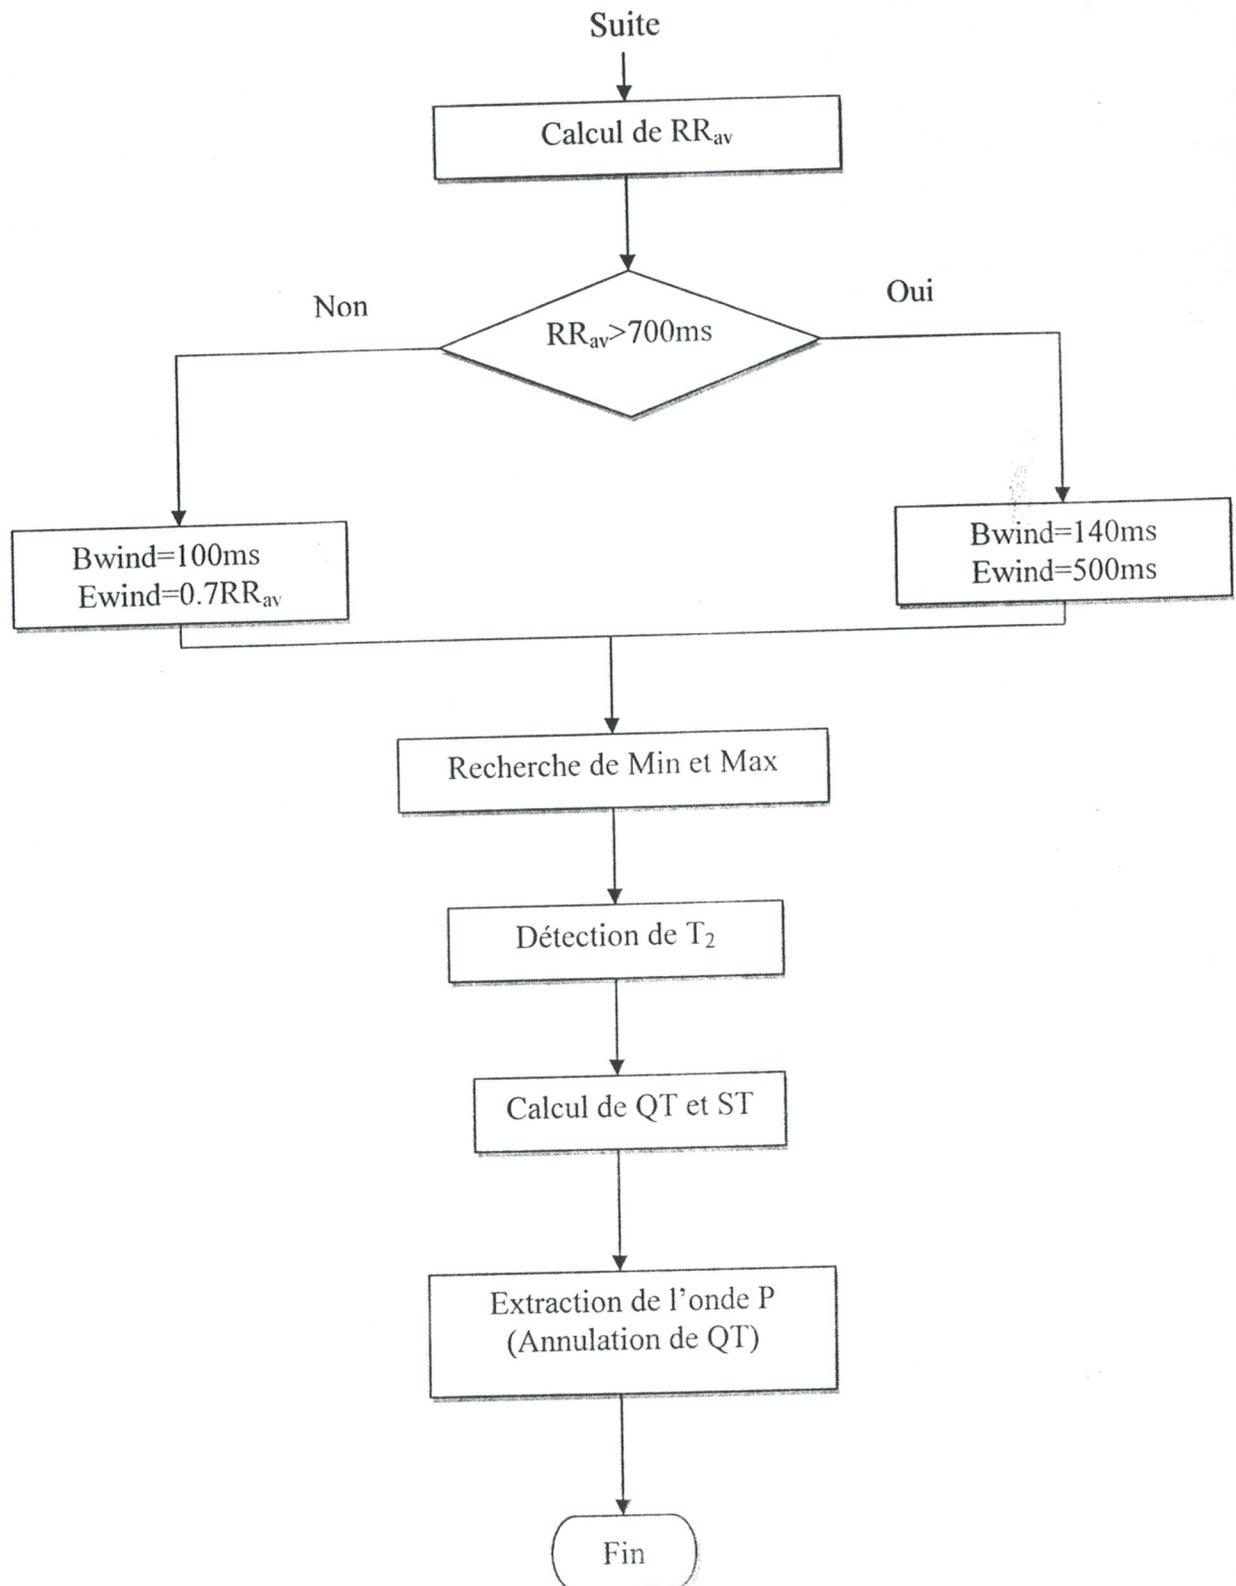


Fig. II.8. Organigramme de détection et mesures des ondes du signal électrocardiogramme.



Nous avons appliqué l'algorithme proposé pour la détection des paramètres des signaux ECG de la base de données MIT BIH pour valider notre algorithme. Le tableau suivant montre les pourcentages de détection obtenus :

| | | | | | | | | |
|----------------|------------|------------|------------|------------|------------|------------|------------|------------|
| Signal | 100 | 101 | 102 | 103 | 107 | 112 | 113 | 115 |
| % de détection | 99.9 | 99.1 | 98.3 | 99.3 | 94.5 | 92.9 | 99.9 | 99.2 |
| Signal | 123 | 205 | 209 | 221 | 212 | 202 | 219 | 234 |
| % de détection | 99.1 | 96.1 | 90.6 | 73.8 | 99.9 | 92.4 | 85.5 | 99.2 |

Tableau II-1. Taux de détection en % (signaux MIT BIH Database).

Le taux de détection est le rapport entre le nombre de cycles détectés par cet algorithme et nombre total des cycles cardiaques lus à partir de la base de données MIT BIH. Nous avons pu avoir un taux de détection global de 96% en utilisant la méthode de la dérivée, ce qui montre la puissance de cet algorithme de pouvoir détecter, identifier et mesurer les paramètres du signal ECG. La technique de la dérivée est aussi appliqué dans la détection des ondes uniphasiques et biphasiques, ce qui rend cette technique un outil très efficace pour l'analyse du signal ECG, en vue de diagnostic [29].

II.5 Préparation des données en vue de la classification

L'extraction des paramètres peut être considérée comme une opération qui consiste à trouver un ensemble de vecteurs qui représentent une observation en réduisant la dimensionnalité. En reconnaissance de formes, il est désirable de préparer et sélectionner les données qui focalisent sur la discrimination entre les classes en sortie. Bien qu'une réduction de dimensionnalité soit désirable, la variation de l'erreur due à la réduction de la dimension ne doit pas sacrifier le pouvoir de discrimination du classificateur. Le développement des méthodes de sélection des données ou plus précisément les paramètres représentatives de classes a été l'un des problèmes les plus importants dans le domaine de l'analyse de formes et a été intensivement étudié [30]. Nous considérons ici les méthodes de réduction

linéaire pour les réseaux de neurones en laissant la tâche de classification aux réseaux de neurones.

II.5.1 Réduction des données

Les électrocardiogrammes regroupent une large gamme de données. Si tous les canaux d'un appareil échantillonnent leur signal à 1KHz, un électrocardiogramme représente rapidement plusieurs méga octets de données.

La compression des données est utile pour plusieurs raisons : économise l'espace de stockage, permet de réduire les capacités mémoire de systèmes portables et d'optimiser le temps de calcul pour des traitements éventuels. En fait, le but réel est de réduire la taille du vecteur représentant un cycle cardiaque.

La représentation des données d'entrée d'un système de classification statistique ou neuronal est importante et peut affecter significativement les performances du système considéré. Le choix de la représentation des entrées est lié au processus général de la reconnaissance des formes, qui consiste à réduire le nombre de variables d'entrée qui affectent fortement la conception du classificateur. Ceci signifie que si les variables d'entrée présentent des différences significatives d'une classe à une autre, le classificateur peut être conçu plus facilement avec de meilleures performances. Par conséquent, la réduction des paramètres est un problème clé en reconnaissance de formes.

Il est nécessaire donc de réduire la dimension des données d'entrée dont le but est d'obtenir un classificateur plus petit qui opère bien, à la fois en termes de précision de classification, d'entraînement et de vérification, c'est à dire, trouver la meilleure représentation des données d'entrée dans un espace de dimension plus petit dans lequel cette réduction ne conduit pas à une diminution sensible de la précision de classification globale en comparaison avec celle obtenue dans l'espace originale.

Dans la littérature, différentes méthodes ont été proposées [31-34]. L'analyse en composante principale (ACP) et la prédiction linéaire (LPC) sont les deux techniques les plus utilisées. Une étude a montré l'efficacité de ces méthodes pour une représentation adéquate des données [35]. Nous avons développé deux classificateurs pour la classification en deux classes : normal et PVC. le vecteur



décrivant un cycle cardiaque contient 33 éléments pour le premier classificateur (sans compression), et 10 éléments pour le deuxième en utilisant l'ACP comme méthode de compression. De même, nous avons développé un autre classificateur dont les données d'entrée sont compressées par application de la prédiction linéaire [36]. Le tableau II.1 résume l'architecture et les performances de chaque classificateur.

| Cls \ % | CC | SP | SE | Nombre de neurones de chaque couche | | |
|-------------------|-------|-------|-------|-------------------------------------|--------|--------|
| | | | | Entrée | Cachée | Sortie |
| Sans compression | 85.17 | 78.05 | 98.61 | 33 | 6 | 2 |
| Compression : ACP | 76.40 | 75.65 | 93.48 | 10 | 3 | 2 |
| Compression : LPC | 77.44 | 73.50 | 87.26 | 5 | 2 | 2 |

Tableau II-1 Comparaison entre les performances des trois classificateurs.

Où CC : est le taux de classification correcte, SP est la spécificité et SE est la sensibilité. Ces paramètres seront décrits en détail en chapitre 3.

Ces résultats montrent que les meilleures performances ont été obtenues sans compression du complexe QRS, mais compte tenu de l'architecture et le temps de réponse du réseau, il est indispensable d'optimiser sa taille. Pour cela, deux méthodes de compression ont été appliquées : la prédiction linéaire et l'analyse en composante principale. Notons que la taille et le type des connexions d'un réseau influent sur ses performances. Nos études ont montré que l'application de la prédiction linéaire pour la compression des données d'entrée d'un classificateur donne des résultats relativement meilleurs par rapport à ceux obtenus par application de l'analyse en composante principale, surtout pour une architecture du réseau optimale.

II.5.2 Compression du complexe QRS et de l'onde P par la prédiction linéaire

L'idée de base de la méthode d'extraction des caractéristiques du signal ECG est que les données peuvent être obtenues par une combinaison linéaire des données



passées de ce signal. L'échantillon prédit \hat{y} est calculé à partir de échantillons passés par la relation II.16 :

$$\hat{Y}_n = \sum_{i=1}^p a_i y_{n-i} \quad \text{Eq. II-16}$$

Où a_i est le $i^{\text{ème}}$ coefficient de la prédiction linéaire (LPC : de Linear Prediction Coding) et p est son ordre.

Afin de réduire la taille du vecteur d'entrée du réseau de neurones, et utilisant les travaux de Lin et al [37], qui ont montré qu'un ordre de prédiction égal à deux ($P=2$) était suffisant pour l'analyse de signal ECG, nous avons implémenté cette méthode de compression. Ainsi le complexe QRS est compressé en deux coefficients (a_1 et a_2), et l'onde P en deux coefficients (a_3 et a_4).

II.5.3 Choix des paramètres

Afin d'aboutir à un meilleur choix des paramètres qui présentent les éléments de vecteur d'entrée de réseau, une des techniques parmi les plus simples à utiliser par les concepteurs de classificateurs consiste à sélectionner un sous-ensemble de paramètres en écartant les autres. Cette approche peut être utilisée lorsqu'il existe des paramètres qui apportent très peu d'informations utiles à la solution de problème ou s'il y a de très fortes corrélations entre les ensembles de paramètres de tel sorte que la même information se trouve être répétée dans plusieurs variables.

Toute procédure de sélection des paramètres doit être basée sur deux composantes. Premièrement, un critère de sélection doit être défini par lequel il est possible de déterminer si un ensemble de paramètres est meilleurs qu'un autre. Deuxièmement, une procédure systématique doit être trouvée pour faire la recherche à travers les différents ensembles de paramètres candidats. Dans une application réelle, on est souvent obligé de considérer les critères de sélection simples ainsi que des procédures de recherche non exhaustives dans le but de limiter la complexité de calcul du processus de recherche [38,39].

Idéalement, le critère de sélection sera obtenu en entraînant le classificateur avec toutes les combinaisons de paramètres possibles et en évaluant chaque fois ses



performances sur un ensemble de données. La combinaison de paramètres qui produira la meilleure classification sera retenue. Cette approche sera cependant trop pénible car le cycle apprentissage-vérification devra être répété pour chaque combinaison de paramètres, entraînant des temps de traitement considérablement long, surtout pour les réseaux de neurones qui impliquent en général des procédures d'optimisation non linéaires pour l'apprentissage. Il est donc convenable d'envisager des approches de sélection de paramètres plus réalistes basées sur des critères simples.

Une étude générale sur les travaux effectués sur la classification du signal ECG, nous a amené à choisir une meilleure représentation du complexe QRS et l'onde P, à savoir :

Les coefficients (a_1, a_2) résultants de l'application de la LPC, plus l'intervalle RR et la largeur du complexe QRS sont les éléments du vecteur qui représente le complexe QRS de chaque cycle cardiaque. Pour l'onde P, les deux coefficients (a_3, a_4) de la LPC, sa largeur $L(P)$, les intervalles PP et PR ont été choisis pour une meilleure description de cette onde. Les informations de chaque cycle sont représentées par un vecteur de quatre éléments pour le complexe QRS, et cinq composantes pour l'onde P. Les coefficients de la LPC représentent la morphologie des deux ondes, alors que les autres éléments sont les caractéristiques temporelles reliées au cycle désigné.

II.6 Conclusion

On a présenté dans ce chapitre une technique pour l'analyse de signal cardiaque basée sur l'utilisation de la dérivée. Cette technique permet la détection et l'identification des ondes de l'ECG. Les résultats obtenus montrent clairement la puissance de cette approche dans l'extraction des paramètres qui représentent les facteurs de discrimination entre les différents cas pathologiques.

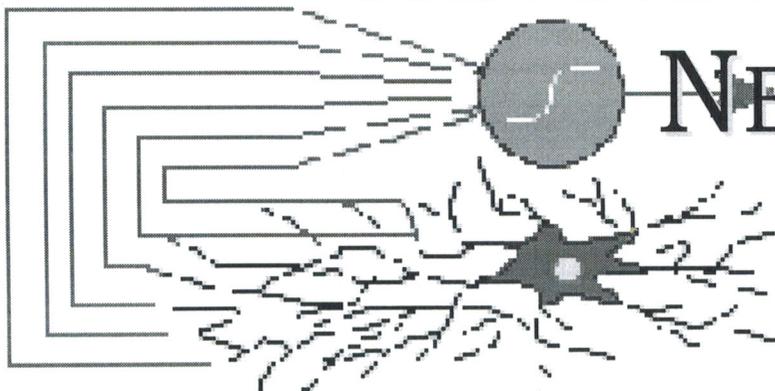
Le choix de la représentation des données est tout à fait représentatif d'un prétraitement destiné à aider le système neuronal en lui fournissant des caractéristiques pertinentes directement exploitables. Il est certain que pour obtenir un système de classification rapide, il faudrait faire appel à une architecture réduite.



Il est nécessaire donc de réduire la dimension des données d'entrée du réseau. Pour cela, on appliqué la prédiction linéaire (LPC) afin de compresser le complexe QRS et l'onde P en deux paramètres (a_1, a_2) et (a_3, a_4) respectivement. Ces éléments plus les paramètres temporels représentent le vecteur décrivant un cycle cardiaque et seront utilisés comme éléments de décision dans notre algorithme d'aide au diagnostic. Ceci sera détaillé dans le prochain chapitre.

Chapitre 3

CLASSIFICATION DES
ARYTHMIES CARDIAQUES
PAR RESEAUX DE
NEURONES





III. CLASSIFICATION DES ARYTHMIES CARDIAQUES PAR RESEAUX DE NEURONES.

III.1 Introduction

Dans le chapitre précédent, nous avons identifié et détecté les différentes ondes et caractéristiques temporelles constituant un signal ECG, à savoir :

- Morphologie du complexe QRS et de l'onde P : coefficients (a_1, a_2) et (a_3, a_4) résultants par application de la LPC.
- Largeur du complexe QRS et de l'onde P : $L(qrs)$ et $L(p)$.
- Intervalle entre deux ondes : RR, PP et PR.

Chaque cycle cardiaque est représenté par un vecteur de neuf éléments suffisants pour fournir au classificateur les informations nécessaires pour la discrimination entre les différentes classes en sortie.

Dans cette optique, nous proposons de concevoir un classificateur des arythmies cardiaques, les classes de sortie sont :

- Normal (N).
- Extrasystole ventriculaire ou PVC (V).
- Fusion entre V et N (F).
- Extrasystole auriculaire (A).
- Ectopique (P).
- Non classé (Q).

Le choix de ces 6 classes repose sur :

- Cas souvent rencontrés au niveau de CHU de Tlemcen.
- Cas pathologiques présentent des caractéristiques communes, ce qui rend la tâche de prise de décision chez le médecin difficile (par exemple classes: N, V et F), le classificateur proposé est capable de différencier entre ces classes malgré leur ressemblance.
- Cas pathologiques très importants, ce qui justifie leurs disponibilités au niveau des bases de données commerciales.

Pour résoudre un problème de classification, nous disposons de toute une panoplie de méthodes qu'il faut utiliser en connaissant bien leur capacités et surtout

leurs limitations (voir chapitre 1 § 1.7). Dans toute les expériences (théoriques et pratiques) effectuées par plusieurs chercheurs [40], les réseaux de neurones conduisent à de bon résultats. Bien dimensionnés, ils obtiennent toujours les meilleurs taux d'erreur de classification.

Le problème de la classification du signal cardiaque a suscité l'intérêt des chercheurs depuis la fin des années 1950. Le premier programme capable de faire la reconnaissance automatique de l'ECG a été mis en oeuvre en 1961. De nombreux travaux ont été réalisés par la suite. L'analyse et l'interprétation automatisée des tracés électriques du cœur constituent une aide au diagnostic dont l'intérêt est croissant.

Nous débutons ce chapitre par une présentation relativement brève sur le principe de calcul neuronal. Cette présentation est suivie de quelques applications générales des réseaux de neurones. Ensuite, nous présentons les critères pour évaluer les performances d'un classificateur neuronal. Enfin, nous présentons la structure et l'architecture de notre système de classification, le dimensionnement du réseau et la méthode d'apprentissage.

III.2 Les réseaux de neurones

III.2.1 Historique

Le concept du réseau de neurones a été introduit par Mc Culloch et Pitts en 1943, qui ont conçu le modèle des neurones interconnectés basé sur le modèle biologique, et qui ont démontré la capacité des réseaux de neurones à effectuer des calculs arithmétiques et logiques [41].

En 1958, Rosenblatt décrivit le perceptron [42], le premier modèle de réseau neuronal opérationnel ayant des capacités d'apprentissage. Le perceptron stimula la recherche jusqu'à ce que Minsky et Papert publient leur livre « Perceptron » en 1969, montrant les limites du perceptron incapable, par exemple, d'effectuer l'opération XOR. A la suite de cette publication seuls quelques chercheurs poursuivirent leurs études sur les réseaux de neurones.

Au début des années 80, les importantes découvertes théoriques (telle que la rétropropagation) et les progrès matériels ravivèrent l'intérêt pour les réseaux de



neurones. De nombreux modèles et de nombreuses règles d'apprentissage furent développés et implémentés, soit sous forme logiciels [43,44], soit sous forme matérielle [18,38]. Ce renouvellement d'intérêt se traduit par une augmentation du nombre de scientifiques, de découvertes, de conférences et d'articles sur les réseaux de neurones.

III.2.2 Principe de fonctionnement

Le neurone est l'unité de base d'un réseau neuronal, il est composé d'une unité de calcul, de registres contenant les poids acquis au cours de processus d'apprentissage (Fig. III.1 et 2). Son fonctionnement est simple, il rend en entrée un vecteur et détermine sa valeur de sortie en fonction des valeurs de chaque élément de ce vecteur et de leurs poids associés. Dans le cerveau, les neurones (~100 milliards) sont reliés entre eux par l'intermédiaire d'axones et de dendrites. On peut considérer que ces sortes de "filaments" sont conducteurs d'électricité et peuvent ainsi véhiculer des messages depuis un neurone vers un autre. Les dendrites représentent les entrées du neurone et son axone sa sortie.

Un neurone émet un signal en fonction des signaux qui lui provient des autres neurones. On observe en fait au niveau d'un neurone, une intégration des signaux reçus au cours de temps, c'est à dire une sorte de sommation des signaux. En général, quand la somme dépasse un certain seuil, le neurone émet à son tour un signal électrique [45].

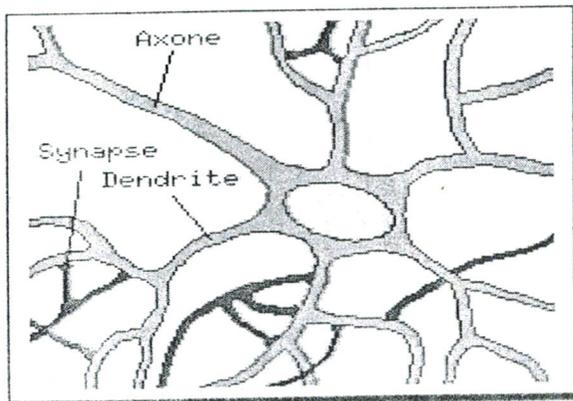


Fig. III.1 Neurone biologique

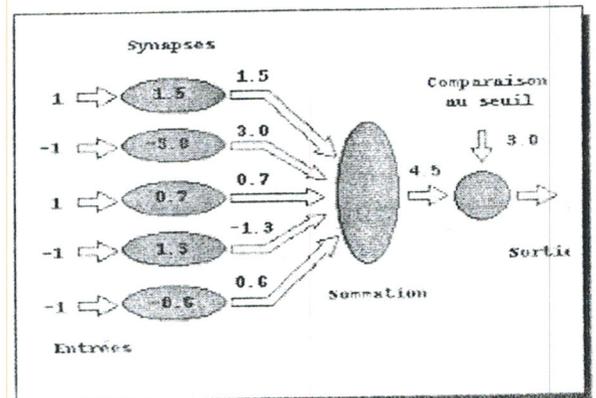


Fig. III.2 Neurone formel.



III.2.3 Le réseau de neurones

Un réseau de neurone (Fig. III.3) est constitué de plusieurs couches, une couche étant un ensemble de neurones dont les sorties sont indépendantes les unes des autres. On dira qu'une couche B est supérieure à une couche A si les neurones de la couche B ont pour entrées les sorties des neurones de la couche A. Dans chaque couche tous les neurones fonctionnent en parallèle. On a une couche d'entrée recevant le vecteur d'entrée de réseau, une couche de sortie définissant la réponse du réseau pour ce vecteur, et des couches intermédiaires dites cachées. On peut ainsi trouver des réseaux de neurones d'une seule couche (perceptron) ou de plusieurs (MLP : Multi layer perceptron) selon la complexité de problème à résoudre.

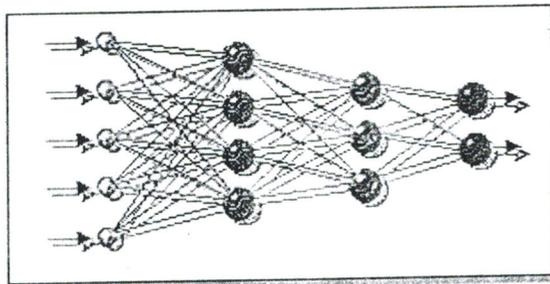


Fig. III.3 Réseau de neurones artificiel.

III.2.4 Apprentissage :

En ajustant les paramètres d'un MLP, on peut lui faire calculer toute sorte de fonction. Si on se donne une fonction vectorielle particulière, on peut tenter de faire apprendre cette fonction par un MLP : c'est l'apprentissage. Le processus d'apprentissage se divise en quatre étapes :

1. Présentation du vecteur d'entrée associé au motif à apprendre.
2. Evaluation par le réseau de vecteur.
3. Evaluation de l'erreur commise entre la sortie effective et la sortie désirée.
4. Correction des poids afin de minimiser cette erreur, on peut donc utiliser les techniques classiques d'optimisation de fonction pour trouver son minimum.

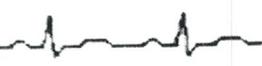


Le réseau de neurones est utilisé pour réaliser une fonction particulière, dans notre cas, il s'agit d'une classification. Cette fonction va être élaborée lors d'une phase d'apprentissage. Le résultat de cette fonction est obtenu lors d'une phase d'utilisation (ou propagation) du réseau. Dans un réseau de neurones, l'information est codée par les poids liés aux connexions. L'apprentissage est réalisé par des algorithmes de calcul dont le but est d'adapter ces poids en fonction des stimuli présentés à l'entrée du réseau. Une fois l'apprentissage fini, les poids ne sont plus modifiés.

Les procédures d'apprentissage peuvent être classées en deux catégories : apprentissage supervisé et apprentissage non supervisé. Dans le cadre d'une classification, la nécessité de pouvoir évaluer un taux de succès pour qualifier la performance du réseau implique qu'on lui présente des exemples connus pour effectuer l'apprentissage et pour procéder aux tests. L'apprentissage est alors qualifié de supervisé. L'apprentissage non supervisé est plutôt adapté à des réseaux appelés généralement « auto-organiseurs » ou à apprentissage compétitif. L'apprentissage s'effectue alors par présentation, à un réseau autonome, de données possédant une certaine redondance. L'objectif du réseau est alors de dégager des régularités. Ainsi comme nous l'avons indiqué dans le chapitre précédent, un tel réseau peut être utilisé pour l'obtention de prototypes. L'objectif de notre étude étant d'effectuer une classification, nous n'utilisons que l'apprentissage de type supervisé.

III.2.5 La rétropropagation

Dans un cadre plus général, l'apprentissage consiste en un entraînement du réseau. On présente au réseau des entrées et on lui demande de modifier sa pondération de telle sorte que l'on retrouve la sortie correspondante. L'algorithme consiste dans un premier temps à propager vers l'avant les entrées jusqu'à obtenir une sortie calculée par le réseau. La seconde étape compare la sortie calculée à celle réelle connue. On modifie alors le poids de sorte qu'à la prochaine itération, l'erreur commise entre la sortie calculée et la sortie connue soit minimisée. On rétropropage alors l'erreur commise vers l'arrière jusqu'à la couche d'entrée tout en



modifiant la pondération. On répète ce processus sur tous les exemples, jusqu'à ce qu'on obtient une erreur de sortie considérée comme négligeable.

L'expression de calcul des nouvelles valeurs de poids synaptiques est donnée par la relation suivante :

$$W_{ij}(k+1) = W_{ij}(k) - \lambda A_i D_j(k)$$

Avec : $D_j(k) = \frac{\delta E_i(k)}{\delta N_i(k)}$, On note :

λ : Pas d'apprentissage ;

E : Erreur commise par le réseau ;

$W_{ij}(k+1)$: Poids synaptique de neurone i de la couche k au neurone j de la couche $k+1$;

$A_i(k)$: sortie de neurone i de la couche k ;

$D_j(k)$: dérivée de l'erreur à partir de neurone j vers la couche k ;

Cet algorithme que l'on désigne couramment par : « BP : back propagation » est une généralisation de la règle de Windrow-Hoff pour un réseau multicouches. Il a été mis au point par deux équipes indépendantes en France par Fogelman-Soulié, Gallinari et Le cun, et aux Etats-Unis par Rumelhart, Hinton, et Williams [46].

III.2.6 Applications

De nombreuses applications de l'algorithme de rétropropagation de gradient ont été réalisées. Le premier domaine est bien entendu la reconnaissance de forme, ainsi les réalisations en reconnaissance de caractères dactylographiés ou manuscrites qui commencent à être classiques. En traitement de la parole, le NETTalk de T.Sejnowski qui est un réseau de synthèse vocale [47]. Couplé en entrée à un scanner et à un OCR (Optic Character Reconnaissance) et en sortie à un synthétiseur de paroles, ce réseau est donc capable de lire un texte à haute voix. Le réseau comprend au total 309 neurones et comme les connexions sont complètes d'une couche à une autre, il y a 18320 connexions. D'après les résultats publiés : 50 000 mots appartenant à un corpus de 1000 mots ont été présentés au réseau. Le temps d'apprentissage a été une nuit sur un VAX 780. Les performances : 95 %



pour l'ensemble d'apprentissage et 75% pour les nouveaux mots. Dans ses conférences, T.Scjnowski faisait entendre à l'auditoire un enregistrement sonore pris à divers moment au cours de la phase d'apprentissage. On pouvait alors entendre le réseau d'abords balbutier, puis on distinguait un découpage de texte en phrases, jusqu'à finalement une lecture raisonnable du texte.

En fait, les performances de NETTalk étaient loin d'être exceptionnels, si on les compare à ce qui se fait de mieux dans ce domaine de la lecture automatique. C'est une application intéressante qui peut être considéré comme un prototype de l'utilisation de la rétropropagation pour un problème réel. Cette simulation démontre le pouvoir potentiel des réseaux de neurones : un temps de calcul raisonnable, une mise en œuvre facile et des performances acceptables.

On peut élargir le champ de reconnaissance de forme en considérant que tout problème de diagnostic est un problème de reconnaissance de forme. Par exemple, J.L Golmard et Y.Lecun [48] ont étudié l'application de la rétropropagation à un problème de diagnostic de douleurs abdominales. Ils disposaient de 5765 cas de malades, chaque cas étant décrit par 132 symptômes qualitatifs ou quantitatifs. La base d'exemples a été séparée en un ensemble d'apprentissage et un ensemble de test. Les résultats étaient de l'ordre de 55 % de diagnostics corrects, pour 44 % avec une méthode de classification bayésienne, alors qu'un praticien en situation d'urgence donne un diagnostic correct dans 60 % des cas.

Dans notre système, nous avons aussi utilisé la méthode de rétropropagation de l'erreur pour l'apprentissage du classificateur des arythmies cardiaques que nous avons développé.

III.2.7 Procédures de développement d'un réseau de neurones :

Le cycle classique de développement peut être séparé en sept étapes :

1. La collecte des données,
2. L'analyse des données,
3. La séparation des bases de données,
4. Le choix d'un réseau de neurones,
5. La mise en forme des données,



6. L'apprentissage,
7. La validation.

a- Collecte des données :

L'objectif de cette étape est de recueillir des données, à la fois pour développer le réseau de neurones et pour le tester. Dans le cas d'applications sur des données réelles, l'objectif est de rassembler un nombre de données suffisant pour constituer une base représentative des données susceptibles d'intervenir en phase d'utilisation du système neuronal. La fonction réalisée résultant d'un calcul statistique, le modèle qu'il constitue n'a de validité que dans le domaine où on l'a ajusté. En d'autres termes, la présentation de données très différentes de celles qui ont été utilisées lors de l'apprentissage peut entraîner une sortie totalement imprévisible.

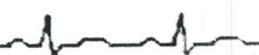
b- Analyse des données

Il est souvent préférable d'effectuer une analyse des données de manière à déterminer les caractéristiques discriminantes pour détecter ou différencier ces données. Ces caractéristiques constituent l'entrée du réseau de neurones. Notons que cette étude n'est pas spécifique aux réseaux de neurones, quelque soit la méthode de détection ou de classification utilisée, il est généralement nécessaire de présenter des caractéristiques représentatives.

Cette détermination des caractéristiques a des conséquences à la fois sur la taille du réseau (et donc le temps de simulation), sur les performances du système (pouvoir de séparation, taux de détection), et sur le temps de développement (temps d'apprentissage). Une étude statistique sur les données peut permettre d'écartier celles qui sont aberrantes et redondantes. Dans le cas d'un problème de classification, il appartient à l'expérimentateur de déterminer le nombre de classes auxquelles ses données appartiennent et de déterminer pour chaque donnée la classe à laquelle elle appartient.

c- Séparation des bases de données

Afin de développer une application à base de réseaux de neurones, il est nécessaire de disposer de deux bases de données : une base pour effectuer



l'apprentissage et une autre pour tester le réseau obtenu et déterminer ses performances. Il n'y a pas de règle pour déterminer ce partage de manière quantitatif. Il résulte souvent d'un compromis tenant compte du nombre de données dont on dispose et du temps imparti pour effectuer l'apprentissage. Chaque base doit cependant satisfaire aux contraintes de représentativité de chaque classe de données et doit généralement refléter la distribution réelle, c'est à dire la probabilité d'occurrence des diverses classes.

d- Choix d'un réseau de neurones

Il existe un grand nombre de types de réseaux de neurones, avec pour chacun des avantages et des inconvénients. Le choix d'un réseau peut dépendre :

- De la tâche à effectuer (classification, association, contrôle de processus, séparation aveugle de sources...),
- De la nature des données (dans notre cas, des données présentant des variations au cours du temps),
- D'éventuelles contraintes d'utilisation temps réel (certains types de réseaux de neurones, tels que la 'machine de Boltzmann' , nécessitant des tirages aléatoires et un nombre de cycles de calculs indéfini avant stabilisation du résultat en sortie, présentent plus de contraintes que d'autres réseaux pour une utilisation temps réel),
- Des différents types de réseaux de neurones disponibles dans le logiciel de simulation que l'on compte utiliser (à moins de le programmer).

Ce choix est aussi fonction de la maîtrise ou de la connaissance que l'on a de certains réseaux, ou encore du temps dont on dispose pour tester une architecture prétendue plus performante.

e- Mise en forme des données pour un réseau de neurones

De manière générale, les bases de données doivent subir un prétraitement afin d'être adaptées aux entrées et sorties du réseau de neurones. Un prétraitement courant consiste à effectuer une normalisation appropriée, qui tienne compte de l'amplitude des valeurs acceptées par le réseau.



f- Apprentissage du réseau de neurones

Tous les modèles de réseaux de neurones requièrent un apprentissage. Plusieurs types d'apprentissages peuvent être adaptés à un même type de réseau de neurones. Les critères de choix sont souvent la rapidité de convergence ou les performances de généralisation. Le critère d'arrêt de l'apprentissage est souvent calculé à partir d'une fonction de coût, caractérisant l'écart entre les valeurs de sortie obtenues et les valeurs de références (réponses souhaitées pour chaque exemple présenté).

g- Validation

Une fois le réseau de neurones entraîné (après apprentissage), il est nécessaire de le tester sur une base de données différentes de celles utilisées pour l'apprentissage. Ce test permet à la fois d'apprécier les performances du système neuronal et de détecter le type de données qui pose problème. Si les performances ne sont pas satisfaisantes, il faudra soit modifier l'architecture du réseau, soit modifier la base d'apprentissage (caractéristiques discriminantes ou représentativité des données de chaque classe).

III.3 Performance d'un classificateur

Afin d'évaluer les performances d'un classificateur, des mesures de performances communes aux systèmes de diagnostic ont été utilisées. En général, on définit les paramètres suivants :

- **Valeur positive vraie (TP)**

La valeur positive vraie ou "True Positive" TP', est définie par le nombre des patients testés, et pour lesquels l'anomalie identifiée par le système de décision coïncide avec celle identifiée par le médecin.

- **Valeur négative vraie (TN)**

La valeur négative vraie ou "True Negative" TN', est définie par le nombre de patients ne présentant pas une anomalie, et pour lesquels le système de décision affirme le même résultat.



• **Valeur positive fausse (FP)**

La valeur positive fausse ou "False Positive" FP', est définie par le nombre de patients présentant une anomalie (identifiée par le médecin) et pour lesquels les systèmes, par erreur de classification n'identifie pas l'anomalie.

• **Valeur négative fausse (FN)**

La valeur négative fausse ou "False Negative" FN' est définie par le nombre de patients ne présentant pas une anomalie (affirmée par le médecin), et pour lesquels le système, par erreur de classification identifie une anomalie.

A partir de ces mesures on définit les pourcentages suivants :

$$\begin{cases} CC=(TN+TP)/(TN+TP+FN+FP). \\ SE=TP/(TP+FN). \\ SP=TP/(TP+FN). \end{cases}$$

Avec :

CC : Le taux de classification correcte.

SE : Sensibilité de système.

SP : Spécificité du système.

Pour une classification de plusieurs cas, les performances de système sont calculées comme le montre le tableau suivant :

| Entrée | Sortie du classificateur | | | | | |
|--------|--------------------------|----|----|----|----|----|
| | N | V | F | P | A | Q |
| N | TN | FP | TN | TN | TN | TN |
| V | FN | TP | FN | FN | FN | FN |
| F | TN | FP | TN | TN | TN | TN |
| P | TN | FP | TN | TN | TN | TN |
| A | TN | FP | TN | TN | TN | TN |
| Q | TN | FP | TN | TN | TN | TN |

Tableau III-1 Identification de : TP, TN, FP et FN.



III.4 Structure du classificateur

III.4.1 Première approche

Dans une première approche, nous avons conçu un classificateur neuronal composé de deux sous classificateurs CLS1 et CLS2 où CLS1 est le classificateur des complexes QRS et CLS2 est un classificateur des ondes P. Chacun de ces deux classificateurs est indépendant de l'autre, les deux sorties sont traitées par un module de comparaison qui, en se basant sur le poids de chaque sortie, fournit à sa sortie le cas pathologique du cycle cardiaque en question.

III.4.1.1 Classificateur des complexes QRS CLS1

Le premier CLS1 est un classificateur neuronal qui permet de classer les complexes QRS en cinq classes : N, V, F, P et Q.

L'entrée de ce classificateur est déterminée par les valeurs présentées précédemment : les 2 coefficients a_1 et a_2 , l'intervalle RR et $L(QRS)$: la largeur du complexe QRS.

III.4.1.2 Classificateur des ondes P CLS2

De même, le CLS2 est un classificateur neuronal qui permet de classer les ondes P normale et anormales. L'entrée de CLS2 est un vecteur de données composé de cinq valeurs : a_3 , a_4 , PP, PR et $L(P)$. La sortie est composée de deux cas :

N : Battement normal. et A : Battement artériel prématuré.

Le classificateur globale (Fig. III.4) est composé de deux blocs montés en cascade :

- Un système de détection, compression et sélection de paramètres. Ses sorties sont appliquées aux entrées des classificateurs CLS1 et CLS2.
- Une partie qui rassemble les deux classificateurs CLS1 et CLS2 montés en parallèle dont les sorties sont les différentes arythmies cardiaques proposées précédemment, et un système capable de comparer ces sorties et sélectionner un seul cas pathologique suivant son poids.

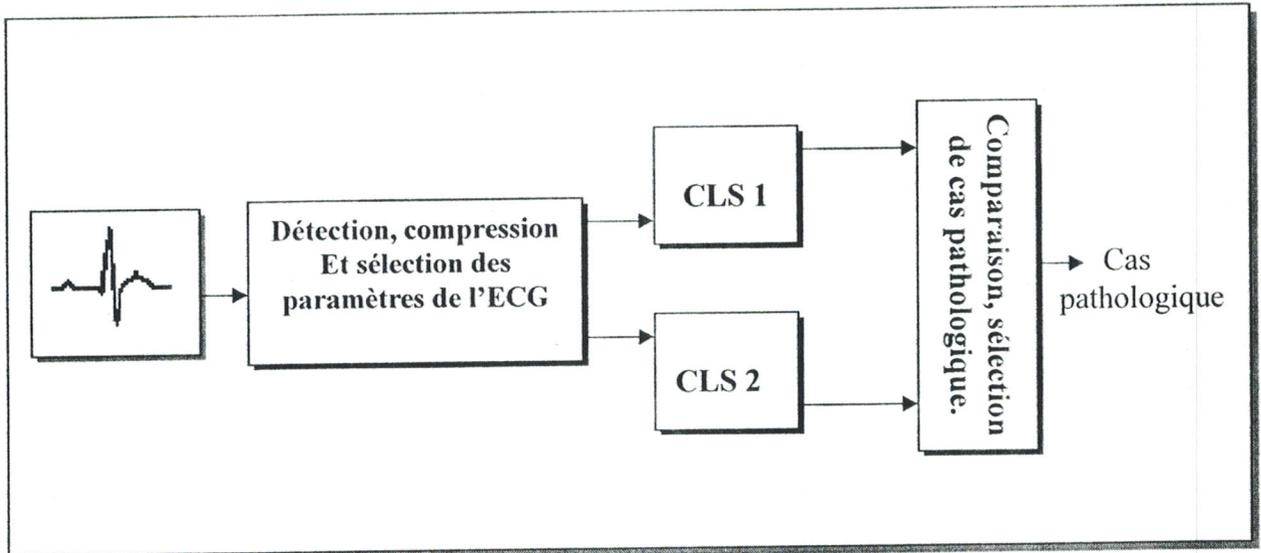


Fig. III.4 Architecture du classificateur des arythmies cardiaques.

Le tableau suivant présente les résultats obtenus après avoir appliqué à l'entrée du classificateur les enregistrements de MIT BIH Database.

| | CC % | SE % | SP % |
|--------|--------------|--------------|--------------|
| CLS 1 | 84.20 | 59.12 | 38.66 |
| CLS 2 | 90.15 | 61.42 | 44.23 |
| Global | 87.17 | 60.27 | 41.44 |

 Tableau III-2. Performances du classificateur (1^{ère} approche).

Cette architecture nous a permis d'obtenir un taux de classification correct élevé, mais les taux de spécificité et sensibilité sont insuffisants. Ces résultats sont justifiés par le fait que les données fournies aux entrées des réseaux de neurones restent insuffisantes pour permettre à chaque classificateur de bien distinguer entre les classes de sortie, ce résultat nous a ramené à adopter une deuxième approche. Le principe est simple : concevoir un seul classificateur dont l'entrée est un vecteur constitué des deux vecteurs précédemment définis.

III.4.2 Deuxième approche

La structure du classificateur est présentée sur la figure III.5. Il est composé de deux parties : la partie de traitement du signal ECG (filtrage, détection et compression), et une partie de classification (un seul classificateur neuronal).

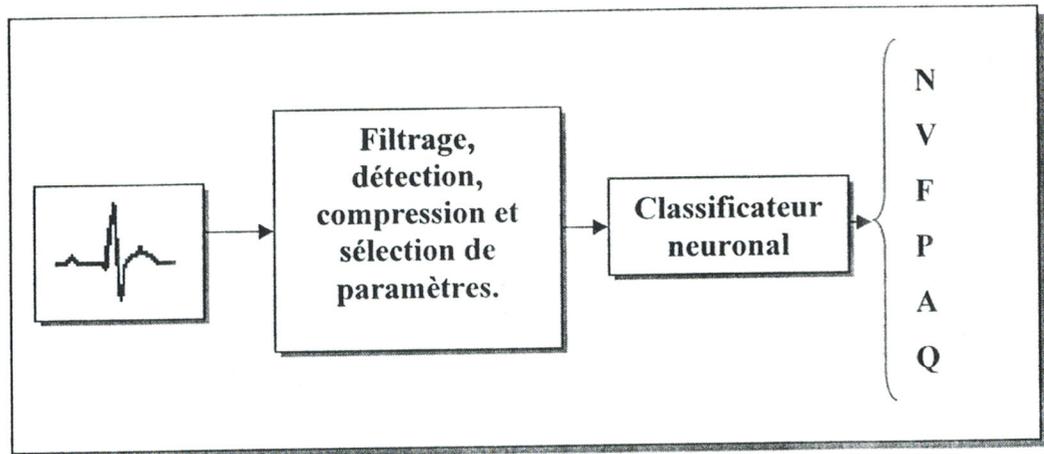


Fig. III.5 Structure du système de classification (2^{ème} approche).

III.5 Implémentation software du classificateur

Le but de l'implémentation software du classificateur est de déterminer la taille et les paramètres de réseaux de neurones, à savoir :

- Nombre de couches et le nombre de neurones pour chaque couche.
- Erreur atteinte.
- Nombre d'itération.

Ces paramètres permettent d'avoir les meilleures performances du réseau. Nous discutons dans cette section les conditions et méthode d'apprentissage, le dimensionnement du réseau et nous présentons le logiciel développé.

III.5.1 Apprentissage

L'apprentissage vise à découvrir les relations et motifs cachés dans des collections des données brutes. Il permet également de pallier les difficultés liées à l'acquisition de connaissances auprès d'experts du domaine. Un système d'apprentissage prend en entrée un ensemble d'exemples (cycles cardiaques) dont il cherche une définition. Dans notre cas, le système cherche à apprendre les formes des arythmies cardiaques à partir des exemples fournis à son entrée. Ces exemples sont présentés sous forme de paramètres (éléments du vecteur d'entrée) qui représentent les caractéristiques temporelles et morphologiques des cycles cardiaques classés selon les arythmies auxquelles elles correspondent. L'algorithme



d'apprentissage, la rétropropagation dans ce cas, assure que les classes produites permettent de discriminer aux mieux les exemples en entrée.

III.5.2 Algorithme de la rétropropagation

Les réseaux de neurones supervisés requièrent un apprentissage par essais/erreurs, en partant d'exemples donnés sous forme de paires (problème, solution à ce problème). Comme un être humain, un réseau de neurones essaie de généraliser les exemples afin de faire face à des situations similaires.

La méthode numérique utilisée pour l'apprentissage et que nous avons adoptée s'appelle le descente de gradient par rétropropagation. Nous disons descente de gradient parce que nous utilisons la direction de gradient comme direction de changement dans l'espace de paramètres. L'algorithme de base est assez simple. Soit l'époque k , θ_k est l'ensemble des paramètres au début de l'époque k , θ_{k+1} les nouveaux paramètres que nous désirons calculer et $g(\theta_k)$ le gradient de la fonction à optimiser, alors :

$$\theta_{k+1} = \theta_k - \varepsilon g(\theta_k)$$

où ε est le pas de gradient. Il s'agit d'une constante positive.

L'idée de cet algorithme d'optimisation est que le gradient d'une fonction pointe toujours dans la direction où cette fonction croît le plus. Inversement, si nous multiplions le gradient par le scalaire -1 , nous obtenons la direction de la plus grande décroissance de la fonction. La difficulté majeure est de choisir ε . En effet, si nous allons le choisir trop petit, nous allons converger vers un minimum local très lentement et si nous le choisissons trop grand, nous ne convergeons pas, car nous allons sauter d'un côté à l'autre.

Plusieurs méthodes et algorithmes d'optimisation ont été proposés pour résoudre ce problème. Chaque méthode possède des avantages et des inconvénients (Voir annexe A). Bien entendu, aucune méthode ne conduit à coup sûr au minimum global. Il convient donc de se placer dans des conditions où les minima locaux sont aussi peu nombreux que possible. Nous avons choisi la méthode de Levenberg-Marquardt qui consiste à modifier les paramètres selon la relation suivante :

$$\theta_k = \theta_{k-1} - [h_{k-1} + \lambda_{k-1} I]^{-1} g(\theta_{k-1})$$



Avec I : matrice identité.

Cette méthode est particulièrement astucieuse car elle s'adapte d'elle-même à la forme de la fonction coût. Elle effectue un compromis entre la direction de gradient et la direction par la méthode de Newton (dans ce cas la valeur de pas est donnée par $\frac{1}{\lambda_{k-1}}$) et si λ_{k-1} est petit la modification des paramètres correspond à celle de la méthode de Newton.

III.5.3 Base de données

Dans cette étude nous nous concentrons sur la classification des extrasystoles ventriculaires (PVC), les 48 enregistrements de "MIT BIH Database" sont utilisés pour le développement et l'évaluation des performances du classificateur. Chaque enregistrement de cette base de données est accompagné par un fichier d'annotation (Voir chapitre 1 §I.7) dans lequel chaque battement ECG (cycle cardiaque) a été identifié par des experts (cardiologues). Ces étiquettes (annotations) sont employées pour l'apprentissage du classificateur et l'évaluation de ces performances pendant la phase de test. Puisque cette étude vise à identifier l'extrasystole ventriculaire (PVC), certains enregistrements de la base de données sans PVC ont été exclus de l'étude, laissant 35 enregistrements d'intérêt.

Les cycles cardiaques utilisés pour l'apprentissage des différents cas pathologiques ont été choisis aléatoirement de plusieurs enregistrements. L'avantage est bien sûr de construire une base de données incluant différentes formes de chaque arythmie cardiaque.

III.5.4 Programmation

Notre choix étant porté sur l'algorithme de la rétropropagation du gradient, un programme est écrit en Matlab pour l'implémentation software de cet algorithme. La fonction d'activation choisie est la fonction sigmoïde (Fig. III.6).

La fonction sigmoïde est inspirée directement de l'examen du comportement des cellules nerveuses face aux signaux qui leur arrivent.

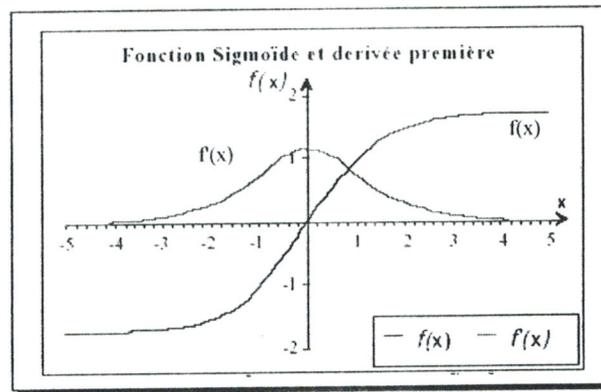


Fig. III.6 Fonction sigmoïde et sa première dérivée.

Une fonction sigmoïde est définie par $f(x)$ donnée par :

$$f(x) = a \frac{e^{kx} - 1}{e^{kx} + 1}$$

En effet, elle tend vers a quand x tend vers $+\infty$ et tend vers $-a$ quand x tend vers $-\infty$. Le paramètre a régule alors la valeur de saturation ; le paramètre k sert à réguler la pente de la courbe en tout point hors saturation.

Dans notre modèle, nous utilisons les fonctions *logsig* et *tansig* implémentées sous Matlab comme fonction d'activation (transition) dans le réseau de neurones [49]. Ces fonctions sigmoïdes sont continues et différentiables, elles sont également non décroissantes. Nous les appelons fonctions quasi-linéaires car elles sont presque linéaires dans l'intervalle d'intérêt. Comme le montre la figure III.6 la fonction sigmoïde $f(x)$ et sa dérivée première $f'(x)$ sont toutes les deux des fonctions continues dans \mathbb{R} . ceci est fort utiles lors des manipulations mathématiques de ces fonctions.

III.5.5 Dimensionnement du réseau

Il n'existe pas de résultats théoriques, ni même de règles empiriques satisfaisantes, qui permettent de dimensionner correctement un réseau de neurones en fonction de problème à résoudre. La conception d'un réseau multicouche se fait de manière expérimentale, la difficulté se pose généralement au moment du choix du nombre de couches intermédiaires et du nombre de neurones dans chacune d'elles. Pour la couche d'entrée, elle contient autant de neurones que le nombre

d'éléments du vecteur d'entrée. De même, pour la couche de sortie, elle contient autant de neurones que le nombre de classes à discriminer. De ce fait, la couche d'entrée est constituée de neuf neurones et la couche de sortie est constituée de six neurones.

Pour déterminer le nombre de neurones de la couche cachée, nous avons procédé de la manière suivante :

1. Préparer les cycles cardiaques correspondants aux arythmies choisies pour l'apprentissage.
2. Créer le réseau de neurones dont le nombre de la couche d'entrée (respectivement de sortie) est fixé suivant le vecteur d'entrée (respectivement classes en sortie)
3. désigner un nombre de neurones arbitraire dans la couche cachée.
4. Fixer une erreur de très faible valeur ainsi que le nombre d'itérations.
5. Lancer l'apprentissage.

Tant que le processus diverge, augmenter le nombre de neurones dans la couche cachée, si celui-ci est trop élevé augmenter le nombre de couches intermédiaires.

Après plusieurs simulations, nous avons obtenu la convergence pour les paramètres suivants :

Couche d'entrée : 09 neurones.

Couche cachée : 20 neurones.

Couche de sortie : 06 neurones.

Erreur atteinte : 10^{-3} .

Nombre d'itération : 1000.

Il n'existe malheureusement pas de « super architecture neuronale », c'est à dire d'architecture fixe pour laquelle il suffirait d'adapter les poids au problème afin d'obtenir les meilleurs performances possibles. De manière générale, la taille et le type des connexions d'un réseau influent sur ses performances. Notons toutefois que cette architecture (09-20-06) n'est pas unique, et qu'il existe souvent plusieurs architectures permettant d'obtenir la même performance. Dans notre cas, l'architecture optimale sera celle qui possède la plus petite taille, ou plus

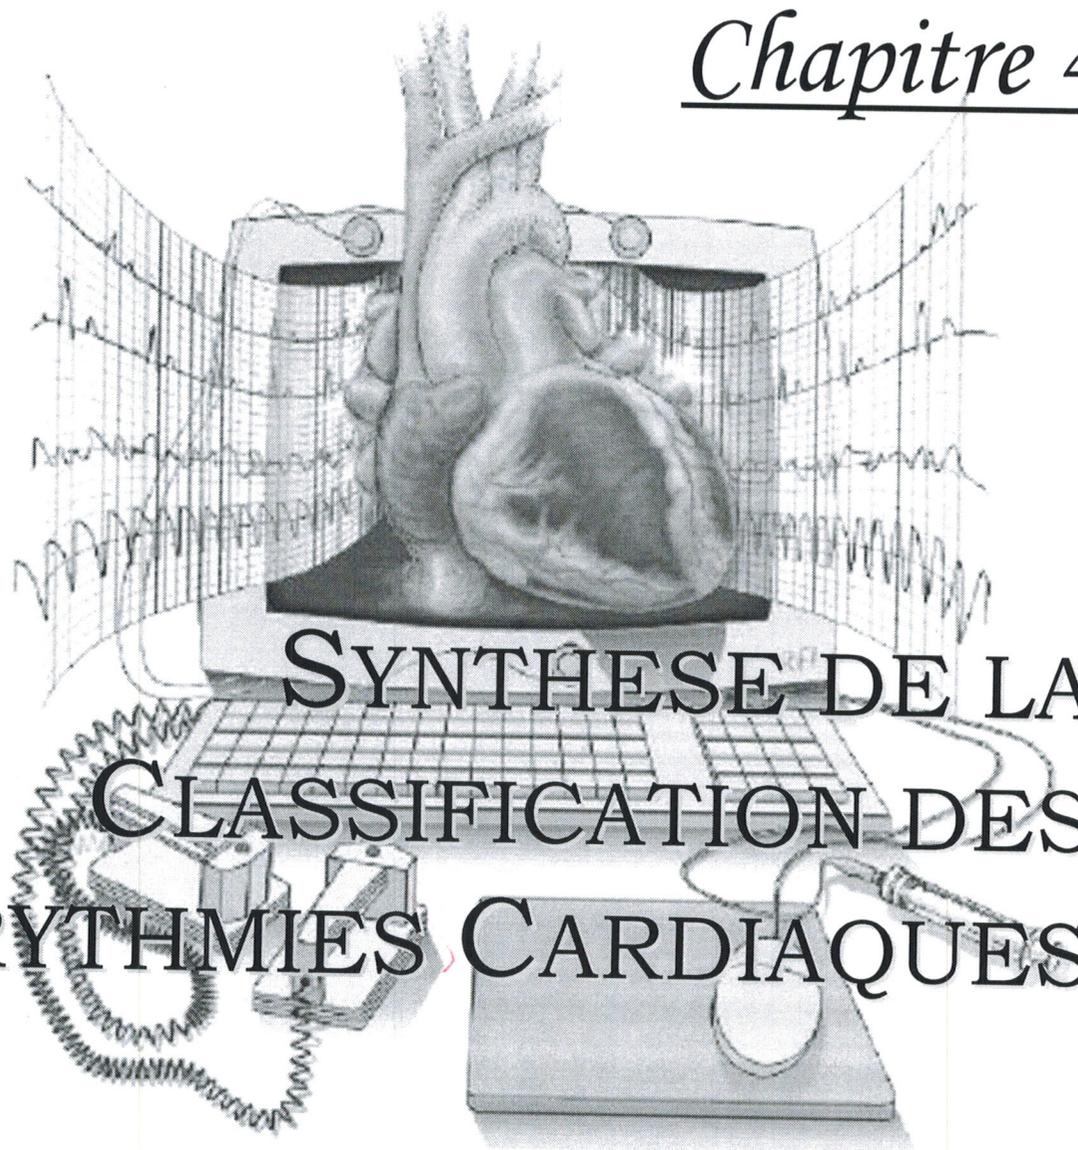
précisément celle qui nécessitera le moins de calculs pour réaliser la fonction demandée.

III.6 Conclusion

Dans ce chapitre, nous avons développé une nouvelle approche pour la classification des arythmies cardiaques suivantes : N, V, F, P, A et Q.

Nous avons discuté les méthodes utilisées lors du développement de notre système de réseaux de neurones. Certaines de ces méthodes ont été déjà explorées dans différents domaines et reportées en bibliographie, d'autres ont été mises au point pour répondre aux particularités de notre application. Lors de cette phase de développement, nous avons dû faire face à un certain nombre de problèmes pour effectuer la classification des arythmies cardiaques. Ces problèmes nous ont amené à compléter nos connaissances d'une part sur l'utilisation des réseaux de neurones et d'autre part sur certaines caractéristiques propres du perceptron multicouches. Ce type de réseaux de neurones nous a permis d'obtenir des résultats très satisfaisants. La présentation et l'analyse de ces résultats ainsi qu'une étude comparative avec d'autres travaux seront présentées dans le prochain chapitre.

Chapitre 4



SYNTHESE DE LA CLASSIFICATION DES ARYTHMIES CARDIAQUES

IV. SYNTHÈSE DE LA CLASSIFICATION DES ARYTHMIES CARDIAQUES.

IV.1 Introduction

Le but de la classification des signaux cardiaques est de déterminer si le patient est malade et exige un traitement, ou si le patient n'a pas de caractères anormaux et n'exige aucun traitement. Dans le cas général, l'approche de classification est visée à aider le spécialiste pour faire son diagnostic en évitant la variabilité de l'observateur.

Dans cette étude, nous avons présenté une nouvelle approche pour la classification des arythmies cardiaques basée sur les réseaux de neurones. Ce système de classification est composé de deux parties : les prétraitements et le classificateur (le réseau de neurones). Le classificateur proposé et qui prend en charge la morphologie des ondes et leurs caractéristiques temporelles, peut classer les cycles ECG en six classes. Dans le cadre d'une étude sur les arythmies cardiaques, l'objectif est de détecter des cycles de caractéristiques considérées comme étant « anormales ». Un cycle est considéré comme anormal lorsque ses paramètres (morphologiques et temporels) sont au delà des valeurs habituellement observées. Ce chapitre est consacré à la présentation du logiciel *ECG Pro* que nous avons développé et qui permet la détection, l'identification et la classification des signaux ECG. Les résultats obtenus sont discutés et comparés avec d'autres travaux dans le domaine.

IV.2 Le logiciel : *ECG Pro*

Le logiciel proposé est conçu autour d'une interface utilitaire graphique développée par le logiciel Matlab de Mathworks, en utilisant le Guide [50].

Le logiciel permet le traitement du signal ECG (lecture, filtrage, détection des ondes, et l'extraction de paramètres pertinents), il permet ainsi la visualisation du signal ECG filtré, la variation de la fréquence cardiaque (HRV), le complexe QRS et l'onde P. En utilisant le classificateur neuronal proposé, ce logiciel affiche le cas pathologique du cycle cardiaque en question, en cas d'un cycle cardiaque anormal détecté, le logiciel provoque un bip sonore différent de celui d'un cycle normal.



La présentation du logiciel est donnée sur la figure IV.1. Il contient une seule fiche et un menu. Les éléments de cette fiche, qui sont mis à la disposition de l'utilisateur (cardiologue), sont :

- 1- 1^{er} graphe : ECG filtré.
- 2- 2^{ème} graphe : la variation de la fréquence cardiaque (HRV).
- 3- 3^{ème} graphe : le complexe QRS.
- 4- 4^{ème} graphe : l'onde P.
- 5- Boutons "<<" et ">>" : basculer d'un cycle à l'autre (précédent ou suivant)
- 6- Les durées ST et QT.
- 7- Affichage du cas pathologique du cycle désigné.
- 8- Bouton "...": faire un zoom pour le complexe QRS et l'onde P.
- 9- Le menu : le menu principal de ce logiciel contient quatre choix :
 - **Charger** : un click sur ce bouton ouvre un fichier déjà traité.
 - **Traitement** : Ce bouton offre la possibilité d'appliquer différentes opérations pour le traitement du signal ECG, à savoir :
 - *Filtrage* : appliquer un filtrage au signal ECG enregistré sur disque dur ou acquis par l'interface ECG (filtrage passe bas et passe haut).
 - *Détection* : Lancer l'opération de détection et d'identification des différentes paramètres du signal (différentes ondes et durées).
 - *Classification* : Faire appel au classificateur neuronal pour effectuer l'opération de la classification.
 - **A propos** : Informations sur le logiciel.
 - **Quitter** : Quitter l'application.

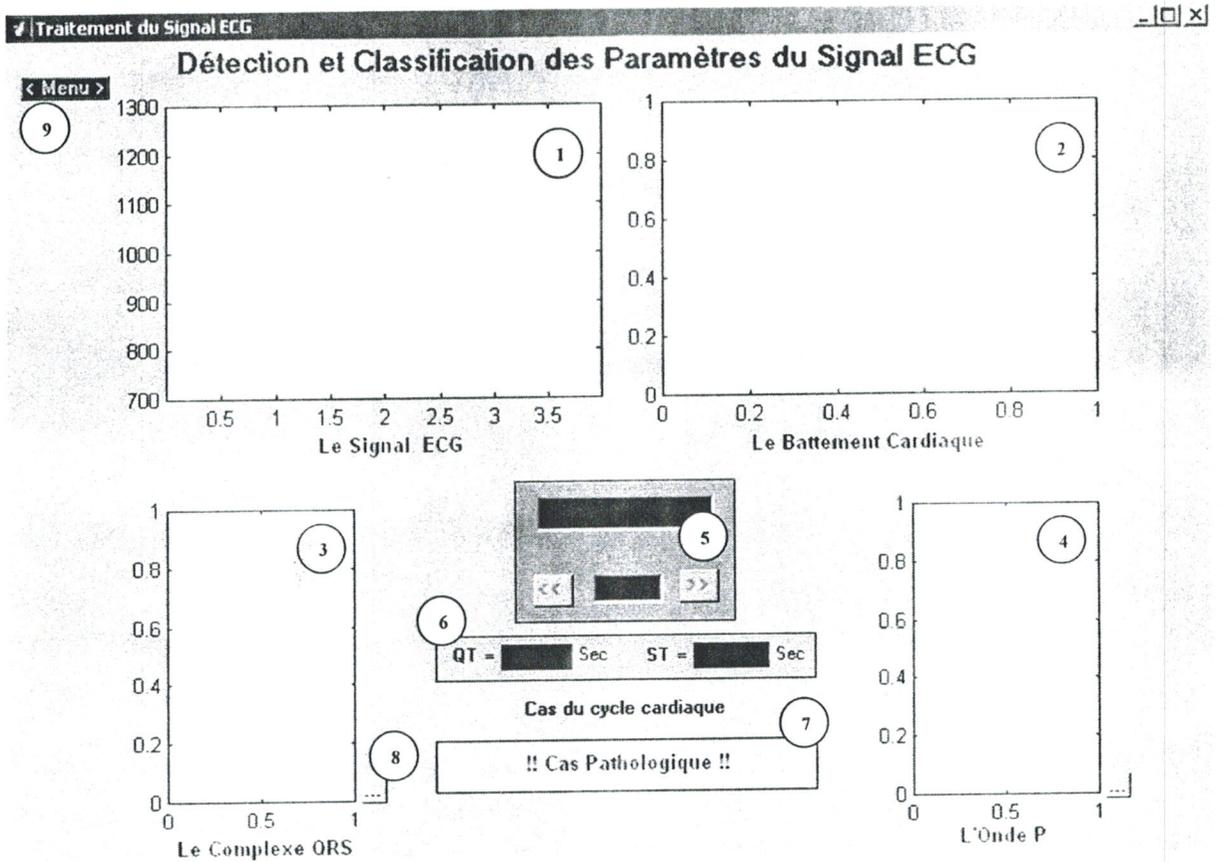


Fig. IV.1 Présentation du logiciel.

Il existe trois autres boutons qui sont activés après avoir charger ou traiter un enregistrement ECG : (Fig.IV.2)

- *Statistiques* : Affiche les statistiques d'enregistrement ECG en cours.
A savoir : durée du signal, nombre total des cycles, nombre de cas normaux et anormaux et la moyenne de la fréquence cardiaque.
- *Enregistrer* : Enregistre l'ECG en cours (signal et annotations).
- *Imprimer* : Imprime le signal ECG et ses annotations.

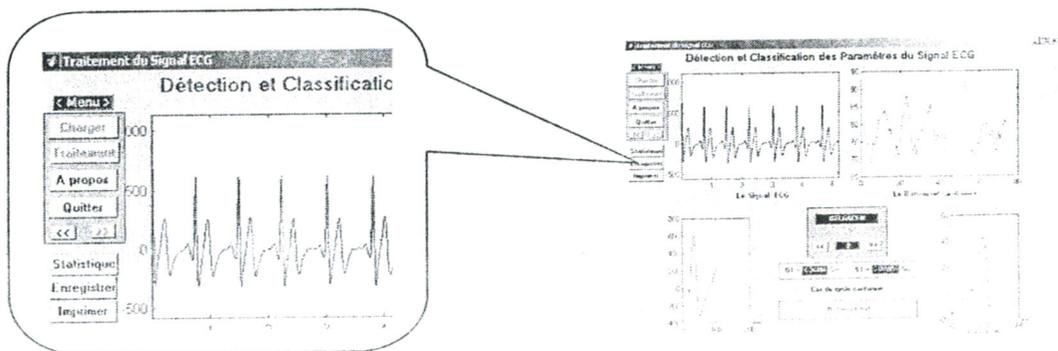


Fig. IV.2 Menu de logiciel *ECG Pro*

Chargement et traitement d'un signal ECG par ECG Pro :

Le logiciel peut lire un enregistrement ECG acquis par l'interface CASSY disponible au niveau de notre laboratoire. Un click sur bouton "Traitement" déclenche les procédures de filtrage, détection et classification du signal acquis. Lors de traitement du signal, *ECG Pro* affiche le signal filtré, le battement cardiaque, le complexe QRS et l'onde P (Fig.IV.3).

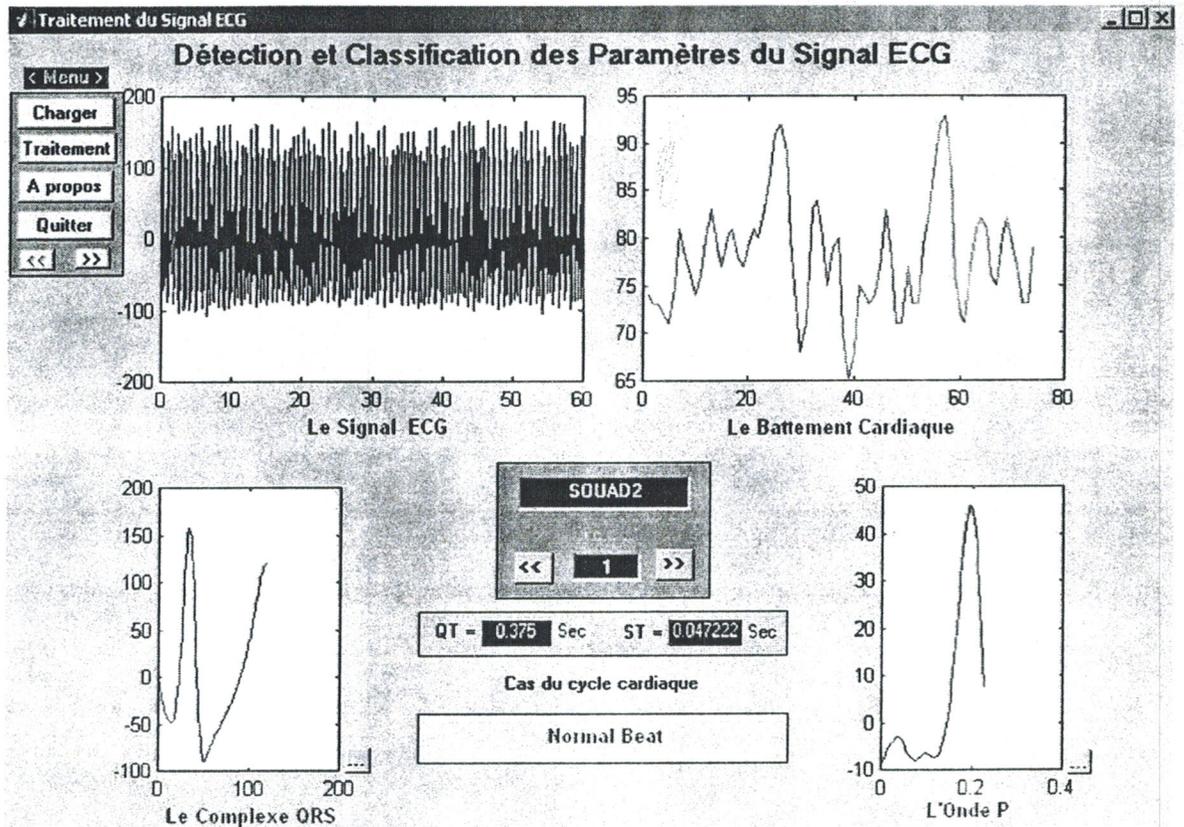


Fig. IV.3 Affichage du signal ECG et de ses paramètres.

Aussi, *ECG Pro* affiche le type (cas pathologique) de chaque cycle cardiaque ainsi que les valeurs QT et ST. En cliquant sur le bouton "Statistiques" une fenêtre apparaît au milieu de la fiche principale indiquant des informations sur le signal ECG en cours, à savoir : la durée du signal, nombre total de cycle cardiaque, nombre de cas normaux, nombre de cas anormaux et la fréquence cardiaque moyenne (FigIV.4).

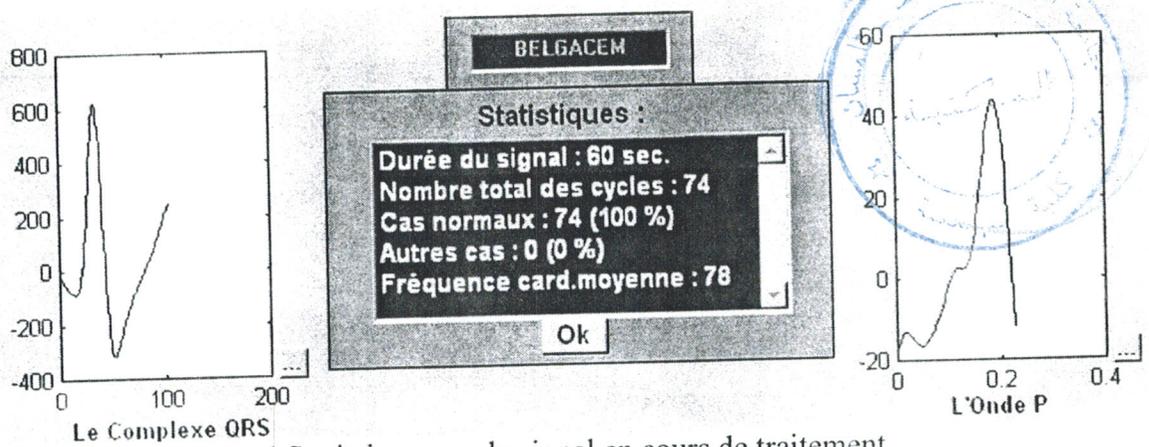


Fig. IV.4 Statistiques sur le signal en cours de traitement.

IV.3 Résultats

Les résultats présentés dans cette étude, pour la classification des signaux ECG ont été obtenus en appliquant à l'entrée de classificateur des signaux ECG de "MIT BIH Arrhythmia Database". Le tableau suivant présente les paramètres TP, TN, FP et FN calculés pour chaque signal :

| Signaux | TP | FP | TN | FN | Signaux | TP | FP | TN | FN |
|---------|-----|-----|------|----|---------|-----|-----|------|-----|
| 100 | 1 | 87 | 2182 | 0 | 119 | 444 | 7 | 1533 | 0 |
| 101 | 0 | 100 | 1762 | 0 | 121 | 1 | 17 | 1842 | 0 |
| 102 | 4 | 0 | 2124 | 0 | 123 | 3 | 0 | 1512 | 0 |
| 103 | 0 | 55 | 2026 | 0 | 200 | 678 | 39 | 1734 | 147 |
| 104 | 2 | 0 | 1558 | 0 | 203 | 430 | 483 | 2048 | 14 |
| 106 | 512 | 21 | 1484 | 7 | 210 | 170 | 377 | 2053 | 24 |
| 108 | 16 | 11 | 1732 | 0 | 221 | 251 | 13 | 2015 | 145 |
| 112 | 0 | 44 | 2492 | 0 | 228 | 280 | 2 | 1687 | 81 |
| 113 | 0 | 13 | 1773 | 0 | 230 | 1 | 349 | 1903 | 0 |
| 117 | 0 | 0 | 1532 | 0 | 234 | 3 | 1 | 2696 | 0 |

Tableau IV-1 Résultats de test du classificateur neuronal.



La sensibilité, spécificité et le taux de classification sont trois paramètres calculés pour chaque signal pour évaluer et comparer les résultats obtenus. Les performances du classificateur sont présentées dans le tableau IV.2.

| Signaux | battements | Normal | SE | SP | CC |
|---------|------------|--------|-------|-------|-------|
| 100 | 2272 | 2239 | 100 | 96.16 | 96.12 |
| 101 | 1864 | 1860 | NaN | 94.62 | 94.62 |
| 102 | 2186 | 99 | 100 | 100 | 100 |
| 103 | 2083 | 2082 | NaN | 97.35 | 97.35 |
| 104 | 2228 | 163 | 100 | 100 | 99.93 |
| 106 | 2026 | 1507 | 98.65 | 98.60 | 98.61 |
| 108 | 1762 | 0 | 100 | 99.36 | 99.37 |
| 112 | 2538 | 2536 | NaN | 98.26 | 98.26 |
| 113 | 1794 | 1789 | NaN | 99.27 | 99.27 |
| 117 | 1534 | 1534 | NaN | 100 | 100 |
| 119 | 1986 | 1543 | 100 | 99.54 | 99.64 |
| 121 | 1863 | 1861 | 100 | 99.68 | 99.08 |
| 123 | 1518 | 1515 | 100 | 100 | 100 |
| 200 | 2601 | 1743 | 82.18 | 97.88 | 92.84 |
| 203 | 2980 | 2529 | 96.84 | 80.91 | 83.29 |
| 210 | 2650 | 2423 | 87.62 | 84.48 | 84.71 |
| 221 | 2427 | 2031 | 73.38 | 99.35 | 93.48 |
| 228 | 2053 | 1688 | 80.96 | 99.88 | 95.95 |
| 230 | 2256 | 225 | 100 | 84.5 | 84.5 |
| 234 | 2753 | 2700 | 100 | 99.96 | 99.96 |

NaN : Not a Number.

Tableau IV-2 Performances du classificateur global en %.

Notre système de classification nous a permis d'obtenir un taux de reconnaissance de 95,84% en appliquant l'ensemble des signaux ECG de MIT BIH Database avec une spécificité de 96.49% et une sensibilité de 94.60%. Ces performances ont été obtenues principalement grâce à :

- L'exploitation des techniques neuronales,
- L'utilisation des procédures adéquates de traitement pour effectuer la détection et l'identification des différents paramètres d'un cycle cardiaque.
- La combinaison des caractéristiques des deux ondes (QRS et P) afin d'aider le classificateur à discriminer entre les différents cas pathologiques.
- L'utilisation d'une base de données réelle (MIT BIH Arrhythmias Database),

- Une méthode d'apprentissage permettant d'obtenir des performances optimales pour une valeur du seuil déterminée avant apprentissage.

Il est à noter que les performances d'un classificateur à base de réseaux de neurones sont en fonction du nombre de classes en sortie. Ce point nous a ramené à tester l'influence de nombre de classes sur la capacité de discrimination d'un classificateur. Nous avons développé un classificateur neuronal dont la sortie est constitué de deux classes seulement N et PVC [51]. Le taux de classification était de 97%, ce qui est nettement meilleurs que le taux obtenu dans la présente étude, raison pour laquelle la majorité des concepteurs de classificateurs des arythmies cardiaques [38, 52] se limitent à deux classes voir à une seule [53,54].

En réalité, le problème ne se pose pas pour un seul cas mais se pose pour un ensemble de cas pathologiques. La discrimination entre les différentes classes devient plus difficile pour la classification lorsqu'il s'agit de plusieurs classes. C'est dans ce cas que l'architecture du réseau devient plus compliqué surtout pour la classification des classes liées aux variations de la morphologie du complexe QRS et de l'onde P.

Dans le but d'obtenir un réseau plus réduit qui opère bien en termes de précision et rapidité de classification, il est nécessaire de réduire la dimension de données d'entrée. Pour cela, nous avons présenté le complexe QRS et l'onde P en deux paramètres par application de la LPC. Les résultats satisfaisantes qui ont été obtenus justifient la puissance et l'efficacité de cette technique pour la compression et la représentation réduite d'un cycle cardiaque notamment pour les cas pathologiques caractérisés par la variation de la morphologie des ondes, les intervalles et les durées séparants ces ondes.

Bien qu'une réduction de la dimension soit désirable, la variation d'erreur due à la réduction de la dimension ne doit pas sacrifier le pouvoir de discrimination du classificateur. Dans ce sens, plusieurs travaux ont été développés en se basant sur diverses techniques. K.Lin et al [38] et Fredric M. Ham et al [52] ont utilisé la prédiction linéaire pour développer leurs classificateurs des signaux ECG en deux classes (N et PVC). Yu Han Hu et al [55] et Nicos Maglaveras et al [40] ont adopté

Si on compare nos résultats avec ceux obtenus dans les autres études, on constate non seulement que nous avons amélioré les performances du classificateur, mais aussi que celles-ci sont obtenues avec un réseau qui possède une architecture minimale vis à vis du nombre de classes en sortie. Ce point est très important, car cela permet de :

- Minimiser le temps de réponse du classificateur surtout si on désire avoir un classificateur temps réel.
- Faciliter la mise en œuvre du classificateur (réalisation pratique), car il nécessite un nombre réduit de neurones et donc moins de connexion.

Notons finalement, qu'il est possible d'obtenir des performances légèrement meilleures en utilisant plus de neurones en couche cachée. Nous avons toutefois conservé l'architecture ci-dessus (tableau IV.3) afin de limiter la complexité algorithmique et le temps de réponse du logiciel *ECG Pro* (5 secondes pour le traitement d'un signal de durée d'une minute).

IV.4 Intérêt

L'évolution des outils de traitement du signal numérisé s'oriente vers leur intégration dans des systèmes d'informations plus large. Cette évolution permet de concevoir des programmes d'aide à la décision beaucoup plus pertinents et plus utiles pour le praticien. Le système développé, "*ECG Pro*", peut être intégré dans des environnements qui proposent des outils pour la réalisation de stations médicales multimédias en tenant compte de la majorité des cas pathologiques présentes au niveau de CHU de Tlemcen. L'intérêt d'une telle station de traitement du signal ECG (accueil, filtrage, détection, compression pour stockage puis classification) est :

- Le couplage d'un système informatique et de capteurs spécialisés augmente les capacités de perception du clinicien. Si l'œil peut visualiser sur un écran des modifications significatives d'amplitude, de formes ou de fréquence, des variations lentes ou plus complexes comme des modifications de l'intervalle RR d'un ECG, peuvent passer inaperçues.



- La qualité des tracés peut être améliorée automatiquement.
- Un tel système peut être lié à un système d'alarme qui permet d'attirer l'attention sur un changement de la situation du patient. Il peut s'agir de signaler des valeurs anormales (paramètres biologiques ou physiologiques) ou des modifications anormales (élévation ou abaissement brutale d'un paramètre).

IV.5 Conclusion

Dans ce chapitre, nous avons montré qu'il était possible d'utiliser un système neuronal pour à la fois détecter et classer les arythmies cardiaques. Nous avons montré que le système est relativement robuste (il permet la détection et la classification des cas pathologiques dont la morphologie est comparable à celle du bruit). D'autre part, le taux de classification obtenu est très acceptable, compte tenu des objectifs que nous nous étions fixés.

A la différence des autres approches que nous avons étudié, notre approche prend en considération la forme du signal représentant l'onde P, la forme du signal représentant le complexe QRS ainsi que les caractéristiques temporelles PP, PR et RR du signal cardiaque.

Afin d'évaluer les performances de cette approche, nous avons effectué un nombre important de tests, en appliquant les enregistrements ECG de MIT BIH Database ainsi que des signaux enregistré au sein de notre laboratoire. Nous sommes convaincu que la partie de l'étude de développement la plus délicate réside dans la détection et le choix des paramètres discriminantes utilisées. Ensuite, il suffit souvent d'appliquer quelques règles dont certaines ont été indiquées dans le chapitre précédent pour obtenir une architecture neuronale satisfaisante.

CONCLUSION GENERALE



CONCLUSION GENERALE

Dans le cadre de la conception d'un système de classification des arythmies cardiaques, nous avons utilisé les réseaux de neurones comme outils statistiques de classification. En raison de leur propriété d'approximation, les réseaux de neurones se sont révélés être des classificateurs très performants. Il faut noter que cette propriété est avantageuse, non seulement dans le cadre de la classification mais plus généralement, dans le cadre de la régression non linéaire, notamment pour la modélisation de processus statiques ou dynamiques.

Ces avantages, maintenant reconnus des réseaux de neurones, justifient le fait que l'on oriente les efforts de recherche vers la sélection des paramètres dérivants les classes. En effet, dans le domaine médicale, la formidable quantité de données (et donc des variables descriptives potentielles) à notre disposition rend obligatoire la sélection des meilleurs descripteurs de classes pour avoir une architecture optimale du réseau. Ainsi, en choisissant le réseau de neurones approprié au problème posé, nous évitons le phénomène de sur-apprentissage (*over training*) trop souvent rencontré dans la littérature et dans la pratique.

En d'autres termes, la méthode que nous avons développée propose un réseau de neurones adapté à la résolution du problème de classification des arythmies cardiaques. Elle permet d'atteindre l'objectif de tout classificateur : avoir un taux de classification élevé avec l'architecture la plus optimale possible. Cette méthode a donné de bons résultats sur les problèmes étudiés jusqu'à ce jour, néanmoins, de nouvelles évaluations restent à accomplir pour la valider et systématiser son emploi dans un domaine plus général de classification.

Pour l'identification des paramètres du signal ECG, on a présenté une technique basée sur la méthode de la dérivée, cette dernière permet une analyse des pentes, amplitudes et les intervalles entre différentes ondes constituant le signal cardiaque. Les résultats obtenus (taux de détection est de 96%) montrent clairement la puissance de cette technique dans la détection et l'identification des ondes constituant l'ECG. Il est important de noter qu'un algorithme d'aide au diagnostic

ne peut être performant que si la détection du signal est adéquate. Le prétraitement des données du réseau de neurones est un facteur contribuant énormément aux performances du système global. Des techniques de compression des données ont été présentées et étudiées sur des signaux cardiaques en particulier la prédiction linéaire, où nous avons montré son efficacité dans la compression de tels signaux. Une description détaillée a été faite des différentes étapes nécessaires à la conception d'un tel projet, ainsi que les fonctions utiles utilisées pour un traitement adéquat du signal cardiaque. L'approche que nous avons exploitée est celle que les cardiologues utilisent afin d'obtenir les informations nécessaires pour la prise de décision.

Cette étude de développement nous a permis de mettre en évidence un certain nombre de points relatifs à l'utilisation du perceptron multi couches (MLP) en particulier et des réseaux de neurones en général. Il a été constaté la nécessité de tenir compte de la forme des signaux ECG et des caractéristiques temporelles liés à chaque cycle cardiaque lors de la définition de l'architecture neuronale. La préparation de la mise en œuvre de la base d'apprentissage a monopolisé une bonne partie du temps de conception. Le recours à des données réelles s'est avéré particulièrement avantageux, d'une part pour la maîtrise de la définition du domaine de reconnaissance, et d'autre part pour évaluer les performances du système.

Le classificateur que nous avons proposé a été testé sur les enregistrements de MIT BIH Arrhythmia Database, le taux de classification globale était 95.84% pour une sortie constituée de six classes : N, V, F, P, A et Q (suivant l'annotation de la base de données de MIT). Les résultats obtenus montrent une autre fois, que les classificateurs à base de réseaux de neurones présentent des propriétés intéressantes et de nombreux avantages par rapport aux autres classificateurs statistiques. Au cours de cette phase de développement, il est nécessaire de définir plusieurs architectures neuronales. Ces architectures ont été mises au point pour tester diverses possibilités dans le but d'améliorer les performances de notre système de détection et classification.

Notre système peut intervenir dans toutes les phases de processus de recueil (filtrage et moyennage), de traitement de signaux (détection et extraction des

paramètres pertinents du signal ECG) et pallier les limites humaines de perception et d'interprétation (classification en six classes fondamentales). Il peut ainsi améliorer la qualité des signaux (affichage sur écran) et faciliter leur interprétation (statistiques en % des cas pathologiques), donc il apporte une aide directe à la prise de décisions médicales.

Ce travail a ouvert de nouvelles perspectives dans le domaine de traitement des signaux physiologiques et plus particulièrement la classification des signaux ECG. Cependant, il reste encore des points à étudier et à développer plus profondément :

- *Algorithme de détection* : étude de nouvelles méthodes d'extraction des paramètres du signal ECG et utiliser des algorithmes plus performants et qui présentent l'avantage de la détection en temps réel.
- *Type de réseau de neurones* : étude des différents types de réseaux de neurones (RBF, Récurrents, etc.) avec la possibilité d'utiliser d'autres techniques utilisées pour l'amélioration des performances du réseau comme par exemples : les algorithmes génétiques, le recuit simulé, etc.
- *Méthode d'apprentissage* : lancer l'apprentissage en utilisant les différentes méthodes existantes et comparer leurs performances.
- *Méthode de compression et réduction des paramètres* : ce point est très important dans la conception des classificateurs, donc une étude détaillée des différentes techniques utilisées dans la réduction des nombres de variables d'entrée de classificateur est souhaitable.

BIBLIOGRAPHIE

- [1] S.Assous : "Etude et analyse de la variabilité de la fréquence cardiaque HRV ", *Thèse de magister en électronique (option : signaux et systèmes), Université Abou Bekr Belkaid, dépt d'électronique. 1999.*
- [2] Z.Hadj Slimane : "Analyse de signal ECG en vue d'aide au diagnostic de cas pathologique", *Thèse de magister en électronique (option:signaux et systèmes), Université Abou Bekr Belkaid, dépt d'électronique. 1998.*
- [3] S.A.Chouakri : "Etude des paramètres du signal ECG en vue du diagnostic des arythmies cardiaques", *Thèse de magister en électronique (option:signaux et systèmes), Université Abou Bekr Belkaid, dépt d'électronique. 1997.*
- [4] M.Bachiri : "Classification de signaux ECG en utilisant l'approche neuronale", *PFE pour l'obtention du diplôme d'ingénieur d'état en électronique, Université Abou Bekr Belkaid, dépt d'électronique. 1999.*
- [5] D.Thomas : "Cardiologie", *édition Ellipses. 1994.*
- [6] R.M.Allal et A.Abdulrahman : "Etude et réalisation d'une station télésurveillance cardio-respirographique", *PFE pour l'obtention du diplôme d'ingénieur d'état en électronique, Université Abou Bekr Belkaid, dépt d'électronique. 1999.*
- [7] R.Rullière : "Eletrocardiographie", *3^{ème} édition, édition Masson. 1984.*
- [8] J.Gay, M.Desnos, P.Benoit : "L'électrocardiogramme: Savoir l'interpréter", *édition Trison-Roche. 1990.*
- [9] MIT BIH Arrhythmia Database Directory. *Third edition, Harvard MIT Division of Health Sciences and technology, Biomed. Eng. Center. 1992.*
- [10] G.B.Moody: "ECG Database Programmer's Guide", *Ninth edition, Harvard MIT Division of Health Sciences and technology, Biomed. Eng. Center. 1997.*
- [11] P.Degoulet, M.Fieschi : " Informatique médicale", *3^{ème} édition, édition Masson, 1998.*
- [12] Paul.A lynn, Wolfgang Fuerst : "Digital Signal Processing", *second edition, édition john Wiley & Sons, 1998.*
- [13] Francis Cottet : "Traitement des signaux et acquisition de données". *édition Dunod, 1997.*
- [14] M.B.Gordon, H.P.Moisy : "Sciences cognitives", *édition Hermes. 1997.*
- [15] B.Kosko: "Neural Network for signal processing", *édition Prentice-Hall. 1992.*
- [16] P.Antognetti and V.Milutinovic: "Neural Networks", *volume II, édition Prentice-Hall. 1991.*

- [17] S.Thiria, Y.Iechevallier,O.Gascull and S.Canu : " Statistiques et méthodes neuronales", *édition Dumod. 1997.*
- [18] N.Izboudjen : "Conception et réalisation en FPGA d'un classificateur neuronal des arythmies cardiaques", *Thèse de magister en électronique (option : télécommunication), Ecole National Polytechnique. 1999.*
- [19] M. Mokhtari et A. Mesbah : "Apprendre et maîtriser MATLAB", *édition Springer, 1997.*
- [20] J.Pan and W.P. Tompkins: "A real-time QRS detection algorithm", *IEEE trans. Biomed. Eng., vol. BME-32, no 3, pp. 230-236, Mar.1985.*
- [21] L.Keselbrener, M.Keselbrener and S.Akselrod : "Nonlinear high pass filter for R wave detection in ECG signal", *Med. Eng. Phys. Vol 19,n°5,pp.481-484. 1997.*
- [22] Y.Sun,T.A.Wrublewski,D.Kunarbasu : "Microcontroller-based real time QRS detection", *Biomed. Instrumentation and technology, November/December 1992.*
- [23] Z.Dokur, T.Olmez,E.Yazgan and O.K.Ersay : "Detection of ECG waveforms by neural networks", *Med. Eng. Vol 19,n°8,pp.738-741. 1997.*
- [24] C.Jerry Whitaker : "Signal Measurement, Analysis and Testing", *édition CRC Press. 2000.*
- [25] T.Y.Lo and P.C.Tang : "A fast bandpass filter for ECG processing", *Proc. IEEE Eng. Med. Biol. Soc. 4th Annu. Int. Conf, pp: 20-21,1982.*
- [26] P.Laguna, R.Jané, S.Olmos, N.V.Thakor, H.Rix, P.Caminal : "Adaptive estimation of QRS complex wave feature of ECG signal by the Hermite model". *Medical And Biological Eng. And Coputing. January 1996.*
- [27] P.Laguna, N.V.Thakor, P.Caminal, H.Yoon: "New algorithm for QT interval analysis in 24-hour Holter ECG: performance and application", *Medical & Biological Eng. & Computing. January 1990.*
- [28] Marek Malik, A.J. Camm : "Heart Rate Variability", *édition Futura. 1995.*
- [29] N.Belgacem, M.A.Chikh, F.Meghnefi, F.Bereksi reguig : "Détection et identification des paramètres du signal ECG", *acte soumis au Séminaire National sur l'Automatique et les Signaux SNAS'02, Annaba : 27-28 octobre 2002.*
- [30] J.François Mari et Amedeo Napoli : "Aspects de la classification". *Rapport de recherche. Acte de la journée "classification" organisée à l'INRIA LIAB. Champenoux. INRIA. Juin 1996.*
- [31] M.Kundo, M. Nasipuri,D.Kumar Basu: " Knowledge-based ECG interpretation: a critical review", *Pattern Recognition n°33,pp.351-373. 2000.*

- [32] G.D.Barmilas and E.S.Skordolakis : "A novel family of compression algorithms for ECG and other semiperiodical one-dimensional biomedical signals", *IEEE Transaction on Biomed. Eng. Vol 43,n°8, August 1996.*
- [33] J.S.Paul,M.R.Reddy, J.Kumar : "A QRS estimator using linear prediction approach", *Signal Processing n°72,pp.15-22. 1999.*
- [34] Y.Zigel,A.Cohen and A.Katz : " ECG signal compression using analyzing synthesis coding", *IEEE Transaction on Biomed. Eng. vol 47, N°10, October 2000.*
- [35] M.A.Chikh, N.Belgacem, F.Meghnefi, F.Bereksi-Reguig : " Artificial Neural Network Classifier (ANNC) in classification of normal and abnormal PVC beats in ECG", *Conférence sur le Génie Electrique CGE'01, Ecole Militaire Polytechnique le 25-26 décembre 2001.*
- [36] M.A.Chikh, N.Belgacem, F.Bereksi-Reguig : "Classification of ECG beat by neural networks", *1^{er} Séminaire National sur le Contrôle et les Signaux SNCS'2001, Djelfa 30 et 31 octobre 2001.*
- [37] Kang Ping Lin and W.H.Chang:" QRS feature extraction using linear prediction", *IEEE Transaction on Biomed. Eng. vol 36, N°10, October 1989.*
- [38] F. Ellie: "Conception et réalisation d'un système utilisant les réseaux de neurones pour l'identification et la caractérisation, à bord de satellite, de signaux transitoires de type sifflements", *Thèse pour l'obtention de grade de docteur de l'université d'Orléans en électronique. CNRS. 1997.*
- [39] J.Collec and L.Bouzidi : "Utilisation du raisonnement par cas pour élaboration d'un système d'aide à la décision en médecine", *Revue Informatique n°1, pp.17-22. 2001.*
- [40] N.Magalaveras,T.Stamkopoulos, K.Diamantaras,C.Pappas,M.Strintzis : " ECG pattern recognition and classification using non linear transformations and neural networks : a review", *International journal of medical informatics.52, pp.191-208, 1998.*
- [41] B.Muller, J.Reinhardt, M.T.Strickland : "Neural Networks : an introduction", *édition Springer, 1995.*
- [42] Hervé Abdi : "les réseaux de neurones", *édition Press Université de Grenoble, 1994.*
- [43] C.D.Nugent, J.A.C.Webb,N.D.Black, G.T.H.Wright, M.Mc Intyre : "An intelligent framework for the classification of the 12 lead ECG", *Artificial Intelligence in Medecine,16,pp.205-222, 1999.*

- [44] D.Price, S.Knerr, L.Personnaz and G.Dreyfus : "Pairwise neural network classifiers with probabilistic outputs", *Neural information processing systems, vol7, 1994*.
- [45] J.A.Hertz,A.S.Krogh and R.G.Palmer : "Introduction to the theory of neural computation", *Artificial Intelligence. 1993*.
- [46] Neural Network FAQ, téléchargé de: <ftp://ftp.sas.com/pub/neural/faq.html>, by Warrens S.Sarle Cary, NC, USA (saswss@unx.sas.com), Copyright 2000.
- [47] Jean-Pierre Changeux : "L'homme neuronal", *édition Hachette, 1984*.
- [48] Jean-Pierre Nadal : "Réseaux de neurones : de la physique à la psychologie", *édition Armand Colin, 1993*.
- [49] H.Demuth, M.Beale : "Neural Network Toolbox for use with Matlab", *Version 3*.
- [50] Building GUIs with MATLAB, *Version 5*.
- [51] M.A.Chikh, N.Belgacem: "Classification des arythmies cardiaques par l'approche neuronale", *1^{er} forum sur la recherche en santé. Tlemcen, 07 juin 2001*.
- [52] Fredric M.Ham and Soowhan Han : " Classification of cardiac arrhythmias using Fuzzy ARTMAP", *IEEE Transaction on Biomed. Eng. vol 43, N°4, April 1996*.
- [53] G.Gunnar, P.Eriksson, M.dellborg : "ECG criteria in diagnosis of acute Myocardial infraction in the presence of the left bundle branch block", *Internationnal Journal of Cardiology, n°78, pp.167-174, 2001*.
- [54] B.Hedden, M.Ohlsson, R.Ritner, O.Pahlm, W.K.Haisty, G.Peterson, L.Edenbrandt : "Agreement between neural networks and human experts for the electrographic dignosis of healed myocardial infraction", *Journal of the American college of cardiology, n°28, pp.1012-1016, 1996*.
- [55] Yu Han Hu, S.Palreddy and W.J.Tompkins : " A patient adaptable ECG beat classifier using a mixture of experts approach", *IEEE Transaction on Biomed. Eng. vol 44, N° 9, September 1997*.
- [56] R.Silipo, M.Gori, A.Tddei, M.Varanini and C.Marchsei: "Classification of arrhythmic events in ambulatory ECG using artificial neural networks", *Computers and Biomed. Reseach, n°28, pp.305-318, 1995*.

ANNEXES

ANNEXE A

Format des fichiers de MIT BIH.

ANNEXE B

Algorithmes d'apprentissage.

ANNEXE C

Contenu des fichiers de MIT.

ANNEXE A**Format de fichiers de MIT BIH Database.**

ECG database signal exist in several formats. Any of these formats can be used for multiplexed signal files, in which samples from two or more signals are stored alternately.

Format 8

Each sample is represented as an 8 bit first difference; i.e., to get the value of sample n , sum the first n bytes of the sample data file together with the initial value from the header file. When format 8 files are created, first differences which cannot be represented instead by the largest difference of the appropriate sign (-128 or +127), and subsequent differences are adjusted such that the correct amplitude is obtained as quickly as possible. Thus the samples read from a format 8 file may not always be identical to those read from an equivalent format 16 file. One-line signal files on magnetic disk are often kept in format 8 to save space. Note that the first differences stored in multiplexed format 8 files are always determined by subtraction of successive samples from the same signal.

Format 16

Each sample is represented by a 16-bit two's complement amplitude stored least significant byte first. Any unused high-order bits are sign-extended from the most significant bit. Most of the signal files on the MIT BIH Arrhythmia Database CD-ROM are format 16 files. The formats used for MIT BIH and AHA database distribution 9-track tapes is format 16, with the addition of a logical EOF and null-padding after the logical EOF.

Format 61

Each sample is represented by a 16-bit two's complement amplitude stored most significant byte first.

Format 80

Each sample is represented by an 8-bit amplitude in offset binary form (i.e., 128 must be subtracted from each unsigned byte to obtain a signed 8-bit amplitude).

Format 160

Each sample is represented by a 16-bit amplitude in offset binary form (i.e., 32,768 must be subtracted from each unsigned byte pair to obtain a signed 16-bit amplitude). As for format 16, the least significant byte of each pair is first.

Format 212

Each sample is represented by a 12-bit two's complement amplitude. The first sample is obtained from the 12 least significant bits of the first byte pair (stored least significant byte first). The second sample is formed from the 14 remaining bits of the first byte pair (which are the 4 high bits of the 12-bits sample) and the next byte (which contains the remaining 8 bits of the second sample). The process is repeated for each successive pair of samples.

Format 310

Each sample is represented by a 10-bit two's complement amplitude. The first sample is obtained from the 11 least significant bits of the first byte pair (stored least significant byte first), with the low bit discarded. The second sample comes from the 11 least significant bits of the second byte pair, in the same way as the first. The third sample is formed from the 5 most significant bits of each of the first two byte pairs (those from the first byte pair are the least significant bits of the third sample). The entire process is then repeated for each successive set of three samples.

ANNEXE B**Algorithmes d'optimisation**

A partir d'une fonction de coût dépendant du vecteur de paramètres θ et des exemples de l'ensemble d'apprentissage, il faut choisir l'algorithme d'optimisation qui permettra d'estimer le vecteur des paramètres pour lequel la fonction de coût choisie est minimale. De nombreux algorithmes ont été proposés ; dans ce paragraphe, nous décrivons la méthode utilisée pour les modèles linéaires par rapport aux paramètres, puis nous présentons les méthodes les plus fréquemment mises en œuvre pour l'apprentissage des réseaux de neurones.

1. Modèles linéaires par rapport aux paramètres :

Un modèle linéaire par rapport aux paramètres obéit à l'équation suivante (les vecteurs des entrées et de la sortie sont centrés) :

$$y = x\theta + \omega$$

Avec :

$$y = \begin{bmatrix} y^1 \\ \vdots \\ y^N \end{bmatrix} : \text{Vecteur de sortie de dimension } N \text{ (} N = \text{nombre d'exemples),}$$

$$X = \begin{bmatrix} x_1^1 \wedge x_p^1 & \vdots & x_1^N \wedge x_p^N \\ \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots \end{bmatrix} : \text{matrice des entrées, de dimension } N \times P \text{ (} P \text{ colonnes correspondant aux } P \text{ variables}$$

descriptives du modèle, et N lignes représentant les N exemples),

θ : Vecteur de dimension P des paramètres inconnus du modèle (dans ce cas, P est égale au nombre de descripteurs),

ω : Vecteur du bruit, centré, non corrélé, de dimension N , normalement distribué (de moyenne nulle et de variance σ^2).

Avec un tel modèle, l'estimation des moindres carrés des paramètres ($\hat{\theta}$) est la solution de l'équation normale :

$$X^T X \hat{\theta} = X^T Y \quad \text{Soit } \hat{\theta} = [X^T X]^{-1} X^T Y, \text{ si } \det(X^T X) \neq 0$$

La solution de cette équation peut être obtenue par diverses méthodes (décomposition de Cholesky, méthodes d'orthogonalisation, ...).

2. Modèles non linéaires par rapport aux paramètres :

Un modèle non linéaire par rapport aux paramètres est défini par (les vecteurs des entrées et de la sortie sont centrés) :

$$Y = f(X, \theta) + \omega \quad \text{avec } f : \text{fonction de régression.}$$

Si le modèle est non linéaire par rapport aux paramètres, les méthodes de résolution précédentes ne sont pas utilisables. Il faut alors se tourner vers des méthodes itératives pour obtenir une estimation des paramètres. Ces diverses méthodes sont assez simples à mettre en œuvre et s'appliquent à toutes les fonctions de coût $J(\theta)$ dérivables par rapport à θ . L'apprentissage des réseaux de neurones s'intègre dans ce cadre. Le principe de ces méthodes est de se placer en un point, de trouver une direction de descente du coût dans l'espace des paramètres θ , et ensuite, de se déplacer d'un pas suivant cette direction. On atteint un nouveau point et l'on recommence la procédure. On poursuit cette démarche jusqu'à satisfaction d'un critère d'arrêt. Ainsi la modification du vecteur de paramètres θ à l'itération k est donnée par l'équation :

$$\theta_k = \theta_{k-1} + \mu_{k-1} d_{k-1} \quad \text{Avec } d_{k-1} = \text{direction de descente, qui dépend des } d_{k-1} \text{ et } \mu_{k-1} = \text{pas.}$$

Les méthodes d'optimisation non linéaires que nous présentons se différencient par le choix de la direction de descente et du pas. Elles font appel aux :

- Gradient = vecteur des dérivées premières de J par rapport à θ , noté $\nabla J = \text{Grad}(J(\theta))$,
- Hessien = matrice des dérivées secondes de J par rapport à θ , notée $H = H(J(\theta))$.

Dans le cas des réseaux de neurones, on utilise l'algorithme de rétropropagation de l'erreur pour le calcul du gradient. On utilise en général une approximation du Hessien pour les méthodes de quasi-Newton ou Levenberg-Marquardt. Néanmoins, le Hessien peut évidemment être calculé exactement.

2.1. Méthode du gradient à pas constant :

C'est la méthode la plus simple à mettre en œuvre ; elle ne repose que sur le calcul du gradient qui donne la direction de descente. Le pas μ est constant. Ainsi, à l'itération k , la modification des paramètres est donnée par :

$$\theta_k = \theta_{k-1} - \mu \nabla d_{k-1} \quad \text{ici } d_{k-1} = -\nabla J_{k-1} \quad \mu_{k-1} = \mu \text{ (constant).}$$

Cette méthode est très simple d'utilisation et elle est efficace loin d'un minimum (à condition de ne pas être sur un plateau de la fonction de coût). En revanche, lorsque l'on s'approche du minimum, le gradient tend vers 0 et la vitesse de convergence diminue très fortement.

2.2. Méthode du gradient à pas variable :

Pour une direction de descente choisie par le gradient ou une autre méthode (voir ci-dessous), il est possible d'asservir le pas μ de telle sorte que la fonction de coût diminue à chaque modification des paramètres. On s'intéresse donc à la fonction $g(\mu)$ unidimensionnelle définie par :

$$g(\mu) = J(\theta_{k-1} + \mu d_{k-1})$$

A partir de la fonction g , il faut trouver une valeur convenable (ni trop petite pour assurer une convergence rapide, ni trop grande pour ne pas être confronté à un comportement oscillatoire). Les méthodes les plus efficaces sont les méthodes de dichotomie mais nécessitent souvent trop de calculs. Les méthodes de minimisation de Nash et de Wolfe et Powell sont plus économiques et permettent de trouver une valeur du pas convenable à partir d'un faible nombre d'évaluations de la fonction de coût $J(\theta)$.

2.3. Méthode de Newton :

La méthode de Newton utilise la courbure (dérivée seconde) de la fonction de coût pour atteindre le minimum plus rapidement. La modification des paramètres est donnée par :

$$\theta_k = \theta_{k-1} - H_{k-1}^{-1} \nabla J_{k-1} \quad \text{ici } d_{k-1} = -H_{k-1}^{-1} \nabla J_{k-1} \quad \mu_{k-1} = 1 \text{ (constant).}$$

Ici le pas est constant et égal à 1. La direction de descente est fonction du Hessien et du Gradient. Si $J(\theta)$ est une quadrique, l'algorithme atteint la solution en une seule itération. Sinon, cette méthode est très efficace au voisinage d'un minimum. Cependant, pour que la méthode converge vers le minimum, le Hessien doit être défini positif. Dans le cas général d'un modèle non linéaire, cette hypothèse de convergence n'est pas toujours respectée et la méthode peut ne pas converger. En pratique elle est peu employée car elle nécessite, de plus, le calcul du Hessien à chaque itération. On lui préfère des méthodes plus économiques dites de "quasi-Newton".

2.4. Méthode de quasi-Newton :

Ici, l'inverse du Hessien est approché par une matrice M_k définie positive modifiée à chaque itération. La suite des matrices $\{M_k\}$ est construite de manière à converger vers l'inverse du Hessien lorsque la fonction de coût $J(\theta)$ est une quadrique. La modification des paramètres est donnée par :

$$\theta_k = \theta_{k-1} - \mu_{k-1} M_{k-1} \nabla J_{k-1} \quad \text{ici } d_{k-1} = -M_{k-1} \nabla J_{k-1}$$

μ_{k-1} est évalué avec une méthode de minimisation unidimensionnelle

A la première itération, la matrice M_0 est prise égale à la matrice identité. Parmi toutes les méthodes de quasi-Newton existantes, l'outil de simulation et d'apprentissage de réseaux de

neurones du laboratoire propose la méthode BFGS, développée indépendamment par Broyden, Fletcher, Goldfarb et Shanno, dont la vitesse de convergence est beaucoup plus grande que celle de la méthode du gradient. De plus elle est relativement insensible au choix du pas qui peut être calculé avec la méthode de Nash.

2.5. Méthode de Levenberg-Marquardt :

La méthode de Levenberg-Marquardt consiste à modifier les paramètres selon la relation suivante :

$$\theta_k = \theta_{k-1} - [H_{k-1} + \lambda_{k-1} I]^{-1} \nabla J_{k-1} \quad \text{Avec } I = \text{Matrice Identité}$$

Cette méthode est particulièrement astucieuse car elle s'adapte d'elle-même à la forme de la fonction de coût. Elle effectue un compromis entre la direction du gradient et la direction donnée par la méthode de Newton. En effet, si λ_{k-1} est grand, on reconnaît la méthode du gradient (dans ce cas la valeur du pas est donnée par $1/\lambda_{k-1}$) et si λ_{k-1} est petit, la modification des paramètres correspond à celle de la méthode de Newton.

3. En résumé :

Chaque méthode d'optimisation possède des avantages et des inconvénients. La méthode de Levenberg-Marquardt présente un intérêt pratique car elle peut être utilisée sans avoir à choisir le pas ; elle est néanmoins plus lente, en général, que la méthode BFGS.

Bien entendu, aucune méthode ne conduit à coup sûr au minimum global. Il convient donc de se placer dans des conditions où les minima locaux sont aussi peu nombreux que possible. Pour pallier ce problème bien connu, diverses solutions ont été suggérées :

Utilisation d'algorithmes qui convergent à coup sûr vers le minimum global ou utilisation d'heuristiques telles que le recuit simulé. Ces méthodes sont très lourdes, et généralement inutiles dans le contexte de l'apprentissage des réseaux de neurones. En pratique, il suffit de réaliser plusieurs apprentissages en choisissant des paramètres initiaux différents. En procédant de la sorte, on possède une plus grande chance de trouver le minimum global. De manière surprenante, il semble que l'on ait consacré plus d'effort à s'efforcer de "sortir des minima locaux" qu'à essayer d'en diminuer le nombre.

ANNEXE C**Contenu des fichiers de MIT BIH Database**

| signaux | N | A | V | F | P | Q |
|---------|------|-----|-----|-----|------|----|
| 100 | 2239 | 33 | 1 | 0 | 0 | 0 |
| 101 | 1860 | 3 | 0 | 0 | 0 | 2 |
| 102 | 99 | 0 | 4 | 0 | 2028 | 0 |
| 103 | 2082 | 2 | 0 | 0 | 0 | 0 |
| 104 | 163 | 0 | 2 | 0 | 1380 | 18 |
| 105 | 2526 | 0 | 41 | 0 | 0 | 5 |
| 106 | 1507 | 0 | 520 | 0 | 0 | 0 |
| 107 | 0 | 0 | 59 | 0 | 2078 | 0 |
| 108 | 1740 | 4 | 16 | 2 | 0 | 0 |
| 112 | 2537 | 2 | 0 | 0 | 0 | 0 |
| 113 | 1789 | 0 | 0 | 0 | 0 | 0 |
| 114 | 1820 | 10 | 4 | 0 | 0 | 0 |
| 115 | 1953 | 0 | 0 | 0 | 0 | 0 |
| 116 | 2302 | 1 | 109 | 0 | 0 | 0 |
| 117 | 1534 | 1 | 0 | 0 | 0 | 0 |
| 119 | 1543 | 0 | 444 | 0 | 0 | 0 |
| 121 | 1861 | 1 | 1 | 0 | 0 | 0 |
| 122 | 2476 | 0 | 0 | 0 | 0 | 0 |
| 123 | 1515 | 0 | 3 | 0 | 0 | 0 |
| 200 | 1743 | 30 | 826 | 2 | 0 | 0 |
| 202 | 2061 | 36 | 19 | 1 | 0 | 0 |
| 203 | 2529 | 0 | 444 | 1 | 0 | 0 |
| 205 | 2571 | 3 | 71 | 11 | 0 | 0 |
| 207 | 0 | 107 | 105 | 0 | 0 | 0 |
| 208 | 1586 | 0 | 992 | 373 | 0 | 2 |
| 209 | 2621 | 382 | 1 | 0 | 0 | 0 |
| 210 | 2423 | 0 | 194 | 10 | 0 | 0 |
| 213 | 2641 | 25 | 220 | 362 | 0 | 0 |
| 214 | 0 | 0 | 256 | 1 | 0 | 2 |
| 215 | 3196 | 2 | 164 | 1 | 0 | 0 |
| 217 | 244 | 0 | 162 | 0 | 1542 | 0 |
| 219 | 2082 | 7 | 64 | 1 | 0 | 0 |
| 221 | 2031 | 0 | 396 | 0 | 0 | 0 |
| 222 | 2062 | 208 | 0 | 0 | 0 | 0 |
| 223 | 2029 | 72 | 473 | 14 | 0 | 0 |
| 228 | 1688 | 3 | 362 | 0 | 0 | 0 |
| 230 | 2255 | 0 | 1 | 0 | 0 | 0 |
| 233 | 2230 | 7 | 831 | 11 | 0 | 0 |
| 234 | 2700 | 0 | 3 | 0 | 0 | 0 |