

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

UNIVERSITÉ MENTOURI DE CONSTANTINE
FACULTÉ DES SCIENCES DE L'INGÉNIEUR
DÉPARTEMENT D'ÉLECTRONIQUE

Thèse

Présentée pour obtenir le diplôme de

Doctorat en Sciences

Spécialité : Electronique

Option : Traitement du signal

Par:

Mohamed Lamine TALBI

THEME

ANALYSE ET TRAITEMENT DU SIGNAL
ÉLECTROCARDIOGRAPHIQUE (ECG)

Devant le jury:

Président	A. BENNIA	<i>Professeur, Université de Constantine</i>
Rapporteur	A. CHAREF	<i>Professeur, Université de Constantine</i>
Examineurs	F.SOLTANI	<i>Professeur, Université de Constantine</i>
	L. HAMAMI	<i>Professeur, Ecole Nationale Polytechnique d'Alger</i>
	R. DJEMILI	<i>Maître de Conférence, Université de Skikda</i>

ANNÉE :2011

*A mes parents,
A ma femme et ma fille,
A mes sœurs et mes frères,*

Remerciements

Je tiens d'abord à remercier Monsieur Abdelhak Bennis d'avoir accepté la présidence de mon jury de thèse, ainsi que Madame Latifa Hamami, Monsieur Fouzi Soltani et Monsieur Rafik Djemili de m'avoir fait l'honneur de faire partie de mon jury de thèse.

Je remercie tout particulièrement Monsieur Abdelfatah Charef de m'avoir encadré durant ces années de doctorat en étant toujours disponible et encourageant, pour son aide et conseils et pour ses grandes valeurs humaines.

J'adresse mes remerciements à toute l'équipe du laboratoire traitement du signal de l'université Mentouri de Constantine.

Je voudrais remercier mes parents pour leur amour et leur soutien. Je remercie affectueusement, mes sœurs et mes frères pour leurs encouragements à poursuivre cette longue route.

Je n'oublierai pas de remercier ma femme Afaf pour sa patience et son soutien et son aide dans les moments difficiles.

Merci à tous ceux qui m'ont aidé de près ou de loin durant ces années de recherche et d'études. Je ne peux conclure sans un mot de remerciement à tous mes enseignants tout le long de ma formation.

Table des matières

Remerciements	v
Introduction Générale	1
 Chapitre I Le cœur et l'électrocardiographie	
1. Introduction	7
2. Anatomie du cœur.....	7
3. Activité mécanique cardiaque.....	7
4. La conduction électrique du cœur.....	9
5. L'Electrocardiogramme (ECG).....	10
5.1 Les dérivations	10
5.2 Ondes et Intervalles de L'ECG	13
6. Troubles du Rythme et de la Conduction Cardiaque	15
6.1 Rythme sinusal	15
6.2 Blocs cardiaques	15
6.2.1 Bloc Sino-Auriculaire (Bloc SA)	15
6.2.2 Blocs Auriculo-Ventriculaire (BAV)	15
6.2.3 Blocs de branche	16
7. Les arythmies cardiaques	16
7.1 Extrasystoles supra-ventriculaires.....	17
7.2 Contraction ventriculaire prématurée (extrasystole ventriculaire)	17
7.3 La tachycardie supra-ventriculaire.....	17
7.4 La fibrillation auriculaire.....	18
7.5 La tachycardie ventriculaire.....	18
7.6 Fibrillation ventriculaire.....	19
8. Artefacts visibles sur l'électrocardiogramme.....	20
8.1 Bruits techniques	20
8.2 Artefacts physiques	21
9. Conclusion.....	23

Chapitre II

Les réseaux de neurones artificiels

1. Introduction.	25
2. Eléments de base des réseaux de neurones.	26
2.1 Historique.	26
2.2 Du neurone biologique au modèle mathématique.	27
2.2.1 Le modèle neurophysiologique.	27
2.2.2 Le modèle mathématique.	27
2.3 Architecture des réseaux de neurones.	30
2.3.1 Les réseaux de neurones non bouclés (en Anglais feedforward)	30
2.3.2 Les réseaux de neurones bouclés (récurrents)	30
2.4 Les types d'apprentissage des réseaux de neurones.	31
2.4.1 L'apprentissage supervisé.	31
2.4.2 L'apprentissage non supervisé.	31
3. Les réseaux de neurones les plus utilisés.	32
3.1 Les Perceptrons	32
3.1.1 Le perceptron mono-couche (Perceptron simple)	32
3.1.2 Le perceptron multicouche (en anglais Multi Layer Perceptron)	33
3.2 Les réseaux à fonction radiale.	33
3.3 Les cartes auto-organisatrices de Kohonen (SOM)	33
3.4 Les réseaux de Hopfield.	33
3.5 Les réseaux ART.	34
4. Le classificateur perceptron multicouche.	34
4.1 Principe	34
4.2 Rétropropagation du gradient de l'erreur.	35
5. Les cartes topologiques de Kohonen.	37
5.1 Définition	37
5.2 L'apprentissage compétitif	38
5.3 Processus d'apprentissage du réseau de Kohonen.	39
5.4 L'algorithme d'apprentissage de Kohonen	39
6. Les différentes applications de RNA.	39
6.1 Reconnaissance des formes.	40

6.2 Modélisation.	40
6.3 Traitement de la parole.	40
6.4 Détection d'anomalies en médecine.	41
6.5 Traitements dépendant du temps	41
7. Conclusion.	41

Chapitre III

Discrimination et classification des anomalies cardiaques par RNA

1. Introduction.	44
2. Les systèmes automatiques de diagnostic cardiaque.	44
3. L'intelligence artificielle et l'ECG.	46
4. L'utilisation des RNA dans la classification des arythmies cardiaques	47
5. Discrimination des battements PVC	48
6. Les problèmes liés à la détection et la classification des désordres cardiaques	49
7. La génération des paramètres descriptifs.	50
8. Les techniques d'étude non supervisées et leurs applications dans la classification de l'ECG	50
9. Les avantages et les inconvénients de traitement par RNA.	51
9.1 Qualité et représentativité des données disponibles.	52
9.2 Algorithmes de détection.	52
9.3 Sélection /extraction des paramètres pertinents.	53
9.4 Étape de classification.	53
10. Conclusion.	54

Chapitre IV

Approximation de la DSP du complexe QRS par les pentes fractionnaires

1. Introduction.	57
2. Les fractales.	58
3. Loi de puissance inverse (processus $1/f$)	59
4. Invariance d'échelle temporelle d'un signal	61
5. Le cœur et le fractionnaire	61
6. Les caractéristiques fréquentielles de l'ECG.	62

7. Spectre de puissance du complexe de QRS.	63
8. La méthode proposée.	64
8.1 Prétraitement du signal	64
8.2 Les étapes de traitement (algorithme principal)	66
8.3 Choix de la fenêtre d'extraction des complexes QRS.	67
8.4 Spectre de puissance et calcul des pentes.	68
9. Conclusion.	70

Chapitre V

Résultats et discussions

1. Introduction.	72
2. Les anomalies cardiaques traitées	72
2.1 La contraction ventriculaire prématurée (Extrasystole ventriculaire)	73
2.2 Les Blocs.	75
3. La base de donnée MIT/BIH.	76
4. La première expérience : Discrimination des PVC par le réseau SOM	76
4.1 Extraction des pentes	77
4.2 Choix de la taille et de l'endroit de la fenêtre d'extraction.	77
4.3 Distribution des deux pentes.	78
4.4 Choix du réseau SOM.	79
4.5 Choix de la taille de la carte.	79
4.6 Evaluation des performances du réseau.	80
4.7 Choix des données d'apprentissage.	80
4.8 Résultats et discussion	81
4.9 Comparaison avec d'autres méthodes.	83
4.10 Conclusion.	84
5. La deuxième expérience: Discrimination du RBBB par MLP	85
5.1 Choix de la taille et de l'endroit de la fenêtre d'extraction.	85
5.2 Distribution des couples (pente1, pente2)	87
5.3 Choix de la classification par MLP.	87
5.4 Architecture du réseau.	87
5.5 Evaluation des performances du réseau.	89
5.6 Choix des données d'apprentissage.	89

5.7 Choix des données de la base de test.	89
5.8 Résultats et discussion.	90
5.9 Conclusion.	91
6. Conclusion.	92
Conclusion Générale.	94
Bibliographie.	97

Table des Figures

1.1 Anatomie du cœur et des vaisseaux associés.	8
1.2 Le système spécialisé d'excitation.	10
1.3 Montage d'Einthoven pour l'enregistrement des derivations bipolaires des membres	12
1.4 Dérivations unipolaires.	12
1.5 Dérivations thoraciques	13
1.6 Tracé ECG.	13
1.7 Exemples d'ECG : (a) normal et (b): bloc de branche gauche.	16
1.8 Tachycardie supra-ventriculaire.	18
1.9 Fibrillation auriculaire.	18
1.10 Tachycardie ventriculaire.	19
1.11 Fibrillation ventriculaire.	19
1.12 Interférence secteur 50 Hz.	20
1.13 Bruit dû aux mouvements des électrodes.	21
1.14 Dérive de la ligne de base.	22
1.15 Bruit myoélectrique ou tremblement somatique.	22
2.1 Schéma d'un neurone.	28
2.2 Schéma d'une synapse.	28
2.3 Neurone formel.	29
2.4 Différents types de fonctions d'activation pour le neurone artificiel.	29
2.5 Réseaux de neurones le plus utilisés.	32
2.6 Perceptron Multi Couches.	35
2.7 La cartes topologiques de Kohonen.	38
3.1 Représentation schématique d'un classificateur des signaux ECG.	45
4.1 Exemple d'une construction fractale la courbe de Von Koch.	58
4.2 Comportement en 1/f de la DSP du complexe QRS (rythme sinusal normal)	60
4.3 Comportement en 1/f de la puissance de la série RR du rythme cardiaque	61
4.4 Illustration schématique du système de conduction électrique ventriculaire du cœur. .	62
4.5 Densité spectrale de puissance du complexe QRS.	63
4.6 filtrage d'un signal ECG normal (Enregistrement 100 de MIT/BIH)	65
4.7 Filtrage d'un signal ECG avec un battement PVC (Enregistrement 221 de MIT/BIH)	66

4.8 Endroit de la fenêtre d'extraction du complexe QRS.	67
4.9 Spectre de puissance du complexe QRS dans deux cas considérés.	68
4.10 Approximation de la DSP du complexe QRS.	69
4.11 Histogrammes de différents types de battement.	69
4.12 La distribution de la deuxième Pente en fonction de la première Pente..	70
5.1 Contraction ventriculaire prématurée (PVC)	73
5.2 Extrasystole PVC.	74
5.3 Doublet ventriculaire.	74
5.4 Rythme de bigéminisme.	74
5.5 Rythme de trigéminisme.	74
5.6 Localisation des blocs standards le long des voies de conduction..	75
5.7 Distribution de Pente2 en fonction du Pente1 pour six enregistrements.	79
5.8 La carte SOM utilisée.	80
5.9 Emplacement de la fenêtre d'extraction du complexe QRS.	86
5.10 Bloc de branche droit et sa DSP correspondante (enregistrement 118)	86
5.11 Complexe QRS normal et sa DSP correspondante (enregistrement 212)	86
5.12 Distribution de la Pente2 en fonction de la Pente1 pour six enregistrements.	88
5.13 Réseau de neurone MLP utilisé.	89

Liste des tableaux

5.1 Annotation des battements de la base de données MIT-BIH	77
5.2 Résultat de clustering.	82
5.3 Résumé des résultats obtenus par la méthode proposée et autres méthodes	83
5.4 Résultats de la classification	90

Abréviations

ECG	Électrocardiogramme
NS	Nœud Sinusal
NAV	Nœud Auriculo Ventriculaire
ESV	Extrasystole Ventriculaire
PVC	Premature Ventricular Contraction (terme anglophone d'ESV)
BBD	Bloc de Branche Droit
RBBB	Right Bundle Branch Block (terme anglophone du BBD)
RNA	Réseaux de Neurones Artificiels
PMC	Perceptron Multi Couches
MLP	Multi Layer Perceptron (terme anglophone de PMC)
SOM	Self Organizing Maps Cartes topologiques de Kohonen Carte auto organisatrice Réseau de Kohonen
DSP	Densité Spectrale de Puissance
AAMI	Association for the Advancement of Medical Instrumentation

Introduction Générale

Introduction Générale

Le cœur est le muscle le plus fort du corps humain, et malgré sa puissance il est vulnérable à l'échec et au dysfonctionnement. Plusieurs types de maladies peuvent l'affecter, nous pouvons citer comme exemples: les arythmies (les extrasystoles, les fibrillations, les tachycardies, etc.) et les différents types de blocs de conduction (bloc de branche gauche et droite, bloc auriculo ventriculaire). Ces maladies ont diverses origines; elles peuvent être coronaires, hypertensives, inflammatoires ou rhumatismales [1]. Les maladies cardiovasculaires constituent l'une des principales causes de mortalité dans le monde, un taux de 60% de ces maladies est enregistré dans les pays en voie de développement où le médicament, le diagnostic et les normes vivantes de base ne sont pas fournis [2]. Pour ces raisons il y a un besoin urgent pour le développement de nouvelles méthodes de prévention, de détection et de traitement de ces maladies. Parmi les examens les plus couramment effectués pour la détection des maladies cardiovasculaires on distingue l'électrocardiogramme (ECG) qui est un signal de nature électro-physiologique dont le tracé matérialise l'activité électrique du cœur capté par des électrodes placées à la surface du corps. Dans le but d'exploiter au mieux les données ECG en grande quantité et dont l'analyse manuelle est difficile, les systèmes intelligents de diagnostic sont apparus. Ces systèmes permettent d'améliorer la qualité du signal (filtrage des bruits), le rehaussement des informations pertinentes, l'extraction des informations qui ne sont pas visibles par une analyse visuelle directe, ainsi que de proposer un diagnostic qui puisse apporter une aide suffisante pour permettre aux médecins non spécialistes ou débutants de prendre les bonnes décisions. Cependant, l'automatisation de la détection des maladies cardiovasculaires à partir du signal ECG n'est pas triviale, notamment parce qu'il est difficile d'extraire de ce dernier toutes les informations dont se sert le médecin pour faire un bon diagnostic. En outre, fournir à un système suffisamment de connaissances expertes pour automatiser le diagnostic est une tâche extrêmement coûteuse et fastidieuse.

Un système de traitement automatisé de l'ECG se compose généralement de quatre étapes successifs comme suit: le prétraitement du signal, la détection des ondes, l'extraction des paramètres pertinents, et enfin la classification/discrimination des anomalies [3]. L'étape de prétraitement (ou filtrage) du signal consiste essentiellement à éliminer les différents types de bruits qui affectent le signal ECG durant son acquisition (par exemple l'interférence à

50Hz avec l'alimentation des appareils de mesures, bruits liés aux électrodes, déviation de la ligne de base liée aux mouvements du cœur et du patient etc.). La détection a pour but la localisation des différentes ondes de l'ECG ainsi que la mesure de leur durée d'une façon exacte et fiable. Dans la littérature on trouve beaucoup d'algorithmes et techniques de détection [4-13]. Comme le complexe QRS est le plus important dans le cycle cardiaque, la détection de l'onde R est la plus recherchée dans la littérature. Les mesures faites sur le signal ECG après la détection peuvent être désignées sous le nom des vecteurs de paramètres caractéristiques. C'est dans l'étape extraction/sélection que se réalisent ces mesures. Ce vecteur des paramètres peut subir une autre étape de traitement avant la classification, Plusieurs techniques de sélection des paramètres pertinents peuvent être utilisées pour réduire la dimension du vecteur de paramètres comme la représentation temporelle [14], les intervalles RR [15], les fonctions Hermites [16], la modélisation autorégressive [17] et la transformée en ondelettes [18-20]. L'étape de sélection permet de choisir les paramètres les plus pertinents pour maximiser la divergence entre les classes, tout en maintenant toujours l'information suffisante pour permettre la discrimination.

Dans cette thèse, le premier axe de recherche abordé est la présentation d'une nouvelle méthode pour l'extraction des paramètres à partir du signal ECG en se basant sur le concept des fractales (fractionnaire). Ce concept est né d'une réflexion des mathématiciens sur la notion de dimension d'espace; il a été dévoilé par B. Mandelbrot [21-22]. Le concept des fractales est souvent lié à un autre concept aussi très important qui est le comportement en $1/f$ des processus et des phénomènes physiques. Ce comportement est souvent vu comme la manifestation ou l'effet d'une multitude de processus locaux évoluant dans le temps et qui provoquent simultanément ce type de processus. Ce comportement a été remarqué dans différents domaines de la nature tel que le bruit électrique [23], le phénomène de relaxation des impédances polarisées dans les milieux diélectriques [24], le rythme cardiaque [25], les membranes cellulaires [26], les ondes cérébrales [27], la densité spectrale de l'onde musicale, ainsi que les données en météorologie, en économie, et en statistique [28]. Les travaux de Goldberger et al [29] sur l'activation du myocarde ventriculaire ont prouvés que l'activation des ventricules par l'intermédiaire des fibres de Purkinje conduit à une dépolarisation fractale des ventricules et que cette dépolarisation est reflétée dans le complexe QRS. Goldberger et al ont prouvés aussi que le spectre du complexe QRS suit une loi de puissance inverse $1/f$ avec une pente de valeur fractionnaire. Cette caractéristique a été justifiée par la structure fractale

du réseau de conduction cardiaque et surtout les fines fibres de Purkinje fortement ramifiées [29-32]. Cette importante caractéristique sera la base de travail de cette thèse.

Le second axe de recherche abordé dans cette thèse est la classification et la discrimination des arythmies cardiaques. Les techniques utilisées dans cette tâche sont des réseaux de neurones alimentés par des paramètres pertinents extraits à partir du signal ECG. Dans la littérature, on trouve pas mal de techniques appliquant les approches de l'intelligence artificielle dans la classification automatisée de l'ECG, telles que l'approche bayésienne et heuristique [33], les modèles de Markov [34], la technique ART (Adaptive Resonant Theory) [35], les machines à support de vecteur (SVM) [36] et les réseaux de neurones artificiels (RNA) [37-38]. Les RNA ont été le choix le plus populaire dans le domaine de la classification automatisée du signal ECG pendant les deux dernières décennies. Ceci est peut être dû aux avancées faites dans les algorithmes d'apprentissages des RNA dans les années 80 leur donnant un niveau de classification comparable à ceux des approches déjà existantes et avec un temps de calcul nettement plus court [39-40]. La polyvalence des applications des RNA concernant leurs variables d'entrée dans le champ des applications liées aux maladies cardiaques est un autre avantage qui a poussé les chercheurs à abandonner les approches traditionnelles pour les RNA [41]. Donc, au lieu d'utiliser des données liées directement à l'ECG tel que l'amplitude, les intervalles temporels etc., les RNA peuvent être alimentés par n'importe quel ensemble de données extraites à partir du signal par des techniques de traitement du signal. Plusieurs architectures des RNA ont été employées dans le cas de la classification et la discrimination des anomalies cardiaques, les plus utilisées sont le perceptron multicouche [42], les réseaux à fonction radiale [43], les cartes auto-organisatrices de Kohonen (SOM) [44], les réseaux de Hopfield [45] et les réseaux ART [46-47].

Objectifs et motivations

Notre travail se situe dans le cadre de l'analyse automatique des troubles cardiaques. Une attention particulière est portée sur les battements ectopiques prématurés (PVC) et le bloc de branche droit (RBBB). Cette thèse propose une méthode originale de classification et de discrimination des anomalies cardiaques à partir d'une seule chaîne du signal ECG. La méthode proposée est basée sur l'utilisation de deux nouveaux paramètres extraits de la densité spectrale de puissance du complexe QRS pour discriminer les battements anormaux des battements normaux. Ces paramètres appelés pentes fractionnaires sont calculés par

interpolation linéaire de la densité spectrale de puissance (DSP) du complexe QRS dans deux intervalles différents de fréquence. La tâche de classification est réalisée par un réseau de neurones alimenté seulement par les deux paramètres qui représentent le complexe QRS ou plus généralement qui représente tout un battement.

Présentation de la thèse

Le premier chapitre de cette thèse présente sommairement l'électrophysiologie du cœur, l'électrocardiogramme, et notamment les différents types d'artefacts qui affectent le signal ECG enregistré. Ces notions sont indispensables pour la bonne compréhension des problèmes étudiés. Il permet, en particulier, de comprendre l'origine des signaux électriques enregistrés par l'électrocardiogramme et présente quelques pathologies cardiaques typiques illustrées chacune par un enregistrement ECG correspondant.

Le deuxième chapitre est consacré à la présentation des réseaux de neurones artificiels. Nous nous sommes concentrés principalement sur deux architectures neuronales qui sont généralement utilisées pour la classification des anomalies cardiaques: le perceptron multi couches (MLP) et le réseau SOM.

Le troisième chapitre donne un aperçu sur les différents étapes constituant un système automatique de diagnostic cardiaque. Une partie du chapitre est consacrée à la présentation d'un état de l'art sur l'application de l'intelligence artificielle dans la conception des systèmes automatiques de diagnostic cardiaque, notamment l'utilisation des réseaux de neurones dans l'étape de la classification avec les avantages et les inconvénients de traitement par RNA.

Pour bien comprendre la méthode utilisée pour l'extraction des paramètres discriminants du signal ECG, la première partie du chapitre 4 présente les concepts de la géométrie fractale, les processus $1/f$ ainsi que la relation entre le signal cardiaque et le calcul des pentes fractionnaires. Sa seconde partie est consacrée à la description détaillée de la méthode proposée d'extraction des paramètres pertinents qui comprend: le prétraitement du signal ECG, le calcul de la DSP du complexe QRS et l'approximation de cette DSP pour parvenir à ces paramètres qui seront utilisés dans la tâche de classification des anomalies cardiaques.

Le chapitre 5 présente les résultats et les discussions obtenus par l'application de la méthode de discrimination proposée en utilisant des électrocardiogrammes réels de la base de données MIT/BIH.

Enfin, une conclusion générale, présente une genèse des principaux résultats de cette thèse et les perspectives de ce travail de recherche.

Chapitre I

Le cœur et l'électrocardiographie

1. Introduction

Le système cardiovasculaire est constitué du cœur et du système vasculaire, sa fonction principale est d'assurer un flux de sang adéquat continu et sous pression suffisante aux organes et aux tissus afin de satisfaire aux besoins énergétiques et au renouvellement cellulaire quelles que soient les conditions ambiantes et l'activité de l'individu. Dans ce chapitre, l'introduction à la cardiologie est volontairement limitée aux notions utiles à la compréhension des chapitres suivants. Le lecteur intéressé pourra cependant trouver des informations complémentaires détaillées dans [48,3] et de manière plus intuitive dans [49,50].

2. Anatomie du cœur

Le cœur est un organe contractile assurant la circulation sanguine. C'est un muscle strié creux séparé en deux moitiés indépendantes (droite et gauche). Sa partie droite contient du sang pauvre en oxygène et assure la circulation pulmonaire; sa partie gauche renferme du sang riche en oxygène et le propulse dans tous les tissus. Chacune des moitiés comporte une oreillette et un ventricule qui communiquent par des valves d'admission qui, à l'état normal, laissent passer le sang uniquement de l'oreillette vers le ventricule. Il existe aussi des valves d'échappement qui assurent la communication entre le ventricule droit et l'artère pulmonaire (valve pulmonaire), ainsi qu'entre le ventricule gauche et l'artère aorte (valve aortique). Ces deux valves se trouvent à l'entrée de l'aorte et de l'artère pulmonaire respectivement. Sur la Figure (1.1), nous pouvons voir l'anatomie du cœur et des vaisseaux associés. Les parois du cœur sont constituées par le muscle cardiaque, appelé myocarde, composé d'un ensemble de cellules musculaires cardiaques ou cardiomyocytes [51].

3. Activité mécanique cardiaque

Le cycle de la circulation sanguine se répète constamment et se divise en deux périodes: la systole et la diastole.

La systole est la période correspondant à l'éjection du sang dans la grande et petite circulation. Elle se décompose en trois phases: la systole auriculaire, la contraction ventriculaire isovolumique et la systole ventriculaire [52].

- La systole auriculaire est la contraction des oreillettes lorsque celles-ci sont remplies de sang.
- La contraction ventriculaire isovolumique commence lorsque les cellules musculaires du myocarde ventriculaire se contractent.
- La systole ventriculaire commence lorsque les pressions dans les ventricules dépassent les pressions dans l'artère pulmonaire et l'aorte.




Figure 1.1 Anatomie du cœur et des vaisseaux associés.

La diastole est la phase de relaxation du cœur pendant laquelle il se remplit de sang. Cette période est composée de deux phases: la relaxation ventriculaire isométrique et la phase de repos.

- La relaxation ventriculaire fait suite à la systole. Les ventricules se relâchent, la pression chute jusqu'à être inférieure à celle exercée dans l'aorte et l'artère pulmonaire.
- La phase de repos est celle pendant laquelle le sang des veines caves et pulmonaires s'écoule librement dans les ventricules via les oreillettes.

4. La conduction électrique du cœur

La contraction du muscle cardiaque (ou myocarde) a pour origine la propagation d'une onde électrique qui excite les cellules musculaires dans un ordre bien établi afin que la contraction soit la plus efficace possible. Le système spécialisé d'excitation/conduction électrique comprend: le nœud sinusal, les voies spécialisées internodales, le nœud auriculo-ventriculaire (NAV), le faisceau de His, appelé nœud pacemaker dominant du cœur, les branches droite et gauche et les fibres de Purkinje, comme montré sur la Figure (1.2) [51,52].

L'activité électrique normale du cœur suit la séquence d'activation suivante :

- **Le nœud sinusal (NS) :**

L'activité électrique est générée spontanément dans le nœud sinusal qui est situé dans la partie haute de la paroi intérieure de l'oreillette droite, au niveau où débouche la veine cave supérieure. L'impulsion cardiaque initiée dans le nœud sinusal est transmise aux deux oreillettes. Cette activation est facilitée au moyen des voies spécialisées internodales qui relient le nœud sinusal au nœud auriculo-ventriculaire.

- **Le nœud auriculo-ventriculaire (NAV) :**

Il est situé en bas de l'oreillette droite et est constitué de cellules qui présentent une conduction électrique lente. L'activation électrique qui arrive au NAV est physiologiquement ralentie (approximativement 100 ms) avant d'arriver au faisceau de His. Cette propriété physiologique du NAV permet de protéger les ventricules d'un nombre excessif d'activations du NAV et d'activations auriculaires et concède aux oreillettes un temps de vidange plus grand, ce qui optimise la contraction ventriculaire.

- **Le faisceau de His :**

Il est situé dans la partie haute du septum interventriculaire et ses fibres traversent le tissu connectif (non excitable) qui sépare électriquement les oreillettes des ventricules. Dans les cas normaux, le NAV et le faisceau de His constituent la seule voie de propagation de l'activité électrique cardiaque entre les oreillettes et les ventricules. L'ensemble de ces deux structures est souvent appelé la jonction auriculo-ventriculaire. Le faisceau de His comprend un tronc initial qui se divise en deux branches, droite pour le ventricule droit et gauche pour le ventricule gauche.

- **Les fibres de Purkinje :**

Les branches du faisceau de His finissent dans un réseau de fibres qui arrivent dans les parois ventriculaires. Les fibres de Purkinje terminent en anastomoses avec les fibres myocardiques musculaires, facilitant leur excitation.




Figure 1.2 Le système spécialisé d'excitation.

5. L'Electrocardiogramme (ECG)

Le terme électrocardiogramme (ECG) désigne en général les techniques permettant de visualiser les différences de potentiel qui résultent de l'excitation du cœur. Ces potentiels naissent à la limite entre les zones excitées et celles non excitées du myocarde et sont mesurés entre deux points de la surface du corps. Une fibre cardiaque en cours de dépolarisation peut être assimilée à un dipôle électrique. A un instant donné le front de l'onde d'activation formé par l'ensemble des dipôles élémentaires crée un champ électrique qui est fonction des moments dipolaires. L'enregistrement de l'évolution temporelle du champ électrique résultant, effectué au moyen d'électrodes cutanées, est nommé l'électrocardiogramme de surface et appelé simplement ECG [50,54].

5.1 Les dérivations

Généralement les appareils électrocardiographiques peuvent enregistrer plusieurs différences de potentiel en même temps, selon l'emplacement et le nombre d'électrodes réparties sur le thorax et les membres. Chaque mesure de ces potentiels correspond à une dérivation de l'ECG. Un système de dérivations consiste en un ensemble cohérent de dérivations, chacune étant définie par la disposition des électrodes sur le corps du patient. L'emplacement des électrodes est choisi de façon à explorer la quasi-totalité du champ électrique cardiaque.

Si on mesure le vecteur cardiaque dans une seule direction, on ne sera pas en mesure de le caractériser entièrement. Il est donc important d'avoir un standard de positionnement des électrodes (dérivations) pour l'évaluation clinique du signal ECG. En pratique, douze dérivations sont utilisées dans les plans frontal et transversal pour explorer l'activité électrique du cœur. On distingue :

- **Trois dérivations bipolaires (ou dérivations standard) :**

Elles ont été déterminées par Einthoven (Einthoven, 1906) et ils sont appelées bipolaires car le potentiel est mesuré entre deux électrodes. Elles sont obtenues à partir des potentiels du DI, DII, DIII obtenues par permutation des électrodes placées sur le bras droit, le bras gauche et la jambe gauche de la manière suivante :

$$D_I = V_L - V_R$$

$$D_{II} = V_F - V_R$$

$$D_{III} = V_F - V_L$$

Où V_R correspond au potentiel au bras droit, V_L correspond au potentiel au bras gauche et V_F correspond au potentiel dans la jambe gauche. La jambe droite est reliée à la masse. Les vecteurs obtenus forment alors un triangle équilatéral appelé triangle d'Einthoven comme donné sur la Figure (1.3).

- **Trois dérivations unipolaires aVR, aVL, aVF :**

Les dérivations unipolaires des membres permettent d'étudier l'activité électrique du cœur sur le plan frontal. Elles ont été déterminées par Wilson (Wilson et al, 1934). Ces dérivations permettent de mesurer la tension entre un point de référence et le bras droit, le bras gauche et la jambe gauche respectivement. Le point de référence est réalisé par la moyenne des signaux qui apparaissent sur les deux autres membres qui ne sont pas en observation. A cet effet, on utilise des résistances de valeur élevée, supérieure à $5M\Omega$. La Figure (1.4) montre les dérivations unipolaires.




Figure 1.3. Montage d'Einthoven pour l'enregistrement des dérivations bipolaires des membres.




Figure 1.4. Dérivations unipolaires.

- Six dérivations précordiales :

Ce sont des dérivations unipolaires mises au point par Wilson (Wilson et al, 1944). Elles sont posées sur le thorax et sont désignées par la lettre V suivie du numéro de leur emplacement. Le potentiel de l'électrode exploratrice est pris par rapport à la moyenne des potentiels V_L , V_R et V_F . Six points, définis par Wilson, permettent d'obtenir les dérivations V1 à V6. Leur emplacement est représenté sur la Figure (1.5).




Figure 1.5 Dérivations thoraciques.

5.2 Ondes et Intervalles de L'ECG

Le processus de dépolarisation et de repolarisation des structures myocardiques se présente dans l'ECG comme une séquence de déflexions ou ondes superposées à une ligne de potentiel zéro, appelée ligne isoélectrique ou ligne de base. Ces déflexions sont dites positives si elles sont situées au-dessus de la ligne isoélectrique sinon elles sont dites négatives. Pour chaque battement cardiaque l'ECG enregistre principalement trois ondes successives [53,54] comme montré sur la Figure (1.6).




Figure 1.6 Tracé ECG.

- L'onde P:

Elle représente la dépolarisation auriculaire. Cette onde peut être positive ou négative avec une durée de l'ordre de 90 ms. Généralement son observation est difficile, spécialement dans des conditions bruitées. Il faut noter que la repolarisation auriculaire n'est pas visible sur l'ECG car elle coïncide avec le complexe QRS d'amplitude plus importante.

- Le complexe QRS:

Il correspond à la dépolarisation ventriculaire précédant l'effet mécanique de contraction et il possède la plus grande amplitude de l'ECG. Il est constitué de trois ondes consécutives : l'onde Q qui est négative, l'onde R qui est positive dans un ECG normal et l'onde S qui est négative. Sa durée normale est comprise entre 85 et 95 ms.

- L'onde T:

Elle correspond à la repolarisation des ventricules, qui peut être négative, positive ou bi-phasique et qui a normalement une amplitude plus faible que le complexe QRS. Bien que la dépolarisation et la repolarisation des ventricules soient des événements opposés, l'onde T est normalement du même signe que l'onde R, ce qui indique que la dépolarisation et la repolarisation ne sont pas symétriques.

L'ECG est aussi caractérisé par plusieurs intervalles comme on peut voir sur la Figure (1.6):

- L'intervalle RR:

Il est délimité par les sommets de deux ondes R consécutives et d'où est évaluée la fréquence cardiaque instantanée. Cet intervalle est utilisé pour la détection des arythmies ainsi que pour l'étude de la variabilité de la fréquence cardiaque.

- Le segment ST:

Il représente l'intervalle durant lequel les ventricules restent dans un état de dépolarisation actif. Il est aussi défini comme la durée entre la fin de l'onde S et le début de l'onde T.

- L'intervalle PQ:

Il représente l'intervalle de temps entre le début de la dépolarisation des oreillettes et le début de la dépolarisation ventriculaire. Il représente le temps nécessaire à l'impulsion électrique pour se propager du nœud sinusal jusqu'aux ventricules et il est mesuré entre le début de l'onde P et le début du complexe QRS.

- L'intervalle QT:

Il représente la durée entre le début du complexe QRS et la fin de l'onde T. Cet intervalle reflète la durée de la dépolarisation et repolarisation ventriculaire. En effet sa dynamique peut être associée à des risques d'arythmie ventriculaire et de mort cardiaque soudaine.

6. Troubles du rythme et de la conduction cardiaque

Sous cette dénomination on regroupe les arythmies cardiaques et les blocs cardiaques. Le meilleur outil pour diagnostiquer une arythmie est l'électrocardiogramme. Dans l'analyse de l'ECG, les pathologies ou anomalies sont détectées et classées en fonction de leur déviation par rapport au rythme idéal qu'est le rythme sinusal. Chaque déviation visible sur l'ECG peut être attribuée à une anomalie physiologique [54,2].

6.1 Rythme sinusal

Le rythme sinusal est le rythme normal cardiaque. Il correspond à une activation physiologique des oreillettes, puis des ventricules, à partir du nœud sinusal. Son rythme est compris entre 60 à 80 battements par minute avec un intervalle régulier entre des battements normaux. Le cœur s'accélère normalement lors de l'activité physique, dans les circonstances physiologiques qui exigent un surcroît de demande métabolique ou sous l'effet des émotions ou d'excitants tels que café, tabac et alcool.

6.2 Blocs cardiaques

Les blocs cardiaques sont dus à une rupture de conduction du myocarde qui altère la dépolarisation. Ces ruptures peuvent être plus ou moins sévères : freinantes (allongement du temps de parcours), intermittentes (le blocage de la conduction se fait aléatoirement), ou complète (aucune conduction).

6.2.1 Bloc Sino-Auriculaire (Bloc SA)

Le nœud sinusal peut ne pas transmettre de stimulus aux cellules des oreillettes. La conséquence est qu'au moins un cycle complet n'est pas effectué. Après la pause, due au bloc, le cycle reprend normalement si aucun autre foyer ectopique n'a déclenché la contraction.

6.2.2 Blocs Auriculo-Ventriculaire (BAV)

On appelle BAV l'altération de la conduction du stimulus de dépolarisation entre les oreillettes et les ventricules.

6.2.3 Blocs de branche

Le bloc de branche est dû au blocage de la dépolarisation dans une des branches du faisceau de His. Un bloc dans l'une ou l'autre branche provoque un retard dans la dépolarisation du ventricule auquel elle appartient. La dépolarisation des ventricules est désynchronisée et le complexe QRS est élargi par rapport à l'ECG normal comme montré sur la Figure (1.7).




Figure 1.7 Exemples d'ECG : (a) normal et (b): bloc de branche gauche.

7. Les arythmies cardiaques

Elles sont une cause majeure de mortalité et constituent une partie très importante de la problématique des maladies cardiovasculaires. L'arythmie survient lorsque l'excitation électrique naît hors du nœud sinusal, dans le nœud atrio-ventriculaire ou les ventricules par exemple, ou que l'onde électrique ne suit plus les voies préférentielles de propagation. La contraction cardiaque qui en résulte s'écarte du rythme normal. Le battement supplémentaire qu'elle provoque se nomme extrasystole, par opposition à la contraction normale nommée systole. On classe les arythmies en fonction de leur lieu de formation et de leurs effets sur le rythme cardiaque. Si le trouble se déclare dans les oreillettes ou le nœud atrio-ventriculaire, on parlera d'arythmie supra-ventriculaire; s'il apparaît dans les ventricules, on parlera d'arythmie ventriculaire. Si une arythmie accélère le rythme cardiaque, on parlera de tachycardie (tachy = rapide); si elle le ralentit, on parlera alors de bradycardie (brady = lent) [2].

7.1 Extrasystoles supra-ventriculaires

Une extrasystole supra-ventriculaire est caractérisée par une stimulation cardiaque prématurée par rapport au rythme de base. Selon son origine, elle pourra être auriculaire (oreillettes) ou jonctionnelle (nœud atrio-ventriculaire). Souvent l'hypertension artérielle, en raison de sa surcharge pour le cœur, provoque une distension des oreillettes et leur contraction prématurée. La faiblesse du muscle cardiaque peut constituer une autre cause de ce type d'extrasystole.

7.2 Contraction ventriculaire prématurée (extrasystole ventriculaire)

L'extrasystole ventriculaire est due à la présence d'une zone irritative dans le ventricule qui ne se soumet pas à l'harmonie de l'activation cardiaque. L'émotion, un déséquilibre de la teneur en sels minéraux, un état fébrile ou une infection peuvent démasquer une propension à cette arythmie. Dans ces cas, celle-ci sera considérée comme bénigne, tandis que l'apparition d'extrasystoles accompagnant une maladie cardiaque peut dévoiler un problème qui nécessite un traitement. Si les extrasystoles se multiplient et que la stimulation électrique suit le mouvement, la fréquence cardiaque augmentera, on parlera alors de tachycardie.

7.3 La tachycardie supra-ventriculaire

Lors de tachycardie paroxystique, le cœur s'emballé soudainement et bat très rapidement, jusqu'à 150 à 220 fois par minute comme montré sur la Figure (1.8). Ces épisodes peuvent durer quelques secondes ou se prolonger pendant plusieurs heures. Ils s'arrêtent aussi soudainement qu'ils sont apparus. Les tachycardies supra ventriculaires peuvent apparaître dès le très jeune âge et persister toute la vie. Après ces crises, le sujet se sent fatigué, mais ce type d'arythmie est rarement dangereux. Elles nécessitent néanmoins l'attention du médecin, car elles peuvent être gênantes et diminuer la qualité de vie.




Figure 1.8 Tachycardie supra-ventriculaire

7.4 La fibrillation auriculaire

Une fibrillation auriculaire est définie comme la contraction anarchique des oreillettes, qui entraîne une contraction rapide et irrégulière des ventricules comme montré sur la Figure (1.9). Il s'agit d'un trouble du rythme du cœur très fréquent, en particulier chez les sujets de plus de 60 ans. Le diagnostic est difficile car les symptômes de fibrillation auriculaire ne sont absolument pas ressentis.




Figure 1.9 Fibrillation auriculaire

7.5 La tachycardie ventriculaire

La tachycardie ventriculaire est en général la manifestation d'un dysfonctionnement du muscle cardiaque. Elle peut apparaître à tout âge, mais elle est fréquemment la conséquence d'un infarctus du myocarde. Elle se manifeste par la désynchronisation des

battements ventriculaires qui conduit à une diminution du pompage du sang (voir Figure (1.10)).




Figure 1.10 Tachycardie ventriculaire

7.6 Fibrillation ventriculaire

La fibrillation ventriculaire (FV) est parfois inaugurale (mort subite), précoce (fibrillation ventriculaire primaire de bon pronostic), parfois tardive (fibrillation ventriculaire secondaire) accompagnant alors un anévrysme du ventricule gauche suite à un mauvais diagnostic. La fibrillation ne peut pas se produire dans un milieu homogène. En fait, la période réfractaire, l'excitabilité, ainsi que la vitesse de conduction n'ont pas des propriétés constantes partout dans le tissu ventriculaire comme montré sur la Figure (1.11).




Figure 1.11 Fibrillation ventriculaire

8. Artefacts visibles sur l'électrocardiogramme

Sur tout enregistrement électrocardiographique il peut apparaître des événements indésirables pouvant brouiller le tracé et, parfois, induire en erreur le diagnostic final. Ces bruits sont reconnaissables par l'œil expérimenté qui les identifie avant d'effectuer son diagnostic. Les effets indésirables peuvent avoir plusieurs sources: techniques, physiques ou pathologiques. Nous allons surtout développer l'aspect technique et physique des bruits et artefacts présents sur les tracés électrocardiographiques notamment sur les tracés Holter. En partant du principe que les bruits fréquents en électrocardiographie sont des bruits additifs, les caractéristiques de ces bruits auxquelles nous allons nous attacher sont l'amplitude, la périodicité et la bande spectrale. Les artefacts prennent une place particulière puisqu'ils induisent des modifications des performances des algorithmes d'analyse automatique de l'électrocardiogramme [2,53].

8.1 Bruits techniques

Le matériel utilisé lors de l'enregistrement doit être manipulé avec précaution car il peut être source de bruits lors de l'enregistrement. Les plus courants sont présentes ci-dessous.

- Bruit dû au secteur

Le réseau de distribution électrique peut parfois brouiller le signal électrocardiographique avec une onde dont l'harmonique principale est à 50 Hz comme montré sur la Figure (1.12). Ce type de bruit apparaît sur tout l'enregistrement et peut être assez fort mais il s'élimine facilement avec un filtre sélectif car c'est un bruit haute fréquence a bande étroite.




Figure 1.12 Interférence secteur 50 Hz.

- Bruit dû aux mouvements d'électrodes

Lorsque les électrodes sont connectées incorrectement, des sauts brusques de la ligne de base apparaissent. L'effet sur le tracé peut aller de la simple diminution d'amplitude à l'apparition de pics lorsque les électrodes sont en contact intermittent avec la peau. Ces pics peuvent parfois être confondus avec les ondes du tracé normal comme montré sur la Figure (1.13). Ce type de bruit intermittent à bande spectrale large s'élimine difficilement car son énergie se trouve dans la même gamme de fréquence que le complexe QRS.




Figure 1.13 Bruit dû aux mouvements des électrodes.

- Autres bruits courants

Parmi les bruits courants on peut citer les artefacts dûs aux mouvements des câbles électriques, la saturation des instruments de mesure, les mauvais câblages, les artefacts dûs au port de vêtements synthétiques, etc.

8.2 Artefacts physiques

Les artefacts physiques sont dus aux activités électriques du corps humain telles que les commandes de contraction des muscles ou la respiration.

- Mouvements de la ligne de base

Lors de l'enregistrement de l'électrocardiogramme, l'activité respiratoire peut faire osciller la ligne de base de l'ECG à un rythme régulier comme montré sur la Figure (1.14). D'autres perturbations peuvent avoir pour effet de déplacer temporairement la ligne de base comme, par exemple, les mauvais contacts entre la peau et les électrodes. Ces perturbations sont généralement peu gênantes pour l'analyse de l'ECG et peuvent être en grande partie filtrées car leur énergie se situe dans une bande de fréquence basse, qui empiète peu sur celle de l'ECG normal.




Figure 1.14 Dérivée de la ligne de base.

- Bruit myoélectrique ou tremblement somatique

La contraction d'un muscle est commandée par une dépolarisation des cellules musculaires et bien que les électrocardiographes soient construits pour être surtout sensibles aux fréquences du myocarde, l'ECG enregistre les contractions des muscles squelettiques comme montré sur la Figure (1.15). L'aspect le plus courant est une oscillation à haute fréquence liée à la tension musculaire d'un sujet qui n'est pas convenablement détendu. Ces perturbations sont assez gênantes lorsque le patient bouge beaucoup ou lorsqu'il frissonne, elles peuvent noyer les ondes P et T et empêcher un diagnostic fiable. L'apparition de ces perturbations dépend de l'état du patient, s'il est très tendu ou atteint de maladie de Parkinson, l'enregistrement peut être de mauvaise qualité sur toutes les voies de l'ECG.




Figure 1.15 Bruit myoélectrique ou tremblement somatique.

9. Conclusion

Ce chapitre est une introduction aux éléments de base de l'électrophysiologie du cœur. Après une introduction sur l'anatomie du cœur humain, nous avons décrit brièvement l'activité mécanique du cœur ainsi que le système de conduction électrique du cœur. Ces notions sont indispensables pour la bonne compréhension des problèmes étudiés par la suite.

Dans une deuxième partie de ce chapitre nous avons exposé les différentes notions de l'électrocardiographie. Quelques pathologies cardiaques typiques ont été présentées et illustrées chacune par un enregistrement ECG correspondant.

Nous avons terminé ce chapitre par donner les différents types d'artefacts qui peuvent affecter le signal ECG enregistré.

Chapitre II

Les réseaux de neurones artificiels

1. Introduction

Inspirés du fonctionnement du cerveau humain, les réseaux de neurones artificiels (RNA) occupent aujourd'hui une place prépondérante dans plusieurs domaines des sciences de l'ingénieur. C'est à partir de l'hypothèse que le comportement intelligent émerge de la structure et du comportement des éléments de base du cerveau, que les réseaux de neurones artificiels se sont développés. Les progrès accomplis dans la compréhension du fonctionnement du cerveau humain ont contribué dans une large mesure au développement des RNA. Cependant les scientifiques sont toujours impressionnés par l'architecture du système neuronal humain, sa complexité, son efficacité et sa rapidité dans le traitement de certains problèmes complexes que le plus puissant des ordinateurs actuels ne peut résoudre avec la même efficacité.

D'un point de vu mathématique, un RNA est un système mathématique possédant une capacité d'apprentissage de l'environnement extérieur. Il est capable de modéliser un processus physique à partir de données expérimentales (il n'est pas strictement nécessaire d'assumer une relation particulière entre les données) mises à sa disposition afin de généraliser sur de nouvelles données. Les RNA peuvent fournir une solution intéressante pour les problèmes de classification des anomalies cardiaques, leur excellente possibilité d'apprendre le rapport entre les entrées-sorties d'un ensemble de données sans n'importe quelle connaissance antérieure les rendent tout à fait appropriés aux tâches de classification dans les situations pratiques comme la notre. Dans nôtre cas le RNA sera utilisé pour la classification des anomalies cardiaques à partir des paramètres ou signatures d'une anomalie, en d'autres termes, son rôle sera la discrimination d'une anomalie cardiaque à partir du signal ECG.

Ce chapitre est structuré en deux parties. Une première partie est consacrée à la présentation des réseaux de neurones artificiels. Nous commençons par donner une brève présentation de l'évolution historique de cet axe de recherche, avant de présenter le principe de fonctionnement des neurones artificiels, nous décrivons les bases essentielles des neurones biologiques ainsi que les différentes architectures de réseaux de neurones. Nous concluons cette partie en présentant les réseaux de neurones les plus utilisés. La deuxième partie de ce chapitre sera consacrée aux architectures neuronales utilisées dans notre thèse qui sont le Perceptron Multi Couches et celui de Kohonen. Nous présentons ainsi leur principe de

fonctionnement avec leurs algorithmes d'apprentissage et nous terminerons par les différentes applications des RNA.

2. Eléments de base des réseaux de neurones

2.1 Historique

L'origine de l'inspiration des réseaux de neurones artificiels remonte à 1890 quand W. James, célèbre psychologue américain, introduit le concept de mémoire associative. Il propose ce qui deviendra une loi de fonctionnement pour l'apprentissage des réseaux de neurones, connu plus tard sous le nom de loi de Hebb. Il a fallu attendre l'année 1943 pour que J. McCulloch chercheur en neurologie et W. Pitts mathématicien proposent le premier modèle mathématique et informatique du neurone (un neurone au comportement binaire). Ce sont les premiers à montrer que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes. C'est avec D. Hebb, neuropsychologue canadien, qu'arrive une nouvelle vague de développement. Il publia en 1949 son livre intitulé 'The Organization of behavior' [55] dans lequel il expose ses idées sur l'apprentissage pour la première fois. Cet ouvrage sera considéré comme source d'inspiration pour le développement des modèles informatiques d'apprentissage et des systèmes adaptatifs ultérieurs.

Un des premiers succès remarquable de cette discipline remonte à 1957 lorsque F. Rosenblatt développe le modèle du Perceptron [56]. Il construit le premier neuro-ordinateur basé sur ce modèle et l'applique au domaine de la reconnaissance des formes. En 1960, B. Widrow et T.Hoff développent le modèle AdaLiNe (Adaptative Linear Neuron). Dans sa structure, le modèle ressemble au Perceptron, cependant la loi d'apprentissage est différente. Ils proposent la minimisation des erreurs quadratiques en sortie comme algorithme d'apprentissage du réseau. Vers la fin des années 1960, M. Minsky et S. Papert montrent dans leur livre intitulé Perceptrons [42] les limitations théoriques du Perceptron. Ces limitations concernent l'impossibilité de traiter des problèmes non linéaires en utilisant ce modèle. Quelques années d'ombre se sont ensuite succédées de 1967 à 1982.

Le renouveau de cette discipline reprend en 1982 grâce à J. J. Hopfield, un physicien reconnu. Au travers d'un article court, clair et bien écrit [45], il présente une théorie du fonctionnement et des possibilités des réseaux de neurones. On peut citer encore les travaux de Kohonen et J. Anderson qui ont mis au point de nouveaux réseaux pouvant servir de

mémoires associatives, ainsi que S. Grossberg qui a mis au point ce que l'on appelle aujourd'hui les réseaux auto-organisés. C'est ensuite, en 1985 que la rétro-propagation du gradient apparaît. C'est un algorithme d'apprentissage adapté au Perceptron Multi Couches. Sa découverte est réalisée par trois groupes de chercheurs indépendants. Dès cette découverte, nous avons la possibilité de réaliser une fonction non linéaire d'entrée/sortie sur un réseau en décomposant cette fonction en une suite d'étapes linéairement séparables. Enfin, en 1989 Moody et Darken [43] exploitent quelques résultats de l'interpolation multi variables pour proposer le Réseau à Fonctions de base Radiales (RFR), connu sous l'appellation anglophone 'Radial Basis Function network' (RBF). Ce type de réseau se distingue des autres types de réseaux de neurones par sa représentation locale.

2.2 Du neurone biologique au modèle mathématique

2.2.1 Le modèle neurophysiologique

Le cerveau humain est composé de cellules distinctes appelées neurones formant un ensemble dense d'environ 10 à 100 milliards d'unités interconnectées. Le neurone est une cellule composée d'un corps cellulaire et d'un noyau comme montré sur la Figure (2.1). Le corps cellulaire se ramifie pour former ce que l'on nomme les dendrites. C'est par les dendrites que l'information est acheminée de l'extérieur vers le soma (corps du neurone). L'information est traitée alors par le corps cellulaire. Si le potentiel d'action dépasse un certain seuil, le corps cellulaire répond par un stimulus. Le signal transmis par le neurone est cheminé ensuite le long de l'axone (unique) pour être transmis aux autres neurones. La transmission entre deux neurones n'est pas directe. En fait, il existe un espace intercellulaire de quelques dizaines d'Angströms entre l'axone du neurone afférent et les dendrites du neurone efférent. La jonction entre deux neurones est appelée synapse comme schématisé sur la Figure (2.2) [57].

2.2.2 Le modèle mathématique

Par analogie avec le neurone biologique, chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones en amont. A chacune de ces entrées est associé un poids w , abréviation du mot poids (weight en anglais), représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie

unique qui se ramifie ensuite pour alimenter un nombre variable de neurones en aval comme montré sur la Figure (2.3) [58]. A chaque connexion est associé un poids.




Figure 2.1 Schéma d'un neurone.

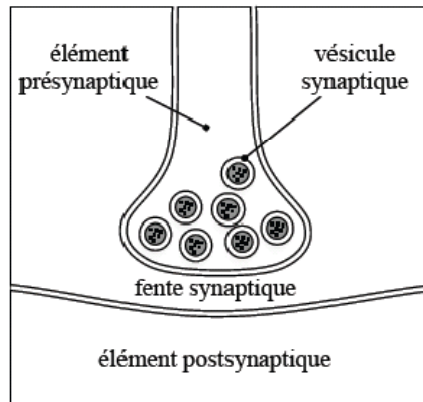


Figure 2.2 Schéma d'une synapse.




Figure 2.3 Neurone formel.

Le comportement du neurone artificiel se compose de deux phases [58]:

La première phase représente le prétraitement des données reçues en calculant la somme pondérée des entrées selon l'expression suivante :

$$a_i = \sum_j w_{ij} x_j \quad (2.1)$$

Dans la deuxième phase, une fonction de transfert calcule la valeur de l'état interne du neurone. C'est cette valeur qui sera transmise aux neurones en aval. Plusieurs possibilités existent pour spécifier la nature de la fonction d'activation du modèle. Les fonctions mathématiques les plus souvent utilisées tel que les fonctions linéaires, sigmoïdes et gaussiennes sont schématisées sur la Figure (2.4). A la différence des neurones biologiques dont l'état est binaire, la plupart des fonctions de transfert sont continues, offrant une infinité de valeurs possibles comprises dans l'intervalle $[0, +1]$ ou $[-1, +1]$. Ainsi, le neurone peut être défini mathématiquement comme étant une fonction algébrique, a priori non linéaire (suivant la fonction d'activation f) et bornée, avec des entrées x et paramétrée par les poids w_{ij} .




Figure 2.4 Différents types de fonctions d'activation pour le neurone artificiel.

2.3 Architecture des réseaux de neurones

On distingue deux grandes familles de réseaux de neurones: les réseaux bouclés et les réseaux non bouclés [59].

2.3.1 Les réseaux de neurones non bouclés (en Anglais feedforward)

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonctions algébriques de ses entrées par composition des fonctions réalisées par chacun des neurones le composant. L'entrée au réseau désigne l'information reçue par ce dernier de l'environnement extérieur. Dans un tel réseau, l'information circule dans une seule direction, de l'entrée vers la sortie. Ce type de réseaux n'autorise pas le retour en arrière de l'information. Le temps ne joue aucun rôle fonctionnel dans un réseau de neurones non bouclé. Pour cette raison, ces réseaux sont aussi qualifiés de réseaux statiques, par opposition aux réseaux dynamiques. Ce type de réseau comprend deux groupes d'architectures: les réseaux mono-couches et les réseaux multi-couches. Ils diffèrent par l'existence ou non de neurones intermédiaires appelés neurones cachés entre les unités d'entrées et les unités de sorties appelées nœuds sources ou nœuds d'entrée et nœuds de sortie respectivement.

Un réseau non-bouclé mono-couche possède une couche d'entrée recevant les stimuli à traiter par l'intermédiaire des nœuds sources. Cette couche se projette en une couche de sortie composée de neurones (nœuds de calcul) transmettant les résultats du traitement au milieu extérieur. Un réseau non-bouclé multi-couche se caractérise par la présence d'une ou de plusieurs couches cachées, dont les nœuds de calcul correspondants s'appellent neurones cachés. Les couches cachées s'interposent entre l'entrée du réseau et sa sortie. Leur rôle est d'effectuer un prétraitement des signaux d'entrée, reçus par la couche d'entrée en provenance du milieu extérieur et de transmettre les résultats correspondant à la couche de sortie où sera déterminée la réponse finale du réseau avant qu'elle soit transmise au milieu extérieur. Les réseaux les plus fréquemment utilisés de cette catégorie sont les perceptrons multi-couches (Multilayer Perceptrons, MLP).

2.3.2 Les réseaux de neurones bouclés (récurrents)

Dans un réseau bouclé, appelé aussi réseau récurrent ou dynamique, il est possible de trouver au moins un cycle où l'information peut revenir à son point de départ. Cela suppose

que la sortie d'un neurone peut être fonction d'elle-même. Or cela n'est possible que si la notion de temps est prise en compte. Ce type de réseau est notamment utilisé pour la modélisation dynamique de processus non linéaires.

2.4 Les types d'apprentissage des réseaux de neurones

L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux de neurones. Elle ne concerne cependant pas tous les modèles, mais uniquement les plus utilisés. L'apprentissage est une phase du développement du réseau de neurones durant laquelle on calcule les poids des neurones de telle manière que les sorties du réseau soient aussi proches que possible des sorties désirées. Les procédures d'apprentissage sont divisées, elles aussi, en deux grandes catégories: apprentissage supervisé et apprentissage non supervisé [60].

2.4.1 L'apprentissage supervisé

L'apprentissage supervisé implique l'existence d'un *professeur* qui a pour rôle d'évaluer le succès (ou l'échec) du réseau quand il lui est présenté un stimulus connu (on dit que ce stimulus est un exemple appartenant à la base d'apprentissage). Cette supervision consiste à renvoyer au réseau une information lui permettant de faire évoluer ses connexions (parfois aussi sa propre architecture) afin de faire diminuer son taux d'échec. L'information peut être explicite, sous la forme d'une mesure de l'erreur commise, par exemple, ou globalement sur l'ensemble des exemples de la base. C'est ce qui se passe dans le cas du Perceptron. Mais elle peut être plus implicite (apprentissage par renforcement), sous forme d'une simple appréciation (*bon* ou *mauvais*, punition ou récompense), sans mesure d'erreur, et même être globale, sur l'ensemble des tâches que le réseau doit exécuter. Dans ce dernier cas, il est facile de comprendre que l'apprentissage est le plus difficile, la difficulté majeure consistant pour le réseau à identifier les étapes du processus qui sont responsables de l'échec ou du succès.

2.4.2 L'apprentissage non supervisé

L'apprentissage non supervisé implique la fourniture à un réseau autonome d'une quantité suffisante d'exemples contenant des répétitions (autrement dit de la redondance), telles que celui-ci en dégagne les régularités automatiquement. Ces réseaux sont souvent

appelés *auto-organiseurs*, ou encore à *apprentissage compétitif*. Dans l'apprentissage non supervisé, les données ne contiennent pas d'informations sur une sortie désirée, il n'y a pas de superviseur ou expert humain. Il s'agit de déterminer les paramètres du réseau de neurones suivant un critère à définir. Dans ce cas, les exemples présentés à l'entrée provoquent une auto adaptation du réseau afin de produire des valeurs de sortie qui soient proches en réponse pour des valeurs d'entrées similaires. Ce type d'apprentissage possède souvent moins de complexité dans le calcul par rapport à l'apprentissage supervisé. Bien entendu, l'architecture du réseau, préalablement définie par son utilisateur, est une forme de supervision.

3. Les réseaux de neurones les plus utilisés

La Figure (2.5) représente les réseaux de neurones les plus utilisés dans la littérature. Dans ce qui suit, nous allons faire une description de chacun d'eux.

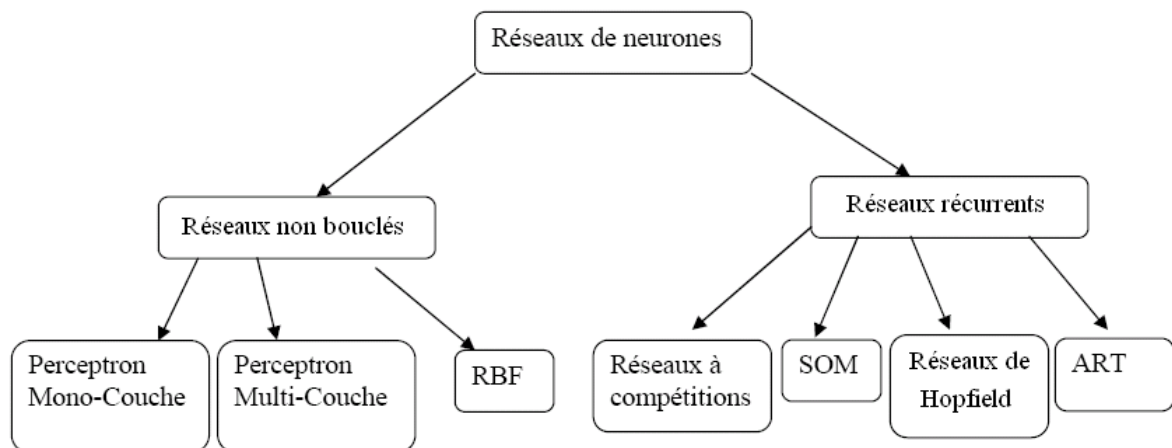


Figure 2.5 Réseaux de neurones le plus utilisés.

3.1 Les Perceptrons

3.1.1 Le perceptron mono-couche (Perceptron simple)

Le perceptron est le premier modèle des réseaux de neurones inventé en 1957 par Frank Rosenblatt [56]. C'est un réseau simple, puisqu'il ne se compose que d'une couche d'entrée et d'une couche de sortie. Il peut aussi être utilisé pour faire de la classification et

pour résoudre des opérations logiques simples, il suit généralement un apprentissage supervisé selon la règle de correction de l'erreur.

3.1.2 Le perceptron multicouche (en anglais Multi Layer Perceptron)

C'est une extension du précédent, avec une ou plusieurs couches cachées entre l'entrée et la sortie [61]. Chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante. Il peut résoudre des problèmes non linéairement séparables et des problèmes logiques plus compliqués. Il suit un apprentissage supervisé selon la règle de correction de l'erreur, ce réseau sera détaillé par la suite.

3.2 Les réseaux à fonction radiale

Les réseaux à fonctions de bases radiales (RBF) ou plus simplement réseaux à bases radiales ont été proposés par J. Moody et C. Darken [43]. Les RBF seront donc employés dans les mêmes types de problèmes que les PMC à savoir, en classification et en approximation de fonctions, particulièrement. L'apprentissage le plus utilisé pour les RBF est le mode hybride et les règles sont soit la règle de correction de l'erreur soit la règle d'apprentissage par compétition.

3.3 Les cartes auto-organisatrices de Kohonen (SOM)

Les cartes topologiques ou cartes auto organisatrices ont été introduites pour la première fois par T. Kohonen [44] en 1982. Ce sont des réseaux à apprentissage non-supervisé qui établissent une carte discrète, ordonnée topologiquement, en fonction de patterns d'entrée. Le réseau forme ainsi une sorte de treillis dont chaque nœud est un neurone associé à un vecteur de poids. La correspondance entre chaque vecteur de poids est calculée pour chaque entrée. Par la suite, le vecteur de poids ayant la meilleure corrélation, ainsi que certains de ses voisins, vont être modifiés afin d'augmenter encore cette corrélation, ce réseau sera détaillé par la suite.

3.4 Les réseaux de Hopfield

Les réseaux de Hopfield [45] sont des réseaux récurrents et entièrement connectés. Dans ce type de réseau, chaque neurone est connecté à chaque autre neurone et il n'y a aucune

différence entre les neurones d'entrée et de sortie. Ils fonctionnent comme une mémoire associative non-linéaire et sont capables de trouver un objet stocké en fonction de représentations partielles ou bruitées. L'application principale des réseaux de Hopfield est l'entrepôt de connaissances mais aussi la résolution de problèmes d'optimisation. Le mode d'apprentissage utilisé ici est le mode non-supervisé.

3.5 Les réseaux ART

Les réseaux ART (Adaptive Resonance Theory) sont des réseaux à apprentissage par compétition [46, 47]. Dans ce genre de réseau, les vecteurs de poids ne seront adaptés que si l'entrée fournie est suffisamment proche d'un prototype déjà connu par le réseau. Il est à noter qu'il existe deux principaux types de réseaux ART : les ART-1 pour des entrées binaires et les ART-2 pour des entrées continues. Le mode d'apprentissage des ART peut être supervisé ou non.

4. Le classificateur perceptron multicouche

4.1 Principe

Un réseau perceptron multicouche (en anglais MLP) est constitué de neurones reliés entre eux par des liens pondérés. Il se compose d'une couche d'entrée, d'une couche de sortie et d'une ou plusieurs couches cachées comme montré sur la Figure (2.6). A l'heure actuelle, il n'existe pas de règles ou lois régissant le nombre de couches et le nombre de neurones par couche à utiliser. Le choix reste heuristique et il est établi en fonction de l'utilisation du réseau. Le but est d'obtenir le réseau le plus simple possible afin de limiter le temps de calcul, mais suffisamment élaboré pour répondre aux critères de discrimination désirés. L'utilisation d'un tel réseau pour la classification impose le nombre de neurones pour la couche d'entrée. En effet, cette couche correspond au vecteur de mesure ou vecteur d'entrée. La couche d'entrée aura alors un nombre de neurones équivalent au nombre de composantes du vecteur d'entrée. En ce qui concerne la couche de sortie, un des choix possibles est de faire correspondre le nombre de neurones au nombre de classes estimées. Pour gérer les neurones, les fonctions d'activation permettent de définir l'état de leur sortie en fonction de leurs entrées. En effet, chaque neurone est relié à tous les neurones de la couche précédente et chacune des connexions est affectée d'un poids w pondérant la sortie du neurone précédent. La somme des

entrées est alors introduite dans une fonction d'activation qui décide de l'état de sortie du neurone [62].




Figure 2.6 Perceptron Multi Couches.

4.2 Rétropropagation du gradient de l'erreur

Soit le réseau à deux couches de la Figure (2.6) dans lequel les unités de sortie sont notées o_i , les unités cachées v_j et les unités d'entrée x_k . Les connexions des unités d'entrée aux unités cachées sont notées w_{kj} et celles des unités cachées aux unités de sortie par w_{ij} . L'entrée k a pour valeur x_k^p lorsque la donnée p est présentée au réseau. Ces valeurs peuvent être binaires (0/1 ou +1/-1) ou continues [62].

Pour la donnée d'entrée p , la valeur de sortie de l'unité cachée j est donnée par :

$$v_j^p = f(a_j^p) = f\left(\sum_k w_{jk} x_k^p\right) \quad (2.1)$$

Les unités de sortie ont comme valeur :

$$o_i^p = f(a_i^p) = f\left(\sum_j w_{ij} v_j^p\right) \quad (2.2)$$

Les fonctions d'erreurs partielles et globales sont alors définies par

$$E^p = \frac{1}{2} \sum_i (o_i^p - x_i^p)^2 \quad \text{et} \quad E = \sum_p E^p \quad (2.3)$$

La minimisation de la fonction d'erreur globale va se faire par une descente de gradient. Par conséquent, après la présentation de tous les vecteurs d'entrée de la base d'apprentissage, nous modifierons la valeur de chaque connexion par la règle suivante:

$$\Delta w = -\eta \frac{\partial E}{\partial w} = -\eta \sum_p \frac{\partial E^p}{\partial w} \quad (2.4)$$

Cette règle d'apprentissage est généralement appelée la règle de delta généralisée. Dans l'expression (2.3), seule la sortie o_i dépend du paramètre w . Selon la position des poids des connexions, deux cas se présentent :

- **Cas des connexions entre la couche cachée et celle de sortie (w_{ij}) :**

Pour le cas des neurones de sortie, l'expression (2.3) devient fonction du paramètre w_{ij} qui influe uniquement sur la sortie du neurone d'indice i . Nous pouvons donc décomposer la dérivée de l'expression (2.3) par :

$$\frac{\partial E^p}{\partial w_{ij}} = \frac{\partial E^p}{\partial o_i^p} \cdot \frac{\partial o_i^p}{\partial a_i^p} \frac{\partial a_i^p}{\partial w_{ij}} = (o_i^p - x_i^p) f'_i(a_i^p) v_j^p \quad (2.5)$$

L'expression (2.4) devient alors

$$\Delta w_{ij} = \eta \sum_p f'_i(a_i^p) (x_i^p - o_i^p) v_j^p \quad (2.6)$$

- **Cas des connexions entre la couche d'entrée et la couche cachée (w_{jk}) :**

Pour le cas des neurones cachés, l'expression (2.4) est fonction du paramètre w_{jk} qui influe non seulement sur la sortie du neurone j de la deuxième couche, mais aussi sur tous les neurones i de la couche de sortie (en aval) qui lui sont connectés. On obtient alors l'équation suivante :

$$\frac{\partial E^p}{\partial w_{jk}} = \frac{\partial E^p}{\partial v_j^p} \cdot \frac{\partial v_j^p}{\partial a_j^p} \frac{\partial a_j^p}{\partial w_{jk}} = \frac{\partial E^p}{\partial v_j^p} f'_j(a_j^p) x_k^p \quad (2.7)$$

Le premier terme de cette expression devient alors :

$$\frac{\partial E^p}{\partial v_j^p} = \sum_i \frac{\partial E^p}{\partial o_i^p} \cdot \frac{\partial o_i^p}{\partial v_j^p} = \sum_i \frac{\partial E^p}{\partial o_i^p} \frac{\partial o_i^p}{\partial a_i^p} \frac{\partial a_i^p}{\partial v_j^p} = \sum_i (o_i^p - x_i^p) f'_i(a_i^p) w_{ij} \quad (2.8)$$

On obtient alors la modification des poids :

$$\Delta w_{jk} = \eta \sum_p \left(f'_j(a_j^p) x_k^p \left(\sum_i (x_i^p - o_i^p) f'_i(a_i^p) w_{ij} \right) \right) \quad (2.9)$$

Après avoir calculé la variation des poids des connexions pour tous les neurones de sortie (équation (2.5)), on calcule alors la variation des poids des connexions de la couche cachée (équation (2.9)). On met ainsi à jour les poids des connexions de la couche de sortie jusqu'à la couche d'entrée: on *retropropage* ainsi le signal d'erreur. C'est de là que vient le nom de cet algorithme: *retropropagation du gradient de l'erreur*. Du fait de sommer les Δw_{ij} pour

tous les vecteurs p de la base d'apprentissage puis de remettre à jour les poids avec la variation totale ainsi calculée, l'algorithme est appelé gradient total. Une autre façon de faire, appelée version séquentielle, modifie les poids des connexions après chaque présentation d'un vecteur d'entrée p . Une version stochastique permet de prendre en compte les vecteurs d'apprentissage p d'une façon aléatoire.

L'algorithme de rétropropagation du gradient de l'erreur a permis de dépasser les limites du Perceptron simple. Il s'avère capable de résoudre un grand nombre de problèmes de classification et de reconnaissance des formes et a donné lieu à beaucoup d'applications. Cet algorithme souffre néanmoins de nombreux défauts, parmi lesquels:

- Une des limitations importantes est le temps de calcul: l'apprentissage est très long;
- Une grande sensibilité aux conditions initiales, c'est-à-dire à la manière dont sont initialisés les poids des connexions;
- De nombreux problèmes sont dus à la géométrie de la fonction d'erreur: minimums locaux. Ce problème est en partie résolu avec le gradient stochastique, mais il subsiste quand même;
- Le problème de dimensionnement du réseau. La rétropropagation apprend une base d'apprentissage sur un réseau dont la structure est fixée a priori. La structure est définie par le nombre de couches cachées, le nombre de neurones par couches et la topologie des connexions. Un mauvais choix de structure peut dégrader considérablement les performances du réseau.

5. Les cartes topologiques de Kohonen

5.1 Définition

Un réseau de Kohonen appelé aussi SOM (Self Organizing Maps) est composé d'une couche d'entrée et d'une couche compétitive comme montré sur la Figure (2.7) [59]. La couche compétitive possède une structure topologique, ce qui permet de définir un voisinage pour le neurone. L'apprentissage est non supervisé. Les cartes topologiques de Kohonen sont constituées de deux couches:

- La couche d'entrée sert uniquement à la présentation des formes à classer et les états de tous ses neurones sont forcés aux valeurs des données d'entrée;

- La couche d'adaptation est formée d'un treillis de neurones évoqué précédemment. Le choix de la géométrie du réseau employé est faite *a priori*. Les neurones utilisés à ce niveau sont des neurones linéaires, chacun d'entre eux étant branché à tous les éléments de la couche d'entrée. De manière à permettre le processus d'auto organisation, les poids qui lient les deux couches sont déterminés de manière adaptative.




Figure 2.7 La carte topologique de Kohonen.

5.1 L'apprentissage compétitif [63]

L'apprentissage compétitif, comme son nom l'indique, consiste à faire compéter les neurones d'un réseau pour déterminer lequel sera actif à un instant donné. Contrairement aux autres types d'apprentissage où, généralement, tous les neurones peuvent apprendre simultanément et de la même manière, l'apprentissage compétitif produit un *vainqueur* et seul ce vainqueur et, potentiellement, son voisinage bénéficient d'une adaptation de leur poids. Dans leur forme la plus simple, les réseaux de neurones qui utilisent l'apprentissage compétitif sont souvent constitués d'une seule couche de neurones de sortie, totalement connectée sur les entrées. Un neurone vainqueur modifiera ses poids synaptiques en les rapprochant (géométriquement) d'un stimulus d'entrée p pour lequel il a battu tous les autres neurones lors de la compétition:

$$\begin{cases} \Delta w = \eta(p - w) & \text{si le neurone est vainqueur} \\ 0 & \text{autrement} \end{cases} \quad (2.10)$$

Où $0 < \eta < 1$ correspond à un taux d'apprentissage. Un neurone qui ne gagne pas la compétition ne modifiera aucunement ses poids. Il ne sera donc pas affecté par le stimulus en

question. L'apprentissage compétitif est surtout utilisé dans le contexte d'un apprentissage dit non supervisé, c'est-à-dire lorsqu'on ne connaît pas les valeurs désirées pour les sorties du réseau.

5.3 Processus d'apprentissage du réseau de Kohonen

A chaque étape de l'apprentissage, c'est-à-dire à chaque nouvelle arrivée d'une observation, chaque neurone de la couche de sortie calcule son activation. A l'issue de ce calcul, le neurone dont l'activation est la plus grande est déclaré vainqueur. Ses poids ainsi que ceux de ses voisins sont mis à jour en fonction de l'influence du neurone gagnant sur son voisinage. A partir de la carte obtenue et de la matrice des poids des neurones de sortie, on peut engendrer un espace de dimension 2 où les points seront projetés [63].

5.4 L'algorithme d'apprentissage de Kohonen [63]

Pour N neurones avec M entrées et le rayon r :

- Les poids sont initialisés aléatoirement.
- Tant que le réseau ne converge pas :
 - Choisir un vecteur d'entrée $I = [I_1, I_2, \dots, I_M]$ dans l'ensemble des vecteurs d'entrée à apprendre.
 - Trouver le neurone gagnant (le neurone j dont le vecteur poids $W_j = [w_{j1}, w_{j2}, \dots, w_{jM}]$ est le plus proche, selon une distance d, du vecteur d'entrée) ;
Avec $j = \text{Arg} (\min [d(W_i, I)]) \quad i=1 \dots N$
 - Modifier les poids du vecteur gagnant et de son voisinage selon l'équation :

$$\text{Si } |k - j| \leq r \rightarrow W_k(t + 1) = W_k(t) + \eta(t) (I_j(t) - W_k(t)).$$

6. Les différentes applications de RNA

Les réseaux de neurones sont utilisés dans plusieurs domaines, citons la classification, la reconnaissance de formes, l'identification et la commande de processus. Le choix d'utiliser tel ou tel type de réseau de neurones dépend de l'application mais aussi des capacités de traitement du processeur sur lequel ils s'exécutent.

6.1 Reconnaissance des formes

C'est un domaine privilégié d'application pour les RNA et c'est lui qui a marqué leur début. Le premier modèle dans cette thématique a été développé aux laboratoires AT&Bell dans la reconnaissance des codes postaux [64].

Le terme de reconnaissance est un terme général qui désigne les processus traitant des données pour en extraire des informations afin de parvenir à leur classification. Une partie non négligeable des applications neuronales actuelles appartiennent à cette catégorie, parmi lesquelles nous pouvons citer [65, 66]:

- Reconnaissance des formes.
- Reconnaissance des caractères.
- Classification et compression d'images.
- Diagnostic des pannes.

6.2 Modélisation

L'une des applications répondu des RNA est la modélisation, nous pouvons citer comme exemples: Modélisation financière, modélisation des processus de fabrication et de production, modélisation en biomédecine [67].

6.3 Traitement de la parole

Le traitement de la parole est une discipline scientifique localisée au croisement du traitement du signal numérique et du traitement du langage. Depuis une vingtaine d'années, les réseaux de neurones artificiels constituent une technique utilisée dans les systèmes de traitement automatique de la parole. Ils peuvent être employés à de nombreux niveaux dans un système de traitement automatique de la parole. De nombreuses études ont été menées pour les utiliser pour le traitement du signal parole (filtrage, annulation d'échos, séparation de sources), la modélisation acoustique mais aussi pour des tâches de plus haut niveaux telles que la modélisation linguistique [65, 68].

6.4 Détection d'anomalies en médecine

Ceci est une dérivation des reconnaissances de formes. On apprend à un réseau une image du fonctionnement *normal* d'un système et celui-ci sera ainsi capable d'indiquer tout état de dysfonctionnement quand certains paramètres engendrent une image *anormale*. Parmi les applications en médecine nous pouvons citer:

- Cardiologie [1]
- Traitement des images MRI (Magnetic Resonance Imager) [69]
- Psychologie [70], psychiatrie [71] et sociologie [72]
- Ophtalmologie [73]

6.5 Traitements dépendant du temps

Dans ce cas, on se retrouve devant des problèmes de prédiction, d'identification et de commande de processus

- Prédiction [74]
- Identification et commande de processus [75].

7. Conclusion

Ce chapitre introduit les notions de base sur les réseaux de neurones artificiels. Après un historique sur l'apparition des RNA, et la présentation des modèles biologique et mathématique du neurone, les différentes architectures des réseaux de neurones ainsi que leurs types d'apprentissage sont présentés. Les RNA les plus utilisés sont aussi exposés.

Nous nous sommes concentrés principalement dans ce chapitre sur deux architectures neuronales qui sont concernées par notre travail de recherche et qui sont généralement les plus utilisées pour la classification des anomalies cardiaques: le perceptron multi couches et la carte auto organisatrice. Nous avons terminé ce chapitre par les différentes applications des réseaux de neurones artificiels.

On note ici que dans tout ce qui suit nous allons utiliser les abréviations en anglais, MLP pour désigner le réseau perceptron multi-couches et SOM pour désigner la carte auto organisatrice de Kohonen.

Chapitre III

Discrimination et classification des anomalies cardiaques par RNA

1. Introduction

Le signal ECG possède une grande valeur clinique pour le diagnostic des troubles du rythme cardiaque et des anomalies de la conduction électrique. Ces pathologies sont en général reflétées par des troubles de l'activité électrique du cœur. Beaucoup de techniques de traitement de signal ont été utilisées pour l'analyse de l'activité électrique cardiaque et se sont avérées des outils reconnus pour l'aide au diagnostic, le traitement et le suivi des pathologies, ainsi que pour une meilleure compréhension de la dynamique de l'activité électrique cardiaque. Ces techniques de traitement permettent de réaliser l'amélioration de la qualité du signal (filtrage de bruits), le rehaussement des informations pertinentes et l'extraction des informations qui ne sont pas visibles par une analyse visuelle directe. De tels traitements automatiques sont devenus une nécessité pour exploiter au mieux les données en grande quantité dont l'analyse manuelle est difficilement envisageable. Cependant, les recherches visant l'analyse et la classification des signaux ECG ont souvent utilisé des algorithmes et des techniques dont le but principal est de modéliser la pensée et le raisonnement d'un expert (le cardiologue). Toutefois, la définition d'une règle ultime fixée pour le diagnostic cardiaque reste irréalisable, et l'effort de beaucoup de recherches a été dirigé vers l'utilisation des techniques basées sur l'extraction et la classification des paramètres descriptifs.

2. Les systèmes automatiques de diagnostic cardiaque

Bien que les travaux sur les systèmes de diagnostic cardiaque aient fait des progrès remarquables depuis le début des travaux d'Einthoven (1901), les maladies cardiovasculaires demeurent une des causes majeures de mortalité à travers le monde. Par conséquent, les systèmes intelligents, capables d'aider les médecins à faire le diagnostic et le suivi des malades devient indispensable. Ces systèmes devraient être facilement applicables, évolutifs, précis, robustes, et stables. En outre, l'adaptabilité à des situations rares est également souhaitable [76]. Les systèmes de surveillance intelligents sont apparus dans les années 90 pour surmonter les inconvénients des moniteurs de la première génération [77]. Leur but était d'intégrer plusieurs sources d'observations et plusieurs types de connaissances médicales pour construire des systèmes de contrôle interactif et utile [1].

Leurs principaux objectifs sont:

- Détecter les situations anormales par l'analyse des signaux.

- Prédire la survenue d'événements anormaux.
- Donner des conseils thérapeutiques.
- Expliquer le mécanisme sous-jacent qui a généré le désordre.

Dans ces approches, trois tâches principales sont nécessaires:

- L'étape d'acquisition, où l'acquisition du signal ECG et des données de suivi de patients sont recueillies.
- L'étape de traitement du signal qui traite les signaux ECG acquis et génère des descripteurs pertinents.
- L'étape de diagnostic qui a pour but de détecter les pathologies en se basant sur les étapes du traitement précédent.

La Figure (3.1) illustre ce régime général d'apprentissage pour la classification de l'ECG.

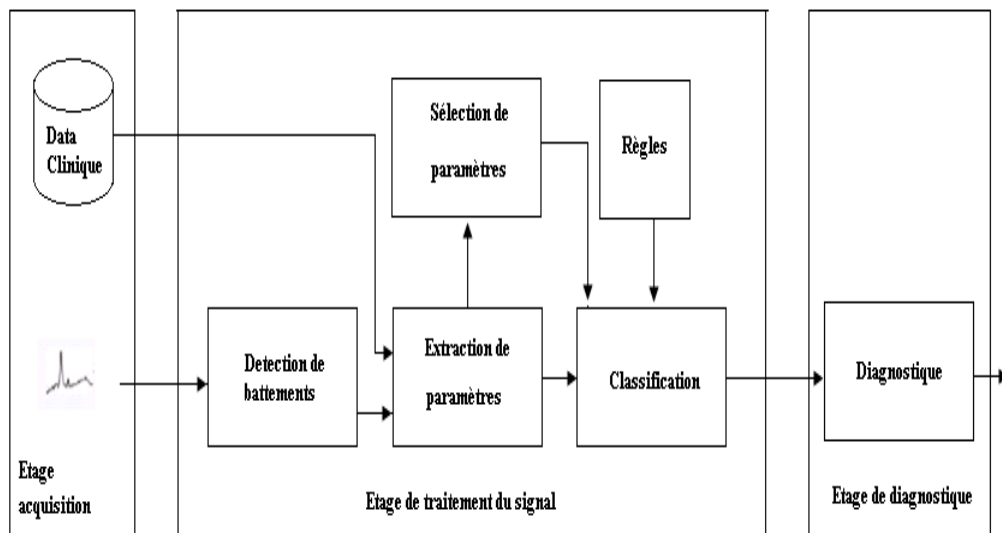


Figure 3.1 Représentation schématique d'un classificateur des signaux ECG.

L'étape de traitement du signal a déjà été formalisée par certains auteurs [78] et [79]. Diverses méthodes de classification automatique de l'ECG se trouvent dans la littérature. Toutefois, le processus de traitement peut être généralement subdivisé en un nombre de modules de traitement:

- L'étape de détection de l'onde R ou du complexe QRS.
- L'étape de sélection ou bien extraction des paramètres.
- L'étape de classification ou de reconnaissance.
- **L'étape de détection de l'onde R ou du complexe QRS**

Le but de la mise en œuvre du bloc de prétraitement est la localisation des différentes ondes de l'ECG ainsi que leur durée, (bien que le complexe QRS soit le plus important). La précision de la détection de chaque cycle cardiaque est d'une très grande importance car elle contribue de manière significative aux résultats de classification.

- **Sélection/extraction des paramètres pertinents**

Dans la majorité des cas, la détection des ondes anormales nécessite une étape préliminaire de sélection ou d'extraction de paramètres les plus pertinentes, (dans le temps par exemple: la durée, la pente, l'amplitude des ondes ...etc.). Une optimisation de la sélection des paramètres peut être incluse dans ce processus, par laquelle le vecteur caractéristique est réduit en dimension, ne retenant que les caractéristiques les plus pertinentes nécessaires à la discrimination et parfois assistés par des connaissances a priori ou des règles.

- **Classification ou discrimination (Pattern Recognition)**

L'étape de reconnaissance des anomalies implique le développement d'un système intelligent qui permet de traiter les paramètres sélectionnés à l'étape précédente. Un grand nombre de méthodes d'apprentissage a été utilisées pour identifier les différents types de pathologies cardiaques. Plusieurs méthodes et techniques ont été proposées dans la littérature. Certaines de ces méthodes s'appuient sur l'interprétation des modèles tels que les filtres de Kalman à étapes multiples [80] ou des modèles de Markov cachés [34].

3. L'intelligence artificielle et l'ECG

Dans la littérature, on trouve pas mal de techniques appliquant les approches de l'intelligence artificielle [81] et en particulier les réseaux de neurones [37], [38] pour l'analyse automatique de l'ECG. Le travail de Mark et al [38] montre que les techniques de réseaux de neurones et spécialement, le réseau MLP et la carte auto-organisatrices (SOM) sont utilisés à des fins de classification. Autres approches, telles que l'approche bayésienne et heuristique [33] et des modèles de Markov [34] ont été également expérimentées pour la classification des signaux ECG. ART (Adaptive Resonant Theory) a été appliqué à une variété de domaines allant des applications médicales, telles que la classification des modèles ECG [35], au traitement sémantique des données. Barro et al, [82] ont utilisé la théorie MART (Multi-

Channel Adaptive Resonance Theory) pour classer les signaux ECG. La mise en œuvre des résultats montrent que ce classificateur peut discriminer les battements normaux des battements ventriculaires avec une précision de plus de 90%. Olmez [83] dans son travail sur la classification des formes d'ondes de l'ECG a classé 4 types de battement tels que les battements normaux, le bloc de branche gauche, la contraction ventriculaire prématurée, et les battements de type P en utilisant un réseau de neurones RCE (Restricted Coulomb Energy) et les algorithmes génétiques et il a obtenu une précision de classification de plus de 94%. Plusieurs études ont confirmés les performances des réseaux de neurones pour la détection et la reconnaissance de l'ECG anormal. L'utilisation du réseau de neurones pour l'analyse du signal ECG offre plusieurs avantages par rapport aux techniques classiques. Donc, les réseaux de neurones ont émergé comme une prétendance sérieuse de la nature fortement non-linéaire et chaotique de l'ECG. Dans ce qui suit, nous allons percevoir les différents champs d'application des réseaux de neurones artificiels dans la discrimination et la classification des pathologies cardiaques en se basant sur le traitement des signaux ECG.

4. L'utilisation des RNA dans la classification des arythmies cardiaques

L'utilisation des RNA dans la discrimination des complexes QRS large comme dans le cas de la tachycardie ventriculaire (VT) et la tachycardie supraventriculaire (SVT) a été le sujet de beaucoup de recherches en électrocardiographie. En fait, la détection prématurée de la fibrillation ventriculaire (VF) est décisive dans le cas du risque de la mort subite, une détection rapide permet au spécialiste d'avoir plus de temps de réaction (intervention) pour donner le traitement approprié au patient. Plusieurs techniques utilisant les RNA ont été développées pour établir des critères permettant la différenciation de la VT parmi des battements normaux [1]. Al-Fahoum et al [84] ont utilisé des transformations en ondelette (continue et discrète) dans la phase de l'extraction des paramètres, le vecteur de paramètres extrait par ondelettes est utilisé ensuite comme entrée d'un réseau de neurones de type RBF dans le but de la détection automatique des arythmies. Dans [85], Rosado-Muñoz et al. combinent une ondelette de Daubechies et un réseau RBF, un classement correct global de 97,5% a été obtenu, avec 100% de classification correcte à la fois pour la fibrillation ventriculaire et la tachycardie ventriculaire.

Une importante partie du domaine de recherche sur la détection des arythmies se concentre sur la détection de la fibrillation auriculaire paroxystique (PAF). Un système de réseau de neurones pour la détection de la fibrillation auriculaire dans l'électrocardiogramme ambulatoire a été mis au point par Cubanski et al [86]. L'algorithme de classification utilise une analyse du rythme qui tient en compte une série d'intervalles RR issue du signal ECG. Ceci est combiné avec une analyse de la morphologie des différentes ondes du signal qui respecte les caractéristiques des parties non QRS de l'ECG. Un réseau de neurones de type MLP a été utilisé dans la phase de classification. La technique a été validée par une base de données constituée de 42 970 exemples de la fibrillation auriculaire (FA) et d'autres troubles du rythme supra-ventriculaire, l'algorithme a montré une sensibilité de 82,4% et une spécificité de 96,6%.

5. Discrimination des battements PVC

La détection de la contraction ventriculaire prématurée (PVC) a également attiré l'attention de nombreux chercheurs. Dans Ham et Han [87], par exemple, les auteurs utilisent la théorie ARTMAP (Adaptive Resonance Theory Mapping) pour classer les arythmies cardiaques. Deux types de battement ont été analysés: battement normal et battement anormal de type PVC. Les résultats du test ont montré que le réseau de neurone basé sur ARTMAP peut classer les arythmies cardiaques avec plus de 97% de sensibilité et 99% de spécificité. Plus tard, Maglaveras et al [88] ont proposé un prétraitement non-linéaire du signal ECG et une classification qui utilise un algorithme basé sur un RNA. La technique a été appliquée au problème de détection de PVC donnant de bons résultats. Une méthode de détection de PVC à partir des enregistrements Holter a été proposée par al Shyu. [20]. La méthode prend en considération les informations utilisées lors de la détection du complexe QRS par une transformée en ondelettes puis un réseau de neurones flou (FNN) est utilisé dans la phase de classification. Une exactitude pour la classification des PVC a été d'environ 99,8%. Lagerholm et al. [89] ont utilisé des fonctions de base d'Hermite (HBF) et un réseau SOM dans le but de classer les signaux ECG. La structure du réseau SOM a été bénéfique dans l'interprétation des données expérimentales. Dans Acharya et al. [90], les auteurs ont élaboré un RNA avec des relations floues pour le classement des rythmes cardiaques. La phase de l'extraction des paramètres dans ce cas est basée sur la mesure des variations du rythme cardiaque. Les résultats ont indiqué un niveau élevé d'efficacité, avec un niveau de précision de 80 à 85%. Wieben et al [91] ont développé un classificateur basé sur un dispositif de banc

de filtres et des arbres de décision (filter bank features and decision trees). L'algorithme a réalisé une sensibilité de 85.3% et une prédiction positive de 85.2%. Une méthode complexe de classification de QRS qui utilise la distance de Mahalanobis comme critère de classification a été développée par Moraes et al [92]. Le classificateur a été testé sur 44 enregistrements de la base de données MIT-BIH et les résultats étaient 90.74 % pour la sensibilité et 96.55 % de prédiction positive. Un classificateur alimenté par vingt-six paramètres de deux dérivations a été également proposé par Christov et al [93]. Cet algorithme a été testé sur tous les enregistrements de la base de données MIT-BIH. Ils ont réalisé 99.7 % de détection correcte des battements normaux et 98.5 % de battements ventriculaires prématurés. Un classificateur des battements PVC basé sur la transformation en ondelettes et les intervalles temporels RR a été proposé par Inan et al [94]. Ce classificateur a réalisé une justesse de classification de 95.16% pour 93.281 battements de 40 enregistrements. Chen [95] a proposé un détecteur des battements PVC basés sur un filtre moyenné non linéaire. Il a rapporté une sensibilité de 97.8% et une spécificité de 99.7% pour 34 enregistrements de la base MIT/BIH. Asl et al [96] ont employé une méthode basée sur un classificateur SVM (Support Vector Machines) pour la discrimination des PVC. Quinze paramètres du signal de HRV (Heart Rate Variability) ont été utilisés et une exactitude de 98.96 % a été obtenue.

6. Les problèmes liés à la détection et la classification des désordres cardiaques

Plusieurs problèmes ont été rencontrés dans la détection et la classification des désordres cardiaques dans différents travaux de recherche qui sont récapitulés comme suit :

- Le signal ECG présente généralement une variabilité élevée inter et intra-patient, dans la morphologie et la synchronisation. Par conséquent, la réalisation d'un classificateur plus simple avec une grande précision pour un grand nombre de patients est un problème très difficile à adresser.
- Les paramètres extraits à partir du signal d'ECG sont très susceptibles aux variations de la morphologie de l'ECG, de ses caractéristiques temporelles et des sujets traités.
- Les processus d'extraction de paramètres sont confrontés à la question d'identifier quels sont les paramètres les plus appropriés (pertinents) qui faciliteront le processus de diagnostic global parmi des centaines de paramètres qui sont disponibles.

- Le procédé de détection doit être rapide pour l'exécution en temps réel.

7. La génération des paramètres descriptifs

L'identification et la classification des modèles, y compris les signaux ECG, exige la génération (extraction) des paramètres descriptifs qui caractérisent exactement ces modèles permettant ainsi leur différenciation en classe. Les paramètres extraits représentent les classes de telle manière que les différences de la morphologie des ondes ECG sont supprimées pour la même classe de battements, et cette différence est rehaussée pour des formes d'onde appartenant à des classes différentes. Dans la pratique, il est clair qu'il y a une grande variété de morphologies d'onde parmi les battements du cœur appartenant à une classe, et même pour le même patient. D'ailleurs, les battements appartenant aux différentes classes sont des fois morphologiquement semblables entre eux. Ils occupent des fois une gamme semblable que se soit dans l'échelle temporelle ou fréquentielle; alors, il est difficile d'identifier l'un de l'autre sur la base d'une représentation en temps seulement ou en fréquence.

8. Les techniques d'étude non supervisées et leurs applications dans la classification de l'ECG

La classification non supervisée, vise typiquement à grouper un ensemble de données (de modèles) sans avoir des informations a priori sur les classes. Le système doit découvrir et apprendre les similitudes qui existent entre les données à regrouper. Les résultats principaux de telles approches sont un ensemble de classes (modèles). Un processus de classification non supervisée peut être implémenté selon les étapes suivantes [3]:

- **Représentation de modèle:** elle se rapporte à la définition du nombre de modèles disponibles, le type, et l'échelle des paramètres disponibles à l'algorithme de groupement (clustering algorithm). L'extraction et le choix des paramètres sont les composantes fondamentales de cette tâche.
- **Choix de la distance ou mesure de similitude:** la définition d'une mesure de similitude entre les paires de modèles est essentielle pour mettre en application un algorithme de groupement. Certains algorithmes de groupement peuvent être implémentés par l'application de différente distance métrique. D'autres techniques sont conçues pour un seul type de fonctions de distance. Des approches à la distance ou à la

similitude de mesure ont été intensivement étudiées [97, 98]. La mesure de similitude la plus connue est la distance euclidienne $E = (\sum_p |x_{ip} - x_{kp}|^2)^{\frac{1}{2}}$. Plus la distance est petite, plus la similitude est grande. Le calcul des distances entre les paires de modèles qui sont représentés par différents types de paramètres peut ne pas être une tâche insignifiante et le choix d'une mesure de distance est donc dépendant des données et de l'application [99].

- **Choix de l'algorithme de groupement:** les algorithmes de groupement ont des avantages et des limitations aussi, qui peuvent dépendre de la nature statistique des données à étudier, le domaine du problème, et les besoins des utilisateurs [100]. Il n'y a aucun consensus clair de savoir si on peut identifier le meilleur algorithme pour un problème particulier puisque les différents algorithmes peuvent dévoiler divers aspects pour les données étudiées. Les exemples traditionnels de ces algorithmes incluent différents types de groupement hiérarchique, l'algorithme K-mans et la carte auto organisée de Kohonen.
- **Validation du modèle:** la validation ou l'évaluation des résultats de groupement est une tâche fondamentale dans l'analyse de groupement [100] et [101]. Etant donné les modèles putatifs produits par un algorithme, il est essentiel de répondre à des questions comme: quelle est la signification de cette répartition en termes de nombre de modèles et d'assignement des modèles? Ces modèles sont-ils significatifs ? Cette tâche devient plus complexe en l'absence des critères et des connaissances objectifs pour interpréter la qualité des modèles [102].

9. Les avantages et les inconvénients du traitement par RNA

Comme présenté dans les sections précédentes, les RNA se sont avérés un outil puissant dans le perfectionnement des systèmes de diagnostic cardiaques dans les dernières décennies. Dans Partridge et al [103], plusieurs avantages des RNA par rapport aux techniques conventionnelles et l'analyse manuelle dans les applications médicales ont été identifiés :

- l'implémentation des systèmes est possible par l'utilisation des paramètres descriptifs au lieu des règles prédéfinies sur les maladies.
- Les RNA peuvent traiter les bruits et les nouvelles situations d'une façon automatique via la généralisation des données.

- Les RNA peuvent être automatisés pour l'analyse en temps réel et d'une façon rapide et fiable.
- Les RNA éliminent les erreurs dues à la fatigue humaine et à l'habitude.
- Les RNA peuvent aussi traiter de grandes quantités de données.

Cependant, un fossé évident existe entre les propriétés théoriques des RNA et leur vraie implémentation dans la pratique clinique, ceci est principalement dû aux caractéristiques et aux conditions spéciales pour qu'une méthode soit acceptable dans ce champ d'application. Bien que les RNA aient donné d'excellents résultats dans beaucoup d'applications cliniques, il y a quelques points faibles vus par la communauté médicale telle que l'issue de l'interprétation des décisions ou de la complexité de la formulation qui peuvent limiter leurs acceptations dans ce domaine. C'est parce que, en dépit de la grande acceptation dans d'autres domaines d'application, l'utilisation des RNA dans la médecine exige des efforts additionnels en termes d'évaluation de la stabilité et de la robustesse du modèle, qui, dans la plupart des cas, n'est pas effectuée. Ce sont des soucis importants qui doivent être abordés. Dans ce qui suit, nous passons en revue les problèmes principaux produits dans la littérature en développant un RNA pour le problème de classification de l'ECG. Après l'étude projetée sur le schéma 3.1, il est facile de trouver des problèmes dans toutes les étapes du développement du modèle.

9.1 Qualité et représentativité des données disponibles

Quand un problème est basé sur l'apprentissage à partir d'un ensemble d'échantillons, la question principale qui se pose est la qualité et la représentativité des données disponibles qui sont particulièrement appropriées dans le diagnostic des pathologies cardiaques. Dans ce contexte, la majorité des bases de données contiennent peu de données, des annotations sont erratiques, tous les types de bruit et ainsi de suite. Ces problèmes affectent considérablement le classificateur.

9.2 Algorithmes de détection

Le problème principal est dû à la présence de divers types de bruit (dérive lente de la ligne de base, bruit de haute fréquence, bruit impulsif) et à la grande variabilité des signaux, qui dépendent du patient et changent aussi avec le temps. Clairement, un fossé existe toujours

entre les résultats académiques et les résultats observés dans la pratique clinique, où des taux élevés de fausses détections sont trouvés [104].

9.3 Sélection /extraction des paramètres pertinents

Un aspect très important de l'extraction /sélection des paramètres est que les paramètres extraits ne devront pas uniquement avoir un sens, mais ils devront également être significatifs pour le diagnostic.

9.4 Étape de classification

Dans les étapes de classification/diagnostic, quatre problèmes principaux existent: le premier est comment définir les classes de diagnostic, le second est comment choisir le classificateur le plus approprié, le troisième est comment former le classificateur choisi, et le quatrième est comment mesurer la qualité et les performances du classificateur. Dans ce qui suit, nous passons en revue ces aspects.

- **Standardisation des classes de diagnostic**

Le problème le plus significatif dans la classification automatisée est que peu de travaux ont fait face aux problèmes de la standardisation, les règles de la classification, et la définition de l'information qui devrait être considérée pendant le diagnostic [105]. Ceci affecte principalement les classificateurs basés sur des règles prédéfinies, car ils dépendent de la connaissance fournie par l'expert humain, qui, dans certains cas, peut être basé sur des procédures de tâtonnements. Ces problèmes peuvent expliquer la popularité récente des RNA, où aucune règle n'est exigée au début.

- **Choix du classificateur le plus approprié**

Le réseau MLP avec le rétro-propagation du gradient comme algorithme d'apprentissage est le réseau de neurones le plus utilisé dans la tâche de la classification des signaux ECG. Cependant, plusieurs avantages et améliorations peuvent être obtenus en employant d'autres types de réseaux de neurones plus raffiné. Les chercheurs utilisent souvent des approches sophistiquées pour résoudre des problèmes faciles et vice versa. Dans Selker et al [106], les auteurs ont noté que la dégradation des performances et le manque d'interprétation du MLP en le comparant avec des modèles plus simples. Ils ont conclu de cette étude que le choix de la technique de classification devrait être faite sur la base des besoins spécifiques de l'application, plutôt que supposer que les méthodes déjà essayées sont intrinsèquement plus puissantes que les autres.

- **Développement du modèle**

Le problème du choix du classificateur et la méthodologie la plus appropriée pour le développement du modèle dans un problème de classification de l'ECG donné est lié à plusieurs aspects. Par exemple, les chercheurs devront penser avant de choisir une famille de classificateurs à leur convenance au problème, c.-à-d., les possibilités de traiter le bruit et les changements dynamiques des signaux, le travail efficacement avec les dimensions élevées de l'espace d'entrée du problème, ainsi que l'utilisation d'un ensemble réduit de données dans l'étape d'apprentissage. En outre, le risque de chute dans des minimum locaux, l'algorithme d'étude est spécifique, ou le besoin des techniques pour éviter la sur-modélisation 'overfitting'. Ces problèmes devront être discutés dans le contexte spécifique de l'application.

- **Évaluation d'exactitude**

Quelques suggestions pour l'évaluation approfondie des systèmes d'aide à la décision médicale intelligente basés sur les RNA sont fournies dans [107]. Les auteurs ont passé en revue quelques concepts nécessaires pour l'évaluation de l'exactitude des systèmes. Comme ils ont indiqué, plusieurs concepts mathématiques utilisés par les chercheurs ne sont pas connus dans la communauté médicale et vice versa. Par conséquent, parfois un RNA est évalué en termes de critères significatifs pour la communauté de chercheurs mais avec peu d'avantages pour la communauté médicale. Ceci implique que les RNA devront être comparés aux normes, admises dans le domaine médical. En outre, la comparaison devra être effectuée pour démontrer l'exactitude par l'utilisation d'un ensemble de mesures et de critères largement reconnus.

10. Conclusion

Ce chapitre donne un aperçu sur les différentes étapes constituant un système automatique de diagnostic cardiaque. L'utilisation des techniques de l'intelligence artificielle dans le traitement du signal ECG notamment les RNA ainsi que les problèmes liés à la détection et la classification des désordres cardiaques sont aussi exposés.

Une partie du chapitre est consacrée à la présentation d'un état de l'art sur l'application de l'intelligence artificielle dans la conception des systèmes automatiques de

diagnostic cardiaque, surtout l'utilisation des réseaux de neurones dans l'étape de la classification.

Nous avons terminé ce chapitre par les avantages et les inconvénients du traitement du signal ECG par les RNA.

Chapitre IV

***Approximation de la DSP
du complexe QRS par les
pentes fractionnaires***

1. Introduction

La deuxième étape dans la classification des anomalies cardiaques après le pré traitement est l'extraction des paramètres caractéristiques à partir des signaux ECG à étudier. Cette extraction est essentielle dans le sens où c'est elle qui va décrire les signaux observés dans un format qui permet d'effectuer un test. Dans cette étape, plusieurs niveaux de traitement peuvent se compléter. Une optimisation de la sélection des paramètres peut être incluse dans ce processus, par laquelle le vecteur caractéristique est réduit en dimension, ne retenant que les caractéristiques les plus pertinentes nécessaires à la discrimination et parfois assisté par des connaissances a priori ou des règles. La représentation du signal ECG sous forme de vecteurs modèles en M dimensions (un vecteur peut contenir n'importe quel ensemble d'échantillons consécutifs du signal ECG original tel que le complexe QRS) est une étape critique dans l'analyse automatisée de l'ECG. Le but d'une telle technique d'extraction de paramètres est de modifier correctement les données selon le contexte spécifique du problème aux fins de l'analyse automatisée. Puisque le contenu d'information d'un ensemble d'échantillons du signal qui constitue un vecteur modèle dépasse habituellement de loin ce qui est nécessaire pour l'analyse, les techniques d'extraction de paramètres réduisent la dimensionnalité de données en rapportant le vecteur de paramètres à N dimensions ($N < M$) dont les composants se nomment paramètres pertinents. Les paramètres pertinents des vecteurs à dimension réduite permettent une implémentation simple, efficace et un temps de calcul réduit. Le choix de la technique qui permet l'extraction des paramètres pertinents est très important, puisque les paramètres extraits doivent conserver le maximum d'information significative. Ce choix est primordial car il influe vivement sur la tâche de classification. Plusieurs paramètres caractéristiques ont été proposés dans la littérature pour la classification des signaux ECG, comme la représentation temporelle [14], les intervalles RR [15], les fonctions Hermites [16], la modélisation autorégressive [17] et la transformation en ondelettes [18-20].

Dans ce qui suit, nous présentons une nouvelle méthode utilisée pour extraire les paramètres à partir du signal ECG basée sur le concept des fractales (fractionnaire) [108-109]. Cette technique permet de réduire en deux paramètres seulement un vecteur qui contient le complexe QRS complet (environ 50 échantillons du signal original). Les paramètres extraits par cette technique sont appelés pentes fractionnaires obtenues à partir de la densité spectrale

de puissance (DSP) du complexe QRS. Ces nouveaux paramètres à dimension très réduite seront utilisés dans la classification et la discrimination des anomalies cardiaques.

2. Les fractales

Le concept des fractals est né d'une réflexion des mathématiciens sur la notion de dimension d'espace. Bien sûr, certains scientifiques avaient auparavant remarqué des objets aux propriétés étranges, que l'on rattache désormais aux fractales, mais leur formalisme complet et cohérent n'a été dévoilé que par B. Mandelbrot dans les années 80 du vingtième siècle [21-22]. Au sens le plus large, le nom ou l'adjectif *fractal* se rapporte aux objets physiques ou aux processus dynamiques qui manifestent de nouveaux détails s'il y a allongement (agrandissement) de l'échelle (l'espace ou le temps). Les fractales se composent souvent d'une hiérarchie de structures (spatiales ou temporelles) en cascade et ils sont souvent accomplis à travers une réplique récursive de modèle jusqu'à des échelles plus fines comme pour l'exemple montré sur la Figure (4.1).




Figure 4.1 Exemple d'une construction fractale la courbe de Von Koch

Si la règle de réplique préserve l'invariance dans l'échelle dans toute l'entité, de telles fractales sont dites auto similaires (au sens exact ou statistique). Une caractéristique très importante des fractales est la capacité de comprimer une structure avec économie des ressources (énergie, espace,... etc.). Ces types de fractales sont dominants en physiologie, comme exemple nous pouvons citer, le système respiratoire, le faisceau de conduction cardiovasculaire et le tissu nerveux [110] qui ont la caractéristique additionnelle d'être "fault tolerant" [31].

La mesure la plus employée dans le diagnostic d'une fractale est la dimension fractale qui est un nombre réel et positif caractérisant la manière dont la masse de l'objet est répartie dans l'espace. La raison pour laquelle ce choix a été fait c'est que la plupart des objets fractals sont auto similaires; en d'autres termes, ils peuvent être caractérisés par une mesure exprimée sous forme de facteur de puissance, où l'exposant de puissance β , lie le changement de la quantité dépendante observée V à la variable indépendante x comme suit $V(x) = x^\beta$ [111]. Le paramètre β est proportionnel au rapport du logarithme de $V(x)$ et x , c'est-à-dire:

$$\beta = \log[V(x)] / \log(x) \quad (4.1)$$

Dans le cas des objets fractals, β est l'exposant de l'échelle dans le sens fractal et il peut avoir une valeur fractionnaire. Une dimension fractionnaire permet de mesurer des qualités qui n'auraient pas de définition claire comme, le degré de rugosité, de fragmentation, ou l'irrégularité d'un objet [112]. La formule qui décrit le concept de l'invariance d'échelle, en exploitant l'homogénéité est donnée par:

$$f(\mu) = f(a.\mu) / b \quad (4.2)$$

Où a et b sont des constantes, et μ est une variable indépendante [110]. Ceci veut dire qu'un changement de l'échelle par un facteur d'ordre croissant ou décroissant produit un changement de l'amplitude de la fonction par un facteur d'ordre inverse. Une solution de cette équation est la fonction:

$$f(\mu) \approx \mu^\beta \quad (4.3)$$

Dans ce cas $\beta = \log(b)/\log(a)$. L'utilité de cette fonction d'échelle particulière a été prouvée plusieurs fois et dans beaucoup de domaines scientifiques, y compris la thermodynamique des transitions de phase [113] et le comportement de seuil des réseaux de percolation [114-115].

3. Loi de puissance inverse (processus $1/f$)

Parfois le contenu fréquentiel des signaux fournit des informations plus utiles que la représentation temporelle. Beaucoup de signaux biologiques comme le signal ECG

démontrent des propriétés utiles une fois vus dans le domaine fréquentiel. Par conséquent un intérêt croissant a été donné par les chercheurs au comportement en loi de puissance inverse dans le domaine fréquentiel, cet intérêt provient en grande partie de l'identification d'une grande classe de signaux et dans divers domaines scientifiques qui possèdent un spectre qui s'atténue en suivant une loi de puissance inverse et qui représente une pente fractionnaire sur le tracé de Bode [116-117]. Un tel comportement est souvent vu comme la manifestation ou l'effet d'une multitude de processus locaux évoluant dans le temps et qui provoquent simultanément les soi-disant $1/f^\beta$ ou, plus généralement, les processus $1/f$. Plusieurs phénomènes qui ont été étudié possèdent cette même caractéristique tel que le bruit électrique [23], le phénomène de relaxation des impédances polarisées dans les milieux diélectriques [24], densité spectrale de puissance de la dépolarisation des ventricules (QRS) [29] (voir Figure (4.2)), le rythme cardiaque [25] (voir Figure (4.3)), les membranes cellulaires [26], les ondes cérébrales [27], la densité spectrale de l'onde musicale, ainsi que les données en météorologie, en économie, et en statistique [28]. Ces processus connus sous le nom de $1/f^\beta$ obéissent à une loi appelée équation de la loi de puissance inverse donnée par:

$$H(S) = \frac{K}{S^\beta} \quad (4.4)$$

où K est une constante positive, $s = j\omega$ est la fréquence complexe et β est un nombre réel dit aussi nombre fractionnaire communément appelé dimension fractale.




Figure 4.2 Comportement en $1/f$ de la DSP du complexe QRS (rythme sinusal normal).




Figure 4.3 Comportement en $1/f$ de la puissance de la série RR du rythme cardiaque (Rythme normal).

4. Invariance d'échelle temporelle d'un signal

Le terme fractal se rapporte aux structures géométriques qui ont la propriété d'auto similarité quelque soit l'échelle [24]. Cette définition n'est pas réservée pour les structures déterministes, mais peut être également appliquée aux structures stochastiques dont les propriétés statistiques exposent une auto similarité (au niveau de l'invariance d'échelle). En outre, ce concept peut être prolongé aux séries temporelles où il y a des fluctuations sur les échelles de temps multiples (en anglais multiple time scales). La technique la plus utilisée pour étudier si un signal possède la propriété d'invariance d'échelle temporelle est l'analyse de son spectre. Si un signal est fractal, donc il possède la propriété d'invariance d'échelle temporelle, l'amplitude de son spectre de puissance diminuera avec l'augmentation de la fréquence, alors il suit une relation de la forme $1/f^\beta$ (où β est un nombre positif), c.-à-d., le spectre de puissance est mesuré par une loi de puissance inverse [24].

5. Le cœur et le fractionnaire

L'activation du myocarde ventriculaire dans le cas du rythme sinusal normal se produit par l'intermédiaire du faisceau de His et Purkinje (voir Figure (4.4)). Les fines fibres de

Purkinje fortement ramifié possèdent une structure fractale [30,32]. Et comme l'activation du myocarde ventriculaire se produit à travers le réseau de Purkinje, Goldberger et al [29] ont prouvé que l'activation des ventricules par l'intermédiaire des fibres de Purkinje mène à une dépolarisation fractale des ventricules [30] et [119]. Cette dépolarisation est reflétée dans le complexe QRS. Le tracé logarithmique du spectre de la puissance moyenne de plusieurs complexes QRS et de différents individus a montré une décroissance en $1/f^\beta$ (où f est la fréquence). Goldberger et al [29] ont conclu que le spectre du complexe QRS suit une loi de puissance inverse, et que ce spectre possède une pente fractionnaire.




Figure 4.4 Illustration schématique du système de conduction électrique ventriculaire du cœur.

6. Les caractéristiques fréquentielles de l'ECG

L'étude de Thakor et al. [118] présente l'analyse spectrale de l'ECG, avec une analyse spectrale des complexes QRS isolés ainsi que différentes sources de bruit. Les spectres observés après moyennage sur 150 battements sont présentés sur la Figure (4.5). Il a été démontré que les composantes fréquentielles d'un ECG normal ont les caractéristiques suivantes :

- Le spectre de l'ECG s'étend entre une fréquence nulle et environ 100 Hz,

- L'onde P se caractérise par une bande spectrale de basse fréquence et de faible amplitude : ses composantes fréquentielles sont entre 0.5 Hz et 10 Hz ;
- L'onde T se caractérise sur une bande spectrale analogue à celle de l'onde P entre 0.5 Hz et 10 Hz ;
- Le complexe QRS possède un contenu fréquentiel bien plus important que les autres ondes de l'ECG. Ses composantes fréquentielles sont concentrées entre 10 Hz et 15 Hz (l'étalement du spectre du complexe QRS est entre 0 Hz et 40 Hz (voir Figure (4.5))
- Le contenu fréquentiel de la ligne de base et des éventuels artefacts de mouvement se situe entre 0.5 Hz et 7 Hz.




Figure 4.5 Densité spectrale de puissance du complexe QRS, des ondes P et T, du bruit d'origine musculaire ou dû aux mouvements respiratoires ou autres.

7. Spectre de puissance du complexe QRS

Le spectre de puissance de la dépolarisation des ventricules dans le cas du rythme sinusal normal suit une loi de puissance inverse (voir Figures (4.2) et (4.5)) comme il a été démontré par Goldberger et al [29]. Ce spectre de puissance représente une approche quantitative potentielle pour caractériser les dysfonctionnements du cœur et peut être employé pour développer une technique qui permet de distinguer les battements anormaux des battements normaux. Par conséquent, si la dépolarisation des ventricules est d'origine ectopique, comme dans le cas des battements des extrasystoles ventriculaires (ou les blocs de branches), le spectre de puissance est affecté puisque l'impulsion de la dépolarisation ne suit

pas le chemin de dépolarisation normal (le faisceau de His et Purkinje). Autrement dit quand l'impulsion d'activation provient de l'oreillette et traverse le chemin normal de conduction, le complexe QRS est étroit, et le spectre contient les composantes à haute fréquence. Quand l'impulsion d'activation provient du ventricule et ne traverse pas le chemin normal de conduction, le complexe de QRS devient plus large, et les composantes à haute fréquence du spectre sont atténués [29]. Pour exploiter la propriété de loi de puissance inverse comme approche quantitative potentielle pour caractériser des anomalies cardiaques, nous avons calculé et tracé le spectre de puissance du complexe QRS et par la suite calculé deux pentes fractionnaires par interpolation dans deux domaines fréquentielles. Les pentes calculés seront utilisés pour caractériser tout un battement comme il sera expliqué par la suite.

8. La méthode proposée

La méthode proposée est basée sur l'utilisation de deux nouveaux paramètres extraits de la densité spectrale de puissance du complexe QRS pour discriminer (classifier) les battements anormaux des battements normaux. Ces paramètres appelés pentes fractionnaires sont calculés par interpolation linéaire de la DSP du complexe QRS dans deux intervalles différents de fréquence. La discrimination (classification) est réalisée par un réseau de neurone alimenté seulement par les deux paramètres qui représentent le complexe QRS ou plus généralement qui représentent un battement.

8.1 Prétraitement du signal

La première étape du prétraitement du signal consiste principalement à éliminer certains bruits qui entachent le signal ECG, tels que interférence à 50Hz avec l'alimentation des appareils de mesures, artefacts liés aux électrodes, déviation de la ligne de base liée aux mouvements du cœur et du patient ...etc. Différentes méthodes reportées dans la littérature proposent déjà des performances très satisfaisantes. Elles sont basées sur des filtres simples ou des filtres adaptatifs [119-120,93]. Dans notre cas nous avons utilisé un filtre passe bande proposé par Christov et al [93] qui est conçu comme suit:

- Notch filtre pour la suppression du bruit du secteur
- Un filtre passe bas pour l'élimination du bruit electromyographique
- Un filtre passe haut pour la suppression de la ligne de base

Ces filtres est donné par:

$$Y_n = C_1(X_n - X_{n-1}) + C_2 Y_{n-1} \quad (4.5)$$

Les coefficients C_1 et C_2 sont donnés comme suit:

$$C_1 = \frac{1}{1 + \tan(F_c \pi T)} \quad \text{et} \quad C_2 = \frac{1 - \tan(F_c \pi T)}{1 + \tan(F_c \pi T)} \quad (4.6)$$

où T est la période d'échantillonnage et $F_c = 1$ Hz est la fréquence de coupure équivalente du filtre passe haut. F_c est proche de la fréquence de coupure recommandée par le standard des instruments de surveillance cardiaque type ECG (IEC 62D/60601-2-27 1994) [121]. Ce filtre est bien adapté au problème de classification, puisqu' il permet de conserver les informations utiles contenues dans le complexe QRS. Les Figures (4.6) et (4.7) montrent le signal ECG original et le signal filtré dans deux cas. Dans le premier cas le signal contient seulement des battements normaux et dans le second cas le signal contient une anomalie de type PVC.

La seconde étape du prétraitement est la détection des complexes QRS qui est considérée comme un problème déjà résolu de manière satisfaisante. Dans [10] de divers algorithmes de détection de l'onde R ont été reportés. Dans notre cas nous avons utilisé directement les annotations associées à la base de données MIT/BIH, cela nous a permis d'éviter les problèmes liés aux erreurs dûes a la détection des ondes R.




Figure 4.6 Filtrage d'un signal ECG normal (Enregistrement 100 de MIT/BIH)


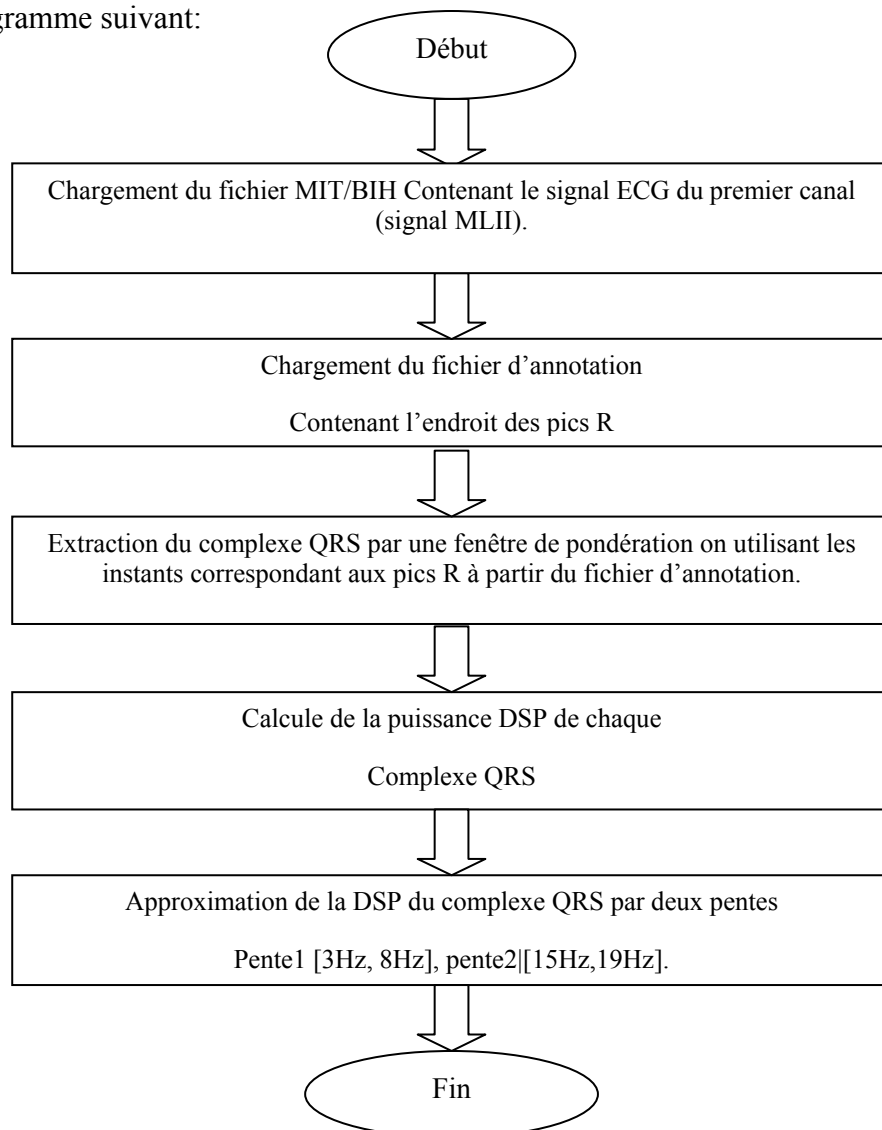


Figure 4.7 Filtrage d'un signal ECG avec un battement PVC (Enregistrement 221 de MIT/BIH).

8.2 Les étapes de traitement (algorithme principal)

L'algorithme principal d'extraction des pentes fractionnaires est donné par les étapes de l'organigramme suivant:



8.3 Choix de la fenêtre d'extraction des complexes QRS

Les complexes QRS ont été extraits en se servant des annotations du signal de la base de données MIT/BIH qui nous donnent l'emplacement de l'onde R et le complexe QRS. Chaque segment extrait couvre un QRS complet obtenu par fenêtrage. Pour minimiser les déformations entraînées par la troncature des complexes QRS et pour réduire les discontinuités du signal nous avons utilisé une fenêtre de Blackman donnée par l'équation (4.7) comme suit [122]:

$$w(n) = 0.42 - 0.5 \cos\left(\frac{2\pi \cdot n}{N-1}\right) + 0.08 \cos\left(\frac{4\pi \cdot n}{N-1}\right), 0 < n < N-1 \quad (4.7)$$

La Figure (4.8) illustre l'emplacement de la fenêtre de Blackman pour extraire le complexe QRS.





Figure 4.8 Endroit de la fenêtre d'extraction du complexe QRS.

Dans cette thèse, nous avons considéré deux types d'anomalies cardiaques, la contraction ventriculaire prématurée (PVC) et le bloc de branche droit (RBBB). Ces deux types d'anomalies cardiaques sont caractérisés par un complexe QRS large par rapport au complexe QRS normal.


Nous avons choisi une fenêtre d'extraction étroite (la taille de cette fenêtre est proche de la largeur d'un complexe QRS normal) pour extraire le complexe QRS, ce choix nous a permis

d'extraire les complexes QRS des battements normaux dans de meilleures conditions (sans les ondes P ou T).

La Figure (4.9) montre les spectres de puissance de plusieurs complexes QRS tronqués par une fenêtre étroite (les battements normaux à gauche et les battements anormaux à droite). On remarque que tous les spectres suivent une loi de puissance inverse; la remarque la plus importante est que le comportement du spectre du complexe QRS normal et du complexe QRS anormal est complètement différent. Cette propriété sera exploitée pour créer une différence entre les battements normaux et les battements anormaux.



Spectre de puissance d'un QRS normal



Spectre de puissance d'un PVC

Figure 4.9 Spectre de puissance du complexe QRS dans deux cas considérés.

8.4 Spectre de puissance et calcul des pentes

La première étape est le calcul du spectre de puissance de chaque complexe QRS en utilisant la transformée de Fourier rapide. Ensuite, le logarithme du spectre de puissance résultant est calculé pour obtenir la propriété de loi de puissance dans le tracé de Bode. Finalement, les deux pentes des droites des meilleures approximations au sens des moindres carrés du spectre sont calculées dans deux intervalles de fréquences différents [3Hz, 8Hz] et [15Hz, 19Hz]. La Figure (4.10) illustre la DSP d'un complexe QRS ainsi que ces approximations par deux droites dans les deux différents intervalles de fréquences [3Hz, 8Hz] et [15Hz, 19Hz].

Les deux pentes obtenues peuvent alors être employées comme paramètres pour distinguer les battements anormaux des battements normaux, dans ce cas ils peuvent remplacer l'information contenue dans un cycle cardiaque, et cela représente un grand gain dans la réduction de la dimensionnalité du problème de discrimination.




Figure 4.10 Approximation de la DSP du complexe QRS.

Les deux intervalles de fréquences ont été choisis en se basant sur les résultats obtenus par Minami et al [123] où les auteurs ont trouvé qu'il y a une nette différence entre les histogrammes des spectres de puissance du complexe QRS normaux et anormaux de différents types d'anomalies cardiaques (voir Figure (4.11)) dans les fréquences 4 Hz, 8 Hz, 16 Hz et de 20 Hz (voir Figure (4.11)).




Figure 4.11 Histogrammes de différents types de battement Minami et al [36].

La Figure (4.12) montre un exemple illustratif du tracé de la seconde pente en fonction de la première. Chaque point sur la figure représente un battement (battement normal en bleu et battement PVC en rouge). On peut facilement voir qu'on a deux différentes régions représentant deux classes séparées. Cette caractéristique sera utilisée dans l'étape de classification des anomalies cardiaques.




Figure 4.12 La distribution de la deuxième Pente en fonction de la première Pente (Battement normal en bleu et anormal PVC en rouge).

9. Conclusion

Ce chapitre comprend deux parties, la première partie présente les concepts de la géométrie fractale, les processus $1/f$ ainsi que la relation entre le signal cardiaque et le calcul des pentes fractionnaires.

La seconde partie est consacrée à la description détaillée de la méthode proposée pour l'extraction des pentes fractionnaires à partir du signal ECG; nous avons expliqué dans cette partie du chapitre les différentes étapes de traitement de la méthode proposée, notamment le prétraitement du signal ECG, le calcul de la DSP du complexe QRS et l'approximation de cette DSP pour parvenir aux pentes fractionnaires, qui seront utilisées par la suite dans la classification des anomalies cardiaques.

Chapitre V

Résultats et discussions

1. Introduction

Ce chapitre présente les résultats de traitement obtenus sur des données réelles de la base de donnée MIT/BIH [124]. Les deux paramètres (pentes fractionnaires) extraits par la méthode proposée dans le chapitre précédent serviront comme entrées aux RNA, dont le but de la discrimination (classification) des anomalies cardiaques et par conséquent pour démontrer et vérifier leur utilité et fiabilité.

Dans le cadre de cette thèse, nous avons considéré deux types de RNA, nous nous sommes intéressés au réseau perceptron multicouches (MLP) largement utilisé dans la classification des anomalies cardiaques ainsi que la carte auto organisée de Kohonen (SOM). Le premier réseau est à apprentissage supervisé et le second est à apprentissage non supervisé. Le choix de ces deux architectures neuronales a été fait pour voir l'influence de l'architecture du réseau et la fiabilité des deux pentes dans la classification. Deux expériences sont présentées dans ce chapitre, chaque expérience est indépendante de l'autre. La première consiste à la discrimination des battements PVC à partir d'un grand nombre de battements normaux. Nous utilisons dans cette expérience un réseau SOM alimenté seulement par les deux pentes extraites [108]. La deuxième expérience est la classification de deux types de battement, la première classe représente les battements normaux et la deuxième classe représente les blocs de branche droit (RBBB). Nous avons utilisé les mêmes paramètres que dans la première expérience, mais nous avons changé les paramètres de l'algorithme pour qu'il soit adapté à la situation traitée. Dans cette partie nous avons utilisé un réseau MLP, pour dire que les deux paramètres utilisés dans la première expérience peuvent être aussi utilisés pour la classification du bloc de branche droit [109]. On note que l'objectif de ces expériences n'est pas le développement des réseaux ni même l'optimisation des résultats obtenus qui sera l'une des perspectives futures.

2. Les anomalies cardiaques traitées

Deux types d'anomalies seront prises en considération dans les expériences citées dans ce chapitre, le choix de ces deux anomalies, a été fait sur la base de la morphologie et la forme des complexes QRS ainsi que sur le processus de dépolarisation des ventricules cité dans le chapitre 4. La contraction ventriculaire prématurée (PVC) et le Bloc de branche droit (RBBB) se caractérisent tous les deux par un complexe QRS large, cette propriété sera exploitée pour

créer une différence entre les battements normaux et les battements anormaux (PVC ou RBBB) [125]. On note que dans la suite de ce chapitre nous allons utiliser les abréviations en anglais PVC et RBBB pour désigner les anomalies cardiaques traitées.

2.1 La contraction ventriculaire prématurée (Extrasystole ventriculaire)

Les PVC (en français ESV) s'observent sur quasiment tous les enregistrements ECG, principalement en période de récupération après un effort. Bien que leur présence n'indique aucune pathologie particulière, si, de façon récurrente, leur nombre par minute est supérieur à 6, elles peuvent être un signe précurseur d'une tachycardie ventriculaire [53], qui constitue une pathologie majeure. Contrairement aux battements normaux qui ont pour origine la dépolarisation des cellules sinusales, le PVC naît de la dépolarisation spontanée d'un petit groupe de cellules ventriculaires, appelé alors foyer ectopique ventriculaire. L'impulsion électrique créée n'emprunte pas la voie normale de conduction (faisceau de His), et se propage donc plus lentement dans les ventricules. La contraction ventriculaire ainsi étalée dans le temps perd de son efficacité. Le tracé d'un battement PVC est caractérisé par deux propriétés: l'onde R n'est pas précédée d'une onde P, puisqu'il n'y a pas eu d'activité auriculaire préalable, et la durée du complexe est supérieure à la durée d'un complexe QRS normal [54] (Figure (5.1)).




Figure 5.1 Contraction ventriculaire prématurée (PVC).

Les PVC sont des battements ectopiques, uniques ou répétés, provenant d'un seul ou de plusieurs foyers qui peuvent entraîner des sensations désagréables de ratés, de coups dans la poitrine, d'arrêts de cœur ou de palpitations. Les PVC sont des phases systoliques en trop qui seront apparentes sur l'ECG par un complexe QRS large (Figure (5.2)). Les PVC ne constituent habituellement pas en elles mêmes un facteur de gravité, leur pronostic dépend de

l'état cardiaque qui peut être absolument normal (PVC dites bénignes) ou pathologique. Lorsqu'il existe un double foyer ventriculaire, on parle de doublet ventriculaire (Figure (5.3)). Les bigéminismes et trigéminismes sont des rythmes à deux commandes. La commande de base (généralement sinusale) est interrompue par des battements d'origine ectopique. Lorsque l'on se trouve en présence d'un bigéminisme les QRS qui appartiennent au rythme de base sont suivis d'un QRS d'origine ectopique avec une succession de 1/1. On parle de trigéminisme lorsqu'on est en présence d'une succession 2/1. Les Figures (5.4) et (5.5) présentent respectivement un exemple de rythme de bigéminisme et de trigéminisme dans le cas d'un rythme sinusal avec un foyer ectopique ventriculaire. Les tachycardies ventriculaires (TV) représentent les arythmies les plus graves, elles compromettent souvent l'hémodynamique et peuvent dégénérer en fibrillation ventriculaire létale. Les complexes QRS sont toujours élargis et le rythme est rapide. L'accès de tachycardie ventriculaire persistante est une urgence médicale, l'arrêt de la crise pouvant être obtenu par injection intraveineuse d'un anti arythmique ou par choc électrique externe. Quand les récurrences de tachycardie ne sont pas prévenues par les médicaments anti-arythmiques, le recours à des méthodes non pharmacologiques est légitime telles que la chirurgie et l'implantation de défibrillateur [2,125].




Figure 5.2 Extrasystole PVC.




Figure 5.3 Doublet ventriculaire.




Figure 5.4 Rythme de bigéminisme.




Figure 5.5 Rythme de trigéminisme.

2.2 Les Blocs

Le bloc est un exemple de problèmes de conduction. C'est un défaut localisé de propagation de l'impulsion électrique dans le tissu cardiaque. Lorsqu'il est complet, c'est-à-dire que l'absence de conduction est totale, des pacemakers de réserve comme un foyer ectopique auriculaire, ou le nœud AV, peuvent prendre le relais et entraîner des bradycardies ou tachycardies [2,125]. A l'inverse, lorsqu'il apparaît de manière sporadique, suivant le cas, il peut se manifester par des troubles du rythme: on observe alors une irrégularité. Au niveau des voies de conduction rapide de l'influx nerveux dans le cœur, il existe essentiellement trois types de *blocs* classés suivant leurs localisations (Voir Figure (5.6)). Le bloc sino-auriculaire (SA) situé entre le sinus et les oreillettes, le bloc auriculo-ventriculaire (AV) entre les oreillettes et les ventricules, et le bloc de branche (droit et/ou gauche) au niveau de la transmission à chacun des deux ventricules; ce sont surtout les deux premiers (blocs SA et AV) qui sont susceptibles d'entraîner des troubles du rythme [2,125].




Figure 5.6 Localisation des blocs standards le long des voies de conduction rapide de l'influx nerveux.

Les troubles cardiaques de la conduction des influx nerveux à l'intérieur des branches du faisceau de His entraînent un retard d'activation d'un ventricule du cœur par rapport à l'autre. On distingue le bloc de branche et le bloc de branche bilatéral appelé également bibloc. Le bibloc est une association de troubles de la conduction concernant les deux des trois branches de division du faisceau de His. On constate un ralentissement voir une interruption de la conduction des influx nerveux (ordre donné aux ventricules de se contracter) vers l'un des deux ventricules. Ce ralentissement entraîne un retard de contraction d'un ventricule par rapport à l'autre.

3. La base de donnée MIT/BIH

La source de l'ECG inclus dans la base de données d'arythmies MIT/BIH est un ensemble de 48 enregistrements échantillonnés à une fréquence de 360 Hz. Chaque enregistrement comporte deux dérivations différentes du signal ECG. La base de données contient 23 enregistrements numérotés entre 100 et 124 pour le premier groupe; et de 25 enregistrements numérotés entre 200 et 234 pour le deuxième groupe. La durée de chacun des 48 enregistrements est de 30 minutes. Le premier groupe est prévu pour servir d'échantillon représentatif de variété de formes d'ondes qu'un détecteur d'arythmie pourrait rencontrer dans l'utilisation clinique courante; tandis que le deuxième groupe est choisi pour inclure une variété de cas pathologiques. Les sujets étaient 25 hommes âgés de 32 à 89 ans, et 22 femmes âgées de 23 à 89 ans. Les enregistrements de MIT/BIH sont tous annotés; ce qui veut dire que chaque battement (complexe QRS) est décrit par une étiquette (annotation). Typiquement, un fichier d'annotation pour un enregistrement MIT/BIH contient environ 2000 annotations [124].

4. La première expérience : Discrimination des PVC par le réseau SOM

L'objectif principal de cette expérience est de vérifier la fiabilité et l'utilité des deux paramètres (pentes fractionnaires) dans la discrimination des anomalies cardiaques. Cette section présente un travail original dans le domaine de la détection des battements PVC; l'étape d'extraction/sélection des paramètres (développé dans le chapitre 4) d'un system de traitement automatisé du signal ECG est suivie d'un classificateur a apprentissage compétitif et non supervisé (le réseau SOM). Plusieurs types de classificateurs peuvent être utilisés dans l'étape de la classification, le choix du réseau SOM sera justifié ultérieurement. Donc cette expérience présente une des configurations possibles d'un discriminateur des battements PVC basé sur les paramètres (pentes fractionnaires) proposés. Nous avons considéré dans cette expérience deux classes, la première classe est la classe des battements normaux, cette classe est constituée de plusieurs types de battements. La deuxième classe est la classe des battements PVC. Le Tableau 5.1 illustre ce regroupement. Les lettres inscrites dans la colonne d'annotation du Tableau 5.1 sont comme mentionnées dans la description des arythmies dans la base de données MIT/BIH.

Tableau 5.1 Annotation des battements de la base de données MIT-BIH

Annotation MIT-BIH Annotation symbol	Type d'arythmie	catégorie
N	Normal beat	Classe N
A	Atrial premature beats	Classe N
L	Left bundle branch beat	Classe N
R	Right bundle branch beat	Classe N
P	Paced beat	Classe N
a	Aberrated atrial premature beat	Classe N
J	Nodal (junctional) premature beat	Classe N
S	Supraventricular premature beat (atrial or nodal)	Classe N
e	Atrial escape beat	Classe N
j	Nodal (junctional) escape beat	Classe N
V	Premature ventricular contraction	Classe V

4.1 Extraction des pentes

Les pentes sont extraites à partir des signaux ECG, en se servant de l'algorithme proposé dans la section 8 du chapitre 4. La taille et l'endroit de la fenêtre d'extraction sont des paramètres clés dans cette méthode, un changement significatif est constaté s'il y a un changement de la taille ou de l'endroit de la fenêtre d'extraction des complexes QRS. Une fenêtre large signifie plus de composantes temporelles et d'ondes du signal ECG prises en considération, ceci aura un effet direct sur le contenu fréquentiel des segments extraits et vice versa. Alors un choix adéquat de la taille/endroit de la fenêtre est essentiel pour obtenir des pentes discriminantes.


4.2 Choix de la taille et de l'endroit de la fenêtre d'extraction

Dans le cas des battements de type PVC, l'impulsion électrique de dépolarisation est générée par un foyer ectopique, alors elle ne suit pas le chemin de conduction du rythme sinusal normal, ceci se traduit par une déformation du contenu fréquentiel du complexe QRS par rapport au spectre issu d'un battement sinusal normal. Par conséquent les formes d'onde du PVC sont plus larges que les normales; alors, nous avons choisi une fenêtre très étroite de 150 ms (69.4 ms avant et 83.3ms après l'onde R) pour extraire les complexes QRS à partir du


signal ECG afin de créer une différence entre le spectre de puissance du complexe QRS des battements normaux et le spectre de puissance du complexe QRS des battements PVC.

4.3 Distribution des deux pentes


La Figure (5.7) montre la distribution de la deuxième pente *Pente2* en fonction de la première pente *Pente1* de six enregistrements. Cette figure montre clairement l'existence de deux classes distinctes ainsi qu'une bonne séparation entre ces deux classes. Alors, les deux pentes extraites à partir de la DSP du complexe QRS peuvent représenter les deux types de battements (Normale et PVC) avec des possibilités acceptables de discrimination et une classification peut être réalisée à la base de ces deux paramètres descriptifs.




Enreg. 106: contient beaucoup de battements PVC




Enreg. 119: contient beaucoup de battements PVC




Enreg. 221: contient beaucoup de battements PVC



Enreg. 100: contient un seul battement PVC



Enreg. 124: contient beaucoup de battements PVC



Enreg. 116: contient beaucoup de battements PVC

Figure 5.7 Distribution de $Pente_2$ en fonction du $Pente_1$ pour six enregistrements.

4.4 Choix du réseau SOM

Diverses techniques de classification peuvent être utilisées pour séparer les deux classes représentées par le couple ($Pente_1$, $Pente_2$). Dans cette section nous avons choisi un réseau SOM vu sa simplicité ainsi que son implémentation facile en utilisant les fonctions de Matlab. La propriété essentielle des réseaux SOM réside dans le fait que la topologie de l'espace initial est conservée dans cette projection dans un espace de faible dimension. Ceci facilite l'interprétation par les cardiologues puisque les classes semblables sont présentées comme voisins sur la carte. Les réseaux SOM sont relativement faciles à mettre en œuvre et bénéficient d'un apprentissage efficace dû aux principes de compétition entre les neurones et de voisinage. Les relations de voisinage de Kohonen nous semblent être plus pertinentes et plus efficaces, surtout pour un apprentissage rapide. Pour ces raisons et d'autres encore, comme la stabilité de l'apprentissage ou la rapidité de convergence de l'algorithme, nous avons opté d'utiliser des cartes auto-organisatrices dans cette expérience. Dans notre cas nous avons un problème de classification classique d'un espace à deux dimensions vers un autre espace à deux dimensions, où les entrées sont les deux pentes et les sorties sont les positions dans l'espace de sortie.

4.5 Choix de la taille de la carte

Le choix de la taille de la carte est un compromis entre trois critères, la bonne séparation entre les classes, la facilité d'interprétation de la carte, et le temps de calcul. Alors, en augmentant la taille de la carte, on aura plus de centres de cluster, donc, une meilleure

séparation entre les classes avec différentes formes. D'autre part il sera plus difficile d'employer une carte très grande par les médecins. Nous avons constaté qu'une structure de SOM avec les nœuds 5x5 était suffisante pour assurer une bonne séparation entre les deux classes, la classe normale et la classe des PVC (voir Figure (5.8)).

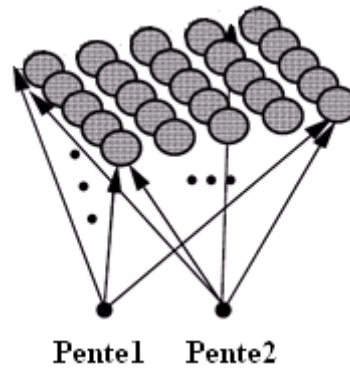


Figure 5.8 La carte SOM utilisée

4.6 Evaluation des performances du réseau

Les équations suivantes ont été utilisées pour évaluer les performances du classificateur

$$\text{Accuracy \%} = \frac{\text{Nombre des battements totales testés} - \text{FN} - \text{FP}}{\text{Nombre des battements totales testés}} * 100 \quad (5.1)$$

$$\text{Specificity \%} = \frac{\text{Nombre des battements normaux testés} - \text{FP}}{\text{Nombre des battements normaux testés}} * 100 \quad (5.2)$$

$$\text{Sensitivity \%} = \frac{\text{Nombre des PVC testés} - \text{FN}}{\text{Nombre des PVC testés}} * 100 \quad (5.3)$$

Où,

F.P (False-Positive) = un battement normal classé comme PVC

F.N (False Négative) = un PVC classé comme un battement normal

4.7 Choix des données d'apprentissage

D'après la Figure (5.7) qui montre la distribution des couples (Pente1, Pente2), il est clair que la distribution des pentes est presque la même pour tous les enregistrements et ceci nous a permis de choisir un seul enregistrement dans l'étape de l'apprentissage. En outre, l'ensemble des données utilisées dans l'apprentissage doit être très petit par rapport à tous les battements à classifier. Par conséquent, la carte a été initialisée aléatoirement, 100 couples de

pentés des battements normaux et 100 pentés des battements PVC de l'enregistrement 106 ont été utilisés dans l'apprentissage du réseau. Le choix de cet enregistrement a été fait à cause de la bonne séparation entre les deux classes constatée pour cet enregistrement. Donc, la classe normale représente les nœuds entiers du réseau SOM qui répondent aux pentés normales dans la phase d'apprentissage et la même chose pour la classe PVC. Un battement est mal classé s'il se trouve dans une classe où la majorité de cette classe est différente de celui-ci.

4.8 Résultats et discussion

Nous avons testé 46 enregistrements de la base de données MIT/BIH et les résultats obtenus sont regroupés dans le Tableau (5.2). Nous avons remarqué lors de l'augmentation de la taille de la fenêtre utilisée pour extraire le complexe QRS (par exemple 220 ms avant l'onde R et 83 ms après l'onde R) il y'aura un chevauchement considérable entre les deux classes (normale et PVC) et la justesse totale ne dépasse pas 50%. On a constaté aussi que cette dégradation des résultats est due essentiellement à l'influence des segments PQ et ST sur la DSP du complexe QRS et par conséquent sur les valeurs des deux pentés d'une manière significative. Nous avons également constaté que la valeur des pentés pour des complexes QRS normaux résulte de la loi de puissance inverse de la DSP, mais la valeur des pentés dans le cas des PVC est due aux informations perdues résultant de l'utilisation d'une fenêtre étroite dans l'extraction des ces derniers. Malgré le très bon résultat obtenu par la méthode proposée, celle-ci souffre de quelques limitations qu'on peut résumer comme suit:

- lorsque un complexe QRS d'un battement normal est plus large par rapport à la moyenne, il sera considéré comme un PVC, d'où l'augmentation du nombre des FP et par conséquent la diminution de la sensibilité du classificateur (comme dans le cas de l'enregistrement 105)
- lorsque l'enregistrement contient des arythmies de type RBBB (Bloc de branche droit) ou LBBB (bloc de branche gauche), ces derniers seront considérés comme des PVC d'où l'augmentation du nombre des FP et par conséquent la diminution de la sensibilité du classificateur (comme dans le cas des enregistrements 109 et 118)
- lorsque des battements sont de type P (Paced beat), ils seront aussi considérés comme des PVC. Mais selon le standard AAMI, ces battements ne seront pas considérés durant le traitement (comme dans le cas de l'enregistrement 107)

Tableau 5.2 Résultat de clustering.

Record	Nombre des battements Normaux	Nombre des battements PVC	Nombre de battement total	F. N	F. P	Justesse %	Spec %	Senv %
100	2272	1	2273	0	1	99.956	99.956	100.00
101	1865	0	1865	0	1	99.946	99.946	-
103	2084	0	2084	0	1	99.952	99.952	-
105	2531	41	2572	38	68	95.879	97.313	7.32
112	2539	0	2539	0	1	99.961	99.961	-
113	1795	0	1795	0	3	99.833	99.833	-
114	1836	43	1879	0	4	99.787	99.782	100.00
115	1953	0	1953	0	1	99.949	99.949	-
116	2303	109	2412	2	16	99.254	99.305	98.17
119	1543	444	1987	5	0	99.748	100.000	98.87
121	1862	1	1863	0	38	97.960	97.959	100.00
122	2476	0	2476	0	1	99.960	99.960	-
123	1515	3	1518	1	0	99.934	100.000	66.67
124	1572	47	1619	0	3	99.815	99.809	100.00
200	1775	826	2601	63	1	97.539	99.944	92.37
201	1765	198	1963	144	85	88.334	95.184	27.27
202	2117	19	2136	9	7	99.251	99.669	52.63
205	2585	71	2656	17	1	99.322	99.961	76.06
208	1963	992	2955	1	145	95.059	92.613	99.90
209	3003	1	3004	0	3	99.900	99.900	100.00
210	2456	194	2650	23	11	98.72	99.55	88.14
212	2748	0	2748	0	1	99.96	99.96	-
213	3031	220	3251	14	83	97.02	97.26	93.64
214	2005	256	2261	94	17	95.09	99.15	63.28
215	3199	164	3363	81	3	97.50	99.91	50.61
219	2090	64	2154	13	0	99.40	100.00	79.69
220	2047	0	2047	0	1	99.95	99.95	-
221	2031	396	2427	8	0	99.67	100.00	97.98
222	2483	0	2483	0	14	99.44	99.44	-
223	2132	473	2605	270	7	89.37	99.67	42.92
228	1691	362	2053	23	4	98.68	99.76	93.65
230	2255	1	2256	0	0	100.00	100.00	100.00
231	1569	0	1569	0	1	99.94	99.94	-
232	1780	0	1780	0	1	99.94	99.94	-
233	2248	830	3078	223	9	92.46	99.60	73.13
234	2750	3	3572	0	0	100.00	100.00	100.00
107	2078	59	2137	9	2033	4.45	2.17	84.75
108	1747	16	1763	7	1709	2.67	2.18	56.25
109	2494	38	2532	7	2485	1.58	0.36	81.58
111	2123	1	2124	0	404	80.98	80.97	100.00
117	1535	0	1535	0	395	74.27	74.27	-
118	2262	16	2278	11	560	74.93	75.24	31.25
203	2536	444	2980	63	981	64.97	61.32	85.81
207	1755	105	1860	9	1668	9.84	4.96	91.43
217	2046	162	2208	6	1638	25.54	19.94	96.30
Total	96445	6600	103864	1141	12405	86.96	88.06	82.71

4.9 Comparaison avec d'autres méthodes

Un résumé des résultats obtenus pour la classification des battements par la méthode proposée et d'autres méthodes est montré dans le Tableau (5.3). Comme notre méthode a été validée en utilisant la base de données MIT-BIH, nos résultats de classification ont été comparés aux résultats rapportés dans les références [95] et [126] parce qu'ils ont les meilleurs résultats que nous avons trouvés dans la littérature. Dans [95] la spécificité rapportée a été de 99.7%, c'est un très bon résultat pour les 34 enregistrements utilisés, mais nous ne savons pas quelle sera cette spécificité si nous utiliserons les 14 enregistrements restants. Le travail qui utilise tous les enregistrements de la base MIT-BIH est présenté dans [126]. Cette méthode donne également un très bon résultat mais elle utilise beaucoup de paramètres complexes; comprenant la corrélation, des paramètres morphologiques du signal, des paramètres fréquentielles et des caractéristiques temporelles du complexe QRS, se qui signifie plus de complexité dans le calcul. La nécessité de l'expert pour décider la nature du battement (battement normal ou anormal) dans l'étape d'initialisation est leur deuxième faiblesse. Dans notre travail nous avons utilisé peu de données dans l'étape d'apprentissage (100 pentes des battements normaux et 100 pentes des battements PVC) et seulement de l'enregistrement (106), ceci représente un progrès significatif dans la généralisation de la discrimination des PVC, le second avantage est que nous avons utilisé seulement deux paramètres pertinents, et on a utilisé 46 enregistrements de la base MIT/BIH dans la phase d'évaluation.

On note que les méthodes proposées dans [95,126] traitent uniquement les battements normaux et les battements PVC. Ce qui justifie le choix de ces deux méthodes dans la comparaison. Les méthodes [15,91-94] traitent plusieurs types d'anomalies cardiaques, par conséquent la comparaison avec ces méthodes ne sera pas convenable.

Tableau 5.3 Résumé des résultats obtenus par la méthode proposée et autres méthodes.

Auteurs	Spec %	Sen %	Type de la méthode	Base
La method proposée	95.18	82.20	Power Spectrum of QRS and SOM	MIT-BIH
Krasteva et al [126]	98.86	98.40	QRS template matching and linear classifier	MIT-BIH
Inan et al [94]	85.20	--	wavelet-transformed with timing information	MIT-BIH
Wieben et al [91]	--	85.30	Filter bank features and decision tree classifier	MIT-BIH
Moraes et al [92]	99.76	90.74	Real-time QRS delineation and application of Mahalanobis distance classifier	MIT-BIH
De Chazal et al [15]	98.80	77.70	Estimation of morphology and RR interval features with linear discrimination classifier	MIT-BIH
Christov et al [93]	99.70	98.50	Estimation of morphology features with neural net works classifier	MIT-BIH
Chen [95]	99.70	97.80	A nonlinear trimmed moving average filter	MIT-BIH

4.10 Conclusion

Dans cette section du chapitre nous avons présenté une technique de classification qui permet de discriminer une anomalie de type PVC parmi un grand nombre de battements considérés comme normaux. Cette technique est basée sur la combinaison du comportement fractal du spectre de puissance du complexe QRS et d'un réseau SOM. Les paramètres utilisés dans la tâche de classification sont les pentes de l'interpolation linéaire de la DSP du complexe QRS dans deux intervalles de fréquence différents. Bien que seulement deux paramètres aient été employés pour caractériser chaque battement, la méthodologie de classification est fiable avec une justesse de 94.02% a été achevée. Alors on peut dire que la combinaison de notre méthode avec d'autres techniques peut conduire à une amélioration significative des résultats de classification.

5. La deuxième expérience: Discrimination du RBBB par MLP

L'objectif principal de cette seconde expérience est de montrer que les deux pertinents paramètres (pentes fractionnaires) peuvent aussi être utilisés dans la discrimination d'autres arythmies que le PVC.

Dans cette section, nous allons traiter le problème de la discrimination des battements bloc de branche droit (RBBB) des battements d'origine sinusal normal. Pour réaliser une telle séparation, nous avons utilisé les mêmes étapes de traitement pour calculer les pentes de la DSP du complexe QRS présentées dans l'expérience précédente. Dans ce cas, les deux pentes extraites alimentent un réseau de type MLP dans la phase de la classification. La méthode de regroupement en classes retenue ici est du type classification supervisée, c'est-à-dire que l'on dispose d'une base de référence étiquetée pour effectuer un apprentissage, de plus cette classification se fera avec des connaissances a priori du nombre de classes. Le choix de l'anomalie RBBB revient essentiellement à sa ressemblance constatées sur le tracé ECG avec les battements de type PVC et cela du point de vue largeur du complexe QRS, par conséquent la similitude entre le PVC et le RBBB nous a obligé à exclure les battements de type PVC dans cette expérience. Donc, Nous avons considéré dans cette expérience uniquement deux classes, la première classe est la classe des battements normaux, la deuxième classe est la classe des battements de type RBBB. Comme pour la première expérience plusieurs techniques de classification peuvent être utilisées, le choix du réseau MLP sera justifié dans la section 5.3 de ce chapitre.

5.1 Choix de la taille et de l'endroit de la fenêtre d'extraction

Dans cette expérience, nous avons choisi une fenêtre de Blackman de 194 ms (111 ms avant l'onde R et 83 ms après l'onde R) pour extraire les complexes QRS. La taille de la fenêtre a été choisie d'une façon empirique dans le but d'éliminer le chevauchement des deux classes (classe normale et classe RBBB). Figure (5.9) illustre l'emplacement et la taille approximative de la fenêtre d'extraction et cela dans le cas d'un battement normal et le cas d'un battement RBBB. Le bloc de branche droit est dû à l'interruption de la conduction des influx nerveux vers le ventricule droit se qui entraîne un retard d'activation du ventricule droit par rapport au ventricule gauche. Ceci se traduit sur le tracé ECG par un élargissement du complexe QRS par rapport au complexe QRS normal [2,125]. Cette dysfonction (comme dans le cas des battements PVC) entraîne une variation remarquable dans le contenu fréquentiel des

complexe QRS extraits par fenêtrage. Cette variation du spectre sera utilisée pour distinguer les battements RBBB des battements normaux.




Figure.5.9 Emplacement de la fenêtre d'extraction du complexe QRS.

Les Figures (5.10) et (5.11) illustrent, respectivement, des complexes QRS normaux et anormaux (RBBB) ainsi que leurs DSP correspondantes. Les remarques, mentionnées dans la section 4.1 pour la première expérience, concernant le choix de l'emplacement et la taille de la fenêtre d'extraction sont aussi valable pour cette expérience.




Figure.5.10 Bloc de branche droit et sa DSP correspondante (enregistrement 118).

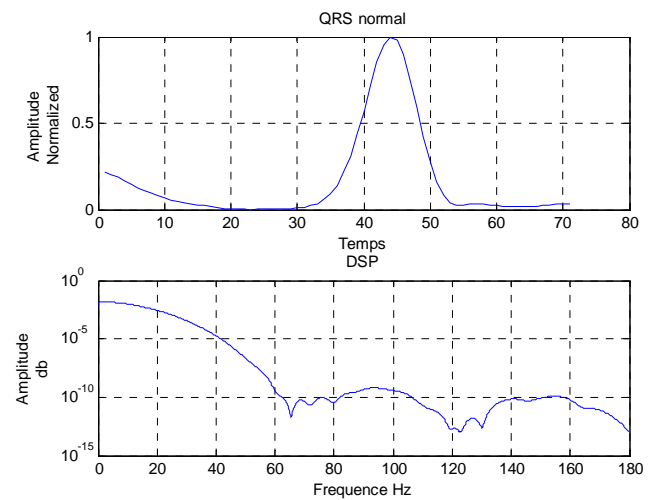


Figure 5.11 Complexe QRS normal et sa DSP correspondante (enregistrement 212).

5.2 Distribution des couples (pente1, pente2)

La Figure (5.12) présente la distribution de la deuxième pente en fonction de la première pente de six enregistrements, cette figure montre clairement l'existence de deux classes distinctes et séparables (la classe normale en bleu et la classe RBBB en rouge). Alors, les deux pentes calculées à partir de la DSP du complexe QRS peuvent être utilisées comme paramètres discriminants, par conséquent ils peuvent représenter les deux types de battements (normale et RBBB) et une classification peut être réalisée en se basant sur ces deux pentes.

5.3 Choix de la classification par MLP

Diverses techniques de classification peuvent être utilisées pour résoudre le problème de séparation des deux classes représentées par le couple (Pente1, Pente2). Une étude statistique sur l'utilisation des réseaux de neurones a prouvé qu'approximativement 95% des applications rapportées dans la littérature sur les applications des RNA utilisent les réseaux MLP avec l'algorithme de rétro propagation du gradient comme algorithme d'apprentissage [127]. Alors, nous avons adopté ce classificateur vu sa simplicité et son efficacité dans ce genre d'application malgré ses inconvénients qui se manifestent essentiellement par l'importance du temps de calcul. Mais cet inconvénient majeur est vite éliminé dans notre cas à cause du non chevauchement des deux classes qui rend les problèmes dus à la géométrie de la fonction d'erreur négligeables et conduit à l'utilisation d'un nombre réduit de données d'apprentissage. Cela conduit aussi à une dimension faible du réseau avec très peu de couches, de connections et de neurones (Voir Figure (5.13)).

5.4 Architecture du réseau

Le réseau est un MLP possédant une couche de neurones cachés dont le nombre est 5. Les entrées du réseau sont les deux pentes seulement, et la couche de sortie contient deux neurones qui peuvent prendre une valeur binaire (1 : battement normal, 0 : RBBB). (Voir Figure (5.13)). Les fonctions d'activation des neurones cachés et des neurones de sortie sont des sigmoïdes. L'algorithme de rétro propagation du gradient a été utilisé comme algorithme d'apprentissage. L'architecture décrite ci-dessus a été suffisante pour assurer une très bonne classification parce que nous avons constaté que l'augmentation du nombre des couches

cachées ou le nombre de neurones dans la couche cachée n'apporte aucune amélioration dans les résultats de la classification déjà obtenue par contre elle augmente considérablement le temps de calcul dans la phase d'apprentissage ainsi que dans la phase de test.

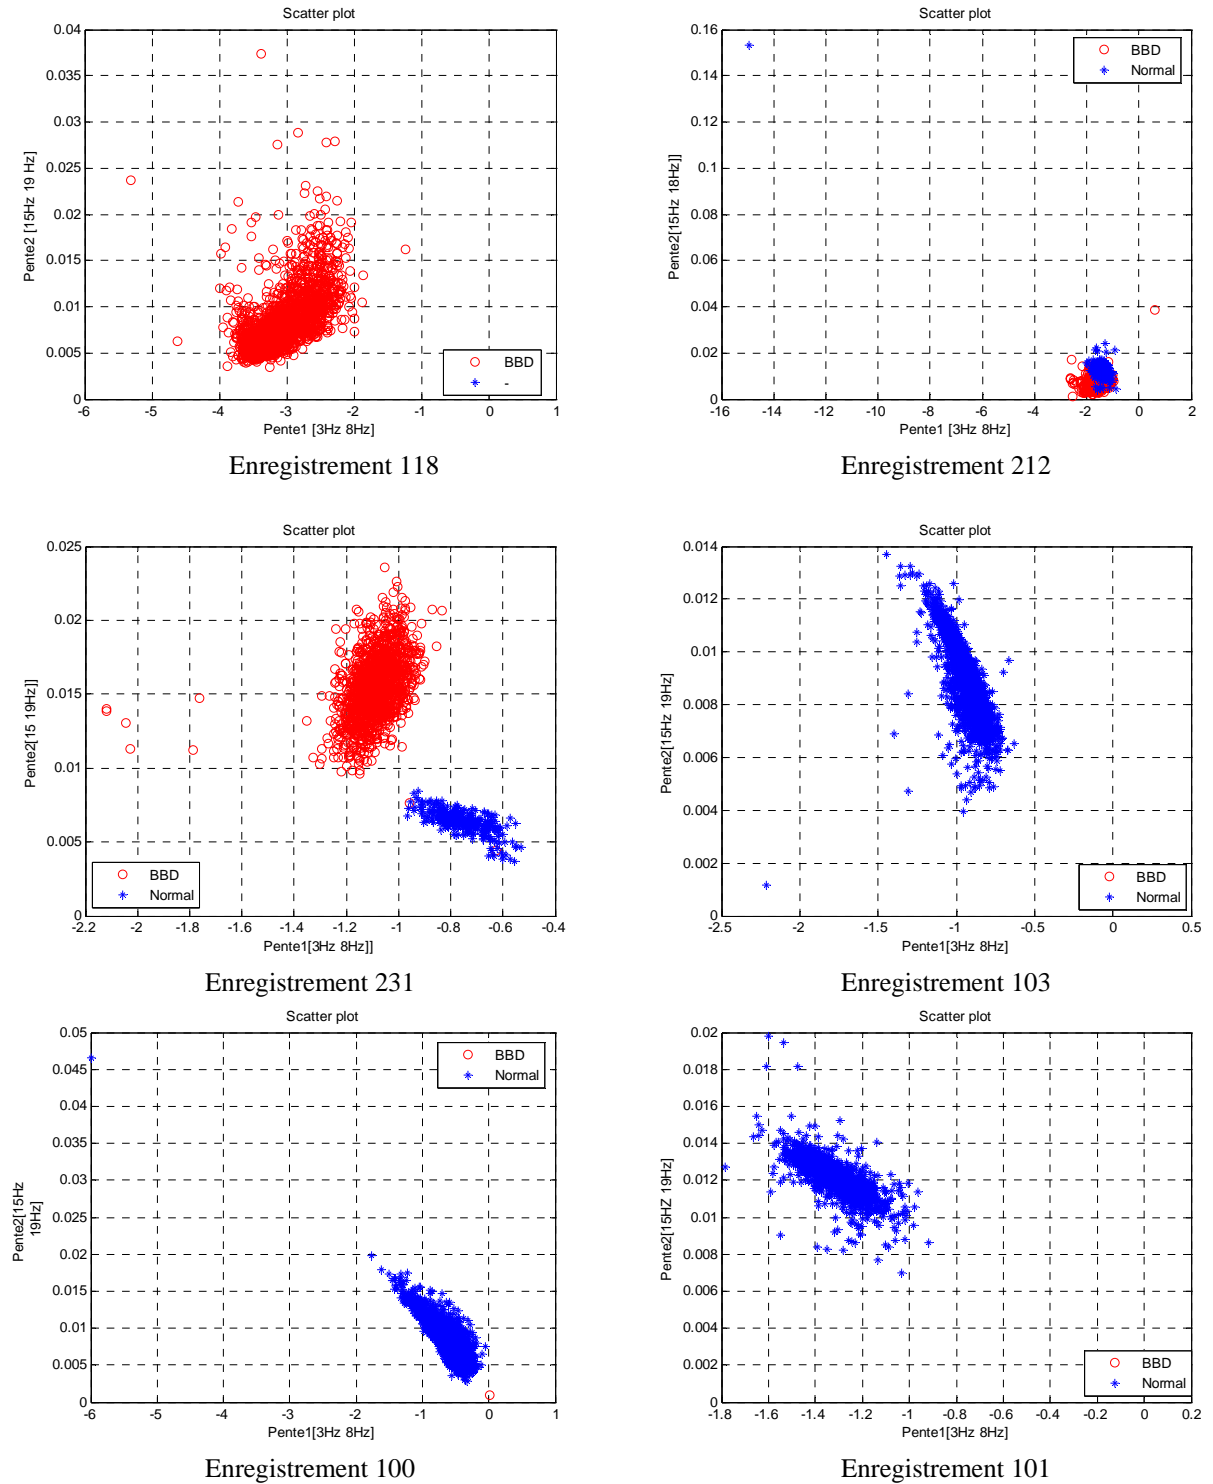


Figure 5.12 Distribution de la Pente2 en fonction de la Pente1 pour six enregistrements.




Figure 5.13 Réseau de neurone MLP utilisé.

5.5 Evaluation des performances du réseau

Les mêmes équations de la première expérience ont été utilisées pour évaluer les performances du classificateur

$$\text{Accuracy \%} = \frac{\text{Nombre des battements totaux testés} - \text{FN} - \text{FP}}{\text{Nombre des battements total testés}} * 100 \quad (5.4)$$

$$\text{Specificity \%} = \frac{\text{Nombre des battements normaux testés} - \text{FP}}{\text{Nombre des battements normaux testés}} * 100 \quad (5.5)$$

$$\text{Sensitivity \%} = \frac{\text{Nombre des RBBB testés} - \text{FN}}{\text{Nombre des RBBB testés}} * 100 \quad (5.6)$$

5.6 Choix des données d'apprentissage

D'après le tracé de la distribution des deux pentes pour quelques enregistrements (voir Figure (5.12)), nous avons constaté que l'enregistrement 231 montre très clairement deux classes distinctes et séparables. Alors nous l'avons choisi pour la phase d'apprentissage en utilisant trente battements normaux et trente battements de type RBBB uniquement.

5.7 Choix des données de la base de test

Dans cette expérience nous avons utilisé 13 enregistrements de la base de donnée MIT/BIH Arrhythmia database pour discriminer les battements de type RBBB parmi un grand nombre de battements cardiaques normaux.

Les enregistrements utilisés sont répartis comme suit:

- 100, 101, 103, 105, 115, 119 et 221 (battements normaux uniquement).
- 118, 124, 207, 232 (battements avec des RBBB uniquement).
- 212, 231 (battements normaux et avec des RBBB).

5.8 Résultats et discussion

Nous avons utilisé dans cette expérience 22 730 battements issus de treize enregistrements choisis pour classifier les deux types de battements. Tous ces battements ont subi les mêmes étapes de prétraitement. Les résultats de classification des battements normaux et des battements de type RBBB obtenus pour chaque enregistrement sont montrés dans le Tableau 5.4. Le résultat global de cette classification a été satisfaisant avec une justesse de 92.78%.

Tableau 5.4 Résultats de la classification.

Record	Nombre de battements Normaux	Nombre de battements RBBB	Nombre de battements total	F. N	F. P	Justesse %	Spec %	Senv %
100	2239	0	2239	0	26	98.84	98.84	-
101	1860	0	1860	0	79	95.75	95.75	-
103	2082	0	2082	0	62	97.02	97.02	-
105	2526	0	2526	0	57	97.74	97.74	-
115	1953	0	1953	0	1204	38.35	38.35	-
118	0	2166	2166	0	0	100.00	-	100.00
119	1543	0	1543	0	274	82.24	82.24	-
124	0	1531	1531	0	0	100.00	-	100.00
207	0	86	86	0	0	100.00	-	100.00
212	923	1825	2748	0	104	96.22	88.73	100.00
221	2031	0	2031	0	0	100.00	100.00	-
231	314	1254	1568	1	0	99.94	100.00	99.92
232	0	397	397	0	0	100.00	-	100.00
Total	15471	7259	22730	1	1806	92.78	-	-

La méthode présente une très bonne classification des battements RBBB, puisque la majorité des battements RBBB sont classés RBBB (le nombre des F.N total est 1).

Les résultats de classification obtenus sont satisfaisants mais l'expérience souffre de quelques problèmes qu'on peut résumer comme suit:

- Seulement deux types de battements sont pris en considération (Normal et RBBB), le choix des enregistrements ne prend pas en considération les battements PVC, ces dernières provoquent un chevauchement considérable entre les deux classes, et ceci est l'une des limitations majeures dans cette expérience.
- A cause du chevauchement entre les battements PVC et les battements RBBB ou LBBB la technique proposée ne peut pas traiter ces deux anomalies simultanément. La solution à ce problème est de disposer de l'avis d'un expert pendant l'étape d'initialisation du classificateur. Cette idée a été développée dans référence [126], où l'avis d'un expert dans l'étape d'initialisation du classificateur est primordial.
- Le nombre total des F.P est élevé, ceci signifie que plusieurs battements normaux sont considérés comme RBBB, la diminution de la sensibilité du classificateur résulte essentiellement de l'enregistrement 115 qui présente le plus grand nombre de F.P (Voir Tableau 5.4).

Plusieurs paramètres dans cette expérience peuvent être optimisés, mais l'objectif principal comme il a été mentionné dans l'introduction est d'introduire les pentes fractionnaires comme paramètres de classification et de discrimination des anomalies cardiaques.

5.9 Conclusion

Dans cette expérience nous avons présenté un classificateur de deux types de battements cardiaques (Normal et RBBB) basé sur les deux pentes fractionnaires et l'utilisation d'un réseau MLP. Nous avons utilisé dans cette expérience 22 730 battements issus de treize enregistrements pour classifier les deux types de battements. Les résultats obtenus sont satisfaisants avec une justesse de 92.78%. Malgré les limitations citées, les résultats reportés prouvent la possibilité d'utiliser les pentes fractionnaires dans la discrimination des battements de types RBBB, et bien sûr ces résultats peuvent être optimisés et améliorés dans des travaux futurs.

6. Conclusion

Dans ce chapitre nous avons présenté et discuté les résultats obtenus par l'application d'une nouvelle méthode de discrimination des anomalies cardiaques. Cette méthode est basée sur le comportement fractionnaire de la densité spectrale de la puissance du complexe QRS et l'utilisation d'un réseau de neurone artificiel comme classificateur.

Deux expériences ont été présentées dans ce chapitre, les données utilisées dans ces expériences sont des données réelles issues d'une base de donnée universelle largement utilisée dans la littérature (MIT/BIH). Bien que deux paramètres seulement aient été employés pour caractériser chaque battement dans les deux expériences, les résultats obtenus par la méthodologie de classification proposée sont fiables avec une très bonne justesse.

L'objectif principal mentionné dans l'introduction du chapitre, qui est l'introduction des pentes fractionnaires dans la discrimination des anomalies cardiaques est atteint au moins pour deux types d'anomalies cardiaques (PVC et RBBB), mais beaucoup de travail reste à réaliser pour la généralisation de la méthode pour qu'elle soit capable de classifier plusieurs types d'anomalies cardiaques simultanément.

Conclusion Générale

Conclusion Générale

Le travail réalisé dans cette thèse présente une nouvelle méthode utilisée pour l'extraction des paramètres pertinents à partir du signal ECG afin de les utiliser dans la classification et la discrimination des arythmies et des anomalies cardiaques. Cette méthode est basée sur le comportement fractionnaire de la densité spectrale de la puissance du complexe QRS.

Les paramètres extraits sont deux pentes fractionnaires qui sont calculées à partir du diagramme de Bode par interpolation linéaire de la DSP du complexe QRS dans deux intervalles fréquentiels différents. Les deux pentes fractionnaires extraites alimentent un réseau de neurones dans le but de la classification. Deux types de réseaux ont été pris en considération dans la phase de classification, le premier est la carte auto organisée (Self Organizing Maps), le deuxième réseau est le perceptron multi couche.

Deux expériences sont présentées dans cette thèse, les données utilisées dans ces expériences sont des données réelles issues d'une base de donnée universelle largement utilisée dans la littérature, la base de donnée MIT/BIH. La première expérience concerne la discrimination des battements PVC à partir d'un grand nombre de battements normaux. On a utilisé dans cette expérience un réseau SOM alimentée seulement par les deux pentes fractionnaires extraites. Les résultats obtenus dans cette expérience sont comparés avec plusieurs techniques de classification existantes dans la littérature. La simplicité, la rapidité et la possibilité d'implémentation sont les points forts de la méthode proposée par rapport aux techniques considérées dans la comparaison.

La deuxième expérience est la classification de deux types de battement, la première classe représente les battements normaux et la deuxième classe représente les blocs de branche droite. Nous avons utilisé les mêmes paramètres pertinents que dans la première expérience avec un petit changement des paramètres de l'algorithme pour qu'il soit adapté à la situation traitée. Dans cette partie nous avons utilisé un réseau MLP pour montrer que les deux paramètres utilisés dans la première expérience peuvent être aussi utilisés pour la classification du bloc de branche droit.

Bien que deux paramètres seulement aient été employés pour caractériser chaque battement, la méthodologie de classification est fiable avec une très bonne exactitude dans les deux expériences présentées.

Le travail effectué dans le cadre de cette thèse a permis de réaliser plusieurs publications et communications, dont notamment :

- Pour ce qui concerne la classification des battements PVC par un réseau MLP [128],
- Concernant la discrimination des battements PVC par la carte auto organisatrice [108,109]
- La discrimination des battements RBBB et PVC dans [109,129]

On pense que beaucoup de travail de recherche reste à faire dans le domaine de la discrimination et la classification des anomalies cardiaques, notamment pour:

- L'optimisation des paramètres des classificateurs.
- Généralisation de la méthode pour qu'elle soit capable de discriminer d'autres types d'anomalies cardiaques, tels que les fibrillations, etc.
- Implémentation hardware de la méthode pour traiter des cas réels.

Bibliographie

Bibliographie

- [1] R. Begg, J. Kamruzzaman, R. Sarker, NEURAL NETWORKS IN HEALTHCARE: POTENTIALS AND CHALLENGES, IDEA Group Publishing, 2006.
- [2] J. Mackay, G. Mensah, THE ATLAS OF HEART DISEAS AND STROCK, Organisation Mondiale de la Santé, 2004.
- [3] G.D. Clifford, F. Azuaje, P.E. McSharry, ADVANCED METHODS AND TOOLS FOR ECG DATA ANALYSIS, Artechouse, 2006.
- [4] J. Pan, W.J. Tompkins, “A real-time QRS detection algorithm”, *IEEE Trans. Biomed. Eng.*, 230–236, 1985.
- [5] P. S. Hamilton, W. J. Tompkins, “Quantitative investigation of QRS detection rules using the MIT/BIH arrhythmis database”, *IEEE Trans. Biomed Eng.*, 1157–1165, 1986.
- [6] G. M. Fresen, T. C. Jannett, M. A. Jadallah, S. L. Yates, S. R. Quint, H. T. Nagle, “A comparison of the noise sensitivity of nine QRS detection algorithms”, *IEEE Trans. Biomed. Eng.*, 85–98, 1990.
- [7] Q. Xue, Y. H. Hu, W. J. Tomkins, “Neural-network-based adaptive matched filtering for QRS detection”, *IEEE, Trans. Biomed. Eng.*, 317–329, 1992.
- [8] C. Zheng, C. Li, C. Tai, “Detection of ECG characteristic points using wavelet transforms”, *IEEE Trans. Biomed. Eng.*, 21–28, 1995.
- [9] J. S. Sahambi, S. N. Tandon, R.K.P. Bhatt, “Using Wavelet Transforms for ECG Characterization”, *IEEE Engineering in Medicine and Biology Magazine*, 77–83, 1997.
- [10] B. U. Kohler, C. Hennig, R. Orglmeister, “The principles of software QRS detection”, *IEEE Eng. Med. Biol. Mag.*, 42–57, 2002.
- [11] Y. Ferdi, J. P. Herbeuval, A. Charef, B. Boucheham, “R wave detection using fractional digital differentiation”, *ITBM-RBM*, 273–280, 2003.
- [12] S. W. Chen, H. C. Chen, H. L. Chan, “A real-time QRS detection method based on moving-averaging incorporating with wavelet denoising”, *Computer Methods and Programs in Biomedicine*, 187–195, 2006.

-
- [13] M. Benmalek, A. Charef, "Digital fractional order operators for R-wave detection in ECG signal", *IET proceedings on Signal Processing*, 381–391, 2009.
- [14] Y. H. Hu, S. Palreddy, W.J. Tompkins, "A patient-adaptable ECG beat classifier using a mixture of experts approach", *IEEE Transactions on Biomedical Engineering*, 891–900, 1997.
- [15] P. de Chazal, M. O'Dwyer, R. B. Reilly, "Automatic classification of heartbeats using ECG morphology and heartbeat interval features", *IEEE Transactions on Biomedical Engineering*, 1196–1206, 2004.
- [16] R. Gopalakrishnan, S. Acharya, D. H. Mugler, "Automated diagnosis of ischemic heart disease using dilated discrete Hermite functions", Proceedings of the IEEE 30th Annual Northeast Bioengineering Conference, San Francisco, CA, USA, 97–98, 2004.
- [17] Z. G. Zhang, H. Z. Jiang, D. F. Ge, X. J. Xiang, "Pattern recognition of cardiac arrhythmias using scalar autoregressive modeling", Proceedings of the Fifth World Congress on Intelligent Control and Automation (WCICA 2004), Hangzhou, China, 5545–5548, 2004.
- [18] M. Engin, "ECG beat classification using neuro-fuzzy network", *Pattern Recognition Letters*, 1715–1722, 2004.
- [19] J. Millet-Roig, R. Ventura-Galiano, F. J. Chorro-Gasco, A. Cebrian, "Support vector machine for arrhythmia discrimination with wavelet-transform-feature selection", *Computers in Cardiology*, 407–410, 2000.
- [20] L. Y. Shyu, Y. H. Wu, W. Hu, "Using wavelet transform and fuzzy neural network for VPC detection from the holter ECG", *IEEE Transactions on Biomedical Engineering*, 1269–1273, 2004.
- [21] B. Mandelbrot, *LES OBJETS FRACTALS : FORME HASARD ET DIMENSION*, Flammarion, Paris, 1975.
- [22] B. Mandelbrot, *THE FRACTAL GEOMETRY OF NATURE*, W. H. Freeman and Co., New York, 1982.
- [23] B. Mandelbrot, "Some noises with $1/f$ spectrum, a bridge between direct current and white noise", *IEEE Trans Information Theory*, 289–291, 1967.
- [24] D.W. Davidson, R.H. Cole, "Dielectric Relaxation in Glycerol, propylene Glycol and n-Propanol", *J. Chem. Physics*, 1484–1490, 1951.

- [25] M. Kobayashi, T. Musha, "1/f fluctuation of heart beat period", *IEEE Trans Biomed Eng*, 456–457, 1982.
- [26] A. A. Verveen, H.E. Derksen, "Fluctuation phenomena in nerve membrane", *Proc IEEE* 906–916, 1968.
- [27] M. Yamamoto, H. Nakahama, K. Shima, T. Kodama, H. Mushiake, "Markov dependency and spectral analysis on spike counts in mesencephalic reticular neurons during sleep and attentive states", *Brain Res*, 279–289, 1986.
- [28] B. Mandelbrot, J.W. Van Ness, "Fractional Brownian Motion, Fractional Noises, and Applications", *SIAM Rev.*, 422–437, 1968.
- [29] A.L. Goldberger, V. Bhargava, B.J. West, A.J. Mandel, "On a Mechanism of Cardiac Electrical Stability-The Fractal Hypothesis", *Bioph. J.*, 525–528, 1985.
- [30] A. L. Goldberger, "Fractal electrodynamics of the heartbeat", *Ann. NYAcad. Sci.*, 402–409, 1990.
- [31] B. J. West, FRACTAL PHYSIOLOGY AND CHAOS IN MEDICINE, World Scientific Publishing, 1990.
- [32] A. L. Goldberger, D. R. Rigney, B. J. West, "Chaos and fractals in human physiology", *Sci. Am.*, 42–49, 1990.
- [33] J. L. Williams, E. Lesaffre, "Comparison of multi-group logistic and linear discriminant ECG and VCG classification", *J. Electrocardiol.*, 83–92, 1987.
- [34] D. A. Coast, R. M. Stern, G. G. Cano, S. A. Briller, "An approach to cardiac arrhythmia analysis using hidden Markov models", *IEEE Transactions on Biomedical Engineering*, 826–836, 1990.
- [35] R. Silipo, C. Marchesi, "Artificial neural networks for automatic ECG analysis", *IEEE Trans. Signal Processing*, 1417–1425, 1998.
- [36] S. Osowski, L. T. Hoai, T. Markiewicz, "Support Vector Machine Based Expert System for Reliable Heart Beat Recognition", *IEEE Trans. Biomed. Eng.*, 2004, 582–589.
- [37] S. Rosaria, M. Carlo, "Artificial neural networks for automatic ECG analysis", *IEEE Trans. Signal Processing*, 1417–1425, 1998.
- [38] V. G. Mark, H. Jansen, "Using artificial neural network for classifying ICU patient states", *IEEE EMB Mag.*, 41–47, 1997.
- [39] G. Bortolan, J. L. Willems, "Diagnostic ECG classification based on neural networks, *Journal of Electrocardiology*", 75–79, 1993.

- [40] T. F. Yang, B. Devin, P. W. MacFarlane, “Deterministic logic versus software-based artificial neural networks in the diagnosis of atrial fibrillation”, *Journal of Electrocardiology*, 90–94, 1993.
- [41] G. Bortolan, C. Brohet, S. Fusaro, “Possibilities of using neural networks for ECG classification”, *Journal of Electrocardiology*, 10–16, 1996.
- [42] M.L. Minsky and S.A. Papert, PERCEPTRONS, Cambridge, MIT Press, 1969.
- [43] J. Moody and C. J. Darken, “Fast learning in networks of locally-tuned processing units”, *Neural Computation*, 281–294, 1989.
- [44] T. Kohonen, “Self-organized formation of topological correct feature maps”, *Biological Cybernetics*, 59–69, 1982.
- [45] J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities”, *Proc. Nat. Acad. Sci.*, 2554–2558, 1982.
- [46] G. A. Carpenter, S. Grossberg, “Art2: Self-organization of stable category recognition codes for analog input patterns”, *Appl. Opt.*, 4919, 1987.
- [47] G.A. Carpenter, S. Grossberg, “The ART of adaptive pattern recognition by a self-organizing neural network”, *Computer*, 77–88, 1988.
- [48] U.R. Acharya, S.J. Suri, A.E.J. Spaan, S.M. Krishnan, ADVANCES IN CARDIAC SIGNAL PROCESSING, Springer-Verlag Berlin Heidelberg, 2007.
- [49] E. Marieb, ANATOMIE ET PHYSIOLOGIE HUMAINES, DeBoeck Université, Paris, 4 édition, 1999.
- [50] M. Blondeau, M. Hiltgen, ELECTROCARDIOGRAPHIE CLINIQUE, Masson, 1980.
- [51] Etienne-Paul D’Alché, COMPRENDRE LA PHYSIOLOGIE CARDIOVASCULAIRE, Flammarion Médecine-Sciences, 2003.
- [52] D. P. Zipes, J. Jalife, CARDIAC ELECTROPHYSIOLOGY: FROM CELL TO BEDSIDE, Philadelphia, W.B. Saunders and Company, 2004.
- [53] J. Adamec, R. Adamec, ECG HOLTER: MANUEL D’INTERPRETATION ELECTROCARDIOGRAPHIQUE, Edition Médecine et Hygiène, 2000.
- [54] S. A. Jones, M.S Ed, MHA, EMT-P, ECG NOTES INTERPRETATION AND MANAGEMENT GUIDE, F. A. Davis Company, Philadelphia, USA, 2005.
- [55] D. Hebb, THE ORGANIZATION OF BEHAVIOR, Wiley, New York, 1949.
- [56] F. Rosenblatt, THE PERCEPTRON: A PERCEIVING AND RECOGNIZING AUTOMATON, Technical report, Cornell Aeronautical Lab, 1957.

- [57] Micheli-Tzanakou Evangelia, SUPERVISED AND UNSUPERVISED PATTERN RECOGNITION FEATURE EXTRACTION AND COMPUTATIONAL INTELLIGENCE, CRC Press LLC, 2000.
- [58] S. Haykin. NEURAL NETWORKS: A COMPREHENSIVE FOUNDATION, 2nd Edition, Prentice Hall, 1999.
- [59] G. Dreyfus, J. M. Martinez, M. Samuelides, M. B. Gordon, F. Badran, S. Thiria, L. Hérault, RESEAUX DE NEURONES : METHODOLOGIE ET APPLICATIONS, Eyrolles, 2002.
- [60] M.H. Hassoun, FUNDAMENTALS OF ARTIFICIAL NEURAL NETWORKS, The MIT Press, 1995.
- [61] E. Keedwell, A. Narayanan, INTELLIGENT BIOINFORMATICS: THE APPLICATION OF ARTIFICIAL INTELLIGENCE TECHNIQUES TO BIOINFORMATICS PROBLEMS, John Wiley, 2005.
- [62] D. Graupe, PRINCIPALES OF ARTIFICIAL NEURAL, 2nd Edition, World Scientific Publishing, 2007.
- [63] T. Kohonen, SELF-ORGANIZING MAPS, Third edition, Springer, 2001.
- [64] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, and L. D. Jackel, “Backpropagation applied to handwritten zip code recognition”, *Neural Computation*, 541–551, 1989.
- [65] B. Prasad, S.R. M. Prasanna, SPEECH AUDIO IMAGE AND BIOMEDICAL SIGNAL PROCESSING USING NEURAL NETWORKS, Springer, 2008.
- [66] B. Dubuisson, DIAGNOSTIC ET RECONNAISSANCE DES FORMES, Hermes Sciences Publication, 1990.
- [67] L. Personnaz, I. Rivals, RESEAUX DE NEURONES FORMELS POUR LA MODELISATION LA COMMANDE ET LA CLASSIFICATION, CNRS Editions, 2003.
- [68] J. P. Haton, RECONNAISSANCE AUTOMATIQUE DE LA PAROLE: DU SIGNAL A SON INTERPRETATION, Dunod, 2006.
- [69] A. Wismuller, A. Meyer-Base, O. Lange, D. Auer, M. F. Reiser, D. Summers, “Model-free functional MRI analysis based on unsupervised clustering”, *Journal of Biomedical Informatics*, 10–18, 2004.
- [70] M. Buscema, M. Maszetti di Pietralata, V. Salvemini, M. Intragaligi, M. Indrimi, “Application of artificial neural networks to eating disorders”,

- Substance Use & Missuse*, 765–791, 1998.
- [71] S. Berdia, J. T. Metz, “An artificial neural network stimulating performance of normal subjects and schizophrenics on the Wisconsin card sorting test”, *Artificial Intelligence in Medicine*, 123–138, 1998.
- [72] P. S. Heckerling, B. S. Gerber, T. G. Tapeç, R. S. Wigton, “Use of genetic algorithms for neural networks to predict community-acquired pneumonia”, *Artificial Intelligence in Medicine*, 71–84, 2004.
- [73] D. B. Henson, S. E. Spenceley, D. R. Bull, “Artificial neural network analysis of noisy visual field data in glaucoma”, *Artificial Intelligence in Medicine*, 10, 99–113, 1997.
- [74] T.G. Barbounis, J.B. Theocharis, “Locally recurrent neural networks for long term wind speed and power prediction”, *Neurocomputing*, 466–496, 2006.
- [75] S. Srivastava, M. Sing, M. Hanmandlu, A.N. Jha, “New fuzzy wavelet neural networks for system identification and control”, *Applied Soft Computing*, 1–17, 2005.
- [76] M. F. Abboud, D. A. Linkens, M. Mahfouf, G. Dounias, “Survey on the use of smart and adaptive engineering systems in medicine”, *Artificial Intelligence in Medicine*, 179–209, 2002.
- [77] A. R. LeBlanc, “Quantitative analysis of cardiac arrhythmias”, *Critical Reviews in Biomedical Engineering*, 1–43, 1986.
- [78] G. Carrault, M. O. Cordier, R. Quiniou, F. Wang, “Temporal abstraction and inductive logic programming for arrhythmia recognition from electrocardiograms”, *Artificial Intelligence in Medicine*, 231–263, 2003.
- [79] C. D. Nugent, J. A. Webb, N. D. Black, G. T. Wright, M. McIntyre, “An intelligent framework for the classification of the 12-lead ECG”, *Artificial Intelligence in Medicine*, 16(3), 205–222, 1999.
- [80] D. E. Gustafson, A. S. Willsky, J. Y. Wang, M. C. Lancaster, J. H. Triebwasser, “ECG/VCG rhythm diagnosis using statistical signal analysis: Identification of transient rhythm”, *IEEE Transactions on Biomedical Engineering*, 353–361, 1978.
- [81] Li. Gang, Ye. Wenyer, L. Ling, “An artificial intelligence approach to ECG analysis”, *IEEE EMB Mag.*, 95–100, 2000.
- [82] S. Barro, M. Fernandez, “Classifying multi-channel ECG patterns with adaptive

- neural network”, *IEEE EMB Mag.*, 45–55, 1998.
- [83] T. Olmez, “Classification of ECG waveforms using RCE neural network and genetic algorithm”, *Electronics Letters*, 1561–1562, 1997.
- [84] A. S. Al-Fahoum, I. Howitt, “Combined wavelet transformation and radial basis neural networks for classifying life-threatening cardiac arrhythmias”, *Medical & Biological Engineering and Computing*, 566–573, 1999.
- [85] A. Rosado-Muñoz, A. Camps-Valls, J. Guerrero-Martínez, J. V. Francés-Villora, J. MuDoz-Marí, A. Serrano-López, “Enhancing feature extraction for VF detection using data mining techniques”, *Proceedings of the Computers in Cardiology Conference*, 209–212, 2002.
- [86] D. Cubanski, D. Cyganski, E. M. Antman, C. L. Feldman, “A neural network system for detection of atrial fibrillation in ambulatory electrocardiograms”, *Journal of Cardiovascular Electrophysiology*, 602–608, 1994.
- [87] F. Ham, S. Han, “Classification of cardiac arrhythmias using fuzzy ARTMAP”, *IEEE Trans. Biomed. Eng.*, 425–430, 1996.
- [88] N. Maglaveras, T. Stamkopoulos, C. Pappas, M. Strintzis, “ECG processing techniques based on neural networks and bidirectional associative memories”, *Journal of Med Eng Technol*, 106–111, 1998.
- [89] M. Lagerholm, C. Peterson, G. Braccini, L. Edenbrandt, L. Sornmo, “Clustering ECG complexes using Hermite functions and self-organizing maps”, *IEEE Transactions on Biomedical Engineering*, 838–848, 2000.
- [90] R. Acharya, A. Kumar, P. S. Bhat, C. M. Lim, S. S. Iyengar, N. Kannathal, S. M. Krishnan, “Classification of cardiac abnormalities using heart rate signals”, *Medical & Biological Engineering and Computing*, 288–293, 2004.
- [91] O. Wieben, V. Afonso, W. Tompkins, “Classification of premature ventricular complexes using filter bank features, induction of decision trees and a fuzzy rule-based system”, *Med. Biol. Eng. Comput.*, 560–565, 1999.
- [92] J.C.T.B Moreas, M.O. Seixas, F.N. Vilani, E.V. Costa, “A real time QRS complex classification method using Mahalanobis distance”, *Computers in Cardiology*, 201–204, 2002.
- [93] I .Christov, G. Bortolan, “Ranking of pattern recognition parameters for premature ventricular contraction classification by neural networks”, *Physiol. Meas.*, 1281–1290, 2004.

- [94] O.T. Inan, L. Giovangrandi, G.T.A. Kovacs, "Robust neural-network-based classification premature ventricular contractions using wavelet transform and timing interval features", *IEEE Trans. Biomed. Eng.*, 2507–2515, 2006.
- [95] S.W. Chen, "A nonlinear trimmed moving averaging-based system with its application to real-time QRS beat classification", *J. Med. Eng. & Tech.*, 443–449, 2007.
- [96] B.M. Asl, S.K. Setarehdan, M. Mohebbi, "Support vector machine-based arrhythmia classification using reduced features of heart rate variability signal", *Artif. Intell. Med.*, 51–64, 2008.
- [97] A. K. Jain, M. N. Murty, P. J. Flynn, "Data Clustering: A Review", *ACM Computing Surveys*, 264–323, 1999.
- [98] M. S. Su, C. H. Chou, "A Modified Version of the k-Means Algorithm with a Distance Based on Cluster Symmetry," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 674–680, 2001.
- [99] H. V. Jagadish, "Similarity-Based Queries," Proc. of the 14th ACM SIGACTSIGMOD- SIGART Symposium on Principles of Database Systems (PODS'95), ACM Press, 36–45, 1995.
- [100] F. Azuaje, "Clustering-Based Approaches to Discovering and Visualising Microarray Data Patterns", *Brief Bioinform.*, 31–42, 2003.
- [101] D. Berrar, W. Dubitzky, and M. Granzow, UNDERSTANDING AND USING MICROARRAY ANALYSIS TECHNIQUES: A PRACTICAL GUIDE, Springer, 2002.
- [102] S. Monti, "Consensus Clustering: A Resampling-Based Method for Class Discovery and Visualization of GENE Expression Microarray Data", *Machine Learning*, 91–118, 2003.
- [103] D. Partridge, S. S. R. Abidi, A. Goh, "Neural network applications in medicine", Proceedings of National Conference on Research and Development in Computer Science and Its Applications (REDECS'96), Universiti Pertanian Malaysia, Kuala Lumpur, 20–23, 1996
- [104] E. Coiera, "Designing for decision support in a clinical monitoring environment", Proceedings of the International Conference on Medical Physics and Biomedical Engineering, University of Cyprus, Nicosia, 130–142, 1994
- [105] J. Kors, J. H. van Bommel, "Classification methods for computerized

- interpretation of the electrocardiogram”, *Methods of Information in Medicine*, 33–36, 1990.
- [106] H. P. Selker, J. L. Griffith, S. Patil, W. J. Long, R. B. D’Agostino, “A comparison of performance of mathematical predictive methods for medical diagnosis: Identifying acute cardiac ischemia among emergency department patients”, *J Investig Med*, 468–476, 1995.
- [107] A. E. Smith, C. D. Nugent, S. I. McClean, “Evaluation of inherent performance of intelligent medical decision support systems: Utilising neural networks as an example”, *Artificial Intelligence in Medicine*, 1–27, 2003.
- [108] M. L. Talbi, A. Charef, “PVC discrimination using the QRS power spectrum and self-organizing maps”, *Computer Methods and Programs in Biomedicine*, 223–231, 2009.
- [109] M. L. Talbi, A. Charef, Ph. Ravier, “Arrhythmias Classification Using the Fractal Behavior of the Power Spectrum Density of the QRS Complex and ANN”, Proceedings of the 2010 International Conference on High Performance Computing & Simulation (HPCS 2010), Caen, France, 399-404, 2010.
- [110] B.J. West, A. Goldberger, “Physiology in fractal dimensions”, *Am Scientist*, 354–365, 1987.
- [111] K. Falconer, FRACTAL GEOMETRY: MATHEMATICAL FOUNDATIONS AND APPLICATIONS, New York, Wiley, 1990.
- [112] Ed. Joseph D. Bronzino, THE BIOMEDICAL ENGINEERING HANDBOOK, Second Edition, Boca Raton, CRC Press LLC, 2000.
- [113] M. Shroeder, FRACTALS CHAOS POWER LAWS, New York, WH Freeman, 1990.
- [114] D. Stauffer, A. Aharony, INTRODUCTION TO PERCOLATION, 2d ed., London, Taylor & Francis, 1992.
- [115] K. G. Wilson, “The renormalization group and critical phenomena”, *Rev Mod Phys*, 583-586, 1983.
- [116] B. J. West, M. Shlesinger, “On the ubiquity of $1/f$ noise”, *Int J Mod Phys*, 795-801, 1989.
- [117] G. W. Wornell, “Wavelet-based representations for the $1/f$ family of fractal processes”, *IEEE Proc*, 1428-1438, 1993.
- [118] N.V. Thakor, J.G. Webstor, W.J. Thompkins, “Estimation of the QRS Complex

- Power Spectra for Design of a QRS Filter”, *IEEE Trans. Biomed. Eng.*, 702-706, 1984.
- [119] N. V. Thakor, Y. S. Zhu, “Applications of adaptive filtering to ECG analysis: noise cancellation and arrhythmia detection”, *IEEE Trans Biomed Eng.*, 785-794, 1991.
- [120] A. K. Ziarani, A. Konrad, “A nonlinear adaptive method of elimination of power line interference in ECG signals”, *IEEE Trans Biomed Eng.*, 540-547, 2002.
- [121] IEC 62D/60601-2-27 1994 Particular requirements for the safety of electrocardiographic monitoring equipment (equivalent to AAMI EC 13).
- [122] A. V. Oppenheim, R. W. Schaffer, J. R. Buck, DISCRETE TIME SIGNAL PROCESSING, 2nd Edition, Prentice Hall, 1999.
- [123] K. Minami, H. Nakajima, T. Toyoshima, “Real-Time Discrimination of Ventricular Tachyarrhythmia with Fourier-Transform Neural Network”, *IEEE Trans. Biomed. Eng.*, 179–185, 1999.
- [124] MIT-BIH Arrhythmia Database, <http://www.physionet.org/physiobank/database>.
- [125] I. R. Tarkowicz, PROGRESS IN CARDIAC ARRHYTHMIA RESEARCH, Nova Science Publishers, 2008.
- [126] V. Krasteva, I. Jekova, “QRS Template Matching for Recognition of Ventricular Ectopic Beats”, *Annals of Biomed. Eng.*, 2065–2076, 2007.
- [127] B. K. Wong, T. A. Bodnovich, Y. Selvi, “Neural network applications in business: A review and analysis of the literature (1988-1995)”, *Decision Support Systems*, 301-320, 1997.
- [128] M.L. Talbi, A. Charef, “Discrimination of Premature Ventricular Contraction (PVC) from Normal Sinus Rhythm by Neural Network and Slopes of QRS Complexes Spectrum”, Conference (IMESE’06), El-Djelfa, Algeria, 2006
- [129] M.L. Talbi, A. Charef, “Classification of RBBB Beats Using the Fractional Slopes of the Power Spectrum Density of the QRS Complex”, Conférence Nationale sur les Systèmes d’Ordre Fractionnaire et leurs Applications (SOFA’2010), Skikda, Algeria, 2010.

Résumé

Le signal ECG représente l'activité électrique du cœur et reflète l'état de santé de l'appareil cardiovasculaire. Il contient aussi des informations qui permettent la distinction des maladies cardiovasculaires. Le taux élevé de mortalité dans le monde dû aux problèmes liés au dysfonctionnement de l'appareil cardiaque a poussé les chercheurs à développer des techniques de classification automatique des maladies cardiovasculaires pour un bon diagnostic.

Le travail réalisé dans cette thèse présente une nouvelle méthode utilisée pour l'extraction des paramètres pertinents à partir du signal ECG afin de les utiliser dans la classification et la discrimination des arythmies et des anomalies cardiaques. Les paramètres extraits sont les pentes fractionnaires calculées à partir du diagramme de Bode par l'interpolation linéaire de la densité spectrale de puissance (DSP) du complexe QRS dans deux intervalles fréquentiels différents. Les réseaux de neurones artificiels ont été utilisés dans la classification et la discrimination. Deux types de réseaux de neurones artificiels ont été considérés, le réseau perceptron multi couches (PMC) ainsi que la carte auto organisée de Kohonen (SOM). Deux expériences de classification sont présentées en utilisant la base de données MIT/BIH. La première expérience consiste en la discrimination des battements (PVC) à partir d'un grand nombre de battements normaux. La seconde expérience est la classification de deux types de battements, les battements normaux et les battements représentant les blocs de branche droit.

Bien que deux paramètres seulement aient été employés pour caractériser chaque battement, les résultats obtenus étaient très satisfaisants. Une comparaison avec plusieurs travaux existants dans la littérature a été faite. La simplicité, la rapidité et la possibilité d'implémentation sont les points forts de la méthode proposée par rapport aux techniques considérées dans la comparaison.

Mots clés : Signal électrocardiographique (ECG), Complexe (QRS), Pente fractionnaire, réseaux de neurones artificiels PMC et SOM.

Abstract

The ECG signal represents the electrical activity of the heart and it reflects the health condition of the cardiovascular system. It also contains information that allows the distinction of the cardiovascular diseases. The high mortality rate in the world due to problems related to the dysfunction of the cardiovascular system has driven researchers to develop cardiovascular diseases automatic classification methods for a good diagnosis.

The work realized in this thesis presents a new method used in pertinent parameters extraction from the ECG signal in order to use them for the classification and discrimination of arrhythmias and cardiac anomalies. The extracted parameters are the slopes of the power spectral density (PSD) of the QRS complex in two different frequency intervals. The neural networks have been used in the classification and discrimination. Two types of artificial neural have been considered, Multi Layer Perceptron (MLP) and the Self Organizing Maps (SOM) of Kohonen. Two classification experiments have presented using the MIT/BIH database. The first experiment consists of the discrimination of PVC beats from a large number of normal beats. The second experiment is the classification of two types of beats, the normal beats and the right bundle branch blocks. Although, only two parameters have been employed to characterize every beat, the obtained results were very satisfactory. The proposed work has been compared to several published works. The simplicity, the rapidity and the possible implementation are the strongest points of the proposed method with respect to techniques used in the comparison work.

Key Words: Electrocardiographic signal (ECG), QRS complex, fractional slope, artificial neural networks (MLP) and (SOM).

ملخص

إن إشارة ECG تمثل تغيرات النشاط الكهربائي للقلب بدلالة الزمن. هذه الإشارة تعكس الحالة الصحية لنظام القلب، وهي تحتوي أيضا على المعلومات التي تمكن من تمييز أمراض القلب.

إن نسبة الوفيات العالية والناجمة عن أمراض القلب دفعت الباحثين في هذا المجال إلى تطوير طرق وتقنيات من أجل الفحص والتصنيف الآلي لأمراض القلب.

العمل المنجز في هذه المذكرة يمثل طريقة جديدة تستعمل من أجل استخراج الوسائط الكافية للتصنيف أمراض القلب.

الوسائط المستخرجة هي "الميلول الكسرية (جمع ميل كسري)" والمحسوبة انطلاقا من تمثيل بود "Diagramme de bode" وذلك بالتقريب الخطي للكثافة DSP لمركب QRS في مجالين توتر مختلفين .

الشبكات العصبية الاصطناعية استعملت في مرحلة التصنيف، نوعين من هذه الشبكات أخذت بعين الاعتبار، شبكة MLP وشبكة SOM.

تجربتين للتصنيف أنجزت وذلك باستعمال قاعدة البيانات MIT/BIM .

التجربة الأولى تستند على التفرقة بين دقات القلب من نوع PVC انطلاقا من عدد كبير لدقات القلب العادية، والتجربة الثانية هي تصنيف نوعين من دقات القلب، الدقات العادية ودقات من نوع RBBB على الرغم من استعمال وسطين فقط من أجل تعريف دقات القلب، النتائج المحصل عليها جد مرضية مقارنة مع طرق سابقة أنجزت.

السهولة، السرعة، هم عناصر قوة هذه الطريقة المقترحة بالمقارنة مع الطرق الأخرى.

كلمات مفاتيح:

إشارة ECG، مركب QRS، ميل كسري، الشبكات العصبية الاصطناعية، MLP، SOM