

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université de Batna
Faculté des Sciences de l'Ingénieur
Département d'Electronique

Thèse
**Reconnaissance de Forme
de Signaux Biologiques**

En vue de l'obtention du diplôme de
Docteur d'état en électronique
Option: contrôle et traitement de signal

Par
SALAMA MEGHRICHE

Jury

Président	N.E. Bougachel	Professeur (Université de Batna)
Rapporteur	M. Boulemden	Professeur (Université de Batna)
Examineur	D. Benatia	Professeur (Université de Batna)
Examineur	K. Mansour	Professeur (Université de Constantine)
Examineur	A. Benia	Professeur (Université de Constantine)
Examineur	Z. Dibi	Maitre de conférences (Université de Batna)

Année 2008

سبحانك

لا علم لنا إلا ما علمتنا

*A tous ceux qui m'ont nourri
de leur amour et de leur tendresse.*

Remerciements

Ce travail n'aurait pu être réalisé sans le soutien de plusieurs personnes. La disponibilité et les compétences de chacun m'ont souvent permis de franchir des obstacles en apparence insurmontables. Que soient donc ici, remerciés tous ceux qui m'ont communiqué l'énergie et la confiance nécessaires au déroulement de cette thèse.

J'exprime ma profonde gratitude et toute ma reconnaissance envers mon directeur de thèse le Professeur Mohammed Boulemden, de m'avoir soutenu avec patience jusqu'au bout, pour ses conseils, ses avis et ses conversations, dont j'ai bénéficiés, pour son amabilité, sa gentillesse et sa confiance

Je remercie vivement les membres du jury: monsieur Nour-Eddine Bougechel professeur de l'université de Batna, monsieur Djamel Benatia professeur de l'université de Batna, monsieur Karim Mansour professeur de l'université de Constantine, monsieur Abdelhak Benia professeur de l'université de Constantine et monsieur Zohir Dibi Maître de conférence de l'université de Batna qui ont accepté de juger cette thèse, l'intérêt qu'ils ont porté à mon travail et la rapidité avec laquelle ils ont lu mon manuscrit.

En particulier je voudrais remercier monsieur Mohamed Toufik Sellami, infographe, pour l'aide précieuse qu'il m'a apportée; sans lui une grande partie des graphes et des schémas n'aurait vu le jour.

Je remercie le Professeur Mohamed Chaouki Baatouche et le Dr. Sihem Baatouche Pour leur accueil au sein du Laboratoire "lire" et au sein de l'équipe "Info vision" et de me permettre d'effectuer mes recherches dans d'excellentes conditions.

Je remercie vivement Mr Amer Draa chercheur de l'équipe "Info vision" pour sa collaboration qui a été essentielle et qui a énormément contribué à l'avancement de mes travaux.

Mes remerciements vont au Dr. Afnen Abada médecin au service de Cardiologie de l'hôpital de Constantine qui a toujours été prête à répondre à mes interrogations techniques.

J'adresse également mes remerciements à Monsieur Zakaria Amamra. Je n'oublierai jamais l'aide précieuse reçue de sa part.

Je ne saurais oublier ma mère et mes sœurs, pour leur soutien moral inconditionnel, pour les aides permanentes et pour leurs encouragements tout au long de mes études.

Mes remerciements chaleureux vont à mon mari pour son encouragement et sa compréhension. Je te suis très reconnaissante pour les multiples attentions, de tout ordre, dont tu as témoigné à mon égard. Je te suis particulièrement reconnaissante pour avoir contribué à stimuler en moi un grand enthousiasme pour la recherche. A toi Fateh, merci encore.

Je voudrais également remercier tous ceux qui ont eu la patience de m'entourer tout au long de ce travail.

Abstract

Heart failure is the most common cause of death nowadays, but if medical help is provided directly, the patient's life may be saved in many cases. Numerous heart diseases can be detected by means of analyzing electrocardiograms (ECG).

Automatic pattern recognizers can help cardiologists in detecting heart problems. What is required at the present time is the development of autonomous processor-based systems with sufficient processing capabilities so as to detect potential abnormalities and make accurate diagnosis in order to provide early treatments. Today, we tend to rely a great deal on the application of pattern recognition techniques to help us meet such a goal.

The inclusion of artificial neural networks in the complex investigating algorithms seems to yield very interesting recognition and classification capabilities across a broad spectrum of biomedical domains. Most of the researchers used current neural network methodologies, almost invariably the multi-layer perceptron (MLP) with 'early stopping' to prevent overfitting.

In our work, we develop a method based on a compound neural network (CNN), to classify ECGs as normal or carrying an AtrioVentricular heart Block (AVB). It uses three different feed forward multilayer neural networks. Two of these networks, (NN1) and (NN2), were set in a parallel configuration in series with the third one (NN3). A single output unit encodes the probability of AVB occurrences. A value between 0 and 0.1 is the desired output for a normal ECG; a value between 0.1 and 1 would infer an occurrence of an AVB. This network was fed with measurements from one lead of the ECG.

This work has been organized into three parts. The first part is the population study. The second one is related to the preparation of digitized signal for input to the compound neural networks (CNN). Finally, the third part concerns the training and recall procedures used by the CNN in the classifying process of the presented patterns.

The performance of the CNN classifier was measured as the area under the receiver operating characteristic curves (ROC). The results show that the CNN has a good performance in detecting AVBs. The sensitivity and specificity were 92.30% and 98.39% respectively.

Résumé

Face au développement récent de la biologie moderne et de la médecine, la recherche ne peut rester indifférente aux multiples retombées que ces développements ont engendrées. En effet, plusieurs domaines ont connu l'éclosion de nouveaux concepts, qui en sont directement issus. L'une des évolutions les plus marquées, qui a été engendrée, est celle de l'introduction des réseaux de neurones dans le domaine biomédical.

Actuellement, les réseaux de neurones bénéficient de fondements théoriques solides. Avec leurs aptitudes en classification, mémorisation, filtrage et approximation, ils sont devenus un moyen très efficace. L'opération de reconnaissance de formes constitue l'une des applications les plus connues en réseaux de neurones. L'application des réseaux de neurones est donc bien destinée à assurer la reconnaissance et la classification des ondes et des anomalies dans un signal électrocardiographique ECG.

Notre travail a été organisé en trois parties. La première est l'étude de la population. La seconde est liée à la préparation du signal numérique pour son apport aux CNN (Compound Neural Network). Finalement, la troisième partie concerne le traitement et les procédures utilisées par le CNN dans le processus de classification des modèles présentés.

L'étude a été basée sur une seule dérivation notée à partir de patients pris en charge avec le diagnostic BAV, et des sujets sains sont choisis arbitrairement à partir d'une population urbaine. Des paramètres ont été choisis à partir de l'ECG et ont été mis en application comme entrées aux CNN.

Le modèle neuronal étudié est un réseau hybride formé à partir de trois réseaux de neurones de type statique multicouche. Deux de ces réseaux de neurones RN1 et RN2 sont placés dans une configuration parallèle en série avec le troisième réseau RN3. Un seul résultat de sortie code la probabilité d'occurrence de la présence d'un BAV dans le tracé ECG.

La sensibilité et la spécificité pour différents seuils ont été étudiées afin d'obtenir une courbe ROC (Receiver Operating Characteristic) de caractéristiques d'efficacité du réseau. L'aire présente la performance du réseau dans l'ensemble.

Les résultats montrent que le CNN apporte une haute performance dans la détection de présence de BAV dans un ECG. Sa sensibilité et sa spécificité approchent respectivement 92,31 % et 98,39%. La valeur de sa précision est de 95,81%.

Table de matières

TABLE DE MATIERES.....	1
INTRODUCTION.....	12
CHAPITRE 1: L'ÉLECTROCARDIOGRAMME.....	6
1. SYSTÈME CARDIOVASCULAIRE.....	14
1.1. Circulation artérielle et veineuse.....	14
1.2. Le cœur.....	16
1.2.1. Anatomie.....	16
1.2.2. Cellules myocardiques.....	17
1.2.3. Electrophysiologie cellulaire.....	17
1.2.4. Fonctionnement électrique.....	18
2. ELECTROCARDIOGRAPHIE.....	19
2.1. Principe de l'électrocardiographie.....	19
2.2. Bref aperçu historique.....	20
3. ELECTROCARDIOGRAMME.....	20
3.1. Définition de l'électrocardiogramme.....	20
3.2. Dérivations.....	20
3.2.1. Dérivations dans le plan frontal.....	21
3.2.2. Dérivations dans le plan horizontal.....	22
4. ACTIVITÉ ÉLECTRIQUE D'UN BATTEMENT CARDIAQUE NORMAL.....	23
5. ELECTROCARDIOGRAMME NORMAL.....	24
5.1. Ondes.....	24
5.1.1. Onde P.....	24
5.1.2. Complexe QRS.....	24
5.1.3. Onde T.....	25
5.1.4. Onde U.....	25
5.2. Intervalles et Segments.....	25
5.2.1. Segments PR ou PQ-R.....	25
5.2.2. Segments ST, RST ou ST-T.....	25
5.2.3. Intervalle PR.....	25
5.2.4. Intervalle QT.....	26
5.2.5. Déflexion Intrinsécoïde DI.....	26
6. DIAGNOSTIC À PARTIR DE L'ECG.....	26
6.1. Diagnostic à partir du rythme.....	26
6.1.1. Bradycardie.....	26
a) Bradycardie sinusale.....	26
b) Bradycardie d'origine jonctionnelle.....	27
6.1.2 Tachycardie.....	27
a) Tachycardie sinusale.....	27
b) Tachycardie auriculaire et nodale.....	28
c) Tachycardie ventriculaire (TV).....	28
6.1.3. Arythmies, ou troubles de la régularité.....	28
a) Fibrillation auriculaire (FA).....	28
b) Fibrillation ventriculaire.....	29
6.1.4. Les Blocs.....	29
a) Bloc sino-auriculaire (SA).....	30
b) Bloc auriculo-ventriculaire (BAV).....	30

6.2. Diagnostic à partir des ondes	31
6.2.1. Forme de l'onde P.....	31
6.2.2. Intervalle PR	32
6.2.3. Forme du complexe.....	32
6.2.4. Intervalle QT	32
6.2.5. Forme de l'onde T.....	32
6.2.6. Intervalle ST.....	33

CHAPITRE 2:ACQUISITION ET TRAITEMENT DES SIGNAUX PHYSIOLOGIQUES34

1. CIRCUIT BIOMÉDICAL	34
1.1. Signal électrique	34
1.2. Tissus biologiques.....	34
1.3. Signal biologique	35
1.4. Adaptation des divers éléments de la chaîne de mesure.....	35
2. CAPTEURS BIOMÉDICAUX.....	37
2.1. Définition	37
2.2. Capteurs et signaux électrophysiologiques.....	37
2.3. Problématiques des capteurs électrophysiologiques	30
2.4. Choix des électrodes	31
2.5. Exemple électrode active conçue à partir d'un AOP.	31
2.6. Exemple de capteur numérique utilisé.	32
3. AMPLIFICATION ET FILTRAGE.....	33
3.1. Traitement du signal	33
4. CONVERSION EN SIGNAL NUMÉRIQUE.....	34
4.1. Principes de la numérisation	34
4.2. Techniques de base	34
4.3. Applications médicales	34
5. ELECTROCARDIOGRAPHE NUMÉRIQUE	34
5.1. Système d'acquisition de données	35
5.2. Echantillonnage	35
5.2.1. Echantillonneur-Bloqueur.....	35
5.2.2. Conversion analogique numérique:.....	36
5.3. Convertisseur Analogique/Numérique.....	37
6. LA NON LINÉARITÉ DES SIGNAUX CARDIAQUES	37

CHAPITRE 3: QUELQUES MODÈLES DE RÉSEAUX DE NEURONES 38

1. INTRODUCTION	38
2. HISTORIQUE.....	38
3. NEURONE FORMEL DE MCCULLOCH ET PITTS	40
3.1. Le neurone formel.....	40
4. RÉSEAUX DE NEURONES ARTIFICIELS	41
4.1. Définition	41
4.2. Architectures neuronales	42
4.2.1. Réseaux de neurones bouclés ou récurrents.....	42
4.2.2. Réseaux de neurones en couches (Perceptrons Multi-Couches).....	43
4.3. Perceptron Multi-Couches (PMC) et approximation de fonctions	44
4.4. Apprentissage.....	44
4.4.1. Apprentissage non supervisé.....	45
4.4.2. Apprentissage supervisé.....	45
4.4.3. Algorithme d'apprentissage supervisé pour les RNA : la rétropropagation.....	46
4.5. Généralisation.....	47
4.5.1. Facteurs indispensables pour une bonne généralisation	48

4.5.2. Optimisation de la généralisation.....	48
4.5.2.1. Algorithme d'apprentissage	48
4.5.2.2. Compromis Apprentissage Généralisation ou « early stopping ».....	50
5. MISE EN OEUVRE DU MODÈLE NEURONAL.....	50
5.1. Choix de l'algorithme d'apprentissage.....	50
5.2. Choix des fonctions de transfert.....	51
5.3. Choix de l'architecture neuronale.....	51
5.4. Ensemble d'apprentissage, de validation et de test.....	52
5.5. Avantage des RNA sur les méthodes statistiques	52
CHAPITRE 4: LES RÉSEAUX DE NEURONES APPLIQUÉS AU DIAGNOSTIC	
CARDIOVASCULAIRE	54
1. INTRODUCTION	54
1.1. Contexte des méthodologies de soutien à la prise de diagnostic médicale.....	54
1.2. Aperçus précédents des applications médicales impliquant les réseaux de neurones...	55
1.3. Etendue des publications.....	57
2. APERÇU SUR LES APPLICATIONS CARDIOVASCULAIRES	58
2.1. Application dans la détection du complexe QRS	58
2.2. Application dans la détection de l'infarctus du myocarde aigu (IDM)	59
2.3. Application utilisant le système de surveillance Holter	62
2.3. Application en détectant d'autres pathologies	62
3. ROBUSTESSE DANS L'ÉVALUATION DES PERFORMANCES	63
4. CONCLUSION.....	64
CHAPITRE 5: ALGORITHME DE DÉTECTION DU BLOC AURICULO	
VENTRICULAIRE	66
1. INTRODUCTION	66
2. ÉTUDE DE LA POPULATION	66
3. EXTRACTION ET ACQUISITION DES PARAMÈTRES D'ANALYSE DES ECG	68
4. DÉTECTION DU COMPLEXE QRS.....	68
4.1. Architecture du réseau de neurones.....	68
4.2. Déroulement de l'apprentissage	69
4.3. Performance.....	71
4.4. Mesure du complexe QRS.....	72
5. DÉTECTION DE L'ONDE P	72
6. RÉSEAU DE NEURONES CNN	72
7. CONCEPTION DE LA MÉTHODE.....	74
7.1. Apprentissage.....	75
7.2. Usage de la mémoire.....	77
7.3. Performance et Évaluation d'exécution du CNN	78
7.3.1. Estimation de la sensibilité et de la spécificité	78
7.3.2. Courbes ROC.....	79
8. RÉSULTATS ET DISCUSSION	80
9. Conclusion	85
CONCLUSION	86
REFERENCES.....	87

INTRODUCTION

Un pilier de la médecine moderne est la mesure des signaux comme le signal électrique cardiaque, le flux respiratoire et l'activité cérébrale. L'extraction de l'information pertinente décrivant une pathologie à partir des signaux physiologiques demande leur analyse par un expert. Par exemple, l'analyse du tracé de l'ECG d'un malade représente un moyen efficace pour la détection des anomalies cardiaques. Jusqu'à un passé assez récent, le cardiologue établissait son diagnostic en faisant recours à ce qu'on l'on peut appeler une interprétation manuelle. Cette méthode d'analyse s'appuie essentiellement sur un constat visuel d'éventuelles irrégularités morphologiques du tracé, a fait de la lecture de l'ECG un exercice difficile et périlleux. Pour pallier à ces problèmes, il devient nécessaire, outre une connaissance approfondie et raisonnée des anomalies électrocardiographiques, de formuler une automaticité de contrôle, d'analyse et d'interprétation.

L'apport des microprocesseurs et le développement de la microinformatique facilitent aujourd'hui la conception et la réalisation de systèmes automatiques d'analyse et de diagnostic. Les techniques numériques modernes du traitement de signal ont contribué significativement à l'analyse des signaux physiologiques les rendant plus précis et plus faciles à interpréter. Ces techniques qui n'ont pas la prétention de remplacer un médecin, peuvent néanmoins contribuer à aider ce dernier dans l'établissement de son diagnostic final. Elles permettent de filtrer le signal, de détecter les éléments pertinents pour le diagnostic, d'accomplir une reconnaissance de forme, une interprétation du signal électrocardiographique et de le classer selon la pathologie.

Les travaux de recherches méthodologiques effectuées ces dernières années ont permis de mettre en évidence la pertinence et la supériorité des méthodes d'identification à l'aide des réseaux de neurones, par rapport aux méthodes classiques.

De plus, les réseaux de neurones se sont avérés particulièrement adaptés, dans le domaine de l'automatisme. Leurs capacités d'approximation sont mises à profil pour la modélisation des systèmes. D'un autre côté, les caractéristiques dont jouissent ces réseaux, d'être utilisés pour les opérations de reconnaissance et plus généralement, en traitement de signal. Ainsi pour la classification, les réseaux de neurones ont prouvé leur efficacité et elles ne cessent de s'élargir.

Nous mettons en place un modèle neuronal basé sur trois réseaux multicouches avec deux réseaux placés en parallèle en série avec le troisième. Nous essayons ainsi de donner des éléments de réponse quant à l'existence d'un bloc auriculo-ventriculaire (BAV).

Cette thèse comprend cinq chapitres:

Le premier chapitre présente une introduction au fonctionnement général du cœur et le principe de l'électrocardiogramme (ECG). Ensuite, nous décrivons très sommairement quelques pathologies cardiaques. Le but, ici, est de mettre en relation certaines observations anormales du tracé ECG avec les pathologies les plus courantes et de donner l'importance diagnostique de l'étude des caractéristiques des ondes P, Q, R, S et T (formes, distances relatives, ...).

Dans le deuxième chapitre nous présentons la technique d'acquisitions de l'électrocardiogramme numérique à partir du tissu biologique jusqu'à l'obtention des valeurs numériques à la sortie de l'ordinateur. Nous parlons des éléments nécessaires pour construire la chaîne de mesure.

Nous exposons dans le chapitre 3, les réseaux de neurones artificiels (RNA) en général et nous nous attardons sur les Perceptrons MultiCouches (PMC) pour leurs capacités à approcher les relations non-linéaires. Les propriétés des PMC en apprentissage et en généralisation sont abordées ainsi que les moyens permettant d'améliorer les performances des PMC en généralisation. Nous donnons les différents choix possibles pour les différents paramètres des modèles : architecture, fonction de transfert et algorithme d'apprentissage. Nous terminons ce chapitre en justifiant nos choix.

Le chapitre 4 est une revue sur les techniques d'automatisation d'ECG en utilisant les réseaux de neurones. Tout d'abord nous donnons un aperçu sur quelques applications médicales impliquant les réseaux de neurones ensuite nous étalons l'étude sur les applications cardiovasculaires en précisant leur adaptabilité et leur évolution. Nous montrons le rôle de leur application dans la prise du diagnostic médical, l'identification des pathologies et notamment le développement du processus de raisonnement modélisé, ainsi que leur impact clinique dans des secteurs spécifiques.

Dans le cinquième chapitre, nous exposons notre méthodologie d'extraction des descripteurs des ECGs et les prétraitements afin d'adapter nos données à l'utilisation neuronale. Nous mettons en place un système de diagnostic (classification) et nous étudions sa performances sur les séquences d'ECG appartenant à divers sujets, sains et pathologiques, afin de détecter d'éventuels dysfonctionnements du cœur au niveau du nœud auriculo-ventriculaire.

CHAPITRE 1 L'ELECTROCARDIOGRAMME

Nous présentons dans ce chapitre le fonctionnement général du système cardiovasculaire, puis, de manière plus détaillée, le principe de l'électrocardiogramme (ECG). Cette présentation se limite au strict nécessaire pour une bonne compréhension de la thèse; le lecteur intéressé par une approche médicale rigoureuse pourra se reporter aux nombreux ouvrages médicaux disponibles sur le sujet comme notamment [DeBakey et al, 1997]. Ensuite, nous décrivons très sommairement quelques pathologies cardiaques susceptibles d'être repérées en étudiant un rythme cardiaque. Le but, ici, n'est pas de faire une analyse détaillée de la problématique du diagnostic des maladies cardiovasculaires; mais plutôt de faire les corrélations possibles de la forme de l'ECG avec certaines observations anormales. [Houghton et al, 1997; Dubin, 1999]. Il s'agit donc de sensibiliser le lecteur à l'importance diagnostique de l'étude des caractéristiques des ondes P, Q, R, S et T (formes, distances relatives, ...), au-delà d'une simple analyse de rythme. De plus, ce chapitre permet de présenter de nombreux tracés.

1. Système cardiovasculaire

Le système cardiovasculaire assure la circulation du sang dans l'organisme et permet ainsi son alimentation en oxygène et en nutriments. Il est composé du coeur, sorte de double pompe, qui assure la circulation dans deux réseaux complémentaires : celui des artères et celui des veines.

1.1. Circulation artérielle et veineuse

Le réseau artériel de la grande circulation est un circuit à haute pression ; il conduit le sang oxygéné à travers le corps dans des vaisseaux sanguins appelés, selon leurs tailles, artères, artérioles ou capillaires artériels (Figure 1.1). Ce dernier niveau est constitué de multiples petites ramifications qui facilitent le transfert de l'oxygène du sang aux organes. Le sang, devenu pauvre en oxygène, revient au cœur par les veines, puis est envoyé par les artères pulmonaires dans la petite circulation où il est oxygéné dans les poumons.

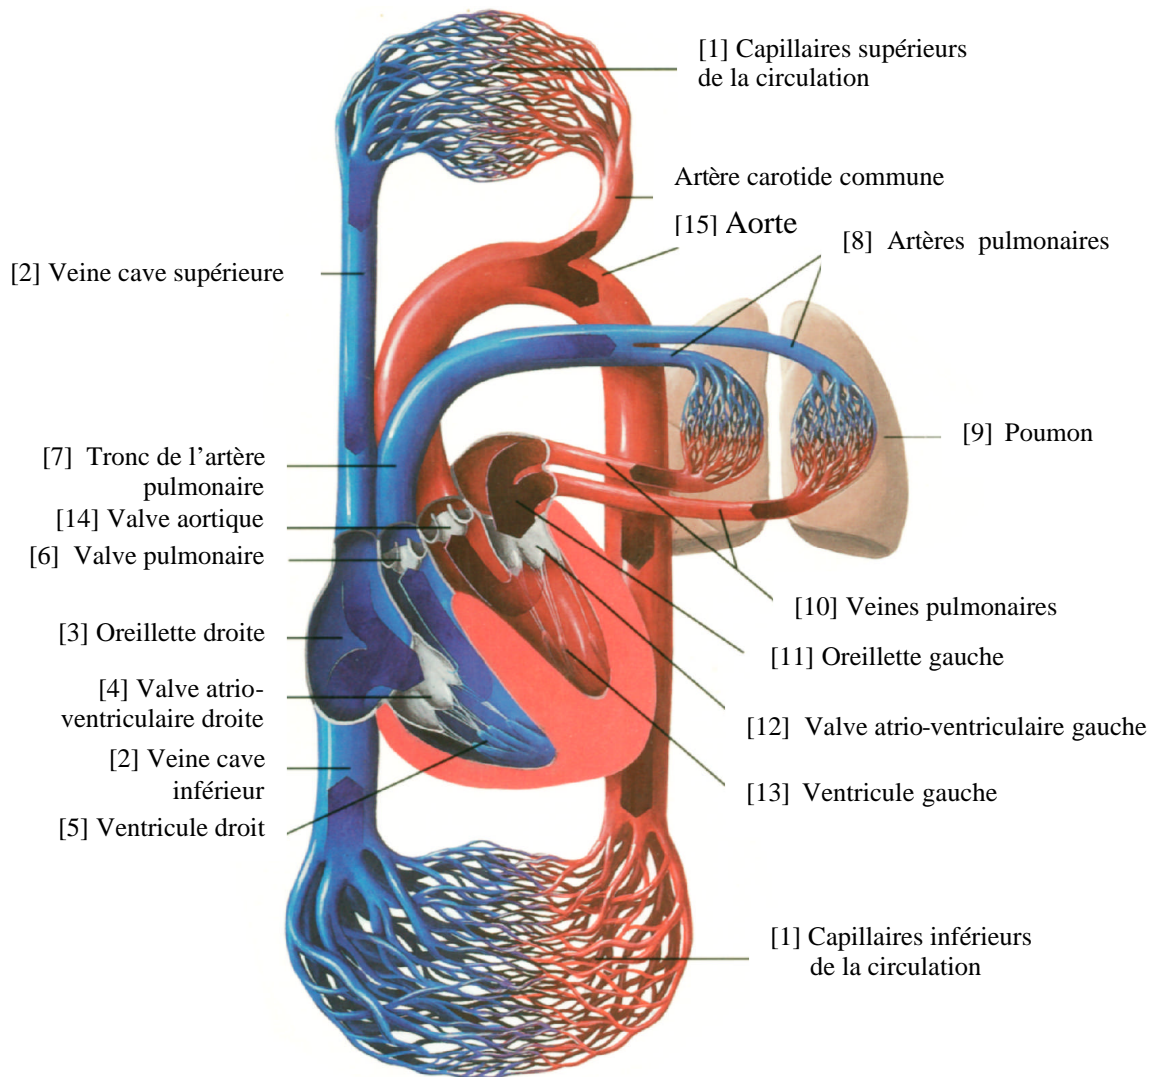


Figure 1.1. Schéma de la circulation. Le sang pauvre en oxygène est amené de la périphérie du corps [1] par l'intermédiaire de la veine cave supérieure et inférieure [2] à l'oreillette droite du cœur. Pendant la systole de l'oreillette, le sang pénètre dans le ventricule droit [5] par la valve atrio-ventriculaire droite [4]. A partir de là, le sang pendant la systole du ventricule est expulsé par la valve pulmonaire [6] dans le tronc de l'artère pulmonaire. Par l'intermédiaire des artères pulmonaires [8], le sang pénètre dans le poumon [9] où il est enrichi en oxygène inspiré. De l'anhydride carbonique se dégage. Ensuite, par l'intermédiaire des veines pulmonaires [10], le sang riche en oxygène pénètre dans l'oreillette gauche [11] et après, pendant la systole de l'oreillette, par l'intermédiaire de la valve atrio-ventriculaire gauche [12] dans le ventricule gauche [13]. Pendant la systole du ventricule, le sang est expulsé dans l'aorte [15] par la valve aortique [14]. Par l'intermédiaire du système artériel, le sang atteint les capillaires du corps [1] où il alimente les tissus en oxygène et en matières nutritives. Ensuite, le sang pauvre en oxygène retourne au cœur droit par l'intermédiaire du système veineux. Le cycle de la circulation recommence.

1.2. Le cœur

Le cœur est l'élément central du système cardiovasculaire. Nous décrivons dans la suite du chapitre l'anatomie et le fonctionnement électrique d'un cœur sain.

1.2.1. Anatomie

Le cœur propulse le sang grâce aux contractions de son tissu musculaire appelé myocarde. Une épaisse cloison le divise en deux moitiés (cœur gauche/cœur droit), et chacune d'elles comporte deux cavités : l'oreillette et le ventricule. À chaque battement, le myocarde suit la même séquence de mouvement : le sang pauvre en oxygène arrive au cœur par la veine cave. Il y entre par l'oreillette droite, et en est chassé par sa contraction appelée systole auriculaire qui le déplace dans le ventricule droit. La systole ventriculaire (contraction des ventricules) propulse à son tour le sang du ventricule droit vers les poumons où il va se charger en oxygène. De retour au cœur par les veines pulmonaires, le sang s'accumule dans l'oreillette gauche puis, lors de la systole auriculaire, passe dans le ventricule gauche qui lors de la systole ventriculaire l'envoie vers les organes par l'artère aorte (Figure 1.2).




Figure 1.2. Position naturelle du cœur, vue dorsale

1.2.2. Cellules myocardiques

Le travail du cœur [Silbernagl et al, 1993] est dû à la contraction des cellules cardiaques, qui sont des cellules musculaires striées hautement spécialisées. A l'opposé de ce qui se passe dans les muscles communs, l'excitation électrique conduisant à la contraction se propage de cellule en cellule, ce qui assure la coordination nécessaire à un pompage efficace. Cette excitation est liée à des échanges d'ions entre les parois interne et externe de la cellule. Ce sont les ions chlorure (Cl^-), sodium (Na^+), calcium (Ca^{++}) et potassium (K^+) qui sont impliqués dans les échanges membranaires, leurs asolarités intracellulaires et extracellulaires présentent des valeurs de potentiel électrochimiques très différentes, spécifiques de chaque ion.

L'activité mécanique du cœur résulte des phénomènes électriques des cellules cardiaques. Les processus d'origine électrique sont créés par des ondes de polarisation/dépolarisation se propageant à la surface des cellules.

1.2.3. Electrophysiologie cellulaire

Le processus d'activation électrique cardiaque prend naissance au niveau de la fibre myocardique. A l'état basique, une fibre myocardique est dite polarisée : La face interne de la membrane cellulaire est tapissée de charges électriques négatives, sa face externe de charges électriques positives, de sorte qu'une microélectrode transperçant cette membrane recueille un potentiel négatif de l'ordre de -90 mV.




Figure 1.3. Electrophysiologie cellulaire

Lorsque cette fibre myocardique est stimulée, des mouvements ioniques se produisent de part et d'autre de la membrane cellulaire. Les charges négatives internes sont remplacées par des charges positives : le potentiel intracellulaire passe brusquement de -90mV à $+20\text{mV}$, la cellule est dite dépolarisée la microélectrode enregistre cette montée rapide du voltage. Ensuite, des mouvements ioniques en sens inverse vont progressivement restaurer l'état de départ : c'est le processus de repolarisation, qui va ramener le potentiel intracellulaire à sa valeur initiale. Au terme du processus, l'électrode exploratrice aura enregistré un potentiel d'action, constitué de 4 phases successives : état de base, montée rapide, plateau et descente progressive. La phase d'ascension rapide correspond au QRS (complexe QRS) tandis que le plateau et la descente correspondent au segment ST et à l'onde T (Figure 1.4).




Figure 1.4. Graphe du potentiel d'action cellulaire avec ses 4 phases successives. État de base, montée rapide, plateau et descente progressive.

1.2.4. Fonctionnement électrique

Comme pour tous les muscles du corps, la contraction du myocarde est provoquée par la propagation d'une impulsion électrique le long des fibres musculaires cardiaques induite par la dépolarisation des cellules musculaires. Dans le cœur, la dépolarisation prend normalement naissance dans le haut de l'oreillette droite (le sinus). L'impulsion électrique arrive alors au noeud auriculo-ventriculaire (AV), seul point de passage possible pour le courant électrique entre les oreillettes et les ventricules. Là, l'impulsion électrique subit une courte pause permettant au sang de pénétrer dans les ventricules. Elle emprunte alors le faisceau de His, qui est composé de deux branches principales allant chacune dans un ventricule. Les fibres constituant ce faisceau, complétées par les fibres de Purkinje, grâce à leur conduction rapide, propagent l'impulsion électrique en plusieurs points des ventricules, et permettent ainsi une dépolarisation quasi instantanée de l'ensemble du muscle ventriculaire, malgré sa taille importante, ce qui assure une efficacité optimale dans la propulsion du sang. Cette contraction constitue la phase de systole ventriculaire. Puis suit la diastole ventriculaire

(décontraction du muscle) ; les fibres musculaires se re-polarisent et reviennent ainsi à leur état initial.

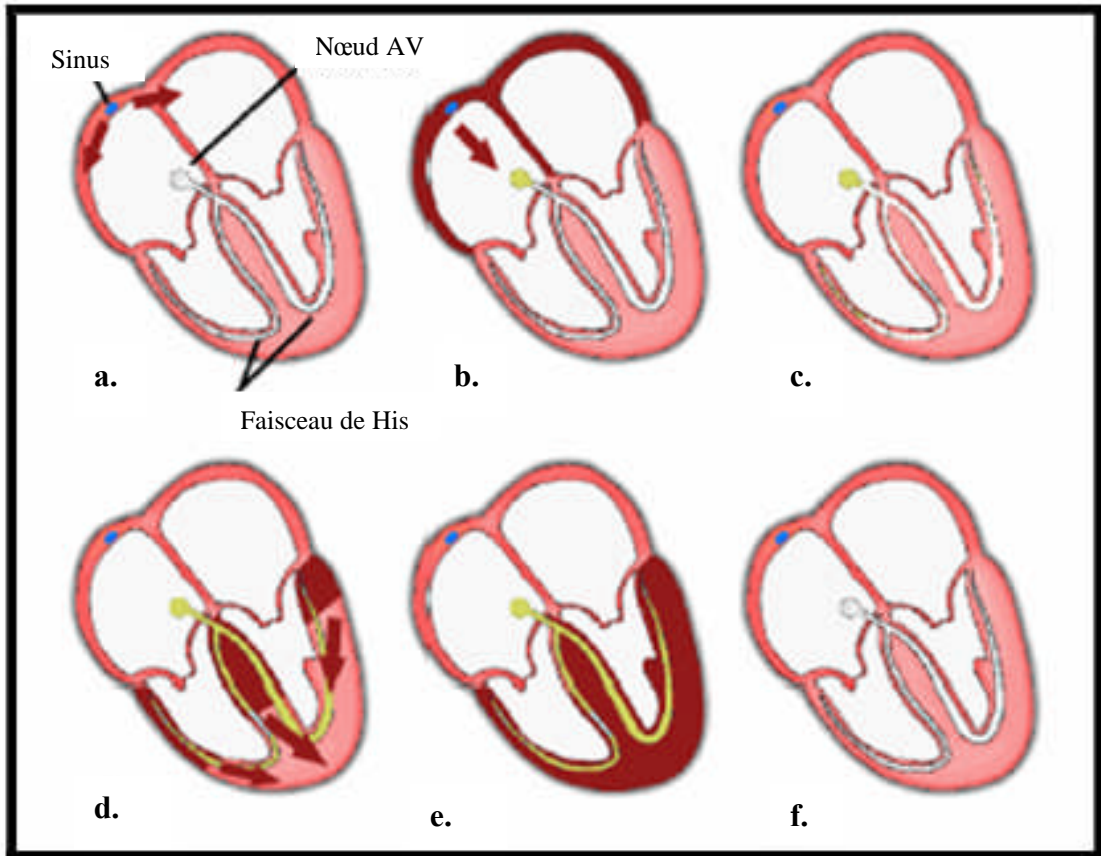


Figure 1.5. Le cycle du battement cardiaque

2. Electrocardiographie

L'électrocardiographie consiste en l'enregistrement de l'activité électrique du muscle cardiaque à l'aide d'un électrocardiographe [Chapelon, 2004]. Ce dernier est constitué des éléments suivants:

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

2.1. Principe de l'électrocardiographie

L'électrocardiogramme (ECG) repose sur un certain nombre de conventions et de postulats :

- On admet que le corps humain constitue un milieu conducteur homogène.

- Le cœur dans sa totalité est constitué d'une infinité de cellules myocardiques élémentaires. On assimile le cœur dans sa globalité à une fibre musculaire unique, à condition que les électrodes d'enregistrement soient suffisamment éloignées.
- Les effets du processus d'action du cœur sur le champ électrique corporel peuvent être assimilés à ceux d'un dipôle électrique
- Les électrodes de l'enregistrement sont placées loin du cœur. les variations du champ électrique produit à la surface du corps.

2.2. Bref aperçu historique

Vers 1880, E. Marey [Marey, 1876] et Augustus Waller [Waller, 1893] montrèrent que l'activité électrique du cœur, découverte quelques années plus tôt, pouvait être suivie à partir de la peau ; et vers 1890, Willem Einthoven réalisa le premier enregistrement cardiographique [Einthoven, 1941]. Le courant mesuré par des électrodes sur le torse du patient mettait en mouvement un mince fil d'argent tendu entre les pôles d'un gros aimant ; ces déflexions étaient enregistrées sur du papier photographique qui se déroulait face à un rayon lumineux. Ainsi naît l'électrocardiogramme à l'aube du 20ème siècle.

Le principe de l'enregistrement moderne est, à peu de chose près, celui qui fut proposé par Einthoven : grâce à deux électrodes collées à la surface de la peau, on enregistre la différence de potentiel entre deux points diamétralement opposés par rapport au cœur, ce signal étant directement corrélé au déplacement de l'impulsion électrique dans les fibres du muscle cardiaque.

3. Electrocardiogramme

3.1. Définition de l'électrocardiogramme

Le tracé électrocardiographique (ECG) est une forme de visualisation des tensions électriques (de différences de potentiels électriques provoquées par la propagation de l'influx électrique au sein du cœur) qui résultent de l'excitation du cœur. Ces signaux sont obtenus à partir de points bien précis situés sur la peau par l'intermédiaire d'électrodes placées à la surface du corps (dérivations cardiaques). L'ECG exprime donc les événements électriques de l'excitation cardiaque et peut renseigner sur l'état du cœur. La fréquence de battement, la nature et la genèse du rythme, l'excitation et ses effets, ainsi que les perturbations éventuelles, que celles-ci soient d'origine anatomique ou mécanique, qu'elles concernent des altérations tissulaires ou des perturbations de la circulation sanguine sont véhiculées par le signal de l'ECG, d'où son extrême importance.

3.2. Dérivations

Les dérivations [Houghton et al, 2000] représentent différents aspects de l'activité électrique du cœur. Un appareil d'électrocardiographie utilise l'information qu'il recueille par l'intermédiaire de ses quatre électrodes des membres et de ses six électrodes thoraciques pour dresser un tableau détaillé de l'activité électrique du cœur, représenté par douze postes d'observation différents. A chaque dérivation est attribué un nom (DI, DII, DIII, aVR, aVL, aVF, V1, V2, V3, V4, V5, V6). Les douze dérivations représentent un nombre suffisant de fenêtres cardiaques utilisables et fournissant un tableau compréhensible de l'activité électrique du cœur. Cependant, dans certains travaux de recherche, on a souvent recours à plus de 100 dérivations pour avoir une image plus précise de l'activité cardiaque.

L'étude temporelle du vecteur résultat est obtenue en clinique par l'examen des dérivations des extrémités et des dérivations à partir de la paroi thoracique. En d'autres termes, chaque dérivation ECG donne une image unidirectionnelle du vecteur résultat et de ce fait, deux dérivations (3 points au moins) déterminent un plan dans lequel elles indiquent l'évolution du vecteur résultat.

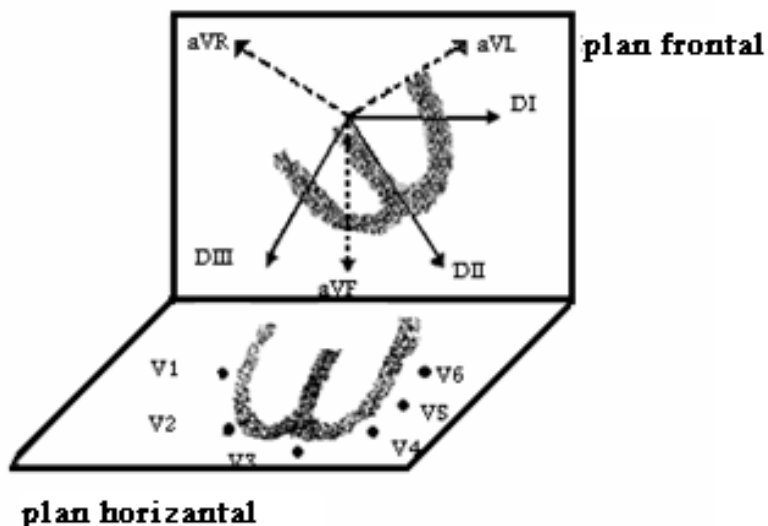


Figure 1.6. Les 12 dérivations.

3.2.1. Dérivations dans le plan frontal

a) Dérivations bipolaires

Les dérivations électrocardiographiques standard DI, DII, DIII de Einthoven sont des dérivations bipolaires dans le plan frontal. Pour les obtenir, on place des électrodes (Figure 1.7) sur chacun des deux avant-bras et sur la jambe gauche, on examine l'évolution temporelle de la différence de potentiel entre les deux bras. C'est la dérivation DI. Entre le bras droit et la jambe gauche. C'est la dérivation DII. Et entre le bras gauche et la jambe gauche. C'est la dérivation DIII.

Ce système de référence est schématisé par un triangle équilatéral dit «triangle d'Einthoven» (Figure 1.7)

b) Dérivations unipolaires

Les dérivations unipolaires de Goldberg sont aussi des dérivations dans le plan frontal. Ces dérivations sont obtenues également à partir des deux bras et de la jambe gauche. Cependant, dans ce cas, deux électrodes sont reliées ensemble (par des résistances) et servent d'électrode de référence par rapport à la troisième. La dénomination des électrodes de Goldberg est la suivante : aVR = bras droit, aVL = bras gauche et aVF = jambe gauche (Figure 1.7).

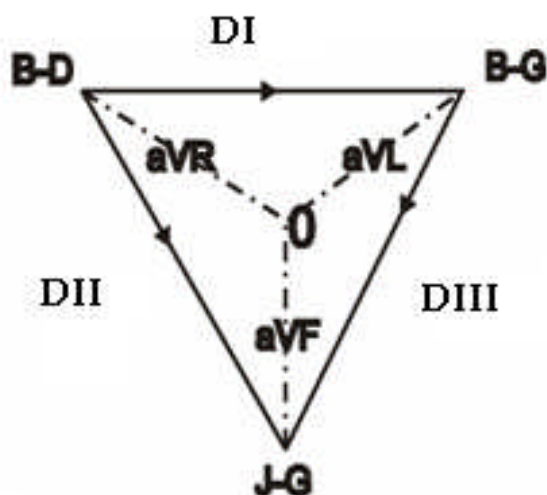


Figure 1.7. Position des électrodes des dérivations bipolaires et des dérivations unipolaires.

3.2.2. Dérivations dans le plan horizontal

Ce sont des dérivations unipolaires précordiales. Elles comportent une électrode exploratrice placée sur le précordium des points définis selon des repères squelettiques conventionnels à une électrode indifférente liée à une borne de potentiel 0. Elles ont pour symbole la lettre V suivie d'un numéro selon sa position sur le thorax (V1, V2, V3, V4, V5, V6).

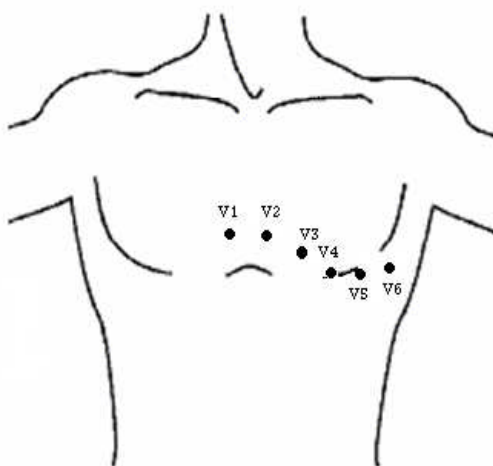


Figure 1.8. Position des électrodes des dérivations précordiales.

Habituellement il existe six dérivations :

V1 : près du bord de sternum.

- V2 : près du bord de sternum.
- V3 : sur la ligne du medio claviculaire.
- V4 : sur le milieu de la ligne qui unit V2 à V4.
- V5 : sur la ligne axillaire antérieur gauche.
- V6 : sur la ligne axillaire moyenne gauche.

Il existe d'autres dérivations précordiales : V3R, V4R, VE, V7, V8 et V9.

Grâce aux dérivations bipolaires DI, DII, DIII et unipolaires aVR, aVL, aVF des membres on explore l'activité électrique dans le plan frontal. A l'aide des précordiales (V1, V2, V3, V4, V5 et V6), on explore l'activité électrique du cœur dans un plan horizontal perpendiculaire au précédent (Figure 1.6).

4. Activité électrique d'un battement cardiaque normal

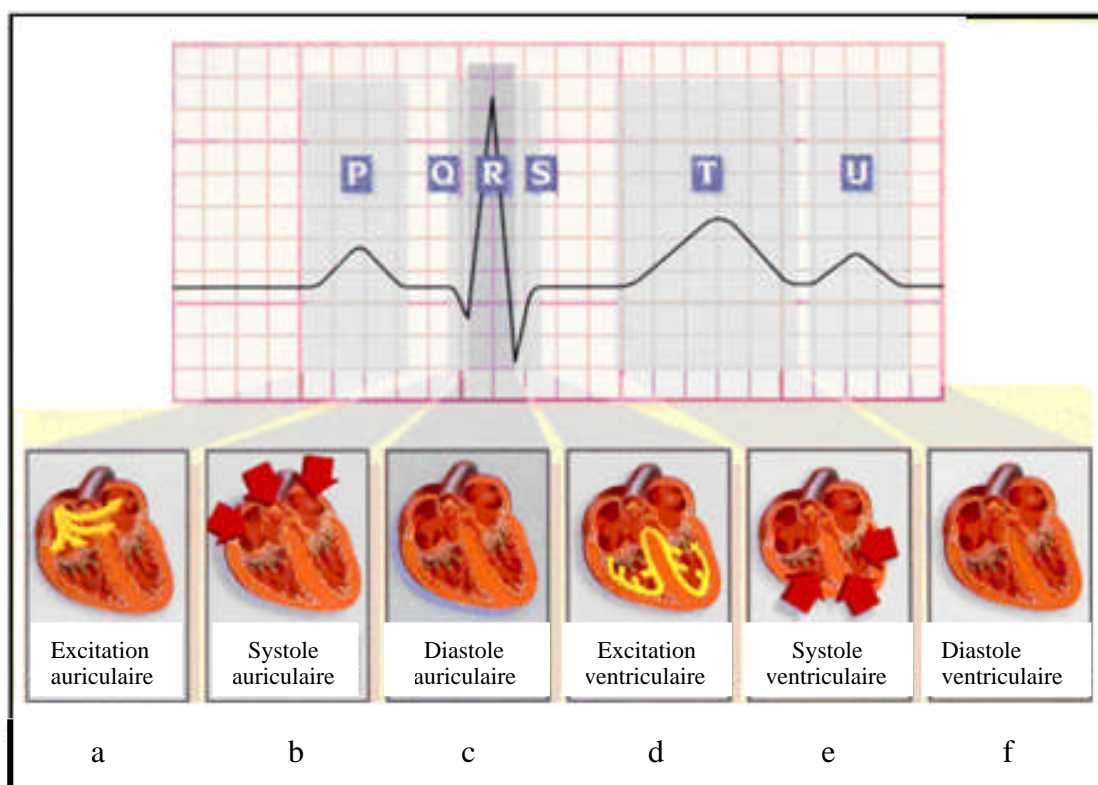


Figure 1.9. Excitation cardiaque.

Le battement cardiaque peut donc être suivi grâce à l'enregistrement en surface du signal électrique qui l'accompagne. En effet, chaque phase du battement possède une trace électrique particulière. L'impulsion initiale vient du sinus. Elle n'est pas visible sur l'ECG. L'onde électrique qui se propage ensuite dans les oreillettes, entraînant leurs contractions, laisse la trace d'une petite déflexion positive sur l'ECG : l'onde P (Figure 1.9a). L'impulsion arrive alors au noeud auriculo-ventriculaire (AV), où se produit la courte pause qui se traduit sur l'ECG par un petit segment plat PR; puis elle emprunte les voies de conduction rapide (le faisceau de His) pour entraîner la contraction des ventricules, suivie de leur repolarisation.

Cette propagation de l'impulsion et la contraction brève et puissante de l'ensemble du muscle ventriculaire, dessinent sur l'ECG une succession de 3 ondes (Q, R et S) appelé complexe QRS (Figure 1.9b). L'onde Q est la première : c'est une onde dirigée vers le bas, qui n'est pas toujours visible sur le tracé ; la seconde est l'onde R : elle est de grande amplitude et dirigée vers le haut ; la dernière est dirigée vers le bas : c'est l'onde S. C'est l'ensemble de ces trois ondes qui constitue le complexe QRS. Après chaque complexe QRS, on observe sur l'ECG une onde appelée onde T. Entre cette onde et l'onde précédente, on note une courte pause appelée le segment ST, dont l'étude est très importante pour l'identification de certaines pathologies. L'onde T traduit la phase de repolarisation des cellules constituant les ventricules; c'est un phénomène purement électrique et pendant cette phase le coeur est mécaniquement inactif (Figure 1.9c).

5. Electrocardiogramme normal




Figure 1.10. Ondes et intervalles de l'ECG.

5.1. Ondes

Le tracé ECG comporte plusieurs déflexions (ondes), une incursion vers le haut étant notée positivement et vers le bas négativement (figure 1.10).

5.1.1. Onde P

Cette onde traduit la dépolarisation des cavités auriculaires, l'onde de la repolarisation auriculaire de très faible amplitude.

5.1.2. Complexe QRS

Le complexe ventriculaire correspondant à la dépolarisation ventriculaire. C'est le plus ample de tous les accidents électriques mais cette amplitude varie d'une dérivation à une autre.

a) Onde Q ou q : déflexion initiale négative qui précède la première déflexion positive (R ou r). Ne peut être présente que dans les dérivations qui font face au côté gauche du septum Inter ventriculaire.

b) Onde R ou r : première déflexion positive. L'onde R' ou r' deuxième déflexion positive et l'onde R'' ou r'' troisième déflexion positive existent dans certain cas.

c) Onde S ou s : première déflexion négative succédant à la déflexion positive R ou r. L'onde S' ou s' deuxième déflexion négative succédant à la déflexion Positive R ou r et l'onde S'' ou s'' troisième déflexion négative succédant à la déflexion Positive R ou r existent aussi dans certain ECGs.

d) Point J : il correspond à la fin de la dépolarisation ventriculaire.

5.1.3. Onde T

Cette onde correspond à la repolarisation ventriculaire. Elle se détache doucement et presque insensiblement de la ligne isoélectrique par une branche presque toujours ascendante dont la pente initiale très douce augmente peu à peu en dessinant une faible concavité supérieure avant de s'incurver progressivement vers l'horizontale puis vers le bas pour dessiner un sommet.

5.1.4. Onde U

Une petite onde positive de très faible amplitude dont l'intérêt tient à la valeur sémiologique de ses déformations éventuelles et en particulier de son inversion. Cette déflexion inconstante est de signification non formelle.

5.2. Intervalles et Segments

Les positions respectives de l'onde P, du complexe QRS et de l'onde T permettent de définir un certain nombre d'intervalles ou de segments. Ces intervalles sont : PR, ST, QT (Figure 1.10).

5.2.1. Segments PR ou PQ-R

Le segment PR correspond au temps de conduction auriculo-ventriculaire, c'est-à-dire au temps que met l'influx pour parcourir l'espace entre le nœud sinusal et le myocarde ventriculaire. Il sépare la fin de l'onde P du début du QRS

5.2.2. Segments ST, RST ou ST-T

Le segment ST débute au point J jusqu'au pied de l'onde T. Il sépare la fin de la dépolarisation ventriculaire du début de la repolarisation ventriculaire. Les espaces ST et PQ sont

5.2.3. Intervalle PR

Représente le temps écoulé entre le début de l'excitation des oreillettes et celui des ventricules. On l'appelle aussi le temps de 'Conduction auriculo-ventriculaire'.

5.2.4. Intervalle QT

Il débute au début de l'onde Q (complexe QRS, début de la dépolarisation ventriculaire) jusqu'à la fin de l'onde T (fin de la repolarisation ventriculaire).

La durée de l'intervalle QT exprime essentiellement la durée de la repolarisation ventriculaire. Elle varie dans de larges proportions chez les sujets normaux.

De l'intervalle QT dépend la fréquence du battement cardiaque (75 battements/min (bpm) en moyenne). C'est le temps nécessaire à la repolarisation des ventricules.

5.2.5. Déflexion Intrinsicóide DI

Elle exprime le temps que met l'onde de dépolarisation à parcourir le myocarde de l'endocarde à l'épicarde. La DI est d'autant plus longue que le myocarde est épais. Elle se mesure au niveau des dérivations droites pour le ventricule droit et des dérivations gauches pour le ventricule gauche. La mesure de DI se fait du début de l'onde Q au sommet de l'onde R ou r, ou du dernier crochetage de R si l'onde R est crochétée.

6. Diagnostic à partir de L'ECG

Pour dresser un diagnostic à partir d'un ECG [Houghton et al, 1997; Dubin, 1999], deux points essentiels sont à étudier : le rythme cardiaque (fréquence et régularité) et la forme des ondes (distances relatives, amplitudes, durées,...).

6.1. Diagnostic à partir du rythme

Un rythme cardiaque régulier est normal lorsqu'il est compris en journée entre 60 et 100 bpm (battement par minute), et entre 40 et 80 bpm pendant la nuit. Hors de ces limites, on parle de bradycardie lorsqu'il est trop lent, et de tachycardie lorsqu'il est trop rapide.

6.1.1. Bradycardie

La bradycardie est caractérisée par le fait que la fréquence cardiaque est inférieure à 60 bpm; elle est dite d'origine sinusale, jonctionnelle ou ventriculaire, selon le site d'initiation de l'impulsion électrique à l'origine des battements considérés.

a) Bradycardie sinusale

Outre sa fréquence basse, la bradycardie sinusale est caractérisée par la présence systématique d'une onde P avant les complexes QRS (Figure 1.11) comme lors de battements normaux.



Figure 1.11. Bradycardie sinusale. Le rythme est de l'ordre de 40 bpm.

b) Bradycardie d'origine jonctionnelle

La morphologie des ondes QRS est identique à celle du battement normal ; en revanche, l'onde P peut être absente ou, si elle est présente, elle peut être désynchronisée de la systole ventriculaire (Figure 1.12). Le rythme devient alors une succession d'ESV (extrasystoles ventriculaires) à une fréquence très lente, entre 15 et 40 bpm.



Figure 1.12. Bradycardie d'origine jonctionnelle.

6.1.2 Tachycardie

À l'inverse de la bradycardie, la tachycardie est caractérisée par le fait que la fréquence est supérieure à 100 bpm ; elle peut être d'origine sinusale, auriculaire ou ventriculaire.

a) Tachycardie sinusale

La tachycardie sinusale correspond à un rythme sinusal dont la fréquence est comprise entre 100 et 180 bpm ; on observe, avant chaque complexe QRS, une onde P de forme identique à celle observée lors du rythme normal (Figure 1.13).




Figure 1.13. Tachycardie sinusale. Le rythme est de 120 bpm.

b) Tachycardie auriculaire et nodale

Très schématiquement, on observe une onde P de forme inhabituelle. La fréquence typique est

c) Tachycardie ventriculaire (TV)

Les battements ont la forme d'extrasystoles ventriculaires très rapprochées (Figure 1.14). Ce type de rythme est dangereux à cause de son possible évolution en *fibrillation ventriculaire* qui, elle, conduit au décès du patient



Figure 1.14. Tachycardie ventriculaire (TV) à une fréquence de 150 bpm.

6.1.3. Arythmies, ou troubles de la régularité

L'absence de régularité des battements cardiaques est une caractéristique du rythme importante pour le diagnostic; elle est souvent associée à un trouble de la production ou de la conduction de l'impulsion électrique

a) Fibrillation auriculaire (FA)




Figure 1.15. Fibrillation auriculaire.

Le fonctionnement du myocarde auriculaire est totalement désorganisé et le rythme des complexes QRS est complètement irrégulier. Le rythme moyen est généralement supérieur à 100 bpm et peut atteindre 200 bpm (Figure 1.15).

b) Fibrillation ventriculaire

La fibrillation ventriculaire est l'équivalent physiologique de la fibrillation auriculaire, mais transposée aux ventricules : il n'y a plus de systole cardiaque et constitue donc une arythmie particulièrement grave (Figure 1.16).




Figure 1.16. Fibrillation ventriculaire.

6.1.4. 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 noeud AV, peuvent prendre le relais et entraîner des bradycardies ou tachycardies, comme cité au paragraphe précédent. 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 coeur, il existe essentiellement trois types de « blocs » classés suivant leurs localisations: le bloc sino-auriculaire (SA) situé entre le sinus et les oreillettes, le bloc auriculo-ventriculaire (BAV) 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 (Figure 1.17).

a) Bloc sino-auriculaire (SA)

Sur l'ECG, on observe l'absence d'un battement là où régulièrement il devrait y en avoir un.

b) Bloc auriculo-ventriculaire (BAV)

C'est justement la pathologie que l'algorithme CNN, proposé dans cette thèse, sera mené à analyser.

Dans le cas d'un BAV, l'influx se propage correctement au niveau des oreillettes mais n'est pas transmis aux ventricules: La contraction des oreillettes n'est donc pas suivie de la contraction des ventricules. Ce type de bloc est habituellement caractérisé par son degré de sévérité.

- **Bloc AV d'ordre I** correspond à l'allongement de la distance PR, c'est-à-dire que la conduction entre les oreillettes et les ventricules s'effectue difficilement, lentement, mais n'est pas absente. Chaque onde P est donc suivie d'un complexe QRS ; le rythme est régulier.
- **Bloc AV d'ordre II** bloque certaines impulsions issues des oreillettes, qui ne donnent alors pas naissance à des contractions ventriculaires (Figure 1.18) ; le tracé ECG présente de temps en temps des ondes P isolées, non suivies de complexes QRS.



Figure 1.18. Bloc AV d'ordre II. Le rythme est sinusal à une fréquence de 80 bpm. Seule une onde P (contraction auriculaire) n'est pas suivie d'une systole ventriculaire, ce qui indique un bloc AV d'ordre II. Le rythme apparaît donc localement irrégulier.

- **Bloc AV d'ordre III** correspond à l'absence totale de conduction entre les oreillettes et les ventricules. Les activités de ces deux parties du cœur, habituellement corrélées, sont, dans ce cas, totalement indépendantes. Le sinus continue à assurer la régularité des battements auriculaires, mais l'absence de transmission de l'influx auriculaire vers les ventricules conduit un foyer ectopique, au niveau du noeud jonctionnel (AV) ou au niveau ventriculaire, à prendre la commande des ventricules, ce qui, selon les cas, peut introduire un rythme régulier ou non, mais assurément plus lent que le rythme sinusal. Les irrégularités du rythme sont donc principalement observables durant les BAV I et BAV II, et surtout lors d'une situation intermédiaire où l'on repère une période dite de Wenckebach, qui correspond à un allongement périodique de la distance PR aboutissant

à une onde P non conduite, suivie d'une onde P conduite. Cette pathologie introduit ainsi une irrégularité régulière du rythme.

L'étude du rythme et de la régularité des battements sur un ECG permet donc d'orienter efficacement un diagnostic : bradycardie, tachycardie, blocs, foyers ectopiques,... Mais la caractérisation du type de pathologie nécessite une étude plus précise des ondes constituant chaque battement. Par exemple l'absence ou non d'une onde P permet de différencier un bloc SA d'un BAV, la forme du complexe QRS indique si une bradycardie est jonctionnelle ou d'échappement ventriculaire. Une analyse et une reconnaissance des ondes caractéristiques apparaissent donc comme un complément indispensable à l'étude du rythme, pour réaliser un traitement automatique du signal ECG qui soit un véritable auxiliaire de diagnostic complet.

6.2. Diagnostic à partir des ondes

Grâce à la puissance des ordinateurs modernes, de nouvelles méthodes de traitement du signal ont vu le jour pour analyser, outre le rythme, la forme des ondes de chaque battement. Cette analyse reste pour l'instant essentiellement limitée à la forme de l'onde R, même si on commence aujourd'hui à repérer des troubles de la repolarisation à partir de la forme de l'onde T. L'avantage d'une étude individuelle de chacune des ondes, en y incluant l'analyse de l'onde P, est qu'elle permettra de réaliser un véritable pré-diagnostic sur la base de la connaissance experte, grâce à la localisation de l'origine du problème lorsque les battements cardiaques ne sont pas normaux. En effet, nous avons vu que chaque onde correspond à une activité spécifique d'une partie du cœur.

6.2.1. Forme de l'onde P



Figure 1.19. Foyer ectopique auriculaire. Pendant 6 battements, un foyer ectopique auriculaire a remplacé le sinus. La forme de l'onde P est clairement différente pendant cette période, puisqu'elle apparaît inversée ; dans cet exemple, le rythme introduit par le foyer ectopique est très proche de celui observé lors de battements sinusaux, ce qui rend la détection de ce type d'anomalie difficile par la seule étude du rythme (on note toutefois le repos compensatoire après la salve d'ESSV, qui, si l'alternance sinus/foyer ectopique est fréquente, peut introduire une irrégularité du rythme).

Une onde P de forme variable peut révéler la présence d'un ou de plusieurs foyers ectopiques auriculaires. Le tracé présente alors une succession de battements dont la forme de l'onde P varie (Figure 1.19), avec ou sans éventuelles conséquences sur la fréquence et le rythme ventriculaires (tachycardie auriculaire). La durée de l'onde P est habituellement inférieure à

80 ms ; des ondes P anormalement larges ou anormalement amples traduisent une dilatation d'une des oreillettes.

6.2.2. Intervalle PR

Il est normalement compris entre 120 ms et 200 ms et reste fixe quelle que soit la fréquence (elle correspond en effet au temps de dépolarisation du noeud AV, qui est une constante physiologique).

Les causes d'un intervalle mesuré inférieur à 120 ms sont généralement les suivantes :

- Un rythme jonctionnel auriculo-ventriculaire (AV):
- Une deuxième cause possible est le syndrome de Wolff-Parkinson-White (WPW) [Houghton, 1997].
- Dans le cas inverse, où l'intervalle PR est supérieur à 200 ms, et où chaque onde P est bien suivie d'un complexe QRS, on peut suspecter **un BAV d'ordre I**. Le fait de pouvoir localiser les différentes ondes indépendamment les unes des autres permettra de suivre l'évolution temporelle des distances entre les ondes comme cette distance PR, de préciser la fréquence d'occurrence de l'apparition de BAV, et ainsi de mieux spécifier leur ordre.

6.2.3. Forme du complexe

Les analyses précises de l'onde R nécessitent un enregistrement clinique de l'activité cardiaque sur 12 dérivations, dont, en particulier, les dérivations thoraciques qui permettent une mesure locale de l'activité électrique cardiaque. Par exemple, l'identification et la localisation d'un infarctus du myocarde ou d'une hypertrophie ventriculaire s'effectuent à partir de l'ensemble de ces 12 dérivations, par comparaison des différents tracés entre eux (et avec des tracés précédents, si possible).

Les algorithmes d'analyse de la forme de l'onde R permettent en général de différencier efficacement les complexes QRS normaux (y compris avec une variante de type «bloc de branche») des extrasystoles ventriculaires (ESV).

6.2.4. Intervalle QT

Le calcul de l'intervalle QT corrigé (QTc) s'avère donc utile pour dresser un diagnostic : proportionnel au QT mesuré divisé par la racine du rythme, le QTc, invariant quel que soit le rythme, doit être compris entre 350 et 430 ms. Il existe des causes extracardiaques au fait que le QTc soit hors de ces limites : il est important de le diagnostiquer, car il existe pour lui un risque de passage en tachycardie ventriculaire.

6.2.5. Forme de l'onde T

Il n'existe pas de domaine de normalité clairement défini concernant la hauteur de l'onde T. Si l'inversion de l'onde T sur l'une des deux premières dérivations peut être considérée comme anormale, et peut être la trace d'une zone d'ischémie dans le myocarde (trace d'un

infarctus ancien) ou d'un début d'ischémie (si accompagnée de douleurs thoraciques, angines de poitrine, ...) (Figure 1.20).



Figure 1.20. Ischémie conséquence d'un petit infarctus.

L'absence de critère objectif sur la normalité ou non de l'amplitude de l'onde T, l'obligation de connaissance de la clinique et d'autres examens, et la nécessaire comparaison avec des ECG plus anciens ne rendent pas possible l'établissement d'un « diagnostic automatique » à partir de l'analyse de l'onde T : dans ce cas, l'apport spécifique d'une telle analyse réside dans la possibilité d'un suivi temporel de paramètres descriptifs de sa forme.

6.2.6. Intervalle ST

En revanche, l'étude de l'intervalle ST se prête mieux à une approche informatique, car des critères de normalité sont clairement définis ; les dernières versions de recherche possèdent des modules permettent une analyse de la position du tracé de cet intervalle par rapport à la ligne de base.

L'intervalle est repéré entre la fin de l'onde S et le début de l'onde T, et, en l'absence de pathologie, doit lui correspondre un segment linéaire d'amplitude nulle (au niveau de la ligne isoélectrique du coeur ou ligne de base); Les observations d'un sus décalage ou d'un sous décalage (Figure 1.21) par rapport à cette ligne sont en général associées à une souffrance cardiaque par hypoxie (début d'ischémie), en particulier lorsque ces décalages sont variables au cours du temps (lors d'un effort ou, au contraire, dans une phase de sommeil par exemple).

Ainsi, la surélévation du segment ST peut s'observer dans des situations diverses, depuis une variante de la normale, jusqu'à un risque vital comme le risque d'un infarctus du myocarde. Comme dans l'analyse de l'onde T.



Figure 1.21. Tracé d'un infarctus passé.

CHAPITRE 2 ACQUISITION ET TRAITEMENT DES SIGNAUX PHYSIOLOGIQUES

1. Circuit biomédical

1.1. Signal électrique

Un signal électrique représente les variations d'une grandeur ou d'un phénomène physique relativement à une variable de référence telle que le temps. Un signal électrique contient de l'information, c'est d'ailleurs sa raison d'être. Cette information est véhiculée par un ou plusieurs des paramètres du signal et dont les plus importants sont : l'amplitude, la fréquence et la phase. La forme du signal va dépendre des variations de ces paramètres qui, eux-mêmes, fluctuent selon des règles bien déterminées ou au contraire de façon aléatoire.

1.2. Tissus biologiques

Les tissus biologiques sont constitués de cellules. Des macromolécules sont distribuées sur toute la surface de la cellule et certaines sont insérées au travers de celle-ci constituant ainsi des canaux d'échanges sélectifs.

La membrane cellulaire se comporte comme un diélectrique de permittivité relative proche de celle des lipides formant une couche isolante séparant deux milieux conducteurs [Rigaux et al, 1996]. Afin de se rendre compte du comportement diélectrique des tissus biologiques, plusieurs modèles ont été proposés et découlent de différentes théories de Wagner [Wagner, 1914], Debye [Debye, 1929], Fricke [Fricke, 1932], Cole [Cole, 1941] et de Maxwell [Maxwell, 1981]. Ces auteurs ont mis en place au cours de la première moitié du 20ème siècle des approches encore utilisées à ce jour.

Ces modèles assimilent les tissus biologiques à une suspension cellulaire dans un milieu dilué qui est fondé sur un circuit électrique composé d'une capacité C_m associée en série avec une résistance R_i traduisant la présence du milieu intracellulaire. Le milieu extracellulaire est modélisé par une résistance R_e .

Un modèle du comportement diélectrique du tissu biologique [Chateaux, 2000] est illustré par la figure 2.1.




Figure 2.1. Modèle du comportement diélectrique du tissu biologique.

1.3. Signal biologique

L'électrophysiologie a pour objet l'étude des phénomènes électriques liés au fonctionnement de divers organes (cœur, muscle, tissu nerveux, considérés dans leur ensemble, ou dans l'un de leurs constituants élémentaires). Ces phénomènes consistent le plus souvent en différences de potentiels électriques $V(t)$ dont l'amplitude et la vitesse de variation diffèrent beaucoup d'un organe à l'autre. L'étude de ces signaux électriques est riche en enseignement sur le fonctionnement, normal ou pathologique, de l'organe qui lui donne naissance.

Ces signaux bioélectriques, pour être étudiés correctement, doivent pouvoir être recueillis, amplifiés (car ils sont le plus souvent d'amplitude faible) et enregistrés ou mémorisés afin d'être traités et analysés.

L'ensemble des étapes qui vont du recueil au traitement, nécessite toute une série d'instrumentations dont l'ensemble constitue ce qu'on appelle une chaîne de mesure.


1.4. Adaptation des divers éléments de la chaîne de mesure

L'expérience et la théorie montrent que pour qu'une source électrique transmette le maximum de puissance, l'impédance de ce circuit doit être égale à l'impédance de la source.

Pour qu'un signal soit transmis correctement il faut que toutes ses fréquences utiles soient transmises de façon à respecter leur spectre d'amplitude relative. Cela n'est pas suffisant, une réserve s'impose, il faut également respecter le spectre de phase.

Au niveau de l'enregistrement, on rencontre des fréquences différentes des divers types des activités physiologiques. Alors nous devons accorder les mesures nécessaires aux caractéristiques du spectre du signal physiologique que nous désirons investiguer. Il est également important de connaître les niveaux de l'activité que nous exposons.

La figure 2.2 illustre les deux caractéristiques : la gamme de fréquences et le niveau d'amplitude d'une variété de spectre physiologiques. Elle montre cinq types de données médicales distinctes.



La figure 2.2. Amplitudes et fréquences de cinq signaux électrophysiologiques.

AAP: potentiel d'action d'axone.
 EMG: électromyographie.
 ECG: électrocardiographie.
 EEG: électroencéphalographie.
 EOG: électro-oculographie.

La figure 2.2 montre que l'amplitude des signaux peut varier, de 10 microvolts à 100 millivolts, avec une gamme de fréquence allant de 0Hz à 10kHz. En Potentiel Evoqué (PE) les signaux recueillis ont une amplitude de quelques microvolts

Nous trouvons aussi, par exemple que l'EEG doit requérir une instrumentation très précise sachant que le potentiel de ce signal peut avoir une valeur plus basse qu'un μV . Pour cette application, le gain, la stabilité et les bruits du système doivent être évalués avec soin. Par contre l'EMG est un signal qui varie entre $40 \mu\text{V}$ et $4000 \mu\text{V}$ (4 mV) de la valeur la plus faible possible à la valeur la plus élevée possible. Pour concevoir un matériel complet il faut prendre soin des composants d'entrées, de la reproduction du parcours dynamique sans introduire des distorsions ou des non linéarités.




Figure 2.3. Exemple d'une chaîne de mesure.

2. Capteurs biomédicaux

2.1. Définition

un capteur est un dispositif qui, soumis à l'action d'un mesurande M non électrique, présente une caractéristique de nature électrique, (charge, tension, courant ou impédance), désigné par S qui est fonction du mesurande [Ichinose et al; 1990].

$$S = f(M)$$

M : grandeur d'entrée ou excitation.

S : grandeur de sortie ou réponse du capteur.



Figure 2.4. Capteur dans une chaîne de mesure.

2.2. Capteurs et signaux électrophysiologiques

Les êtres vivants sont communément le siège de phénomènes électriques intimement liés aux activités vitales, dont ils sont un des aspects les plus révélateurs. Ces phénomènes électrophysiologiques sont mis en évidence à l'aide de capteurs appliqués en surface ou introduit dans la profondeur des tissus [Geddes et al, 1989; Webster, 1997]. Les capteurs, généralement appliqués au corps du patient, doivent obéir aux différentes contraintes suivantes :

- Très haute sensibilité.
- Supportent la stérilisation.
- Possibilité d'usage unique.
- Non invasivité.
- Biocompatibilité.
- Résister aux agressions du corps humain
- Provoquer le minimum de perturbation du signal physiologique mesuré.
- Fiabilité et stabilité de leurs caractéristiques.

2.3. Problématiques des capteurs électrophysiologiques

A tout signal biologique, viennent se greffer des phénomènes accessoires qui peuvent le polluer et qui dans certain cas, le rendent méconnaissable. Ces signaux parasites sont les bruits. Un des potentiels de recueil de l'amplification et de la transmission de l'enregistrement et du traitement d'un signal est de donner au rapport signal/bruit (S/B) la valeur la plus forte possible. Ce bruit a des origines diverses :

- L'agitation thermique des électrodes.
- La présence de champs électromagnétiques due à la proximité d'émetteurs, de transformateurs, de moteurs et de générateurs d'ondes de basse ou de moyenne fréquence sont aussi à l'origine de parasites (radio, TV, radar, téléphone portable, etc.) et peuvent induire des courants dans le patient (Figure 2.5).
- Les signaux biologiques peuvent constituer du bruit les un pour les autres. Ainsi en est-il de l'électromyogramme (EMG) qui est un bruit très gênant pour l'ECG (Figure 2.6).




Figure.2.5. Interférences du champ magnétique à 50Hz venant du secteur.



Figure.2.6. interférences d'origine électromyographique.

Les remèdes sont nombreux et varient selon la cause. Citons par exemple la mise à la terre pour évacuer les parasites du potentiel du secteur, les divers modes de blindage pour constituer des cages de Faraday, utilisation des filtres analogiques et des filtres numériques [Bahoura et al, 1997].

Dans notre cas plusieurs techniques permettent d'améliorer le rapport S/B. Citons notamment:

- Amplification du signal à la source, au niveau de l'électrode, et transmission sur ligne basse impédance (insensibilité aux perturbations extérieures).
- Filtrage du signal transmis (filtre rejeteur 50 Hertz, filtre passe bas, passe haut), sachant que cela entraîne une perte d'information.
- Conversion analogique/numérique du signal à la source, permettant une transmission de type numérique et une immunité au bruit.

Réduction du bruit :

- Utilisation d'amplificateur différentiel de haute qualité.
- Utilisation de blindage efficace (câble haute qualité à blindage multiple).
- Réinjection du bruit en opposition de phase sur le blindage du câble de transmission.

Plusieurs problèmes inhérents à la conception de ces capteurs actifs, peuvent être soulignés :

- Référence : problème pour l'amplification des signaux par rapport à une référence unique.
- Alimentation : pile, batterie incorporée, téléalimentation.
- Stérilisation : étanchéité, résistance à la température.
- Marquage CE : compatibilité électromagnétique.
- Encombrement : intégration des composants, poids, taille.
- Coût : usage unique ou non.

2.4. Choix des électrodes

Les tissus corporels étant très complexes sur le plan de la chimie, mais cependant fortement diélectriques, l'un des gros problèmes rencontré est celui de "la polarisation des électrodes". En fait ce ne sont pas les électrodes qui sont en cause mais bien la nature diélectrique/ionique des tissus. Pour assurer une prise d'information convenable il faut que la résistance de contact entre l'électrode et la peau soit la plus faible possible, ce qui permet alors l'emploi d'électrodes de faible surface et donc une plus grande précision de positionnement. Pour cela on a pris l'habitude d'interposer entre l'électrode métallique et la peau un matériau conducteur à l'état liquide ou, plus récemment et à l'état de gel, à base de chlorure de potassium le plus souvent. Ce matériau est peu agressif. Pour figer le positionnement, les électrodes sont solidaires d'un anneau autocollant et parfois munies d'une languette facilitant la dépose ultérieure de l'électrode.

Les électrodes utilisées en électrophysiologie pour la stimulation et le recueil doivent être impolarisables, c'est à dire telle que la différence de potentiel de contact soit invariable ne dépendant ni du temps, ni de l'intensité du courant. Plus les potentiels à mesurer varient lentement, plus il faut être exigeant sur cette condition d'impolarisabilité.

Les électrodes doivent présenter certaines qualités pour ne pas s'abîmer ou se corroder. Les facteurs les plus déterminants qui permettent d'évaluer la qualité d'une électrode sont : la densité de charge par phase limite, la densité de courant limite et la biocompatibilité.

2.5. Exemple électrode active conçue à partir d'un AOP.

Lorsque des électrodes sèches, avec leur haute impédance inhérente sont utilisées pour mesurer des paramètres électrophysiologiques, les interférences liées au réseau électrique sont généralement incontournables.

Ces perturbations peuvent être efficacement réduites en intégrant un amplificateur à l'électrode sèche.

Cela peut être réalisé comme le montre la figure 2.7 en incorporant, dans un petit boîtier, un amplificateur de gain unité jouant un rôle d'adaptateur d'impédance (impédance d'entrée coté électrode très élevée : plusieurs $M\Omega$, et impédance de sortie très faible : quelques dizaines d'ohms).

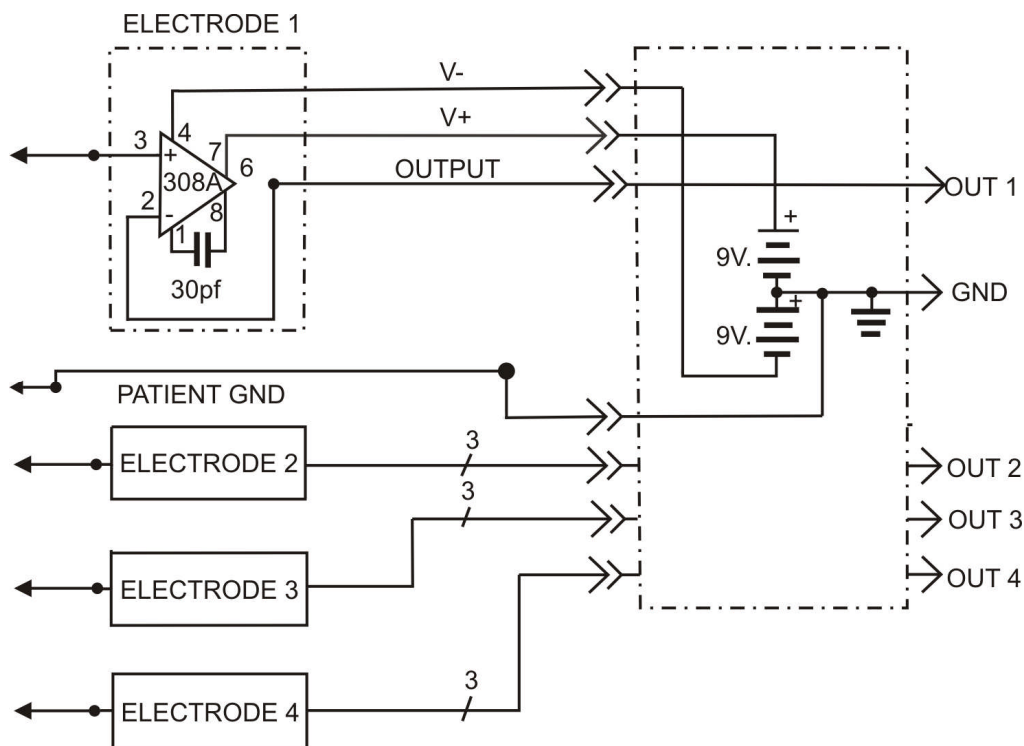


Figure 2.7.: Electrode active conçue à partir d'un AOP.

2.6. Exemple de capteur numérique utilisé.

Ce capteur numérique se compose du capteur proprement dit et de sa tête électronique. Ces capteurs possèdent les mêmes dimensions que les capteurs conventionnels, et peuvent être installés grâce aux mêmes dispositifs de fixation.

La tête électronique contient les circuits qui assurent la transformation numérique du signal, et la gestion des communications avec le réseau Orbite.

Les progrès de la miniaturisation en microélectronique permettent d'envisager la conception de capteurs associant un micro système qui effectue les tâches de conditionnement, échantillonnage, calcul et communication du signal, aboutissant à un ensemble de volume très réduit et très fiable. Cette association est appelée capteur intelligent (Figure 2.8 : exemple de schéma de principe).

Cette tendance actuelle au tout numérique, apporte des avancées très importantes par rapport aux technologies existantes.

Dans le domaine médical des problèmes spécifiques sont à résoudre, notamment la référence dans la mesure en monopolaire des signaux électrophysiologiques, l'étanchéité et la résistance à la température pour la stérilisation et le coût en cas d'usage unique. Le poids la taille et l'encombrement (forte intégration des composants) sont aussi des contraintes à considérer.




Figure 2.8. Schéma de principe du capteur intelligent (capteur numérique).

3. Amplification et filtrage

Il est évidemment essentiel que le signal $V(t)$, que l'on obtient à la sortie de la chaîne de mesure, soit l'image aussi parfaite que possible du signal bioélectrique original $v(t)$, ce qui veut dire que l'on doit se rapprocher autant que possible de l'équation idéale :

$$V(t) = G * v(t)$$

Où G est une constante (indépendante du temps, de l'amplitude et de la vitesse de variation). Une chaîne de mesure possède une chaîne d'amplification qui est formée en général de plusieurs amplificateurs disposés en série, qu'on appelle parfois, étage d'amplification.

Les différences de potentiels captées par des électrodes distantes de 3 à 5 cm se situent entre 10 et 200 μV . Les amplificateurs utilisés doivent donc avoir un gain élevé. Ils sont constitués par un préamplificateur dont le bruit de fond est inférieur à 5 μV et un post-amplificateur à liaison continue. Des commandes manuelles permettent de modifier le gain d'amplification entre 10 et 300 $\mu\text{V}/\text{cm}$ [Bahoura et al, 1997].

3.1. Traitement du signal

Les techniques d'investigation autour des bio-impédances sont nées avec le 20^{ème} siècle, elles présentent de nombreux avantages. La disponibilité des outils informatiques et mathématiques permettent d'assurer la promotion de ces techniques [Herman et al, 1957], [Schwan et al, 1957], [Schwan, 1992] et [Herman et al, 1992].

On peut citer les techniques de moyennage qui permettent d'extraire le signal d'un bruit de fond.

Des filtres peuvent être employés pour atténuer soit les fréquences rapides supérieures à 100, 50, 30 et même 15 Hertz, soit les fréquences lentes (inférieures à 0.3, 0.5 et même 2 Hertz par le choix des constantes de temps respectivement 0.1, 0.3 et 0.7 secondes). Ces atténuations sont en effet parfois nécessaires pour éliminer les composantes rapides ou lentes des

différences de potentiel, qui peuvent s'avérer être d'origine extra cérébrale, ou pour mettre en valeur une bande passante spécifique.

Les méthodes numériques de filtrage sont indispensables dans ce cas et devront être choisies avec soin. Elles reposent toutes sur le principe, sur un échantillon de courte durée, d'analyse spectrale obtenue par le biais d'une conversion temps fréquence suivie d'une élimination des indésirables et d'une restauration ultérieure du signal analogique débarrassé du bruit. Toutes les procédures employées dérivent de la même constatation due à Fourier [Jalal, 1995].

4. Conversion en signal numérique

4.1. Principes de la numérisation

Le signal électrique issu du capteur fait l'objet d'un traitement analogique (amplification, filtrage...) puis subit une conversion analogique numérique qui consiste à échantillonner à fréquence fixe le signal pour en donner une valeur comprise entre un minimum et un maximum avec un nombre de valeurs possibles fini (256 si on utilise une conversion analogique/numérique sur 8 bits)

La transformation analogique numérique est imparfaite. La perte d'information due la transformation peut être contrôlée par le choix de la fréquence d'échantillonnage et par le nombre de bits affecté à chaque mesure. Pour N bits affectés à la mesure, on peut distinguer 2^N valeurs.

La fréquence d'échantillonnage doit être au moins le double de la fréquence du signal échantillonné. Par exemple pour le traitement de l'électrocardiogramme, on échantillonne à une fréquence de 500 HZ.

4.2. Techniques de base

- Amélioration du signal recherché.
- Augmentation du rapport signal/bruit par des techniques de moyennage de signal et d'autocorrélation ou par des techniques de filtrage numérique.
- Extraction de traits pertinents.
- Analyse du signal.
- Reconnaissances de formes.

4.3. Applications médicales

Aux USA plus que 50% des tracés ECG sont analysés de manière automatique par l'ordinateur. Les enregistrements peuvent être stockés sous forme numérique. A partir des séquences ECG, les programmes permettent la mesure des différents paramètres (P-R, Q-T, R-R...) mais également l'interprétation des tracés pathologiques (extrasystole, trouble de la repolarisation).

5. Electrocardiographe numérique

Un électrocardiographe numérique se présente sous la forme d'un appareil compact intégrant de nombreuses fonctions. En effet, celui-ci comporte un écran à cristaux liquides, une dizaine de dérivations, une imprimante, un logiciel d'exploitation des résultats, et une possibilité de

stocker les enregistrements sur disque dur, ou de les transmettre sur une ligne téléphonique. L'appareil pouvait aussi contrôler une épreuve d'effort.

5.1. Système d'acquisition de données

Les systèmes d'acquisition de données consistent le plus fréquemment en des interfaces avec les ordinateurs et les dispositifs d'enregistrement. Le choix des techniques d'acquisition dépend de l'environnement dans lequel le système sera utilisé [Lepoutre et al, 2001; Asch et al, 1999]

Les principales caractéristiques d'un système d'acquisition de données sont :

- La vitesse d'acquisition de données.
- La précision des mesures.

Exemple d'une chaîne de mesure numérique:

Cette dernière est munie d'une logique de commande à base de microprocesseur (Figure 2.10).

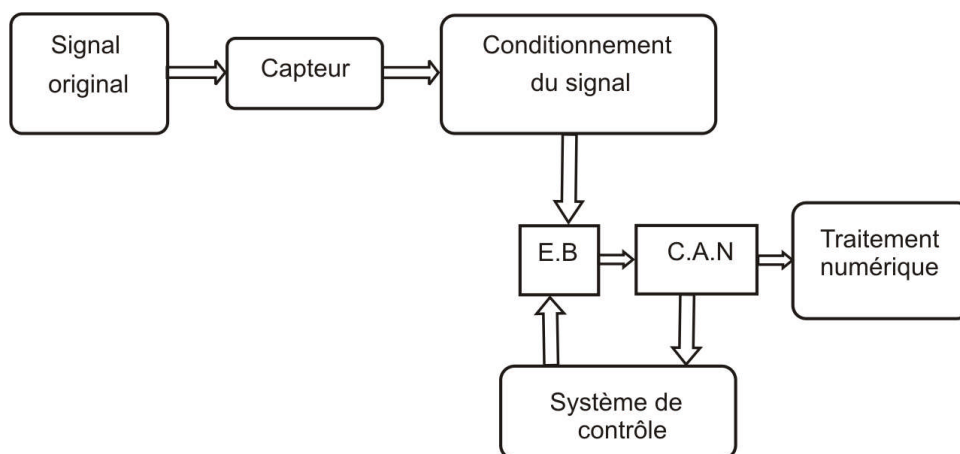


Figure 2.10. Système d'acquisition de données

5.2. Échantillonnage

5.2.1. Échantillonneur-Bloqueur

On a coutume de modéliser l'échantillonnage par le produit du signal $S(t)$ par la fonction peigne $Pte(t)$ représentée par une suite d'impulsions de Dirac $d(t)$.

$$Pte(t) = \sum d(t - kte)$$

Le signal échantillonné S^* est alors définie par :

$$S^*(t) = S(t)Pte(t)$$

L'échantillonnage-blocage se fait comme si le signal $S^*(t)$ traverse un système tel la réponse à une impulsion $d(t)$ soit un signal rectangulaire de largeur T_e . En effet, le signal $S(t)$ est prélevé et figé pendant un intervalle de temps. Les impulsions de Dirac sont assimilées en fait à des signaux rectangulaires de largeur T_e (Figure 2.11). L'échantillonneur-Bloqueur est constitué d'un commutateur associé à un condensateur. Lorsque le commutateur est fermé, la tension aux bornes du condensateur évolue avec la tension d'entrée.

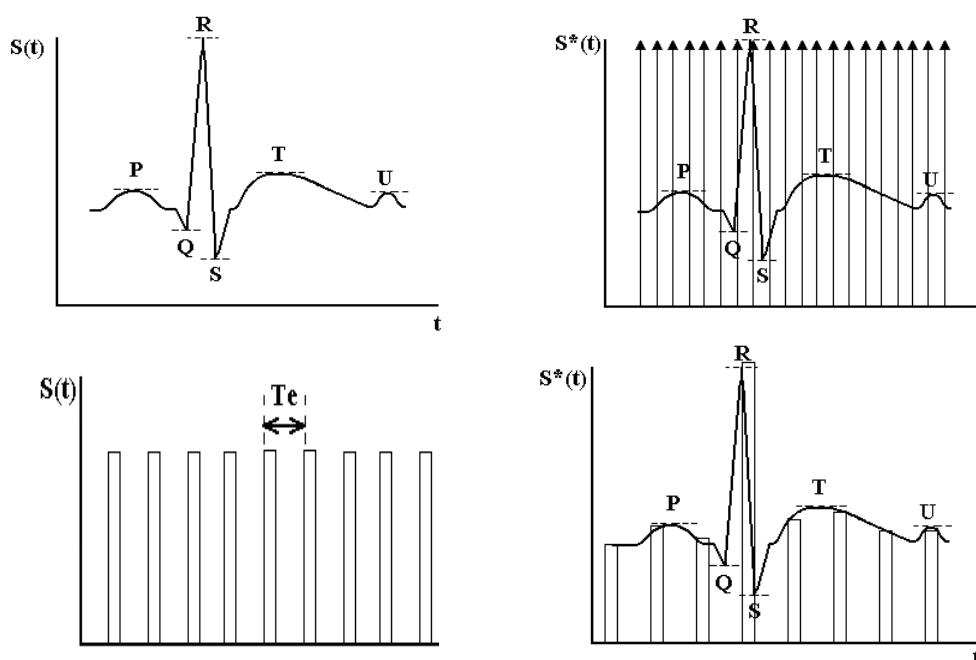


Figure 2.11. Principe d'Echantillonnage-Blocage Appliqué à un Signal.

Lorsque le commutateur est ouvert, la capacité conserve cette tension jusqu'à ce qu'elle soit utilisée par le convertisseur Analogique/Numérique placé en aval. Les caractéristiques principales d'un échantillonneur-bloqueur sont :

- **Temps de charge :**

La précision de la mesure dépend en grande partie du temps de charge de la capacité. Généralement, on veille à ce que ce temps soit le plus court possible.

- **Maintien de la tension de charge:**

Durant le temps de conversion, il convient de maintenir la tension de charge aux bornes de la capacité à son niveau initial. Pour ce faire il faut, d'une part, choisir une capacité de faible coefficient de fuite et, d'autre part, faire en sorte que les circuits en amont et en aval de la capacité soient de très haute impédance.

5.2.2. Convertissage analogique numérique:

On désigne sous le nom de conversion analogique numérique (CAN), toute opération analogique continue dans le temps, en un nombre significatif dans un système de numérisation (décimal, binaire...).

5.3. *Convertisseur Analogique/Numérique*

Le convertisseur analogique/numérique [Rutkowski, 1977] effectue une conversion de la tension analogique en un signal numérique. Le signal analogique est échantillonné, quantifié puis codé en binaire. Ces trois fonctions sont assurées par le convertisseur lui-même associé à un échantillonneur bloqueur.

Le CAN est caractérisé essentiellement par sa résolution, sa précision et sa vitesse de conversion. La vitesse de conversion dépend du nombre de bits, de la technologie des éléments intégrés, de la technique de conversion ainsi que de la fréquence de l'horloge.

Parmi les très nombreuses techniques de conversion possible, nous retenons les convertisseurs parallèles, les convertisseurs à approximations successives et les convertisseurs à comptage d'impulsions.

Le principe du CAN parallèle consiste à comparer simultanément, la tension d'entrée à n niveaux de tension de référence. Ce type de convertisseur est très rapide. La fréquence de l'horloge de commande peut atteindre 100 MHz et le temps de conversion est de 500 ns pour une résolution de 12 bits.

6. *La non linéarité des signaux cardiaques*

La plupart des connaissances actuelles concernant les systèmes physiologiques ont été apprises en utilisant des modèles linéaires. Cependant, plusieurs signaux biologiques sont apparemment aléatoires ou apériodiques dans le temps. Traditionnellement, l'aspect aléatoire des signaux biologiques est attribué aux bruits ou aux interactions entre des nombreux composants. Les nouvelles techniques non linéaires, comme les réseaux de neurones artificiels, les ondelettes et l'analyse du chaos, permettent une investigation des systèmes non linéaires que les méthodes linéaires traditionnelles ne permettent pas.

La complexité du système cardiovasculaire est dû à un comportement chaotique non linéaire [Guzzetti, 1996]. Quelques études actuelles s'intéressent à l'utilisation des techniques non linéaires pour l'approche des fonctions cardiovasculaires, nous citerons à titre d'exemples quelques travaux, utilisant les réseaux de neurones, dans le chapitre 4.

CHAPITRE 3 QUELQUES MODELES DE RESEAUX DE NEURONES

1. Introduction

Contrôler un système complexe, modéliser un processus, détecter un objet mobile, reconnaître une forme ou une voix au milieu d'un bruit ambiant..., sont autant de domaines de recherche pour l'ingénieur.

Malgré la puissance grandissante des calculateurs et la mise en œuvre d'approches théoriques de plus en plus sophistiquées plusieurs des problèmes posés dans le cadre de ces recherches résistent encore aux algorithmes et aux méthodes classiques. Les problèmes sont souvent dépendants de l'environnement et ne répondent pas à des modèles physiques connus.

Chez les êtres vivants, la reconnaissance rapide d'un visage, le contrôle d'une centaine de muscles du corps et la génération de trajectoire suivant la survenue d'obstacles, par exemple, sont autant de tâches remplies quotidiennement de manière naturelle. Faire réaliser ces opérations par une machine « c'est le défi ». Il est donc aisé de comprendre l'intérêt marqué par l'ingénieur au neurone biologique. Sans prétendre copier le cerveau, il entend s'inspirer des architectures et des fonctions du système nerveux.

Le développement continu des connaissances en biologie, l'apparition de nouvelles méthodes théoriques et l'incessante montée en puissance des outils de simulation autorisent les meilleurs espoirs.

2. Historique

Des modèles de réseaux de neurones [Dreyfus et al, 2004] existent depuis longtemps. Ainsi le physiologiste viennois Sigmund Exner proposait en 1894 un modèle neuronal de la détection du mouvement par l'œil de la mouche. Cependant en 1943 W.S. McCulloch et Pitts [McCulloch et al, 1943] constituent certainement un des premiers jalons dans l'étude mathématique des réseaux de neurones formels. Dans le modèle de McCulloch et Pitts, chaque unité de traitement (ou neurone formel) calcule une somme pondérée des signaux formés par les autres unités auxquelles elle est connectée et ce résultat est comparé à une valeur de seuil. Si le seuil est franchi, le neurone est activé et cet état d'activation est propagé à travers le réseau pour les étapes de calcul ultérieures. Sous cette forme très simplifiée, les réseaux de neurones formels fonctionnent comme des systèmes itératifs discrets. A l'époque, cette idée a très vite fleuri et suscitent beaucoup d'intérêt parce qu'elle montrait que toute fonction logique pouvait être réalisée par un tel réseau de neurones formels. En 1949 le psychanalyste Donald Hebb proposait deux idées fondamentales [Hebb, 1949] :

- i) tout percept ou concept est physiquement représenté dans le cerveau par l'entrée en activité d'un ensemble de neurones (on parle de l'assemblée de Hebb) ;
- ii) deux neurones, ou deux ensembles de neurones, qui sont activés en même temps, vont finir par être «associés», de sorte que l'entrée en activité de l'un facilitera celle de l'autre. Ainsi la

mise en mémoire s'effectue aux lieux d'interaction entre neurones, c'est-à-dire à la synapse (on parle de la synapse de Hebb).

Au début des années soixante, Rosenblatt [Rosenblatt, 1961], présenta le « Perceptron » qui ne différait par rapport au modèle de Mc. Culloch et Pitts, que par sa faculté d'apprentissage basé sur la règle de Hebb, ce qui constitua une nouveauté à l'époque. Ce réseau qui était capable de prendre de bonnes décisions en classification a vite montré son inaptitude devant les problèmes non linéaires. En 1969 Papert et Minsky [Minsky et al, 1969] ont démontré clairement les limites du perceptron, et la nécessité de plusieurs couches identiques à celle du perceptron pour résoudre ces problèmes. N'ayant aucun moyen pour faire l'apprentissage de ces couches de neurones nécessaires, cette étude plongea l'idée de réseaux de neurones dans l'ombre [Simpson, 1990].

Durant les années 70, les travaux se sont orientés vers les mémoires associatives, qui sont des réseaux à apprentissage non supervisé à architecture généralement interconnectée. Anderson et Kohonen [Anderson, 1977; Kohonen, 1977] ont apporté des modèles très intéressants. Cependant, se sont heurtés aux problèmes d'instabilité et de concepts liés aux systèmes dynamiques, que ni la théorie mathématique ni les moyens de calcul disponibles à l'époque, n'ont pu prendre en charge.

Il a fallu attendre 1982 où Hopfield [Hopfield, 1982] montra que, dans certaines conditions, le comportement dynamique des réseaux récurrents est gouverné par une fonction d'énergie décroissante le long d'une trajectoire. Ce qui implique que le réseau converge vers un minimum local de cette fonction d'énergie. Il en résulte que les réseaux récurrents peuvent être utilisés, non seulement comme mémoire associative, mais aussi pour résoudre certains problèmes d'optimisation. Le problème de stabilité des réseaux dynamiques est définitivement réglé par Cohen et Grossberg [Cohen et al, 1983] Ce premier obstacle franchi, plusieurs travaux ont pu voir le jour.

Le plus grand événement qui est venu propulser les réseaux de neurones par la suite, est sans doute le résultat du travail d'un groupe de chercheurs [Rumelhart et al, 1986]). Ce travail a permis la résolution du vieux problème posé par Minsky et Papert, en mettant en œuvre l'algorithme d'apprentissage de « Back propagation ».

Désormais, il est possible d'effectuer l'apprentissage des réseaux de neurones statiques à plusieurs couches et de ce fait de s'attaquer aux problèmes non linéaires. A partir de là, les réseaux de neurones ont connu un essor continu. Ainsi à cet algorithme d'apprentissage, sont venus s'ajouter d'autres, qui lui ont apporté des améliorations [Trentelman et al, 1993]. Les architectures de ces réseaux ont eux aussi connu une très grande évolution donnant naissance à de nouveaux types de réseaux, parfois plus complexes, mais souvent plus adaptés à certains problèmes tels réseaux Gaussiens GPN (Gaussien Potential Network), les DBNN (Data Based Neural Network), les RBN (Radial Based Networks) [Renders, 1995], et les réseaux dynamiques.

Depuis une vingtaine d'années, les intérêts pour les RNA ont considérablement augmentés de sorte sont passé aujourd'hui du domaine de la recherche à des domaines applicatifs [Neuro Dimension, 2001].

3. Neurone formel de McCulloch et Pitts

Les premières modélisations du neurone biologique ont été menées par McCulloch et Pitts. Leur observation du fonctionnement de la cellule nerveuse les a conduit à un modèle simple de neurone artificiel [Alliot et al, 1992; 1997; 2002]

3.1. Le neurone formel

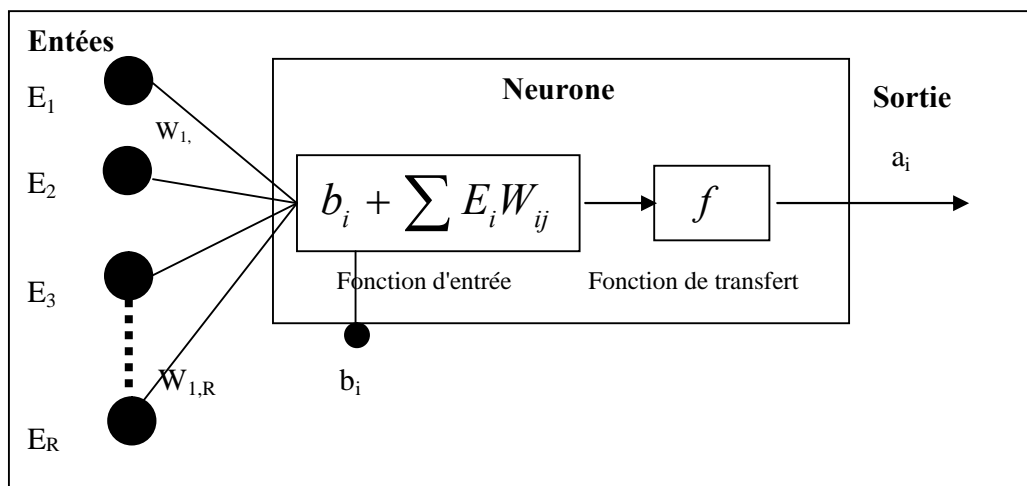


Figure 3.1. Neurone Formel effectuant l'opération suivante.

$$a_i = f\left(b_i + \sum_{j=1}^R E_j W_{ij}\right)$$

Le neurone artificiel est nommé «unité de calcul» ou «de traitement». Les données, venant d'autres éléments processeur, sont accumulées. La sommation d'entrées est nommée activation interne. Elle est alors transformée par une fonction d'activation. La connexion des poids simule le synapse biologique. Dans les réseaux de neurones artificiels, les poids sont modifiés itérativement ou ajustés, pour atteindre la sortie désirée, ou cible. (Figure 3.1).

Chaque neurone possède plusieurs entrées E_j , à chacune d'entre elles on affecte un poids W_{ij} , un biais b_i , et une sortie a_i qui peut être une valeur réelle ou booléenne. A chaque entrée peuvent être connectées plusieurs sorties d'autres neurones. La sortie est calculée à partir des entrées et des poids synaptiques. Une fonction d'entrée calcule le potentiel du neurone, celle-ci est très souvent la somme pondérée (par son coefficient) des entrées augmentée d'un seuil. Une fonction de transfert f génère alors la sortie grâce à ce potentiel. Cette fonction de transfert est très importante, et détermine le fonctionnement du neurone et du réseau. Elle peut prendre de nombreuses formes, peut être linéaires, binaires, saturées ou sigmoïdales.

4. Réseaux de neurones artificiels

4.1. Définition

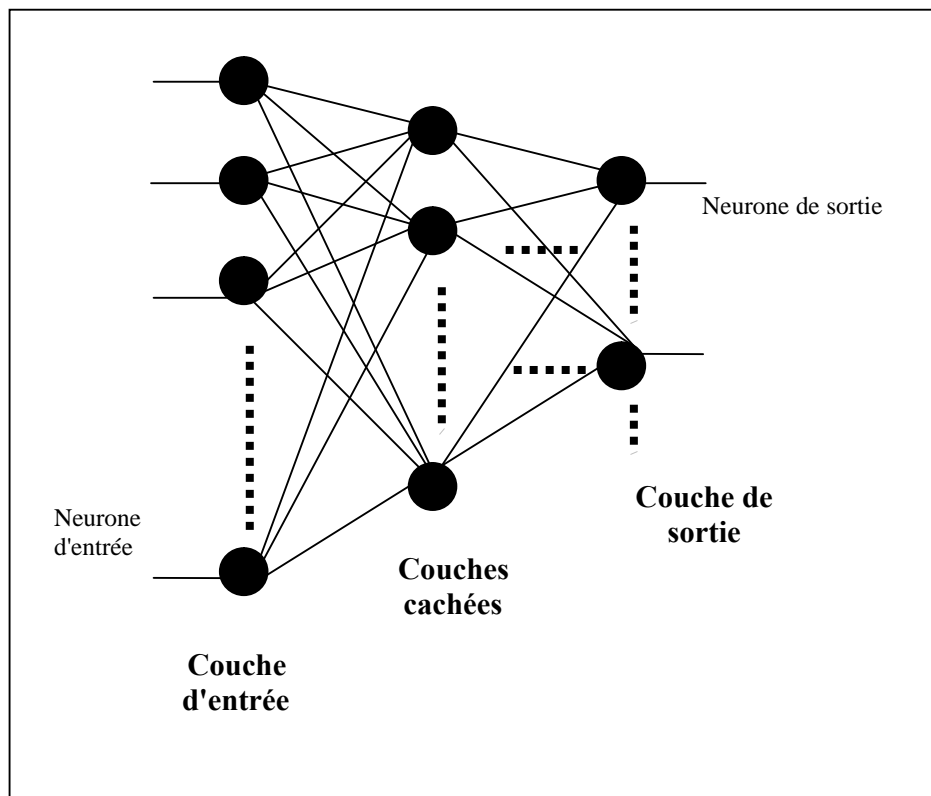


Figure 3.2. Réseau de neurone artificiel.

Il n'y a pas de définition universelle des Réseaux de Neurones Artificiels (RNA). Voilà quelques propositions de définition de réseaux de neurones artificiels issues de la littérature :

Selon Haykin [Haykin, 1994]:

Les réseaux de neurones sont un processus distribué parallèle qui a la propriété de stocker de la connaissance et la rendre disponible à l'utilisation. Les RNA ressemblent au cerveau humain dans deux aspects:

1. *La connaissance est acquise grâce à un processus d'apprentissage.*
2. *Les poids des connexions inter-neuronales, ou poids synoptiques sont utilisés pour stocker la connaissance.*

Selon Zurada [Zurada, 1992] :

Les réseaux de neurones artificiels sont des cellules physiques capables d'acquérir, de mémoriser et d'utiliser une connaissance expérimentale.

Donc on peut dire qu'un réseau de neurones est une structure de traitement parallèle et de distribution d'information comportant plusieurs éléments de traitement (neurone), qui peuvent posséder des mémoires locales et exécuter des opérations de traitement d'information locales, interconnectés les uns aux autres avec des canaux de signaux unidirectionnels (Figure 3.2).

Chaque élément de traitement a une sortie unique branchée à plusieurs connexions collatérales, qui transmettent le même signal, le signal de sortie du neurone. Tout le traitement effectué dans un élément de traitement doit être complètement local, c'est-à-dire, il ne dépend que des valeurs courantes des signaux d'entrée et des données stockées dans ce même local.

On peut définir donc un réseau de neurones comme un ensemble de neurones associés en couches et fonctionnant en parallèle. L'information donnée au réseau (binaire ou réel) va se propager couche par couche, de la couche d'entrée à la couche de sortie, en passant soit; par : aucune, une ou plusieurs couches intermédiaires (dites couches cachées).

4.2. Architectures neuronales

Il est difficile de décrire exactement la totalité des réseaux de neurones artificiels. Actuellement, de nouveaux RNA sont sans cesse inventés et des variantes d'anciens modèles sont proposées dans la littérature scientifique. Il est fréquent de différencier les réseaux suivant la présence ou non de cycles dans le graphe orienté des connexions entre les neurones [Orsier, 1995]. Dans le premier cas on parle de réseaux récurrents ou bouclés, et dans le deuxième cas on parle de réseaux en couches.

4.2.1. Réseaux de neurones bouclés ou récurrents

Dans les RNA bouclés (Figure 3.3), les connexions entre les neurones forment des boucles. A chaque fois qu'une entrée est présentée, le réseau doit itérer pendant une longue période avant de produire une réponse. En général, les réseaux bouclés sont plus difficiles à entraîner que les réseaux non bouclés. Il est à noter que ces connexions circulaires, dont les valeurs dépendent des activations antérieures des unités du réseau, permettent de mieux traiter des problèmes comportant un aspect temporel. L'apprentissage est cependant généralement assez complexe dans ces réseaux, et leurs propriétés sont souvent moins bien connues que celles des réseaux non récurrents ou non bouclés.

Pendant les dernières années, depuis le premier réseau récurrent de Hopfield, beaucoup d'intérêt a été accordé aux réseaux récurrents, en raison de leur aptitude à gérer des tâches complexes et de la richesse de leur comportement dynamique. Leur capacité de mémoriser le passé des entrées grâce aux boucles neuronales fait d'eux des candidats de choix pour la prédiction des séries temporelles. Nous trouvons leurs applications dans la plupart des problèmes de prévision où un aspect temporel subsiste comme la prévision des taches solaires avec une pseudo période de 10-11 ans ou la prédiction des débits des rivières qui est fortement corrélée aux saisons [Rfai, 2001].




Figure 3.3. Réseau de neurones bouclé.

4.2.2. Réseaux de neurones en couches (Perceptrons Multi-Couches)

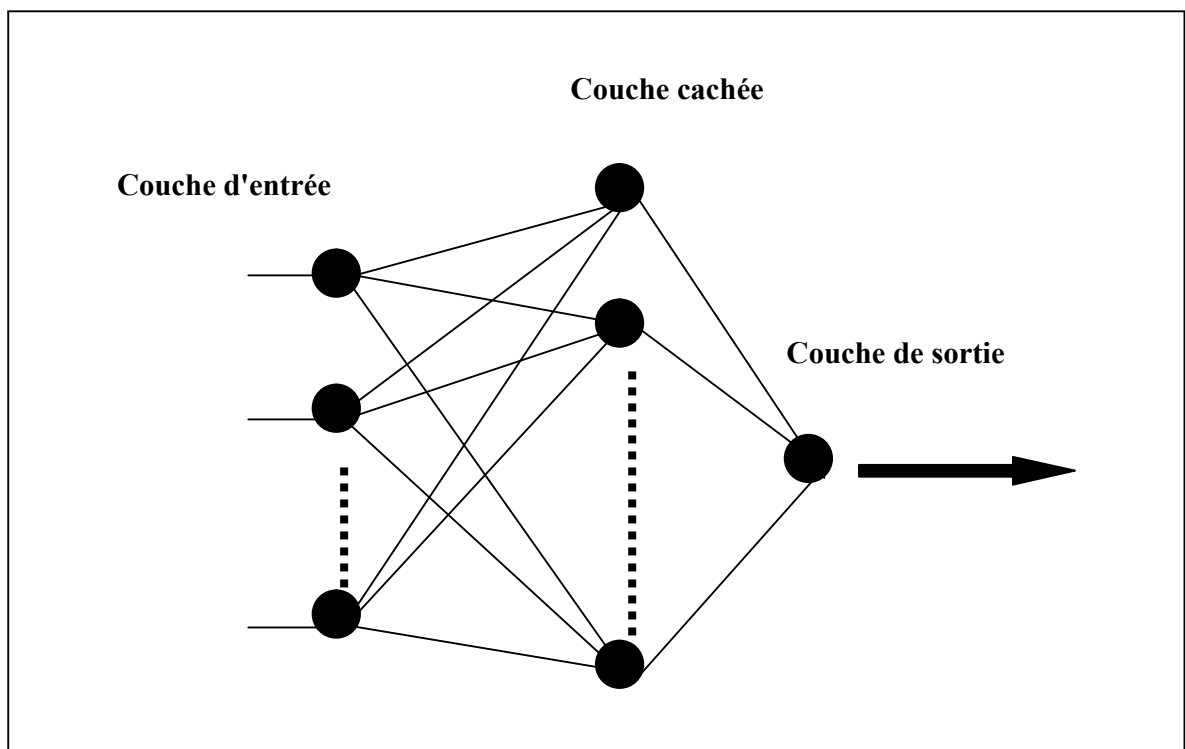


Figure 3.4. Réseau de neurones non bouclés : Perceptron Multi-Couches (PMC).

Dans les réseaux de neurones dits en couches (Figure 3.4), on distingue deux types de neurones particuliers : les neurones d'entrée recevant les données du monde extérieur, et les neurones de sortie fournissant le résultat du traitement effectué. Les autres unités sont généralement qualifiées de cachées. Les réseaux non bouclés produisent une réponse rapide aux entrées

présentées. La plupart de ces réseaux utilisent des algorithmes d'apprentissage issus des méthodes numériques classiques (Levenberg-Marquardt, gradient conjugué) ou par des algorithmes issus directement des recherches sur les réseaux de neurones artificiels.

Nous étions plus particulièrement intéressés à évaluer les capacités du Perceptron Multi-Couches [Meghriche et al, 2008]. Nous allons revenir plus en détail sur ce type de réseaux.

4.3. Perceptron Multi-Couches (PMC) et approximation de fonctions

Les réseaux de neurones artificiels sont un outil extrêmement précieux pour les problèmes de classification et d'approximation de fonctions, surtout si on dispose d'un grand ensemble d'apprentissage.

Selon Cybenko [Cybenko, 1989] : *"Toute fonction bornée non linéaire suffisamment régulière peut être approchée uniformément, avec une précision arbitraire, dans un domaine fini de l'espace de ses variables, par un réseau de neurones comportant une couche de neurones cachés en nombre fini, possédant tous la même fonction d'activation, et un neurone de sortie linéaire."*

Selon cette définition, les seuls paramètres ajustables sont le nombre de neurones cachés ainsi que leur fonction d'activation.

Lorsqu'on veut modéliser un processus à partir des données, on cherche toujours à obtenir les résultats les plus satisfaisants possibles avec un nombre minimum de paramètres ajustables. Dans cette optique, Hornik [Hornik, 1994] a montré que : *"Si le résultat de l'approximation (i.e. la sortie du réseau de neurones) est une fonction non linéaire des paramètres ajustables, elle est plus parcimonieuse que si elle était une fonction linéaire de ces paramètres. De plus, pour des réseaux de neurones à fonction d'activation sigmoïdale, l'erreur commise dans l'approximation varie comme l'inverse du nombre de neurones cachés, et elle est indépendante du nombre de variables de la fonction à approcher. Par conséquent, pour une précision donnée, le nombre de paramètres du réseau est proportionnel au nombre de variables de la fonction à approcher."*

Ces résultats s'appliquent aux Perceptrons MultiCouches (PMC) à fonction d'activation sigmoïdale, puisque la sortie de ces neurones n'est pas linéaire par rapport à leurs coefficients. Ainsi, l'avantage des PMC par rapport aux approximateurs usuels (tels que les polynômes) est d'autant plus sensible que le nombre de variables de la fonction à approcher est grand. Pour des problèmes faisant intervenir une ou deux variables, on pourra utiliser indifféremment des réseaux de neurones, des polynômes, des réseaux d'ondelettes, etc. En revanche, pour des problèmes présentant trois variables ou plus, il est généralement avantageux d'utiliser des réseaux de neurones.

Bien entendu, cette propriété est démontrée de manière générale à condition d'avoir une architecture adéquate. Dans le cas où l'architecture ne serait pas adaptée, cette propriété peut ne pas s'appliquer. Elle constitue néanmoins une justification fondamentale de l'utilisation des Perceptrons Multicouches.

4.4. Apprentissage

L'apprentissage est un processus calculatoire qui a pour but de découvrir les règles qui gouvernent et régissent un système. L'apprentissage s'effectue grâce à des algorithmes itératifs,

appelé algorithme d'apprentissage, qui modifient les poids des connexions pour les adapter aux données présentées au réseau et sont caractéristiques du système à modéliser. Les données utilisées en apprentissage sont appelées ensemble d'apprentissage ou base d'exemples.

Les deux principales méthodes d'apprentissage sont l'apprentissage non supervisé et supervisé [Milgram, 1993].

4.4.1. Apprentissage non supervisé

Par nature, cet apprentissage est destiné à l'élaboration d'une représentation interne de la connaissance de l'environnement, identifiant la structure statistique sous-jacente des stimuli sous une forme plus simple ou plus explicite. L'algorithme d'apprentissage exploite pour ce faire une mesure prédéterminée de la qualité de représentation de la connaissance afin d'ajuster les paramètres du réseau.

On l'appelle aussi, suivant l'approche utilisée, classification automatique, ou apprentissage sans professeur ou encore apprentissage par corrélation [Leschi, 1991]. Ce type d'apprentissage est utilisé dans le cas où on disposerait d'une base d'apprentissage dont les classes ne sont pas définies à l'avance. Il s'agit alors de regrouper les différentes formes en classes en fonction d'un critère de similarité choisi a priori. Ce type d'apprentissage permet la construction automatique des classes sans intervention d'un opérateur [Nadal, 1993]. On distingue essentiellement deux types de méthodes : les processus de coalescence et la classification hiérarchique [Belaid et al, 1992].

Plus particulièrement, concernant les réseaux de neurones artificiels, la règle d'apprentissage n'est pas fonction du comportement de sortie du réseau, mais plutôt du comportement local des neurones. L'ensemble des exemples d'apprentissage ne comprend que des entrées, aucune réponse désirée n'est associée. Dans ce cas, la motivation est de trouver des classements ou des organisations au sein de l'ensemble d'apprentissage.

4.4.2. Apprentissage supervisé

L'apprentissage est dit supervisé si les différentes familles de formes, ou classes, sont connues a priori ainsi que l'affectation de chaque forme à telle ou telle famille. Le processus d'apprentissage en mode supervisé peut se résumer comme suit : on dispose d'un ensemble de formes ou d'individus, qui est un ensemble d'apprentissage d'individus parfaitement classés, ensemble que l'on se propose de reconnaître. On construit dans un premier temps une "machine" sachant classer correctement les individus de l'ensemble d'apprentissage. La description de chaque forme est prise en compte par la tâche d'apprentissage. Le travail d'apprentissage consiste à analyser les ressemblances entre les formes d'une même classe et les dissemblances entre les formes de classes différentes pour en déduire les meilleures séparations possibles entre classes. Ensuite, on fait en sorte que cette "machine" ait une bonne capacité à prédire la classe d'une forme qui n'est pas dans l'ensemble d'apprentissage. D'où l'exigence de tester cette "machine" sur un ensemble de validation composé d'individus parfaitement classés. Cette phase de test est nécessaire car elle permet aussi de savoir si la machine élaborée n'a pas été entraînée à apprendre "par cœur" sans possibilité de généralisation (sur-apprentissage ou over-design) [Belaid et al, 1992; Leschi, 1991].

Plus particulièrement, concernant les Perceptrons Multicouches, les entrées ainsi que les sorties désirées sont soumises conjointement au réseau. La sortie produite par le réseau, en réponse à une entrée donnée, est comparée à la réponse désirée fournie par l'expert. La différence entre la réponse désirée et la réponse du réseau est alors utilisée pour adapter les paramètres du réseau de façon à corriger son comportement. Ce processus est ainsi répété jusqu'à émulation de l'expert par le réseau de neurones artificiels. Les connaissances de l'expert sont représentées par une base d'apprentissage (base d'exemples).

En général, les règles d'apprentissage supervisé utilisent l'algorithme de descente du gradient [Chauvin et al, 1995; Nadal, 1993].

4.4.3. Algorithme d'apprentissage supervisé pour les RNA : la rétropropagation

Quel que soit le cas de l'utilisation du réseau (approximateur de fonction ou classifieur), le processus d'apprentissage supervisé nécessite une base d'exemples composée des entrées du réseau associées aux sorties désirées. Pendant la phase d'apprentissage, les poids et biais du réseau sont ajustés pour minimiser la fonction de performance ou fonction de coût. La fonction de coût doit permettre de mesurer l'écart entre le modèle et les observations. Nous présentons ci-après la fonction d'erreur quadratique moyenne MSE qui est la plus utilisée pour l'apprentissage des RNA, mais d'autres fonctions de coût peuvent aussi être utilisées [Chauvin et al, 1995; Hagan et al, 1996]:

$$MSE = \frac{1}{N} \sum_i^N e_i^2 = \frac{1}{N} \sum_i^N (t_i - a_i)^2 \quad (3.1)$$

où i parcourt les indices des neurones de sortie,

a_i et t_i représentent respectivement l'activation mesurée et l'activation désirée pour ces neurones.

Les poids et biais du réseau sont initialisés, puis le processus itératif de l'apprentissage peut commencer à chaque itération :

- Les sorties du RNA sont calculées;
- la fonction de coût est mesurée;
- les poids et biais sont modifiés en utilisant l'algorithme de la rétropropagation;
- le critère d'arrêt est évalué.

L'arrêt de l'apprentissage est décidé lorsqu'un critère d'arrêt est atteint.

Nous présentons ici l'algorithme de rétropropagation du gradient [Chauvin et al, 1995] qui est le plus connu pour réaliser l'adaptation des réseaux multicouches. C'est à sa découverte que l'on doit le renouveau d'intérêt pour les RNA apparus au début des années 80. Il s'agit d'une méthode d'apprentissage supervisé, fondée sur la modification des poids du réseau dans le sens contraire à celui du gradient de l'erreur (Figure 3.5). La qualité d'apprentissage du réseau est évaluée par la fonction de performance décrite plus haut. A chaque itération la valeur de l'erreur quadratique MSE (équation 31) est renvoyée de la couche de sortie vers les couches cachées pour la mise à jour des poids et biais du réseau. L'algorithme de rétropropagation

modifie les poids et les biais dans la direction de diminution de la fonction de performance (la valeur négative du gradient).

$$W_{k+1} = W_k - \eta_k G_k \quad (3.2)$$

W_k est le vecteur de poids et biais du neurone k .

η est le facteur d'apprentissage.

G est le gradient de l'erreur.

Cet algorithme, présenté ici dans sa version la plus simple, possède de nombreuses variantes. Elles correspondent généralement à l'utilisation de valeurs variables pour le facteur d'apprentissage η [Riedmiller et al, 1993], ou à l'utilisation de méthodes du deuxième ordre pour le calcul du gradient. Nous présenterons plus loin dans ce chapitre les principaux algorithmes utilisés en apprentissage des Perceptrons Multicouches [Fahlman, 1988].

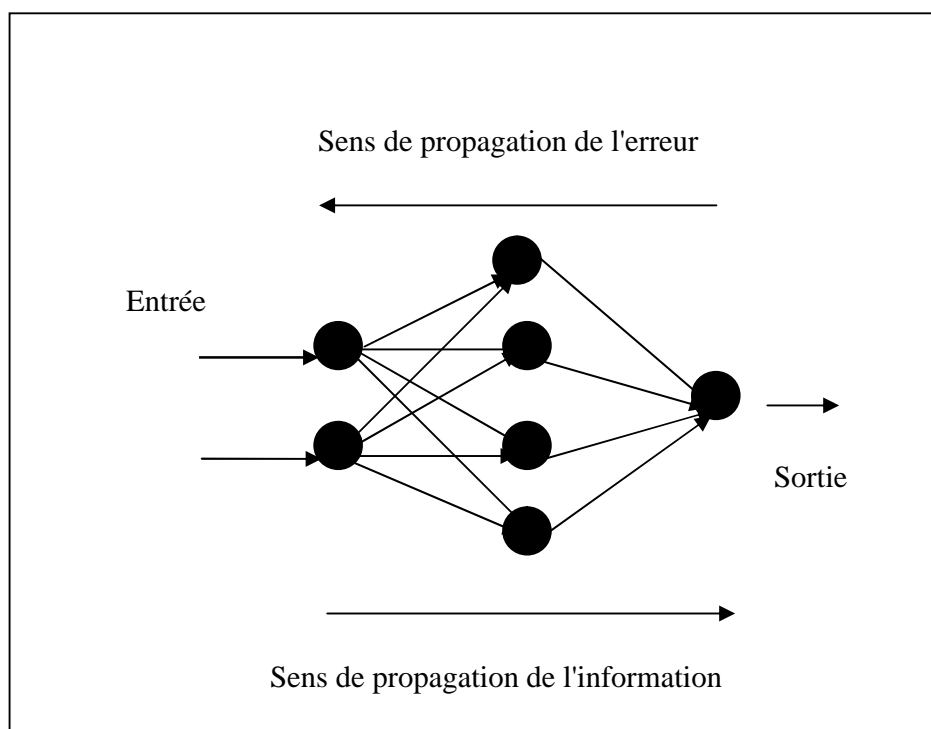


Figure 3.5. Un réseau multicouches comportant 2 neurones d'entrée, 4 neurones cachés et un neurone de sortie.

4.5. Généralisation

Pendant le processus d'apprentissage, les sorties d'un réseau non bouclé tendent à approcher les sorties fournies dans l'ensemble d'apprentissage. Mais l'intérêt principal des réseaux réside dans leur capacité de généralisation, en d'autres termes, de fournir des valeurs pour des entrées inconnues qui n'appartiennent pas à l'ensemble d'apprentissage. Pour avoir une bonne généralisation, il y a certaines règles à respecter, sans lesquelles les RNA donneront des résultats erronés. Les entrées choisies pour le réseau doivent être pertinentes et représentatives de la fonction recherchée ; nous ne pouvons pas inclure toute entrée sans lien avec les sorties fournies au risque d'augmenter artificiellement la complexité du modèle recherché.

Lorsque la séquence d'apprentissage est choisie, il faut s'assurer qu'elle soit représentative de la fonction que nous cherchons à approximer, et que les ensembles que nous essayons de prédire soient de la même classe que l'ensemble d'apprentissage.

4.5.1. Facteurs indispensables pour une bonne généralisation

Trois conditions sont nécessaires mais pas suffisantes pour obtenir une bonne généralisation:

1. Les entrées du réseau doivent contenir suffisamment d'information les reliant aux sorties désirées, pour qu'il y ait une relation mathématique reliant les entrées aux sorties avec une précision acceptable. Nous ne pouvons pas imaginer les RNA apprendre une relation non existante. Le choix des entrées pertinentes et la création d'un ensemble d'apprentissage, prennent souvent plus de temps que l'apprentissage des réseaux. Cela est particulièrement important lorsque nous essayons de modéliser des fonctions biologiques, où souvent les paramètres influençant le processus à apprendre sont difficiles à quantifier.
2. La fonction à modéliser (reliant les entrées aux sorties) doit être peu sensible. En d'autres termes, de faibles variations des valeurs d'entrées doivent, dans la plupart du temps, entraîner de faibles variations sur les sorties. Quelques réseaux de neurones sont capables d'apprendre des discontinuités à condition que la fonction à modéliser soit composée d'un nombre fini de segments continus. Cela explique l'incapacité des RNA d'apprendre certaines fonctions comme les tirages aléatoires et les algorithmes de cryptage. Pour les problèmes de classification, la condition de faible sensibilité n'est pas nécessaire. Les Perceptrons Multi-Couches avec suffisamment de neurones cachés sont des classificateurs fiables [Devroye et al, 1996].
3. L'ensemble d'apprentissage (base d'exemples) doit être suffisamment grand et représentatif de l'ensemble de l'espace des entrées et de sorties. Cette condition influence directement les deux types de généralisations possibles : l'interpolation et l'extrapolation. L'interpolation s'applique sur les cas proches des exemples d'apprentissage et l'extrapolation sur les cas loin de l'ensemble d'apprentissage. Les RNA sont capables d'une bonne interpolation. En revanche, leur performance en extrapolation reste assez médiocre. Avant d'utiliser les RNA en généralisation, leur performance en interpolation et en extrapolation doit être vérifiée.

En résumé, pour une fonction donnée, peu sensible, et pour les cas de généralisation proches des exemples d'apprentissage, la sortie du réseau sera proche des sorties correctes des exemples d'apprentissage. Si la base d'apprentissage est correctement construite, tout cas de généralisation sera proche d'un cas d'apprentissage. Sous ces conditions et avec une architecture et un algorithme d'apprentissage approprié, les RNA sont capables de généraliser correctement l'ensemble de la population.

4.5.2. Optimisation de la généralisation

Il est possible d'améliorer la qualité des réseaux de neurones en généralisation en modifiant les algorithmes d'apprentissage ou même les conditions d'arrêt du processus itératif de l'apprentissage. Nous présentons différents algorithmes d'apprentissage ainsi que la méthode « d'arrêt avant convergence » ou autrement dit la méthode du « early stopping ».

4.5.2.1. Algorithme d'apprentissage

Les algorithmes d'apprentissage itératifs utilisés dans les réseaux de neurones explorent l'espace des paramètres (poids et biais du réseau) à partir d'un point de départ fixé par les

valeurs initiales de ces paramètres et selon une trajectoire qui sera fonction de l'algorithme utilisé et des données. Pour améliorer les performances des modèles neuronaux en généralisation, nous pouvons également utiliser des algorithmes basés sur la descente du gradient. Nous présentons ci-après les algorithmes les plus utilisés en apprentissage supervisé [Hagan et al, 1996].

a) *Algorithme du facteur d'apprentissage adaptatif η*

Il est aussi possible d'améliorer les performances du RNA en modifiant à chaque itération la valeur du facteur d'apprentissage η dans la formule modifiant les poids et les biais (équation 3.2). Cette méthode est connue sous le nom de l'algorithme du «facteur d'apprentissage adaptatif». La performance du réseau est très sensible au facteur d'apprentissage: s'il est trop grand, l'algorithme peut osciller et devenir instable, s'il est trop petit, l'algorithme mettra beaucoup de temps avant de converger. Ce n'est pas évident de choisir une valeur avant l'apprentissage, d'autant plus que la valeur optimale du facteur d'apprentissage change pendant le processus d'apprentissage.

La performance de l'algorithme de descente du gradient peut être améliorée si on modifie le facteur d'apprentissage pendant le processus itératif. Un facteur adaptatif permet de maintenir un pas d'apprentissage le plus large possible en maintenant un apprentissage stable. A chaque itération, l'erreur d'apprentissage (e_i) (équation 3.1) est calculée. La méthode du facteur d'apprentissage adaptatif propose de modifier η au fur et à mesure de l'apprentissage en fonction de e_i selon la méthode suivante :

Si	$e_i > \alpha$	alors	
	$\eta = \eta * \delta$	$(\delta < 1)$	
Sinon			
	$\eta = \eta * \delta'$	$(\delta' > 1)$	
Fin Si			

b) *Méthode de Newton*

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

$$W_{k+1} = W_k - H_k^{-1} G_k \quad (3.3)$$

La direction de descente est fonction du Hessien H (matrice des dérivées secondes de la fonction de coût) et du gradient. La méthode de Newton nécessite moins d'itérations pour converger que l'algorithme de rétropropagation classique, mais malheureusement, le calcul du Hessien est coûteux en temps pour les réseaux non bouclés. Il existe cependant une classe d'algorithmes basée sur l'algorithme de Newton appelée Quasi Newton qui utilise une approximation du Hessien pour la mise à jour des poids du réseau. Le plus connu parmi ces algorithmes est celui de Broyden, Fletcher, Goldfarb et Shanno (BFGS) [Dennis et al, 1983; Hagan et al, 1996].

c) *Méthode de Levenberg-Marquardt*

Comme les méthodes de Quasi-Newton, la méthode de Levenberg-Marquardt [More, 1977] utilise une approche du second ordre sans calculer le Hessien. Quand la fonction de coût est une somme au carré (i.e. comme le MSE équation 3.1), le Hessien peut être approximé par :

$$H = J^T J \quad (3.4)$$

Le gradient peut être décomposé sous la forme :

$$G = J^T e \quad (3.5)$$

où J est le Jacobien qui contient les dérivées premières des erreurs du réseau

et e est le vecteur d'erreur

$$e_i = a_i - s_i \quad (3.6)$$

Le jacobien peut être calculé avec l'algorithme de rétropropagation; ce qui est beaucoup moins complexe que le calcul du Hessien.

4.5.2.2. Compromis Apprentissage Généralisation ou « early stopping »

Pour les réseaux de neurones artificiels, l'ensemble des données disponibles est souvent divisé en trois sous-ensembles distincts, un ensemble d'apprentissage, un ensemble de validation et un ensemble de test. La distinction entre ces sous-ensembles est cruciale, mais les termes validation et test sont souvent confondus. Nous présentons les définitions données par Ripley [Ripley, 1996] :

Ensemble d'apprentissage : un ensemble d'exemples utilisé en apprentissage pour la modification des paramètres du réseau (poids et biais).

Ensemble de validation : un ensemble d'exemples utilisé pour l'ajustement de l'architecture (nombre de couches et nombre de neurones cachés mais pas les poids du réseau). Cet ensemble peut aussi servir à arrêter le processus itératif de l'apprentissage lorsqu'un seuil d'erreur est atteint.

Ensemble de test : un ensemble d'exemples utilisé pour tester la performance du réseau.

5. Mise en oeuvre du modèle neuronal

5.1. Choix de l'algorithme d'apprentissage

Le choix de l'algorithme d'apprentissage dépend essentiellement de la complexité de l'architecture neuronale :

- Pour un réseau ayant un petit nombre de poids, les méthodes de Newton ou de Levenberg-Marquardt sont adéquates.
- Pour un réseau ayant un nombre modéré de poids, les divers algorithmes Quasi-Newton sont bien adaptés.

- Pour un réseau ayant un grand nombre de poids, les algorithmes de rétropropagation classiques ou du facteur d'apprentissage adaptatif sont préférables.

Chaque méthode d'optimisation possède des avantages et des inconvénients. Aucune de ces méthodes ne conduit à coup sûr au minimum global. En pratique, il suffit de réaliser plusieurs apprentissages en choisissant des paramètres initiaux (poids et biais initiaux) de différentes valeurs. En procédant de la sorte, on augmente la probabilité de trouver le minimum global.

5.2. Choix des fonctions de transfert

Les fonctions d'activation (Figure 3.6) pour les couches cachées sont nécessaires pour introduire de la non linéarité dans les réseaux. Sans cette non linéarité, les neurones cachés ne rendront pas les Perceptrons Multicouches plus puissants qu'un simple Perceptron puisque la combinaison de fonctions linéaires reste une fonction linéaire. Or, l'intérêt de l'utilisation des PMC est dans la non linéarité (la capacité d'approcher des fonctions non linéaires). La plupart des fonctions non linéaires peuvent être utilisées. Néanmoins, le choix de l'algorithme de la rétropropagation pour l'apprentissage du réseau impose des fonctions dérivables. Les fonctions sigmoïdes comme la fonction tangente-sigmoïde ou la fonction Gaussienne sont de très bons candidats aux fonctions de transfert pour les neurones des couches cachées [Cybenko, 1989].

Le choix des fonctions d'activation pour les neurones situés sur la couche de sortie dépend de la distribution des valeurs à prédire. Pour des valeurs binaires (0/1), la fonction « seuil » est un excellent choix [Jordan, 1995]. Pour les valeurs de sortie continues, la fonction d'activation « identité » (absence de fonction) est la plus utilisée.

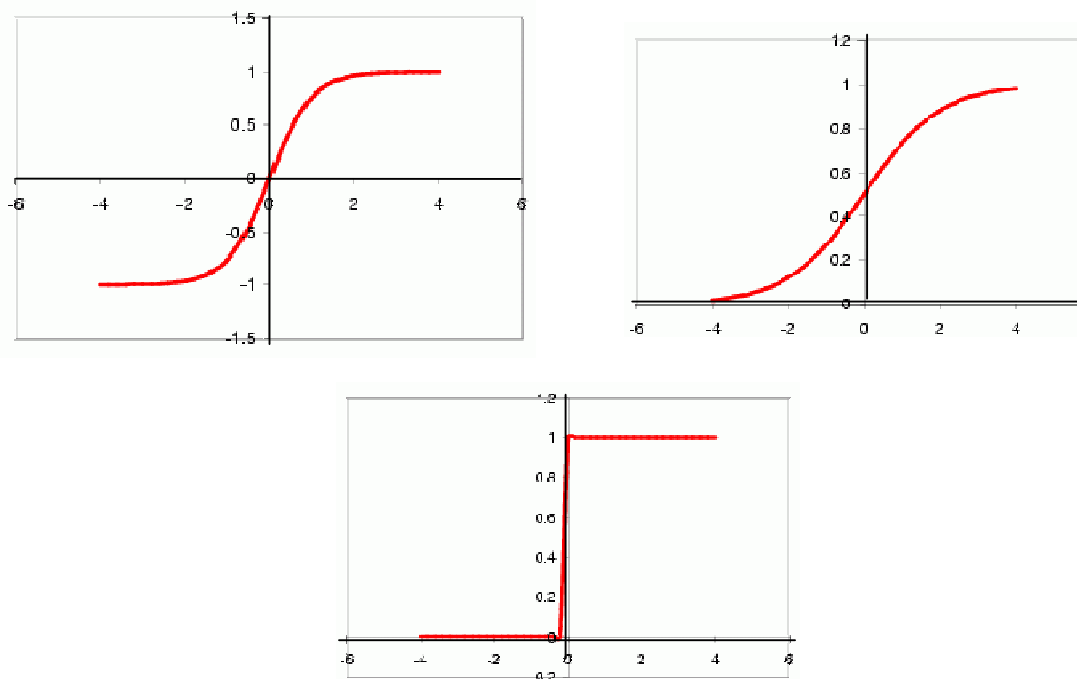


Figure 3.6. Quelques exemples de fonctions de transfert utilisées pour les RNA.

5.3. Choix de l'architecture neuronale

Choisir une architecture nécessite de fixer le nombre de couches cachées ainsi que le nombre de neurones dans chaque couche. L'architecture d'un réseau détermine la classe des fonctions calculables par celui-ci ou encore sa complexité potentielle. C'est le premier paramètre sur lequel les utilisateurs de ces techniques ont joué pour contrôler les performances d'un système.

Une démarche empirique exhaustive pour la sélection du modèle, consiste à tester sur le problème traité un grand nombre de solutions différentes. On peut par exemple explorer la famille des PMC (Figure 3.5) pour un critère d'erreur donné en faisant varier le nombre d'unités cachées. L'estimation des performances devient alors le point sensible de la démarche. De nombreuses procédures ont été proposées pour cela dans la littérature statistique (validation croisée, bootstrap,...) [Baxt, 1995; Efron et al, 1997] et peuvent être appliquées pour les séries temporelles [Hjorth, 1994]. La procédure la plus courante et qui est bien adaptée lorsqu'on dispose de beaucoup de données, consiste en l'utilisation d'un ensemble additionnel unique qui sert à sélectionner la bonne architecture et qui est appelé ensemble de validation. L'architecture sélectionnée sera celle offrant les meilleures performances sur cet ensemble de validation qui intervient donc dans l'apprentissage.

5.4. Ensemble d'apprentissage, de validation et de test

Comme nous l'avons vu précédemment, l'ensemble « d'apprentissage » servira à la modification des poids du réseau tandis que l'ensemble de « validation » servira à l'arrêt « prématuré » du processus itératif de l'apprentissage. La phase d'application des modèles est effectuée ensuite sur l'ensemble de « test ».

Une validation préalable de ces trois ensembles est nécessaire avant leur utilisation pour l'élaboration des modèles neuronaux. Dans le domaine médical, ces données doivent être validées et vérifiées par un praticien confirmé, mais dans certains cas, les connaissances actuelles ne suffisent pas à valider ces ensembles. La mise en place de méthodes basées sur des données artificielles pour valider les modèles neuronaux avant de passer à la phase de diagnostic est indispensable [El Dajani, 2001 -b]. Le choix des données constituant ces différents ensembles conditionne la portée et le domaine de validation du modèle identifié. Ainsi, nous utiliserons la sélection des ensembles d'apprentissage, de test et de validation comme un degré de liberté supplémentaire pour construire et valider le modèle.

5.5. Avantage des RNA sur les méthodes statistiques

Pourquoi alors utiliser les réseaux de neurones artificiels (le Perceptron Multicouches (PMC)) au lieu des méthodes statistiques pour l'approche des modèles non linéaires ? Il y a beaucoup de réponses à cette question [Hornik, 1994; Ripley, 1996]:

- L'utilisation d'un nombre d'entrée relativement grand.
- la plupart de l'information prédictive est contenue dans un sous-espace à faible dimension.
- capacité de représentation de n'importe quelle fonction, linéaire ou pas, simple ou complexe.
- Faculté d'apprentissage à partir d'exemples représentatifs, par « rétropropagation des erreurs ». L'apprentissage (ou construction du modèle) est automatique
- Simple à manier, beaucoup moins de travail à fournir que dans l'analyse statique classique.
- Pour l'utilisation nocive, l'idée d'apprentissage est plus simple à comprendre que les complexités des statistiques multi variables.

- Consultation rapide.
- Relations spatiales faciles à analyser et modéliser.
- Le modèle fourni est continu et dérivable et se prête bien à la visualisation, à une recherche de profils-type (par ascension du gradient de probabilité prédite), au calcul de sensibilités (par dérivation partielle), etc....

Les avantages des PMC sur les méthodes statistiques sont détaillés dans la référence [Warren, 2001].

Comme nous l'avons vu, les réseaux de neurones sont essentiellement des procédures permettant d'approcher n'importe quelle fonction linéaire ou non, à partir d'exemples de valeurs de cette fonction. La réussite de cet apprentissage suppose cependant qu'un certain nombre de conditions portant sur le choix et le nombre de ces exemples ainsi que sur l'architecture initiale du réseau, soient vérifiées.

CHAPITRE 4 LES RESEAUX DE NEURONES APPLIQUES AU DIAGNOSTIC CARDIOVASCULAIRE

1. Introduction

1.1. Contexte des méthodologies de soutien à la prise de diagnostic médicale

On a proposé l'intelligence artificielle comme outil de raisonnement pour soutenir la prise de diagnostic médical dès les débuts du traitement de l'information [Ledley et al, 1959]. Les problèmes théoriques et pratiques rencontrés ont conduit à des développements importants en statistique et en informatique, mais c'est seulement pendant la dernière décennie du siècle dernier que des systèmes interactifs d'aide au diagnostic ont été régulièrement employés dans la pratique clinique à une échelle significative. Certains de ces derniers impliquent les réseaux de neurones artificiels. Cependant, avant de se lancer dans un examen spécifique d'applications du système à neurones, il est important de considérer le cadre le plus large des méthodes existantes issues des aides d'intelligence artificielle et des diagnostics statistiques dont l'expérience fournit un cadre de discussion du potentiel des approches inédites.

La recherche scientifique s'est orientée vers une formalisation du processus de raisonnement modélisé, sur les traces des études de stratégies de résolution des problèmes qui ont indiqué que l'expertise clinique dans des cas difficiles est en grande partie dépendante du raisonnement causal et de la pathophysiologie. Cette approche a été suivie dans [Shortliffe, 1976], qui a établi les bases des systèmes experts. Curieusement, cette méthodologie a été la plus réussie dans les domaines prescriptifs dont la portée peut être restreinte. D'autres produits performants se sont développés comme systèmes experts de laboratoire, qui ne s'imposent pas directement dans le processus du soin clinique.

Une approche alternative, plus près des statistiques classiques, a été de construire et d'évaluer des hypothèses en assortissant les caractéristiques d'un patient avec des profils enregistrés d'une maladie donnée [Schwartz, et al, 1987].

On note qu'il peut être difficile de suivre les recommandations du système afin de les expliquer en juste proportion aux cliniciens, en partie parce qu'elles sont fondées sur des notes numériques peu assimilables en confrontation avec l'incertitude [Kulikowski, 1988].

Parmi d'autres exemples qui ont réussi le modèle bayésien. Il y a le système de De Dombal pour le diagnostic de la douleur abdominale aiguë (DAA) [De Dombal et al, 1972].

Les réseaux structurés mis en application à l'aide du théorème de Bayes ont survécu aux années 70 et 80. Indépendamment, le théorème de Bayes a été employé il y a 30 ans. De bonnes approximations des intégrales de distribution sont maintenant possibles avec des méthodes numériquement robustes comme la chaîne de Markov Monté Carlo [Neal, 1996]. Ces développements ont été précurseurs de la confluence actuelle d'intérêt pour les modèles graphiques [Lunn et al, 2000; Spiegelhalter et al, 1999] provenant des domaines de l'Intelligence artificielle, du modèle statistique et de l'étude assistée par l'ordinateur.

Néanmoins, à la fin des années 80, de sérieuses insuffisances ont été identifiées dans les systèmes experts et l'assortiment simpliste de Bayes. Ils ne pouvaient faire face aux aléas de la présentation et l'identification de la pathologie. Ils ne pouvaient non plus prendre en charge l'évolution de la maladie avec le temps, par exemple, en répondant au traitement, comment fournir des explications fondées sur la pathophysiologie, ou comment déterminer l'influencer d'une pathologie par la présentation d'une autre [Schwartz et al, 1987].

Une troisième approche au raisonnement informatique a émergé, construite autour des modèles en considérant l'anatomie, la physiologie et la pharmacologie. Le raisonnement modélisé est exprimé en équations non linéaires couplées ou en réseaux probabilistes causaux, par exemple pour simuler la réaction dynamique à la thérapie [Andreassen et al, 1994]. Ces méthodes ont été le centre d'intérêt pour la modélisation du diagnostic dans les années 80, succédant ainsi aux systèmes experts et la modélisation des données dans l'espoir de résoudre les problèmes importants concernant les méthodes qui ont été décrites, en particulier la nécessité d'adapter le diagnostic multi pathologique [Lucas, 1997]. Le rôle de l'appui du diagnostic médical peut maintenant être récapitulé et prolongé dans le contexte d'un examen des applications des réseaux de neurones.

S'adapter à partir des taxonomies d'intelligence artificielle en médecine [Shortliffe, 1990; Coiera, 1997] il y a trois catégories générales de demande de réseaux de neurones dans la prise du diagnostic médical.

- Outil de concentration de l'attention, visant à détecter des anomalies, soit dans les systèmes d'information d'origine hospitalière, soit dans les systèmes cliniques de laboratoire.
- Contrôle du patient et conseil, lancé en tant qu'outils de soutien de la consultation générique en fournissant des inférences diagnostiques et pronostiques.
- Les outils interactifs de critique et de planification constituent des planches permettant au clinicien d'obtenir de nouvelles perspectives par le test d'hypothèses concernant l'état du patient et d'étudier les effets possibles de différents choix de traitement.

1.2. Aperçus précédents des applications médicales impliquant les réseaux de neurones

Les premières tentatives d'application des réseaux de neurones au domaine médical se sont concentrées sur l'analyse des données non linéaires, le partage de la mémoire associative afin d'éviter la difficulté d'acquisition de la connaissance experte, la tolérance au bruit due à l'architecture intrinsèquement parallèle et l'adaptabilité à accommoder de nouvelles manifestations de la maladie [Reggia, 1993].

Beaucoup d'articles ont souligné la prédominance, dans la pratique clinique, d'une fonction de mémoire associative [Cross et al, 1995] adaptée à la variabilité des présentations de la

maladie et des degrés de sévérité qui combinent des effets inhérents aux patients eux-mêmes et entre les patients les uns aux autres.

Cependant, technologiquement, les réseaux de neurones demeurent une partie « du sujet mystérieux de l'inférence et de la modélisation statistiques non linéaires » [Cross et al, 2000] avec l'intention de rendre ce domaine important et de développer l'accès aux statisticiens non-spécialiste. On pourrait argumenter que des principes statistiques sont importants pour compter sur l'évidence de bases fondées sur toute méthodologie de base de données, y compris les réseaux de neurones [Schwartz, et al, 2000]. Par conséquent, ces méthodes sont le mieux justifiées lorsqu'elles fournissent une fonctionnalité supplémentaire à celle des modèles statistiques déjà établis, qui sont typiquement linéaires en paramètres. Cela fournit deux possibilités. L'une est de tracer avec précision des dispositifs de données qui sont difficiles ou coûteux à trouver dans un développement statistique conventionnel, composé habituellement d'interactions complexes entre des variables ou des attributs particuliers. L'autre possibilité est d'augmenter sensiblement la puissance de l'analyse exploratrice des données, par exemple en élevant les hypothèses concernant les composantes non linéaires insoupçonnés dont la modélisation explicite pourrait améliorer la précision des méthodes statistiques classiques, ou encore en prévoyant une visualisation directe des données complexe de haute dimension. Cette revue se concentre essentiellement sur l'application clinique des systèmes à réseaux de neurones, qui est destinée principalement à l'inférence non-linéaire. Ces derniers apportent leur puissance en analyse exploratrice.

Vers 1995, il y a eu près de 1000 citations des réseaux de neurones dans la littérature biomédicale [Baxt, 1990; 1992; 1994; 1995; 1996; Baxt et White, 1995; Baxt et Skora, 1996]. La plupart des études décrites comportaient des données historiques et le plus souvent un taux d'exactitude (accuracy) sur un ensemble de données a été testé. Certains domaines médicaux ont été identifiés pour avoir le potentiel pour l'appui diagnostique, au moins sur la base d'exactitude dans des terrains d'essais particuliers et uniques. Un bon exemple est celui de la présélection des patients qui se présentent aux unités des urgences avec des douleurs thoracique aiguës afin de tenter l'identification de ceux qui sont les plus susceptibles d'avoir fait un infarctus du myocarde aigu (IDM). Les études faisant participer 706 patients ont changé les sensibilités et les spécificités de 80 à 96% [Baxt et White, 1995], en comparaison avec une étude d'envergure des médecins qui a revendiqué une sensibilité ainsi qu'une spécificité de 88 et de 71% respectivement [Goldman et al, 1988]. La plupart de ces études ont employé les méthodologies actuelles des réseaux de neurones, presque invariablement le perceptron multicouches avec arrêt anticipé pour prévenir le sur ajustage.

Une étude méthodologique particulièrement intéressante s'est préoccupée de l'influence des variables d'entrée sur la réponse d'un réseau qualifié pour identifier le haut risque de l'IDM. Cette analyse de la sensibilité utilise les boucles de retour pour corriger les petites valeurs des biais et démontre que ces biais sont significatifs pour améliorer les résultats [Baxt et White, 1995].

Un autre aperçu de la valeur diagnostique des différentes procédures peut être dérivé en factorisant le rapport de la vraie positivité et de la fausse positivité afin de définir comment le discriminateur s'améliore sur la ligne d'estimation. Ceci définit un facteur amplifiant, entre la prédominance et la valeur prédictive positive (PPV) du procédé, donné par l'expression (1) ci-dessous.

$$\frac{PPV}{1 - PPV} = \frac{Sensitivité}{1 - Specificité} * \frac{Pr(class)}{Pr(-class)} \quad 4.1$$

$Pr(class)$ et $Pr(-class)$ dénotent respectivement la prédominance en dehors et dans la classe diagnostique.

1.3. Etendue des publications

Afin de rendre maniable un sujet aussi vaste, l'étude des applications se consacre au domaine de la cardiologie ainsi que les fonctions cliniques de l'analyse du diagnostic, du pronostic et de la survie. Cet aperçu omet délibérément des domaines d'application importants qui mériteraient d'être étudiés. Par exemple, l'oncologie, le traitement critique et l'identification de modèle de surveillance. Cet aperçu fournit un instantané étroitement concentré sur les réseaux de neurones, à l'exclusion des méthodes hybrides telles que les systèmes neuro-flou [Szczepaniak et al, 2000].

Un aperçu de quelques publications classées par domaine médical et par fonction clinique est illustré dans les tables 4.1 et 4.2. Les domaines de l'oncologie, du soin critique et de la cardiologie sont ceux où les épreuves cliniques sont prédominantes. La plupart des études citées s'intéressent à l'extrapolation diagnostique ou pronostique avec seulement une épreuve clinique visant directement la survie.

Table 4.1. Aperçu de quelques publications classées par domaine médical et par fonction clinique.

	Oncologie	Soin critique	neurologie	Autre
Radiologie	IRM d'osteosarcoma: Glass and Reddick (1998)	Scintigraphie de perfusion pour la détection de la sténose coronaire : Goodenday et al. (1997) Le signal micro embolique du Doppler chez les patients avec des valves prothétiques du coeur : Georgiadis et al. (1995)	l'épilepsie : Bakken et al. (1999) Alzheimer : Horwitz et al. (1995)	Images myocardiques de perfusion: Lindahl et al. (2000) Détection des sténoses par écho Doppler: Smith et al. (1996)
Surveillance physio- logique		EEG en pédiatrie: Si et al. (1998)	Épreuve simple des PEVE Heinrich et al. (1999) Corrélation d'EEG et d'EMG: Gaetz et al. (1998) Potentiels évoqués dans la sclérose en plaque: Guterman et al. (1996)	Surveillance foetale pendant le travail à partir d'ECG foetal : Stock et al. (1994)

Table 4.2. Aperçu de quelques publications classées par domaine médical et par fonction clinique.

	Oncologie	Soin critique	neurologie	Autre
Diagnostic	cancer de la prostate: Gamito et al (2000) Finne et al. (2000) Cancer cervical : Doornewaard et al. (1999) Mango et al. (1998) Sherman et al. (1997) Cancer du sein: Naguib et al. (1996) Simpson et al. (1995) Leucémie aiguë : Kothari et al. (1996)	Hémorragie intracrânienne chez les nouveau-nés : Zernikow et al. (1998)	Détection d'embolie: Kemeny et al. (1999) EEG Spontané: Anderson et al. (1998) EEG au sommeil: Baumgart-Schmitt et al. (1997, 1998) EEG Quantitatif: Winterer et al. (1998) Identification du mode de ventilation : Leon et Lorini (1997)	Appendicite : Pesonen (1997) Méthodes de référence pour des patients avec les troisièmes molaires : Goodey et al. (2000) Modèles de protéine de larme : Grus et Augustin (1999) Hémodialyse: Smith et al. (1998) moment d'ovulation: Gurgen et al. (1995)
Prévision de résultats	Réponse à la thérapie dans le cancer de la tête et du cou : Bryce et al. (1998) Répétition du cancer du sein chez les patientes avec nœud négatifs axillaires : McGuire et al. (1992) Myélome multiple: Bugliosi et al. (1994)	Longueur de séjours chez les nouveau-nés prématurés : Zernikow et al. (1999)		Niveaux de sang de Tracolimus : Chen et al. (1999) Croissance en calculs après lithotripsie : Michaels et al. (1998) Effet de traitement dans la schizophrénie et la dépression : Modai et al. (1996) conséquence de rupture d'anévrisme: Dombi et al. (1995)

Il y a également des domaines spécialisés liés au traitement des signaux auxquels il faudrait consacrer des études à part, tels que le traitement d'image et l'analyse en temps réel, y compris les développements dans l'analyse des composants pour la suppression d'artefact. [Lisboa et al, 2000a]. Un autre domaine d'application, la bioinformatique, est actuellement en développement en étroite corrélation avec la biomédecine [Shi et al, 2000].

2. Aperçu sur les applications cardiovasculaires

2.1. Application dans la détection du complexe QRS

L'électrocardiographie a eu un impact profond sur la pratique de la médecine. En effet, l'électrocardiogramme (ECG) contient une quantité de l'information importante qui peut être

exploitée de différentes façons. L'ECG tient compte de l'analyse des aspects anatomiques et physiologiques du muscle cardiaque de totalité.

Une application des réseaux de neurones pour la discrimination entre les complexes normaux et pathologiques d'ECG est présentée dans [Conde, 1994]. La rétropropagation est employée comme algorithme d'apprentissage pour la méthode : La sortie du réseau n'utilisait pas la discrimination pour distinguer entre les complexes normaux et pathologiques, mais fait seulement l'extrait de prototype du complexe dans l'ECG analysé. Une tentative est faite pour individualiser automatiquement une morphologie pathologique du QRS, mais les battements ventriculaires étaient moins de 15% dans les ECG traités.

Dans [Dassen et al, 1992] les auteurs décrivent le développement d'un réseau de neurones conçu pour différencier l'étiologie d'un large QRS d'une tachycardie en utilisant les douze dérivations de l'ECG. De cette façon 75% de toutes les tachycardies ont été diagnostiquées correctement.

Dans le domaine du traitement des signaux en temps réel, il y a les systèmes tout à fait différents dans leur détection du complexe QRS.

Dans [Casaleggio et al, 1991], les auteurs ont développé un algorithme pour la détection des complexes QRS des signaux ambulatoires d'électrocardiogramme. Le seuil qui est obtenu à partir d'une fonction de distribution de l'amplitude du signal filtré d'ECG, change avec du temps, s'adaptant au changement des niveaux de morphologie du QRS du bruit et des artefacts. Le seuil extrait la période qui inclut le complexe QRS et alors ce dernier est détecté pendant cette période.

2.2. Application dans la détection de l'infarctus du myocarde aigu (IDM)

Le diagnostic précoce de l'infarctus du myocarde aigu (IDM) chez les patients se présentant aux urgences avec des douleurs sévères au thorax suscite beaucoup d'intérêt pour l'application de la reconnaissance des formes. L'intention principale est d'employer les marqueurs biochimiques d'un échantillon de sang pour prévoir le résultat des mesures de protéines qui durent plusieurs heures pour être obtenus. L'intérêt quand l'IDM est détecté tôt, permet d'administrer l'anticoagulant au moment où il a le plus grand effet tout en réduisant la sévérité des dommages pouvant affecter le muscle cardiaque. Plusieurs études se concentrent sur ce thème qui, avec la radiologie, sont énumérées dans le tableau 4.1.

Dans une première étude, Ellenius et ses collaborateurs [Ellenius et al, 1997] ont suivi le diagnostic d'un patient avec un IDM mineur dès le moment de l'infarctus, en surveillant l'augmentation de la concentration des marqueurs biochimiques et en identifiant l'étape à laquelle le MLP, et chacun de trois cliniciens professionnels, confirme le diagnostic. Cette approche peu commune à l'évaluation de système a montré le modèle de détection de l'IDM et la capacité de prévoir l'étendue de l'infarctus dans le futur, simultanément avec les premières indications fournies par les experts.

Une étude à grande échelle d'interprétation automatisée des 12 dérivations de l'électrocardiogramme pour la détection de l'IDM, a été effectuée avec une multitude de patients présents dans un seul hôpital sur une période de cinq ans, comportant 1120 cas confirmés et 10.452 contrôlés. Un tracé de 20 secondes a été représenté par six mesures automatiquement produites de ST-T de chacune des 12 dérivations de l'ECG, fournissant 72

unités d'entrée d'un MLP avec une seule couche cachée [Heden et al, 1997]. L'apprentissage est contrôlé par un arrêt précoce accordé de huit procédés. Le même procédé a été employé pour l'évaluation de la performance des tests, donnant 15.5% (de 12.4 à 18.6%) d'amélioration de la sensibilité employée au-delà des critères basés sur les règles utilisées par les électrocardiographes numériques et informatisés au service des urgences, avec une spécificité de 95%. Une plus petite amélioration de 10.5% (de 7.2 à 13.6%) a été obtenue au-dessus du taux de détection de l'IDM par les cardiologues, qui ont été restreints à lire les ECG en l'absence d'information contextuelle telle que des données personnelles et des résultats cliniques à l'examen initial, ramenant la spécificité à 86.3%.

La comparaison avec les critères basés sur les règles automatisées représente une augmentation de 50% du facteur amplifiant à partir d'environ six à neuf, alors que dans la comparaison avec les cliniciens le changement atteint 20% à un gain de probabilité d'environ 3.5. Les améliorations se détériorent à des spécificités plus élevées mais ces résultats ont néanmoins été rapportés avec enthousiasme dans les journaux médicaux [Fricker, 1997; Josefson, 1997]. Les auteurs font remarquer que le système pourrait être d'un intérêt particulier pour des internes aux urgences, et la prochaine étape serait d'intégrer l'information contextuelle additionnelle telle que les antécédents médicaux et les résultats des enquêtes cliniques. Certaines de ces idées sont développées plus loin dans les travaux décrits ci-après.

Une étude méthodologique avancée de détection de l'IDM dans les services des urgences en utilisant les réseaux de neurones, comporte une série d'études par Baxt et collaborateurs. Des premières études qui devaient optimiser la précision des prévisions de réseau neurones [Baxt, 1992; 1994] ont été suivies d'une analyse bien soignée des différentes entrées cliniques pour avoir une bonne décision à la sortie du réseau [Dreiseitl et al, 1999], et de l'application de méthodologies rigoureuses pratiques pour l'analyse de la sensibilité [Baxt, 1995]. Il est d'un intérêt particulier d'utiliser un circuit fermé pour corriger l'erreur en effet, un biais a été utilisée au niveau de l'apprentissage des données permettait une bonne évaluation de la sensibilité. Un échantillon comportant 706 observations a été utilisé. Cette polarisation est assez significative pour changer l'ordre d'importance des entrées cliniques.

L'analyse des entrées par le calcul des biais corrige la sensibilité chez Baxt et White [Baxt et al, 1995], classe les nouvelles variables mieux que certains indicateurs couramment utilisés par les cliniciens. Le modèle obtenu est conforme à une autre l'étude, celle des choix des variables pour la prédiction de l'IDM [Neal, 1996] comparant le LogR (multiple logistic regression), les réseaux de neurones bayésiens [Selker et al 1995] et les ensembles approximatifs. Le choix de 43 variables est convenu pour chaque approche modélisée, appliquée à un ensemble de 500 tracés dont 335 tracés utilisés pour l'apprentissage et 165 pour le test. Seul un indicateur, sus décalage du segment ST, a été sélectionné pour toutes les méthodes. Ceci est reconnu cliniquement comme très approprié, mais trois autres variables communément employées par les cliniciens n'ont été choisies par aucun de ces modèles, à savoir antécédents de diabète, douleur de poitrine intense et durée de la douleur. Les résultats des études sont en conformité avec ces variables, suggérant qu'elles peuvent être sensibles à l'IDM.

Les études initiales ont été suivies d'une comparaison prospective entre les taux de détection par des cardiologues et le MLP pour un groupe de 1070 patients adultes présentant des douleurs thoraciques antérieures. Encore une fois, ces études se limitent à un seul hôpital [Baxt et Skora, 1996]. C'est une étude d'observation dans laquelle les cliniciens et le système

de décision ont séparément examiné les mêmes patients. Elle revendique de façon discutable la plus grande augmentation dans la performance par un système du réseau de neurones comparé aux cliniciens experts, amplifiant la probabilité de prendre un diagnostic au-dessus de la prévalence.

Une épreuve multicentre plus ancienne impliquant les services des urgences de six hôpitaux a comparé trois structures parfaitement différentes en vue d'une classification, notamment l'induction régulière, LogR et le MLP, pour la prédiction de l'ischémie cardiaque aiguë (ICA), qui comprend l'IDM et l'angine de poitrine instable, à partir de huit variables [Polak et al. 1997].

Les variables représentent l'historique du patient ainsi que les signes extraits à partir d'un examen clinique et d'un électrocardiogramme. Le MLP a eu un étalonnage sensiblement plus faible que les autres méthodes. Il est également plus difficile à interpréter. On a conclu à partir de cette étude que le choix de la méthode du support de décision de base de données devrait être fait sur la base des besoins d'application spécifiques. Néanmoins, les résultats obtenus indiquent qu'une limitation importante de la performance prédictive pour ces résultats cliniques est la disponibilité de données fiables, plutôt que le besoin de développements algorithmiques.

Dans [Henrik et al, 2004] les auteurs ont employé les réseaux de neurones bayésiens comme outil pour détecter l'IDM en utilisant les 12 dérivations de l'ECG. Les six mesures suivantes, prises de chacune des 12 dérivations, ont été choisies pour une analyse meilleure utilisant les réseaux de neurones: Amplitude du ST-j, pente de ST, amplitude de 2/8 de ST, amplitude de 3/8 de ST, amplitude positive de T et amplitude négative de T. L'amplitude 2/8 de ST et l'amplitude 3/8 de ST ont été obtenues en divisant l'intervalle entre le point ST-j et l'extrémité de l'onde T en huit parts de durée égale. Les amplitudes à la fin du deuxième et du troisième intervalle étaient l'amplitude dénotée 2/8 de ST et l'amplitude 3/8 de ST. Ces mesures ont été obtenues à partir des enregistreurs automatisés d'ECG en utilisant leur programme de mesures. En outre, pour expliquer le raisonnement derrière la sortie du réseau de neurones, une méthode a été développée pour montrer les régions de l'ECG les plus pertinentes pour ce cas particulier. Les principaux ingrédients de cette approche sont: une représentation de l'ECG en utilisant des fonctions de Hermite, déjà utilisées par [Sornmo, 1981; Jane. R, 1993], et une formulation combinatoire du problème d'optimisation pour trouver les entrées importantes du réseau.

Chaque dérivation de l'ECG est exprimée comme série de fonctions de base de Hermite, et les coefficients de cette série sont employés comme entrées pour le réseau. Après l'apprentissage, un nombre restreint de coefficients pour un ECG indiqué sont perturbés dans un intervalle limité; ces perturbations sont choisies afin de maximiser le changement correspondant du diagnostic (sortie du réseau). Un ECG perturbé est reconditionné à partir des coefficients perturbés, et en comparant cet ECG perturbé à original. La possibilité de construire les ECGs perturbés à partir des entrées perturbées du réseau de neurones est l'une des vertus de la décomposition de la fonction de Hermite; aucune reconstruction n'est possible dans l'approche traditionnelle où l'extraction de dispositif se compose des mesures des amplitudes et des pentes.

L'étude de la population a été également étudiée en [Hedén et al, 1997] où une définition détaillée des critères pour le diagnostic de l'infarctus du myocarde aigu peut être trouvée. La

performance était légèrement meilleure en employant des mesures traditionnelles d'amplitude et de pente du complexe STT (84.3% comparés à 83.4%). La performance employant des polynômes de Hermite était conforme également aux résultats se trouvant dans l'article de Heden et ses collaborateurs.

2.3. Application utilisant le système de surveillance Holter

Une autre application tout à fait différente est de prévoir la probabilité de développer une ischémie myocardique transitoire pendant une période de surveillance Holter ambulatoire, en utilisant des paramètres issus d'un ECG 12-lead au repos [Polak et al, 1997]. C'est l'exemple d'une étude où le MLP traité par la rétropropagation a été surpassé par une analyse linéaire de discriminants et un modèle alternatif au MLP.

Une étude de la prédiction de QT en fonction de RR utilisant les réseaux de neurones artificiels a été effectuée par [Hamidi, 1995]. Elle consistait à comparer les résultats des modèles paramétriques et neuronaux. Les performances des modèles paramétriques ont été jugées insuffisantes par l'auteur; cela est dû à la non linéarité de la relation $QT=f(RR)$. Les réseaux de neurones multicouches utilisant l'algorithme de rétropropagation dans la phase d'apprentissage, sont capables de modéliser la relation entre RR et QT. Le modèle utilisé avait pour entrée une série de RR sur une durée de 1 à 8 minutes et pour la sortie le QT correspondant au dernier RR de la série. Cette étude a mis en évidence la fiabilité de la modélisation neuronale et établit qu'un retard de 4 minutes est suffisant pour identifier la relation entre QT et RR. Ces premiers résultats ont servi de base pour un autre travail qui consiste à établir des modèles neuronaux prédictifs du comportement dynamique de l'intervalle QT en fonction des variations instantanées de l'intervalle RR et à étudier le comportement et le domaine de validité de ces modèles [El Dajani, 2002].

2.3. Application en détectant d'autres pathologies

Haiying et son équipe décrivent un modèle-clé de classification ainsi qu'une plateforme de visualisation basée sur les réseaux neurologiques auto-adaptatifs [Haiying et al, 2004].

Une classification entre patients et sujets normaux s'est concentrée sur deux maladies : sommeil en apnée obstructif (SAO) et arrêt du cœur congestif (CHF) [Abdulnasir H, 2006].

Dans [Meghriche et al, 2006; 2007; 2008] la méthode développée, basée sur un réseau de neurones composé (Compound Neural Network CNN), pour classer les ECG comme normaux ou portant un bloc atrioventriculaire (BAV). Cette méthode emploie trois réseaux de neurones statiques multicouches, placés dans une configuration spécifique. Cet algorithme est justement l'étude de notre thèse (chapitre 5).

Table 4.3. Aperçu de quelques publications utilisant les réseaux de neurones appliqués à l'ECG.

Reference	Clinical function
<i>IDM Ellenius et al. (1997)</i>	Diagnostic précoce ou exclusion de l'IDM à partir de marqueurs biochimiques L'approche de MLP a pu fournir l'appui utile pour l'évaluation des patients en IDM suspecté
<i>IDM Baxt and White (1995)</i>	Détection d'IDM dans les départements d'urgence, à partir de 19 variables représentant l'historique du patient, les résultats cliniques et les mesures ST-T prises de l'ECG
<i>IDM Haraldsson et al. (2004)</i>	Un réseau de neurones pour détecter des signes d'infarctus du myocarde aigu dans l'ECG est employé. Les 12-dérivations d'ECG sont décomposées en fonctions de base de Hermite, et les coefficients résultants sont employés comme entrées au réseau de neurones
<i>Ischémie Polak et al. (1997)</i>	La prédiction de l'ischémie passagère pendant la surveillance par le Holter en ambulatoire des 12 dérivations de l'ECG.
<i>Ischemia Selker et al. (1995)</i>	Des indicateurs cliniques disponibles dans un délai de 10 minutes de soin au département d'urgence ont été employés pour prévoir l'IDM et l'angine de poitrine instable en temps réel
<i>Repolarisation ventriculaire R. M. EL Dajani (2001,2002)</i>	Les résultats indiquent que MLP peut approcher l'aspect non linéaire du rapport QT-RR, et modeler la réponse du comportement dynamique de $QT=f(RR)$ à différents intervalles fixes de RR
<i>BAV Meghriche et al (2006); (2007); (2008)</i>	Une performance élevée d'architecture hybride de réseaux de neurones (CNN) pour la détection de BAV en utilisant seulement une dérivation.
<i>SAO Haiying et al (2004)</i>	Décrire une plateforme principale du modèle et de visualisation de classification basée sur les réseaux neurologiques adaptatifs
<i>SAO/CHF A. Hossen (2006)</i>	L'identification entre les patients et les sujets normaux était concentrée sur les deux maladies : SAO et CHF en utilisant les ondelettes et les réseaux de neurones.

3. Robustesse dans l'évaluation des performances

Les sources d'incertitude qui réduisent la capacité de maintenir la performance des résultats d'un groupe de patients à un autre sont nombreuses, y compris la variation chez un même patient, la diversité entre patients, la variété des cas qui impliquent différents facteurs de confusion pour chaque groupe, de même que l'instrumentation et les différents protocoles entre les centres cliniques. En conséquence, les études doivent clairement distinguer:

- Validation interne, où un échantillon prototype est employé pour traiter et accorder les paramètres modèles (échantillon d'essai)
- Validation temporelle utilisant des données postérieures du même centre hospitalier.

- Validation externe où les données viennent de centres hospitaliers complètement différents non concernées par la conception du modèle.

Tandis que les recherches de modélisation commencent par employer des données rétrospectives, les études exploratoires de la phase II exigent normalement des données prospectives et les essais cliniques de la phase III exigent l'application prospective du système à un grand nombre de sujets à travers de multiples centres.

Quand les dimensions des échantillons sont petites, la contre validation est parfois employée pour l'évaluation de la performance [Efron et al, 1997; Jain et al, 2000; Tibshirani, 1996]. Il peut être souligné que les revendications optimistes de performance sont une grande barrière à l'accueil des réseaux de neurones par la communauté médicale. Le choix variable rigoureux, ainsi que la régularisation appropriée, les repères et l'évaluation robuste de la performance rendront les résultats de recherche moins impressionnants mais plus significatifs.

Un aspect de l'évaluation des performances est l'analyse des résultats dans le cadre de la courbe de caractéristiques d'efficacité (ROC) [Hanley et al, 1982]. Ce qui n'est pas couramment fait est de séparer également l'effet de la prévalence des différentes maladies [Hilden, 2000], qui affecte de manière significative les évaluations de précision. La puissance prédictive peut être factorisée en combinant la sensibilité et la spécificité au seuil de décision de fonctionnement pour calculer l'amélioration du discriminateur sur la ligne d'estimation montrée dans équation 4.1.

4. Conclusion

Des réseaux de neurones artificiels ont été identifiés en tant que nouvelles tendances dans les statistiques médicales [Altman, 2000]. Les réseaux de neurones ont eu un impact clinique dans des secteurs spécifiques, la cytologie notamment cervicale et la détection précoce de l'IDM, où des études prospectives multi-centres à grande échelle ont été effectuées. Plus généralement, les développements rapides dans l'instrumentation, la communication et le stockage des données, garantissent que même les signaux les plus complexes deviendront couramment disponibles en forme numérique. Ces développements assureront que le rôle pratique pour l'aide au diagnostic automatisé dans la médecine continuera à se développer [Barach et al, 2000; Brennan et al, 1991; Kohn et al, 1999; Reason, 2000; Weingart et al, 2000; Wilson et al, 1995].

L'inférence de réseaux de neurones a été la plus utile pour fournir une visualisation pratique des signaux haute dimension. Sans compter leur rôle dans le soutien des prévisions fondées sur preuve et pour réduire la surcharge en information, les modèles non linéaires génériques sont également utiles dans l'analyse exploratoire des données en produisant des hypothèses au sujet des limites complexes qui peuvent être intégrées de façon contrôlée dans les modèles statistiques standard.

Il y a d'autres facteurs importants qui limitent généralement l'accueil des systèmes intelligents de diagnostic, à savoir la nécessité de concevoir des systèmes qui satisfont les besoins cliniques réels, et qui sont plus aisément intégrés dans l'environnement courant de la gestion des données [Shortliffe, 1993]. Sa réalisation a été le cachet des quelques applications réussies des réseaux neurones qui l'ont transformé en utilisation clinique courante.

Schwartz [Schwartz, 1970], prévu que vers l'année 2000 les ordinateurs « *auraient un rôle entièrement nouveau dans la médecine, agissant en extension puissante de l'intellect du médecin* ». Tandis que cette prévision est encore loin d'être une réalité pour les outils d'intelligence artificielle en consultation clinique générale, cela s'est réalisé pour l'instrumentation médicale. Lors de la dernière décennie, les systèmes interactifs d'aide au diagnostic par inférence ont commencé à s'imposer dans l'usage clinique courant sur une échelle significative.

A l'avenir le rôle des ordinateurs en médecine sera sensiblement étendu dans plusieurs directions. Cela ira de la gestion du patient à une sophistication plus grande des systèmes électroniques pour l'acquisition, le stockage, et la transmission de données stimulée par une acception progressive des normes d'industrie telles que les langages hautement extensibles, vers l'apparition des applications radicalement nouvelles en télémédecine et l'automédication. Dans le contexte global de la santé, l'aide au diagnostic est susceptible de devenir une nécessité plutôt que des frais supplémentaires facultatifs, tout à fait comme est avancée l'instrumentation électronique aujourd'hui.

Les réseaux de neurones doivent se faire une place dans l'appui du diagnostic clinique, mais leur succès dépend d'une meilleure intégration avec les protocoles cliniques, ainsi que de la conscience de la nécessité de combiner différents paradigmes afin de produire la structure de raisonnement globale la plus simple et la plus transparente, et de la volonté de l'évaluer dans des véritables environnements hospitaliers.

CHAPITRE 5 ALGORITHME DE DETECTION DU BLOC AURICULO VENTRICULAIRE

1. Introduction

Notre travail a été organisé en trois parties. La première consiste en l'étude de la population tandis que la seconde reste essentiellement liée à la préparation du signal numérique en vue d'optimiser son apport au réseau de neurone (CNN). Cette dernière partie se doit d'être minutieusement exécutée en raison de son impact sur le résultat final en l'occurrence en minimisant le bruit véhiculé par le signal numérique et en fournissant les vecteurs d'entrée appropriés au réseau CNN. Une troisième partie relève du traitement et des procédures d'interprétation employées par le CNN dans le processus de classification des modèles présentés. La structure générale de l'algorithme est présentée dans la figure 5.1.

2. Etude de la population

L'étude a été basée sur une seule dérivation notée à partir de patients ayant été soumis au diagnostic lors des trois dernières années. Les patients, des deux sexes, sont des adultes ayant des problèmes cardiaques aux symptômes connus. Ces patients ont été pris en charge avec le diagnostic BAV.

Les sujets sains sont choisis arbitrairement à partir d'une population urbaine. Les sujets ont été examinés et interrogés. Ils n'ont présenté aucune affection cardiaque connue ou soupçonnée, ou tout autre élément pathologique qui puisse influencer les caractéristiques de l'ECG. Les ECGs comportant des défaillances techniques graves ainsi que les ECGs avec des stimulateurs cardiaques (pacemakers) ont été exclus.

Plusieurs patients ont participé avec plus d'un ECG. Autrement dit, un patient présenté au service de cardiologie en deux ou trois différentes occasions peut avoir contribué par deux ou trois ECGs. Chaque diagnostic de prise en charge a été confirmé par un cardiologue au service de cardiologie.

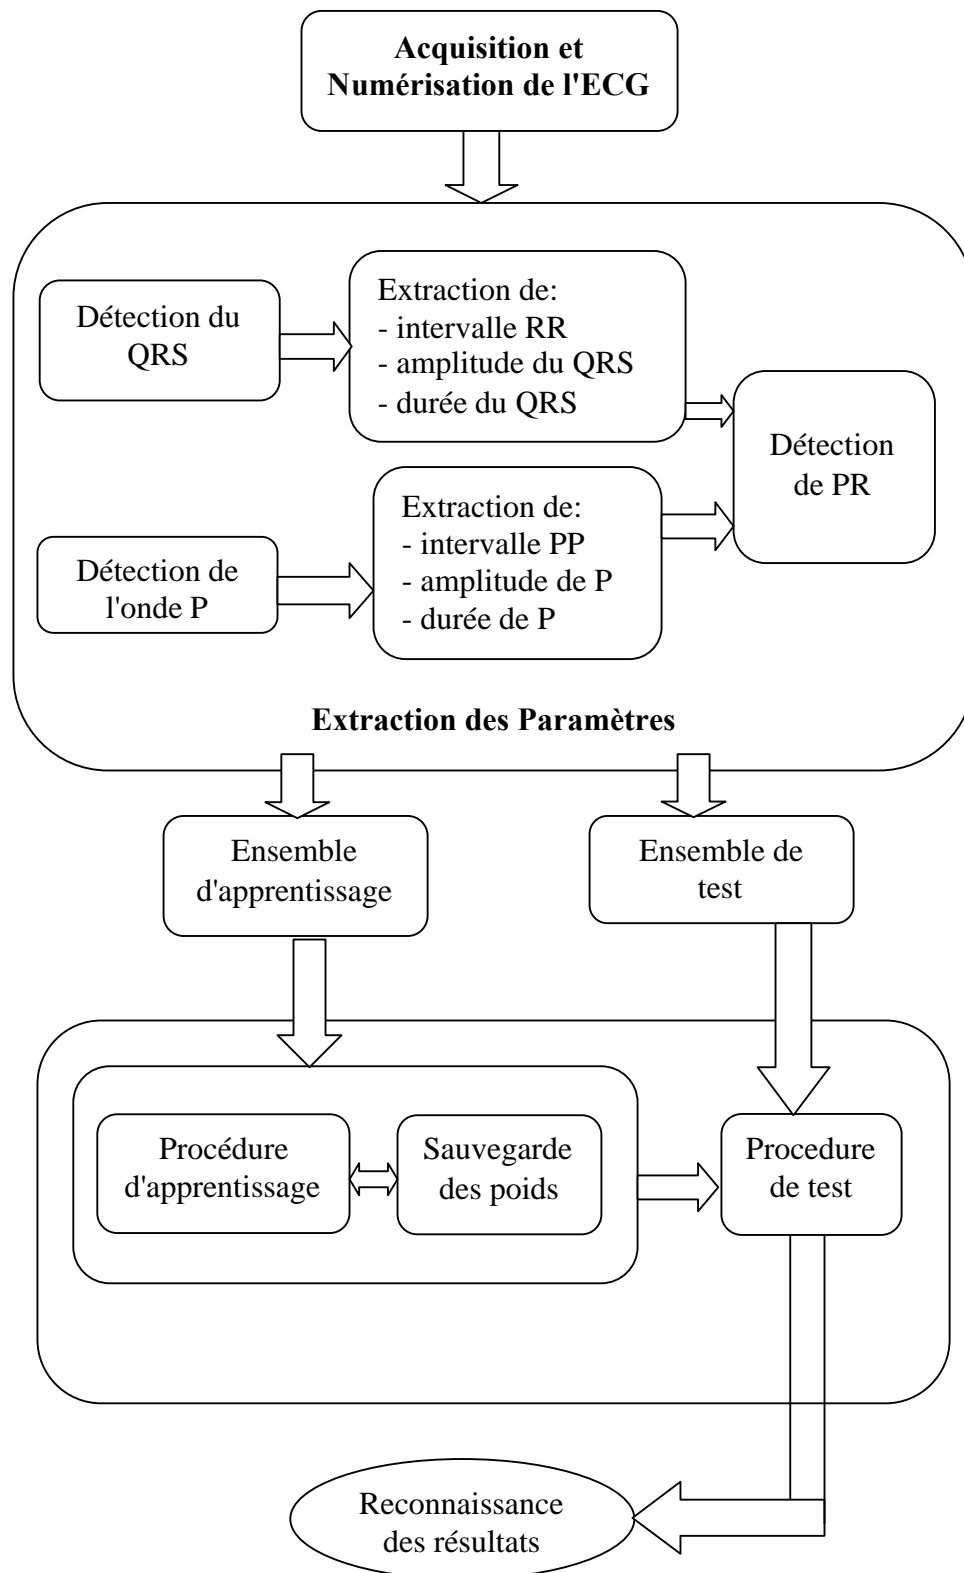


Figure 5.1 schéma global de l'algorithme.

Le groupe de BAV consiste en 108 ECGs enregistrés sur des hommes et 90 ECGs enregistrés sur des femmes. L'âge moyen est 51 ans. Le groupe normal est constitué de 73 ECGs

enregistrés sur des hommes et 60 ECGs enregistrés sur des femmes. L'âge moyen est de 48 ans. Ainsi, au total il y avait 331 ECGs.

3. *Extraction et acquisition des paramètres d'analyse des ECG*

Les définitions des mesures suivent les recommandations de l'action Européenne "Standards Communs pour Electrocardiographie Quantitative" CSE [CSE, 1985]. Les résultats sont les valeurs des amplitudes et des durées du complexe QRS, les amplitudes et les durées de l'onde P, les intervalles RR entre deux ondes R successives, les intervalles PP entre deux ondes P successives et les intervalles PR entre l'onde P et le complexe QRS. Ces paramètres ont été choisis car ils sont les critères conventionnels dans la détection d'un BAV dans un ECG et qui ont été mis en application comme entrées aux CNN.

4. *Détection du complexe QRS*

Dans le but de reconnaître des formes dans l'ECG, il est d'abord nécessaire de situer le complexe QRS qui est une forme ondulatoire importante qui apparaît dans la plupart des signaux normaux et anormaux.

L'une des caractéristiques les plus évidentes du complexe QRS est le grand pic de l'onde R. La détection de routine ne ferait que chercher un pic périodique. Toutefois, en raison du bruit présent lors de l'acquisition de l'ECG, cette technique va rendre des ondes faussées. En effet, un filtre sera nécessaire pour éliminer les artefacts et ajuster la ligne de base.

Le système emploie essentiellement un réseau de neurones pour une classification des ondes [Jeffrey et al, 2000]. Nous l'avons cependant adapté afin de réduire le temps de calcul et d'accélérer la vitesse de convergence. L'utilisation du réseau de neurones nous donne alors la meilleure fonctionnalité générale avec, bien sûr, d'autres algorithmes structurés considérés en second lieu pour mieux spécifier les caractéristiques du QRS.

4.1. *Architecture du réseau de neurones*

Le réseau choisi est un perceptron multicouche MLP (Multilayer Perceptron) possédant une couche de neurones cachée (le nombre de neurones cachés N_{cc} reste à déterminer). Les entrées du réseau sont au nombre de 30 représentés par les échantillons d'un fragment du signal ECG. Les neurones dans la couche d'entrée effectuent seulement une fonction de tampons qui distribuent les échantillons d'entrée aux neurones de la couche cachée. Chaque neurone au niveau de la couche cachée additionne ses échantillons après les avoir multipliés avec les poids des connexions respectives à partir de la couche d'entrée, et fait l'estimation de sa sortie en appliquant la fonction d'activation à la somme calculée. La sortie est représentée par un neurone unique. Les fonctions d'activation des neurones cachés et du neurone de sortie sont des sigmoïdes.

Une structure générale du réseau de neurones est illustrée dans la figure 5.2.




Figure 5.2. Le Perceptron multicouche (MLP) pour la détection du QRS.

4.2. Déroulement de l'apprentissage

L'apprentissage est réalisé par la minimisation d'une fonction de coût choisie ici comme l'erreur quadratique moyenne sur la sortie. L'algorithme d'apprentissage choisi c'est la retropropagation.

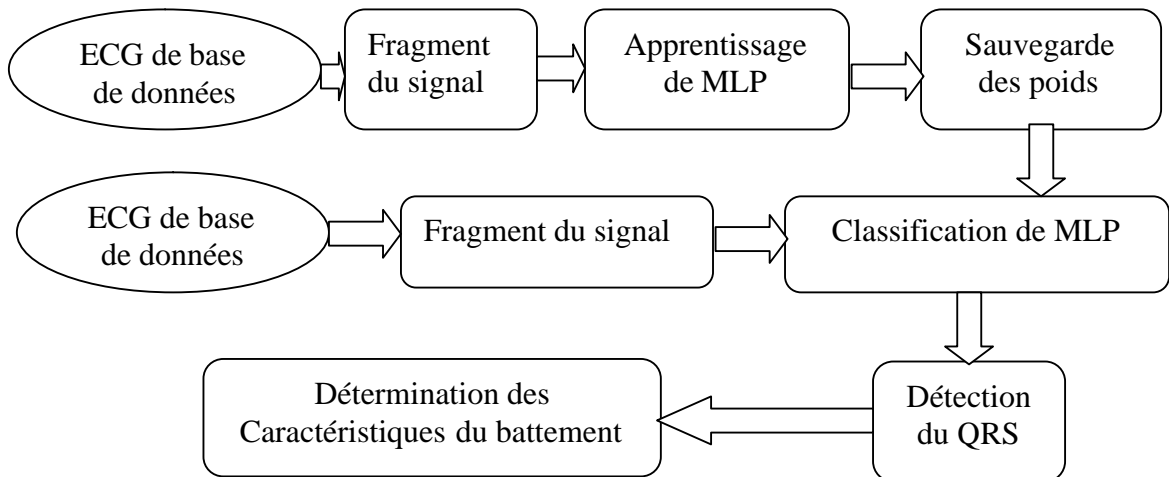


Figure 5.3. Diagramme de détection du QRS.

Le principe de la rétropropagation consiste à présenter au réseau le vecteur d'entrées des 30 échantillons d'un fragment du signal ECG, de procéder au calcul de la sortie par propagation à travers les couches, de la couche d'entrée vers la couche de sortie en passant par la couche cachée. Cette sortie obtenue est comparée à la sortie désirée, une erreur est alors obtenue. A partir de cette erreur, est calculé l'erreur qui est à son tour propagée de la couche de sortie vers la couche d'entrée, d'où le terme de rétropropagation. Cette technique permet la modification et l'ajustement des poids du réseau. L'opération est réitérée pour chaque vecteur d'entrée et ce, jusqu'à ce qu'un des critères d'arrêt soit vérifié.

Notons que la phase d'apprentissage va s'arrêter sous l'une des conditions suivantes:

- L'erreur est inférieure à 10^{-25} .
- Le nombre d'itérations maximum (10^5) est atteint.

Afin de déterminer le nombre optimal de neurones cachés (N_{cc}) nous allons effectuer des apprentissages pour différentes architectures: pour chacune de ces architectures, nous effectuons 20 différentes initialisations des paramètres, ce qui conduit à 20 modèles par architecture.

Une base de validation nous permet de choisir parmi l'ensemble de ces architectures celle qui est la plus adaptée à notre problème. Pour un nombre de neurones cachés N_{cc} fixé, nous avons réalisé 20 apprentissages successifs avec des initialisations différentes des paramètres du réseau.

Nous sélectionnons ici le meilleur réseau pour N_{cc} fixé parmi les 20 initialisations. Nous constatons que plus le nombre de neurones cachés est important, plus le nombre d'exemples bien classés est grand. Pour éviter le surajustement, nous avons choisi un N_{cc} optimal à partir de la base de validation. Les résultats obtenus par les réseaux sélectionnés précédemment sur la base d'apprentissage nous permet de donner le meilleur résultat pour un $N_{cc}=10$.

4.3. Performance

Pour juger de la qualité d'un algorithme de ce type, trois grandeurs sont habituellement mesurées :

- NTA (Nombre Total Analysé) : c'est le nombre de battements analysés par l'algorithme.
- FP (faux positifs) : c'est le nombre d'ondes R qui ont été détectées par l'algorithme alors qu'elles ne font pas partie de cette catégorie: ces erreurs peuvent correspondre à des emplacements repérés par l'algorithme alors qu'il n'y avait aucune onde caractéristique, ou encore à une onde repérée comme R alors qu'il s'agit d'une autre onde caractéristique.
- FN (faux négatifs) : c'est le nombre d'ondes étiquetées R que l'algorithme n'a pu détecter.

Chaque analyse a été effectuée en deux étapes. Dans ce qui suit nous présentons les résultats obtenus en fin d'étape. Les tracés utilisés dans cette partie ont été sélectionnés de la base de données MIT [MIT-BIH].

La première étape correspond à analyser la totalité de chaque enregistrement: les annotations issues de l'algorithme sont comparées à celles des fichiers de référence et les erreurs sont comptabilisées. C'est l'étape « sans analyse du bruit ».

Par opposition, la seconde étape est l'analyse « avec analyse du bruit » : dans ce cas, on ne comptabilise pas, dans les erreurs, les annotations issues de zones trop bruitées. Ces zones sont identifiées de manière automatique pendant l'analyse. C'est cette dernière analyse qui est utilisée par la suite, car il est primordial de repérer les zones trop bruitées pour ne pas les analyser. Les tables 5.1 et 5.2 présentent les valeurs des trois grandeurs (NTA, FP et FN) obtenues lors de l'analyse de quelques enregistrements, ainsi que le résultat de la bonne détection du QRS.

Table 5.1. Valeurs du traitement sans l'analyse du bruit.

Enregistrement	NTA	FP	FN	Sensibilité
0103	1000	0	1	99.90%
0105	1000	15	3	98.20%
0107	1000	0	2	99.80%
0111	1000	0	1	99.90%
0115	1000	1	1	99.80%
0119	1000	0	1	99.90%
0121	1000	0	2	99.80%
0123	1000	0	1	99.90%
0203	1000	36	6	95.80%
0205	1000	0	1	99.90%
0212	1000	0	1	99.90%
0214	1000	1	1	99.80%

Table 5.2. Valeurs du traitement avec l'analyse du bruit.

Enregistrement	NTA	FP	FN	Sensibilité
0103	1000	0	0	100%
0105	1000	8	2	99.00%
0107	1000	0	1	99.90%
0111	1000	0	0	100%
0115	1000	0	0	100%
0119	1000	0	0	100%
0121	1000	0	0	100%
0123	1000	0	0	100%
0203	1000	33	6	96.10%
0205	1000	0	0	100%
0211	1000	0	0	100%
0213	1000	0	0	100%

4.4. Mesure du complexe QRS

Lors de la détection du complexe QRS, nous avons mémorisé, un certain nombre de paramètres, notamment les intervalles *RR* du représentant avec le battement qui le suit (*RRs*) et le battement qui le précède (*RRp*). On mémorise aussi le rythme *RR*. Une fois que le QRS est détecté et localisé, d'autres caractéristiques du battement sont déterminées en utilisant d'autres algorithmes : L'amplitude du QRS de part et d'autre de la ligne de base sur chacune des pistes valides de l'enregistrement. Ainsi, nous avons calculé la durée du complexe en déterminant le onset et l'offset du complexe. Un paramètre utile, le repos qui précède l'onde Q, est mémorisé.

5. Détection de l'onde P

L'onde P est identifiée après la reconnaissance des autres paramètres de l'ECG, à savoir le complexe QRS et l'onde T.

Nous procédons de la même manière que pour la détection du complexe QRS. Ainsi, un MLP de trois couches (une couche d'entrée avec 20 neurones, une seule couche de sortie et une couche cachée de 7 neurones) est envisagé. Ensuite, un ensemble de paramètres sont calculés afin de spécifier l'onde P (durée de P, amplitude de P et intervalle PP) par l'emploi d'autres algorithmes structurés.

6. Réseau de Neurones CNN

Le modèle neuronal étudié pour la détection du BAV est un réseau hybride appelé CNN (Compound Neural Network). Il est formé à partir de trois réseaux de neurones de type statique multicouches. Deux de ces réseaux de neurones RN1 et RN2 sont placés en configuration parallèle, en série avec le troisième réseau RN3. Le schéma de la figure 5.5 montre une telle structure, employée pour la classification de l'ECG reconnu normal ou portant un BAV.

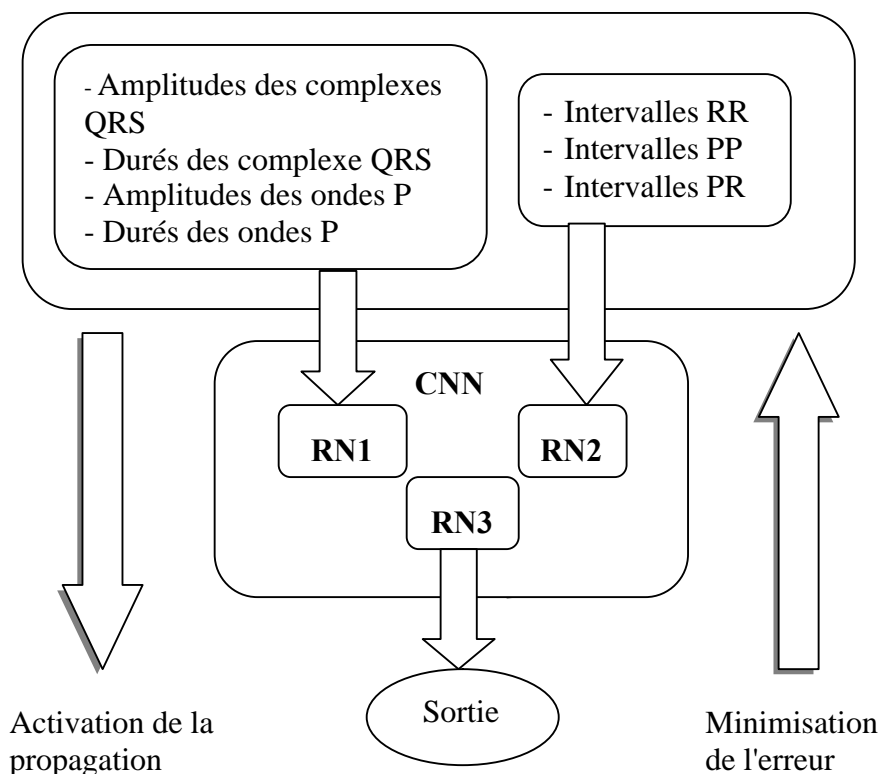


Figure 5.5. Structure Générale du réseau de neurones CNN.

Le réseau RN1 lui-même inclut trois couches telles que représentées dans la figure 5.6. Vingt paramètres sont injectés dans la couche d'entrée. Ces paramètres sont :

- Cinq valeurs successives des amplitudes des complexes QRS.
- Cinq valeurs successives des durées des complexes QRS.
- Cinq valeurs successives des amplitudes des ondes P.
- Cinq valeurs successives des durées des ondes P.

Le choix de cinq valeurs successives de chaque paramètre est nécessaire car, pour donner un diagnostic correct à partir d'un ECG, les cliniciens exigent que l'interprétation se fasse sur quatre battements successifs.

La couche cachée a cinq neurones. Ce nombre est empiriquement choisi pour éviter les problèmes de répétition et pour optimiser le temps de traitement. Quant à la troisième couche, un seul neurone est utilisé. Cette sortie est injectée comme entrée au réseau RN3.

Le réseau de neurones RN2 est également un réseau statique à trois couches. Quinze entrées forment la première couche:

- Cinq valeurs successives des intervalles PR.
- Cinq valeurs successives des intervalles RR.
- Cinq valeurs successives des intervalles PP.

La couche cachée possède trois neurones tandis que la dernière couche, constituée d'un seul neurone, représente en même temps une entrée pour le réseau RN3.

Le dernier réseau RN3 n'est formé que de deux couches dont la couche d'entrée est un destinataire pour les sorties RN1 et RN2. Un seul résultat de sortie fournit la probabilité d'occurrence d'un BAV dans le tracé ECG.




Figure 5.6 Structure du premier réseau de neurones RN1.

7. Conception de la méthode

Les données expérimentales acquises ont été subdivisées en deux ensembles : Un ensemble pour l'apprentissage et un ensemble pour le test. Un tiers des données de l'ECG dans chacun des groupes normaux et des groupes présentant un BAV ont été choisis aléatoirement pour l'ensemble d'apprentissage. Ce dernier a été employé pour ajuster les poids entre les connexions des neurones, tandis que l'ensemble du test a été utilisé pour évaluer la performance du CNN. Une triple cross-validation est utilisée afin de décider de la fin de traitement pour prévenir l'over-training, pour l'apprentissage du réseau et l'évaluation de sa

performance. L'apprentissage est arrêté lorsqu'un minimum est atteint, soit en fonction du critère d'arrêt sur la fonction de coût, soit sur la valeur minimale de la norme du gradient, ou encore lorsque la valeur maximale du nombre d'itération est atteinte.

Une fois que le nombre de couches ainsi que les unités dans chaque couche aient été choisis, les poids du réseau doivent être disposés de façon à minimiser l'erreur issue du réseau. C'est le rôle des algorithmes d'apprentissage.

7.1. Apprentissage

Les poids du CNN ont été ajustés par l'algorithme de Levenberg-Marquardt (LM) [More, 1977]. C'est un algorithme de la famille quasi-Newton qui est un standard pour l'optimisation de l'erreur quadratique grâce à ses propriétés de convergence rapide et de sa robustesse. Cette approche s'appuie sur les techniques des moindres carrés non linéaires ou Mean Square Error (MSE) et de l'algorithme de Gauss-Newton à voisinage restreint.

$$MSE = \frac{1}{N} \sum_1^N E_i^2 \tag{5.1}$$

Où E représente le vecteur des erreurs du CNN

$$E = output_D - output \tag{5.2}$$

$output_D$ est la valeur désirée et $output$ est la sortie du CNN.

La principale motivation du choix de l'algorithme de LM repose sur la taille de la matrice du Hessien en fonction de la quantité de données de la base d'apprentissage, du coût moindre des calculs et de la garantie rapide de la convergence vers un minimum. LM entraîne le CNN de la même manière que l'algorithme de retropropagation. Son utilisation se limite seulement aux réseaux à simple unité de sortie ainsi qu'à ceux à taille modérée (quelques centaines de poids).

L'algorithme a été conçu pour approcher le gradient du second ordre de l'apprentissage sans avoir à calculer la matrice Hessienne. La matrice Hessienne H peut être approximée comme :

$$H = J^T J + \eta I \tag{5.3}$$

Et le gradient G peut être calculé comme :

$$G = J^T E \tag{5.4}$$

J est la matrice de Jacobi. Elle contient les dérivées premières des erreurs du CNN en tenant compte des poids et des biais. Le Jacobien est beaucoup moins complexe que le calcul du Hessien.

L'algorithme emploie cette approximation à la matrice Hessianne dans Newton comme suit:

$$W_{k+1} = W_k - [J^T J + \eta I]^{-1} J^T E \quad (5)$$

W_{k+1} : Valeur du vecteur poids à l'étape (k+1) après l'ajustement.

W_k : Valeur du vecteur poids à l'étape (k) avant l'ajustement.

I : Matrice identité.

η : Facteur d'apprentissage.

Le premier terme de l'équation 5.5 représente la supposition linéaire alors que le second une étape de la méthode de descente du gradient (GD).

Ainsi, quand le taux du facteur d'apprentissage est zéro, on retrouve la méthode de Newton, en utilisant la matrice Hessienne.

Le CNN emploie la fonction sigmoïde $f(x)$ comme fonction de transfert.

$$f(x) = \frac{1}{1 + e^{-x + \text{biais}}} \quad 5.6$$

x : le vecteur d'une couche n, est défini comme :

$$x = \sum_i^N a_i W_i \quad 5.7$$

Où :

a_i : représentent les entrées et W_i : représentent les poids.

Cette fonction comprime un rang infini d'entrées en une valeur finie de sorties. Les fonctions sigmoïdes sont caractérisées par le fait que leurs pentes doivent être proche du zéro pendant que l'entrée est grande. Ainsi la sortie se trouve entre 0 et 1. Elles ont l'avantage de fournir une forme de commande de gain automatique, d'autant plus que sa dérivée est simple à calculer (figure 5.7).




Figure 5.7. La fonction sigmoïde choisie pour le calcul des neurones.

Le taux du facteur d'apprentissage η est initialisé à 0.5. Pendant le traitement η a été réduit.

Les poids du CNN ont été initialisés avec des valeurs aléatoires appartenant à l'intervalle [-0.025 et 0.025]. Pour les réseaux RN1 et RN2 un biais constant est ajouté à toutes les couches cachées permettant de ce fait une convergence plus rapide du processus d'apprentissage et évitant la confusion dans la classification.

7.2. Usage de la mémoire

L'usage de la mémoire pour une seule forme d'onde n'était pas grand. Il était de 24 KB approximativement. La plus grande source d'utilisation de mémoire se situe dans le stockage de toutes les formes d'onde et des poids pendant l'apprentissage. Les poids et les biais sont stockés en tant que nombres réels à virgule flottante.

La taille Z de la matrice de Jacobi est:

$$Z = Q * n \tag{5.9}$$

Où Q est le nombre d'itérations pendant l'apprentissage du CNN et n est le nombre de poids et des biais.

Pour les valeurs maximales de $Q=10^5$ et $n = 166$ (158 poids et 8 biais), Z devient :

$$Z = 166 * 10^5.$$

Par conséquent, le Jacobien entier ne peut pas exister dans la mémoire en même temps. Comme palliatif à ce problème nous avons calculé le Hessien approximé en additionnant une série de sous termes comme indiqué ci-dessous :

$$H = J^T J = [J_1^T J_2^T \dots J_m^T]^* \begin{bmatrix} J_1 \\ J_2 \\ \vdots \\ J_m \end{bmatrix} = J_1^T J_1 + J_2^T J_2 \dots + J_m^T J_m \tag{5.10}$$

Une fois qu'un sous terme est calculé, la sous matrice correspondant du Jacobien s'efface de la mémoire.

Tout d'abord, nous déterminons le rang du Jacobien qui doit être calculé dans chaque sous matrice. Dans notre cas, il est préférable de choisir le rang 2. Le Jacobien est divisible en deux sous matrices égales. La matrice Hessienne a été calculée comme suit:

$$H = J^T J = [J_1^T J_2^T]^* \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = J_1^T J_1 + J_2^T J_2 \tag{5.11}$$

Seule la moitié de la matrice jacobienne J est calculée en même temps. Cette façon de procéder économise une partie de la mémoire utilisée dans le calcul du Jacobien entier. Ce qui rend la mémoire suffisante pour le stockage et l'apprentissage.

Les résultats prouvent que cette technique réduit le temps de calcul et l'erreur de sortie. L'apprentissage a été terminé à une erreur de 10^{-25} (Figure 5.8).

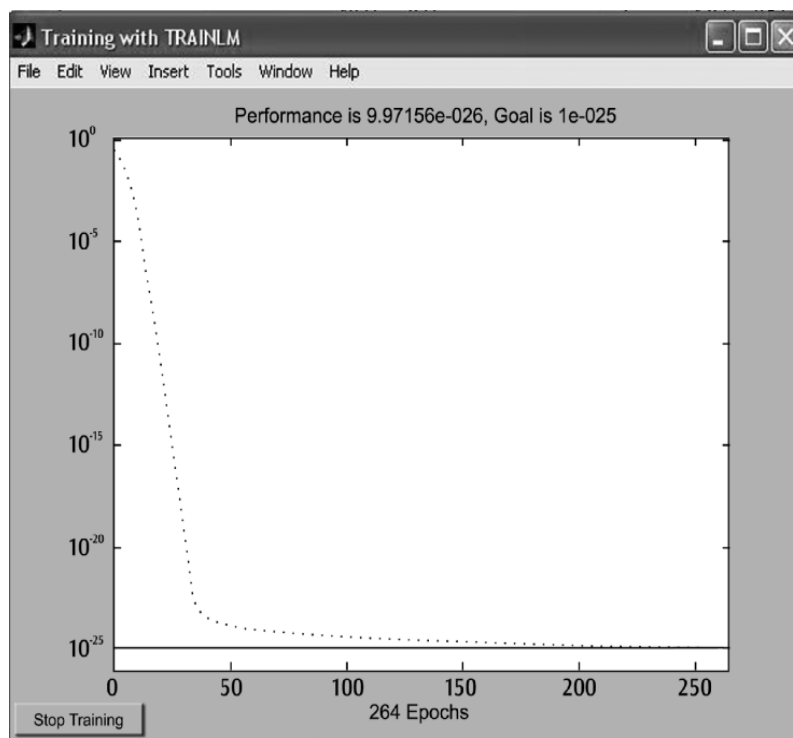


Figure.5.8. courbe d'apprentissage en utilisant l'algorithme de Levenberg-Marquardt (ligne brisée). Le but est terminé à une erreur d'apprentissage de 10^{-25} (en trait plein).

7.3. Performance et Évaluation d'exécution du CNN

7.3.1. Estimation de la sensibilité et de la spécificité

Afin de vérifier la performance du classificateur, nous avons appliqué trois lois statistiques basées sur la reconnaissance des catégories mutuellement exclusives de :

- T_n (normal vrai) est le nombre d'ECGs normaux identifiés en tant que normal.
- T_{BAV} (BAV vrai) est le nombre d'ECGs portant un BAV identifiés comme BAV.
- F_n (normal faux) est le nombre de BAV portés par l'ECG identifiés en tant que normal.
- F_{BAV} (BAV faux) est le nombre d'ECGs normaux identifiés en tant qu'un BAV.

Ces lois sont la sensibilité, la spécificité et la précision (accuracy).

La sensibilité indique la capacité d'un classificateur à détecter des formes négatives (sujets normaux.). C'est la fraction des cas réels normaux correctement reconnus sur tous les cas réels normaux.

$$sensibilité = \frac{T_n}{T_n + F_{BAV}} 100$$

5.12

La spécificité représente la capacité d'un classificateur les cas positifs (sujets avec BAV) C'est la fraction des cas réels portant un BAV correctement reconnu sur tous les cas réels portant un BAV.

$$spécificité = \frac{T_{BAV}}{T_{BAV} + F_n} 100$$

5.13

La précision (accuracy) représente la performance globale du classificateur. Elle indique le pourcentage des formes positives et négatives correctement classifiées de tous les cas.

$$accuracy = \frac{T_{AVB} + T_n}{T_{AVB} + F_n + T_n + F_{AVB}} 100$$

5.14

7.3.2. Courbes ROC

a) Définition

Les courbes ROC (Receiver Operating Characteristic) [Hanley et al, 1982] sont des techniques graphiques qui permettent d'étudier les variations de la spécificité et de la sensibilité d'un test pour différentes valeurs du seuil de discrimination. Le terme de courbe ROC peut être envisagé comme une "*courbe de caractéristiques d'efficacité*".

b) Construction de la courbe

On porte sur l'axe des abscisses, la variable '1-spécificité' et sur l'axe des ordonnées, on retrouve la sensibilité. La courbe se construit de façon empirique en calculant la sensibilité puis la spécificité d'un test pour différents niveaux de seuils de discrimination. Dans la figure.5.9, la courbe est tracée à partir de l'exemple des seuils de discriminations.

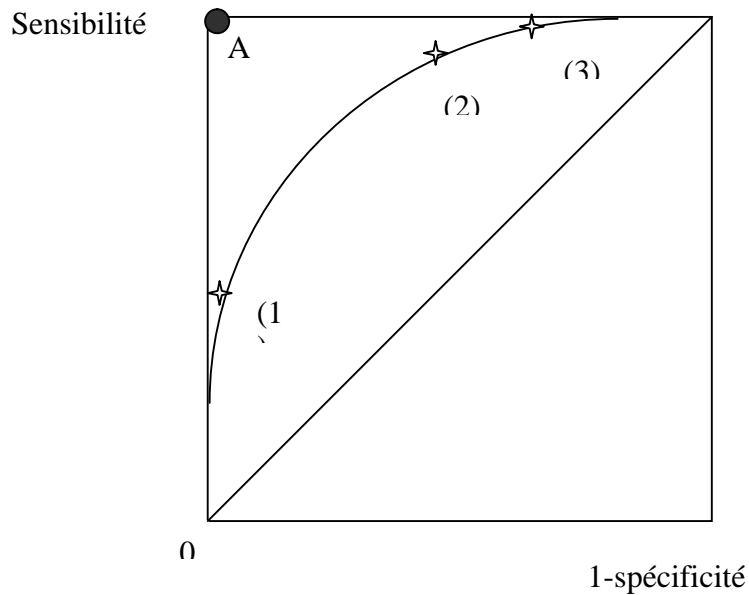


Figure 5.9. Courbe R.O.C.

c) seuil

Un *seuil* est *idéal* s'il permet de séparer totalement tous les positifs des négatifs, sans faux positifs, ni faux négatifs. Il est donc défini par une sensibilité et une spécificité égales à 1. C'est donc le point A situé dans l'angle en haut et à gauche de la figure 5.9.

Pour un test *non informatif*, on se situe sur la diagonale qui passe par le point 0. La courbe ROC correspondante est donc représentée par la diagonale de la figure 5.9. Un test sera donc d'autant meilleur que sa courbe se situera proche du point A et loin de la diagonale.

d) Aire sous la courbe

L'*aire sous la courbe ROC* est un estimateur de l'*efficacité globale* du test ; si le test n'est pas informatif, l'aire est de 1/2. Si le test est parfaitement discriminatif, l'aire sera de 1. On peut montrer que cette aire correspond à la probabilité que le résultat au test d'un sujet malade soit supérieur à celui d'un sujet non-malade.

Il existe différentes méthodes d'approximation de cette aire dont celle de Hanley qui n'est pas paramétrique en ce sens qu'elle ne nécessite pas d'approximation statistique sur la courbe. Elle est fondée sur un calcul de rang. La méthodologie adéquate fait encore l'objet de travaux de recherche [James et al; Wehrens et al, 2000].

8. Résultats et discussion

La technique décrite ci-dessus a été appliquée en utilisant un grand nombre de morphologies d'ECG. Ces ECGs ont été collectés à partir de patients ayant des atteintes de conduction auriculo-ventriculaire et de sujet sains et sur la base de 35% des données disponibles sont

utilisées pour l'apprentissage, et de 65% pour le test, nous avons constaté que 60% des ECGs analysés étaient étiquetés pathologiques (porteurs de BAV).

Table 5.3. valeurs statistiques concernant l'étude de population.

	ECG avec BAV	ECG Normal	Total
Population	198	133	331
Ensemble d'apprentissage	69	47	116
Ensemble de test	129	86	215

La table montre la distribution détaillée des données expérimentales en utilisant un ensemble d'apprentissage et un ensemble de test. 35% des données d'ECG dans chacun des groupes de BAV et normal ont été choisies pour l'ensemble d'apprentissage et 65% pour l'ensemble de test.

En effet, l'exécution du classificateur a été évaluée en utilisant l'ensemble de test comportant 215 patients aléatoirement choisis de toute la population de 331 cas. Cet ensemble de test ne faisait partie d'aucun cas utilisé dans la conception du modèle de l'algorithme (apprentissage). Pour chaque cas dans l'ensemble de test, le réseau de neurones CNN présente une valeur de sortie entre 0 et 1. Nous avons employé un seuil dans cet intervalle où toutes valeurs au-dessus ont été considérées comme conforme à un BAV. Les ECGs avec des valeurs de sortie proche de 1 indiquent une marque de BAV et de ceux avec des valeurs de sortie proche de 0 sont normaux.

La sensibilité et la spécificité pour différents seuils ont été étudiées afin d'obtenir une courbe ROC des caractéristiques d'efficacité du réseau. Les résultats présentent la performance globale du réseau. La performance du classificateur CNN a été mesurée comme l'aire qui se situe sous la courbe de ROC (figure 5.10).

L'algorithme développé est très rapide tant dans l'apprentissage que dans l'exécution des tests. Cette performance est due principalement à l'application de cette nouvelle architecture de réseaux de neurones et le fait qu'on fasse appel à une quantité d'information minimale, en appliquant l'algorithme pour une seule dérivation du signal ECG, ce qui réduit considérablement la quantité de données exigées pour le traitement.

Les résultats montrent que le CNN se caractérise par une haute performance dans la détection de présence de BAVs dans un ECG. Pour un seuil de 0,1 (Une valeur entre 0,1 et 1 étant la sortie désirée pour la présence d'un BAV et une valeur tombant en dehors de cette gamme, autrement dit, de 0 jusqu'à 0,1 pour un ECG normal.). Sa sensibilité et sa spécificité approchent respectivement 92,31 % et 98,39%. La valeur de sa précision est de 95,81%.

Quelques exemples d'applications, aléatoirement choisis, et correctement détectés par le CNN sont représentés dans la figure 5.11. L'application de la technique diagnostic appliquée aux mêmes ECGs donne les résultats indiqués sur la table 5.4.

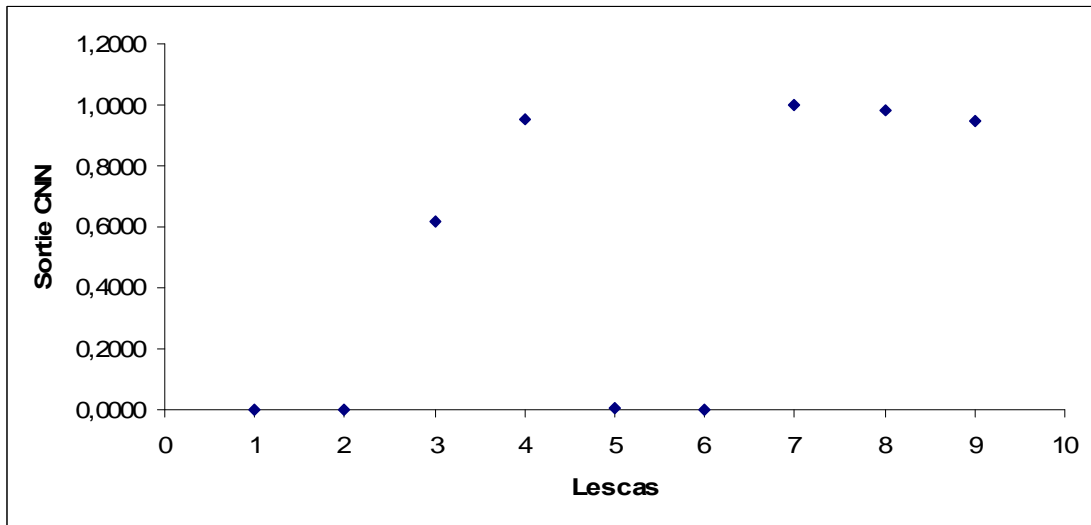


Figure 5.11. Diagramme des valeurs de sortie du CNN en utilisant les mesures de dix données.

Un groupe de 7 cas ont été incorrectement classifiés par le CNN. Tous ces ECGs ont des complexes QRS avec des encoches anormales. Certains ECGs ont des ondes R à amplitude décroissante; les autres ont de larges complexes.

Sept valeurs de sortie du CNN du groupe incorrectement classifié sont présentées dans la figure 5.12 et la table 5.5.




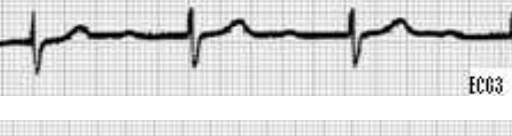

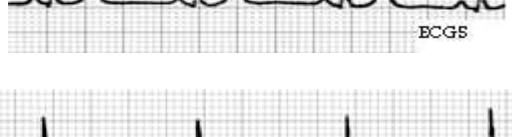
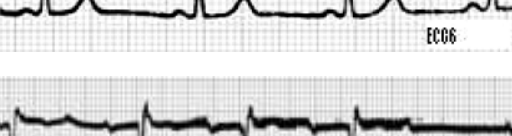
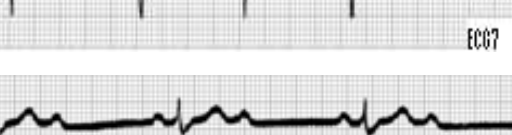
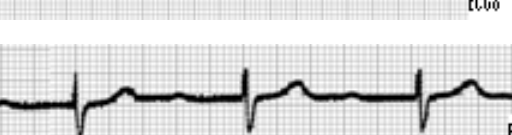
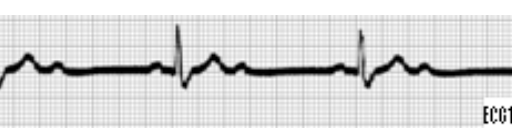
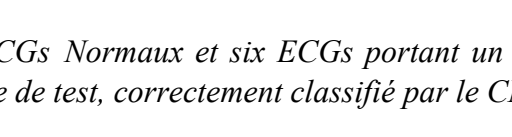


Figure 5.12. Diagramme des valeurs de sortie du CNN des mesures des sept données incorrectement classifiées.

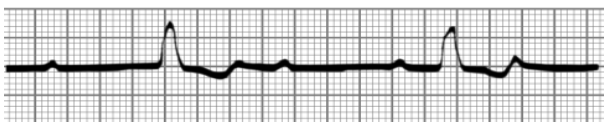
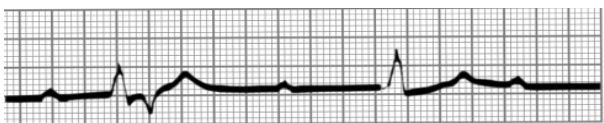
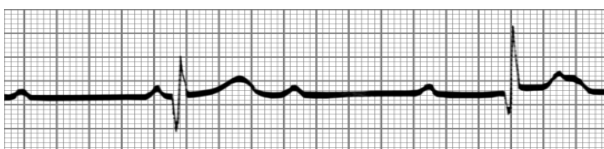
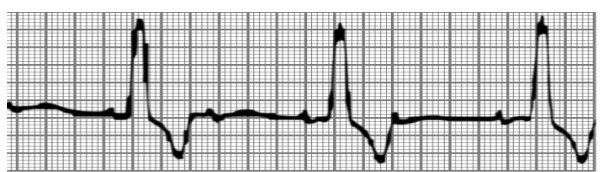
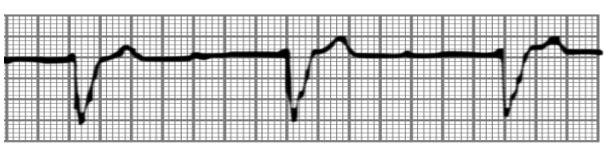
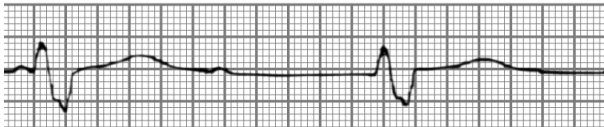
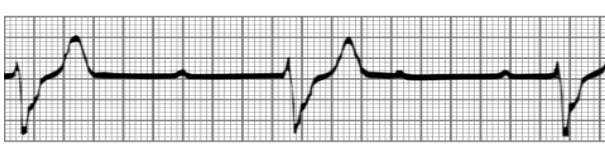
Table 5.4: Résultats concernant dix ECGs aléatoirement choisis de l'ensemble de test.

ECG	TRACÉ	Sortie du CNN	Cardiologue
ECG ₁		0.0000	Normal
ECG ₂		0.0006	Normal
ECG ₃		0.6200	BAV
ECG ₄		0.9505	BAV
ECG ₅		0.0080	Normal
ECG ₆		0.0010	Normal
ECG ₇		1.0000	BAV
ECG ₈		0.9800	BAV
ECG ₉		0.9500	BAV
ECG ₁₀		0.9000	BAV

Quatre ECGs Normaux et six ECGs portant un BAV, aléatoirement choisis de l'ensemble de test, correctement classifié par le CNN

La décroissance progressive de l'onde R trouvée dans l'ECG 13 de la table 5.5 n'était pas une information commune pour le matériel. Par conséquent, ce modèle pourrait être difficile pour le réseau. Les ECGs 14, 15, 16 et 17 ont de large QRS. Cette information n'est pas fournie au réseau. Le traitement utilisait seulement la résolution normale du complexe QRS. La classification donnée par le CNN n'est pas donc surprenante. Nous pensons qu'un système expert pourrait être combiné au CNN pour venir à bout de ce problème.

Table 5.5: Résultats des ECGs du groupe incorrectement classifiés par le CNN.

ECG	TRACÉ	SORTIE DU CNN	CARDIOLOGUE
ECG ₁₁		0.0353.	BAV
ECG ₁₂		0.0386	BAV
ECG ₁₃		0.0400	BAV
ECG ₁₄		0.0389	BAV
ECG ₁₅		0.0650	BAV
ECG ₁₆		0.0653	BAV
ECG ₁₇		0.0700	BAV

- a) ECG 11 et ECG 12 sont des ECGs avec des complexes QRS anormaux.
 b) ECG 13 est un ECG avec une décroissance progressive de l'onde R.
 c) ECG 14 et ECG 15 sont des ECGs avec un large QRS.
 d) ECG 16 et ECG17 sont des ECGs avec de très larges QRS.

9. Conclusion

Cette étude montre que les réseaux de neurones peuvent apporter un soutien appréciable dans la prise de diagnostic quant à la détection de BAV dans un ECG. Les réseaux de neurones s'avèrent également très efficaces lorsqu'il s'agit de procéder à une classification des signaux ECG. Ces résultats sont d'autant plus intéressants que globalement, le temps de calcul n'est pas à proprement dit contraignant sachant que la génération des poids ne requiert que quelques minutes, la vérification séquentielle est très rapide et que le temps de détection des BAV avoisine les deux secondes.

CONCLUSION

L'objectif assigné à ce travail consiste à mettre à la disposition du médecin un outil d'aide dans la prise de décision quant au diagnostic d'une présence possible de BAV.

Dans cette perspective, nous avons développé un programme de diagnostic automatique basé sur un réseau de neurones hybride (CNN) ayant une capacité de discrimination entre les situations de présence et d'absence d'un BAV. Cette discrimination se fait par référence à une valeur de comparaison obtenue par application de l'algorithme en question après une construction d'une base de données significatif.

L'application expérimentale de cette méthode sur un grand nombre d'ECG utilisant une seule dérivation permet une confirmation de la validité et de la fiabilité de la technique. La performance a été comparée avec celui d'un cardiologue expérimenté. Aucune différence significative n'a été relevée. La spécificité et la sensibilité étaient de 92,31 % et 98,39% pour un seuil de 0.1.

Les résultats prouvent que le réseau CNN peut être employé pour améliorer l'interprétation automatisée d'ECG pour la détection de BAV et un médecin pourrait employer cette approche comme appui à la prise de diagnostic.

Le réseau de neurones de la présente étude peut être incorporé dans des programmes sur ordinateur d'interprétation d'ECG et peut détecter dans l'ECG au moyen des variables d'entrée de mesure la présence d'un BAV. L'avantage avec ce type d'entrées est que la même exécution pourrait être prévue quand le réseau est employé dans des centres hospitaliers ou ambulatoires.

Cette étude indique que les réseaux de neurones peuvent être utiles comme soutien de prise de diagnostic. Ils ont montré qu'ils sont des dispositifs très intéressants pour la reconnaissance des formes et très efficaces pour la classification des signaux ECG.

Références Bibliographiques

- [Abdulnasir, 2006] Abdulnasir H., "*Biomedical Signals Classification Intelligent Systems*", Proc. CSIT Jordan, 2006.
- [Alliot et al, 1992] Alliot JM et Schiex T. "*Intelligence Artificielle et Informatique Théorique*." Cepadues, ISBN: 2-85428-324-4; 1992.
- [Alliot et al, 1997] Alliot J.-M. and Schiex T., Thomas Schiex, "*Intelligence Artificielle & Informatique Théorique*". Année p 3-11; 1997.
- [Alliot et al, 2002] Alliot J.M., Schiex T., Brisset P. et Garcia F. "*Intelligence Artificielle et Informatique théorique*." Cépadues Editions, Toulouse, France; 2002.
- [Altman, 2000] Altman, D. G. "*Statistics in medical journals: some recent trends*." *Stat. Med.*, 19, 3275-3289, 2000.
- [Anderson, 1997] Anderson J.A.; "*Brain modeling and memory*." In: X.J.R. Avula (Ed.), *Proceedings of the First International Conference on Mathematical Modeling*. (Invited paper). Rolla, Missouri: University of Missouri, 1977.
- [Andreassen et al; 1998] Anderson, C. W., Stolz, E. A., & Shamsunder, S. "*Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks*." *IEEE Biomed. Eng.*, 45 (3), 277-286. 1998.
- [Andreassen et al; 1994] Andreassen, S., Benn, J. J., Hovorka, R., Olesen, K. G., & Carson, E. R. A "*probabilistic approach to glucose prediction and insulin dose adjustment - description of a metabolic model and pilot evaluation study*." *Comp. Meth. Prog. in Biomed.*, 41, 153-166. 1994.
- [Asch et al, 1999] Asch G. & al, "*Acquisition de données, du capteur à l'ordinateur*", Dunod, Paris, 1999
- [Bahoura et al, 1997] Bahoura M., Hassani M., Lee S-G., Hubin M., "*Modification de la méthode de Widrow pour l'élimination de l'interférence 50Hz du signal ECG*," *Innov.Tech.Biol.Med.*,18 (2), pp 119-127. 1997.
- [Bakken et al, 1999] Bakken, I. J., Axelson, D., Kvistad, K. A., Brodtkorb, E., Muller, B., Aasly, J., Gribbestad, I. S. "*Applications of neural network analyses to in vivo 1H magnetic resonance spectroscopy of epilepsy patients*." *Epilepsy Res.*, 35 (3), pp 245-252. 1999.
- [Barach et al, 2000] Barach, P., Small, P. D. "*Reporting and preventing medical mishaps: lessons from non-medical near-miss reporting systems*." *BMJ*, 320, 759-763, 2000.
- [Baumgart et al, 1997] Baumgart-Schmitt, R., Herrmann, W. M., Eilers, R., Bes, F." *On the use of neural network techniques to analyse sleep EEG data. First communication: application of evolutionary and*

- genetic algorithms to reduce the feature space and to develop classification rules.*" *Neuropsychobiology*, 36 (4), pp 194-210. 1997.
- [Baumgart et al, 1998] Baumgart-Schmitt, R., Herrmann, W. M., Eilers, R. "On the use of neural network techniques to analyze sleep EEG data. Third communication: robustification of the classifier by applying an algorithm obtained from 9 different networks." *Neuropsychobiology*, 37(1), pp 49-58. 1998.
- [Baxt, 1990] Baxt, W. G. *Use of an artificial neural network for data analysis in clinical decision making: the diagnosis of acute coronary occlusion.* *Neural Computation*, 2, 480-489. 1990.
- [Baxt, 1992] Baxt, W. G. *Improving the accuracy of an artificial neural network using multiple differently trained networks.* *Neural Computation*, 4 (5), 772-780. 1992.
- [Baxt, 1994] Baxt, W. G.. *A neural-network trained to identify the presence of myocardial-infarction bases some decisions on clinical associations that differ from accepted clinical teaching.* *Med. Dec. Making*, 14 (3), 217-222. 1994.
- [Baxt, 1995] Baxt W. G. *Application of neural networks to clinical medicine.* *Lancet*, 346, 1135-1138; 1995.
- [Baxt et al, 1995] Baxt, W. G., White, H. *Bootstrapping confidence intervals for clinical input variable effects in a network trained to identify the presence of acute myocardial infarction.* *Neural Computation*, 7 (3), 624-638; 1995.
- [Baxt, 1996] Baxt, W. G. *Artificial neural network to identify acute myocardial infarction-Reply.* *Lancet*, 347, 551. 1996.
- [Baxt et al, 1996] Baxt, W. G., & Skora, J. *Prospective validation of artificial neural network trained to identify acute myocardial infarction.* *Lancet*, 347, 12-15. 1996.
- [Belaid et al, 1992] Belaid A. et Belaid Y. *Reconnaissances des formes. Méthodes et applications.* Paris: Inter Editions 429p. 1992
- [Brennan et al, 1991] Brennan, T. A., Leape, L. L., Laird, N. M., Hebert, L., Localio, A. R., Lawthers, A. G., *Incidence of adverse events and negligence in hospitalized patients.* *N. Engl. J. Med.*, 324, 370-376. 1991.
- [Bugliosi et al, 1994] Bugliosi, R., Tribalto, M., Avvisati, G., Boccardoro, M., de Martinis, C., Frieria, R., Mandelli, F., Pileri, A., Papa, G.. *Classification of patients affected by multiple myeloma using neural network software.* *Eur. J. Haematol*, 52 (3), pp 182-183. 1994
- [Casaleggio et al, 1991] Casaleggio A., Morando M., Ridella S. "Neural Networks for Automatic Anomalous QRS Complex Detection," *Myocardial Infarction Proc. Computer in Cardiology*, pp. 553-6, 1991.
- [Chapelon, 2004] Chapelon-Abric C. *Encyclopédie Médico-Chirurgicale* 11-003-F-30 2004.
- [Chateaux, 2000] Chateaux J.F., "Conception et réalisation d'une cellule de caractérisation des tissus biologiques par spectroscopie de bioimpédance dans la gamme fréquentielle (100 Hz-1 MHz), application aux tissus osseux-prise en compte de l'anisotropie", Thèse de Doctorat, Université Henri Poincaré, Nancy I, 15 novembre 2000
- [Chauvin et al, 1995] Chauvin, Yves et Rumethart, David E. *Back propagation: Theory architectures, and applications.* Lawrence Erlbaum Associates, 1995;
- [Chen et al, 1999] Chen, H. Y., Chen, T. C., Min, D. L., Fischer, G. W., Wu, Y. M. *Prediction of tracolimus blood levels by using the neural network with genetic algorithm in liver transplantation patients.* *Ther. Drug Monit.*, 21 (1), 50-56. 1999.
- [Cohenet et al, 1983] Cohen M. A Grosberg S. *Absolute Stability of Global Pattern Formation and Parallel Memory Storage by Competitive Neural Networks.* *IEEE Transactions on Systems, Man and Cybernetics*, Vol.SMC-13, No.5, Sept/Oct 1983.

- [Coiera, 1997] Coiera, E. *Guide to medical informatics, the internet and telemedicine*, London: Chapman & Hall Medical. 1997.
- [Cole et al, 1941] Cole K. S., Cole R. H., " *Dispersion and absorption in dielectrics. I. Alternating current characteristics* ", Journal of Chemical Physics, Vol. 9, pp. 341-351,1941.
- [Conde, 1994] Conde T., " *Automatic Neural Detection of Anomalies in Electrocardiogram (ECG) Signals,*" IEEE pp. 3552-58. 1994.
- [Cross et al, 1995] Cross S. S., Harrison R. F., Lee Kennedy, R. *Introduction to neural networks*. Lancet, 346, 1075-1079. 1995.
- [Cross et al, 2000] Cross S. S., Stephenson T. J., Mohammed T., Harrison R. F. *Validation of a decision support system for the cytodiagnosis of fine needle aspirates of the breast using a prospectively collected dataset from multiple observers in a working clinical environment*. Cytopathology, 11 (6), 503-512. 2000.
- [CSE Working Party, 1985]The CSE Working Party- *Recommandation for Measurement Standards in Quantitative Electrocardiography*, European Heart Journal; 1985.
- [Cybenko, 1989] Cybenko G. *Approximations by superpositions of sigmoidal functions*. Math. Control, Signals, Systems, 2:303--314. 1989.
- [Dassen et al, 1992] Dassen W., Mulleneers R., Bleijlevens B., Den Dulk K, Rrodriguez LM, Schlapfer J., Katsivas A., wellens H., " *Determination of the Aetiology of Wide-QRS Tachycardia Using an Artificial Neural Network,*" IEEE, pp. 165-68. 1992.
- [De Bakey et al,1997] DeBakey M. E. Gotto A. M., *Le cœur en action*. Institut d'édition Sanofi~Synthelabo, 1997.
- [Debye, 1929] Debye: P., " *Polar molecules* ", Edition New York: The chemical catalog, 1929
- [De Dombal, et al, 1972] De Dombal, F. T., Leaper, D. J., Tanisland, J. R., McCann, A. P., Horrocks, J. C. *Computer-aided diagnosis of acute abdominal pain*. BMJ, 2, pp 9-13. 1972.
- [Dennis et al, 1983] Dennis, J. E. Schnabel, R. B. *Numerical methods for unconstrained optimization and nonlinear equations*. Englewood Cliffs: Prentice-Hall, 354p. 1983
- [De Sutter et al, 2000] De Sutter, J., Van de Wiele, C., D'Asseler, Y., De Bondt, P., De Backer, G., Rigo, P., Dierckx, R. *Automatic quantification of defect size using normal templates: a comparative clinical study of three commercially available algorithms*. Eur. J. Nucl. Med., 27 (12), pp 1827-1834. 2000.
- [Devroye et al, 1996] Devroye L. Lugosi G. *A probabilistic theory of pattern recognition*. New York: Springer, 292 p. 1996
- [Dombi et al, 1995] Dombi, G. W., Nandi, P., Saxe, J. M., Ledgerwood, A. M., Lucas, C. E. *Prediction of rib fracture injury outcome by an artificial neural network*. J. Trauma, 39 (5), pp 915-921. 1995.
- [Doornewaard et al, 1999] Doornewaard, H., van der Schouw, Y. T., van der Graaf, Y., Bos, A. B., Habbema, J. D., van den Tweel, J. G. *The diagnostic value of computer-assisted primary cervical smear screening: a longitudinal cohort study*. Mod. Pathol, 12 (11), pp 995-1000. 1999.
- [Dreiseitl et al, 1999] Dreiseitl, S., Ohno-Machado, L., Vinterbo, S. *Evaluating variable selection methods for diagnosis of myocardial infarction*. Proc. AMIA Symp. 1-2, pp 246-250. 1999.
- [Dreyfus, 2004] Dreyfus G., Martinnez J.M., Samuelides M., Gordon M.B., Badran F., Thiria S., Hérault J. Sous la direction de Gérard Dreyfus. France-Tauve, " *Réseau de Neurones Méthodes et Applications*" 11-bd de Sébastopol, Paris. Edition Eyrolles Avril 2004.

- [Dubin, 1999] Dubin D., *Lecture Accélérée de l'ECG*, Maloine ed, 1999.
- [Efron et al, 1997] Efron B. et. Tibshirani R. J. *Improvements on cross-validation: the bootstrap method*. Journal of the American Statistical Association. Vol. 92, pp. 548-560, 1997
- [Einthoven, 1941] Einthoven W., "*The galvanometric registration of the human electrocardiogram, likewise a review of the use of capillary-electrometer in physiology*", in *Cardiac classics: Willius FW-CV Mosby*, St Louis, 1941.
- [El Dajani et al, 2001] [EL](#) El Dajani [R.](#), [Miquel M.](#), [Rubel P.](#), Forlini M. C., [Fayn J.](#), Maison-blanche P.: *A Neural Network Approach for Predicting and Modelling the Dynamical Behaviour of Cardiac Ventricular Repolarisation Tenth World Congress on Health and Medical Informatics*, Medinfo,10(Pt 1):444-48,London; 2001.
- [El Dajani et al, 2001] El Dajani R., [Maryvonne M.](#), [Rubel P.](#): *A Multi Layer Perceptron Approach for Predicting and Modeling the Dynamical Behavior of Cardiac Ventricular Repolarisation*. [IWANN \(2\)](#) 377-384. 2001
- [EL Dajani, 2002] El Dajani R. M. *Artificial neural networks for modeling and predicting the dynamical behavior of the ventricular repolarization phase*, theses INSAL 2002.
- [Ellenius et al, 1997] Ellenius, J., Groth, T., & Lindahl, B. *Neural network analysis of biochemical markers for early assessment of acute myocardial infarction*. Stud. Health Technol. Inform., 43, 382-385 1997.
- [Fahlman, 1988] Fahlman S. E. *An empirical study of learning speed in back propagation networks*. Technical Report CMU6CS-88-162, CMU.1988.
- [Finne et al, 2000] Finne, P., Finne, R., Auvinen, A., Juusela, H., Aro, J., Maattanen, L., Hakama, M., Rannikko, S., Tammela, T. L., Stenman, U. *Predicting the outcome of prostate biopsy in screen-positive men by a multilayer perceptron network*. Urology, 56 (3), pp 418-422. 2000.
- [Fricke, 1932] Fricke H., "*The theory of electrolytic polarization* ", Phil. Mag., pp. 310-318, 1932.
- [Fricker, 1997] Fricker, J. *Artificial neural networks improve diagnosis of acute myocardial infarction*. Lancet, 350, 935. 1997.
- [Gaetz al, 1998] Gaetz, M., Weinberg, H., Rzepoluck, E., Jantzen, K. J. *Neural network classifications and correlation analysis of EEG and MEG activity accompanying spontaneous reversals of the Necker cube*. Brain Res. Cogn. Brain Res., 6 (4), pp 335-346. 1998.
- [Gamito al, 2000] Gamito, E. J., Stone, N. N., Batuello, J. T., Crawford, E. D. *Use of artificial neural networks in the clinical staging of prostate cancer: implications for prostate brachytherapy*. Tech. Urol, 6 (2), pp 60-63. 2000.
- [Geddes et al, 1989] Geddes L.A., Baker L.E., *Principes of Applied Biomedical Instrumentation.*, Wiley Interscience Publication 1989
- [Georgiadis et al, 1995] Georgiadis, D., Kaps, M., Siebler, M., Hill, M., Konig, M., Berg, J., Kahl, M., Zunker, P., Diehl, B., Ringelstein, E. B. *Variability of Doppler microembolic signal counts in patients with prosthetic cardiac valves*. Stroke, 26(3), pp 439-443. 1995.
- [Glass al, 1998] Glass, J. O., Reddick, W. E. *Hybrid artificial neural network segmentation and classification of dynamic contrast-enhanced MR imaging (DEMRI) of osteosarcoma*. Magn. Reson. Imaging, 16 (9), pp 1075-1083. 1998.
- [Goldman al, 1988] Goldman, L., Cook, E. F., Brand, D. A., Lee, T. H., Rouan, G. W., Weisberg, M. C., *A computer protocol to predict myocardial infarction in emergency department patients with chest pain*. N. Engl. J. Med., 318, pp 797-803. 1988.

- [Goodenday et al, 1997] Goodenday, L. S., Cios, K. J., Shin, I. *Identifying coronary stenosis using an image-recognition neural network*. IEEE Eng. Med. Bio. Mag., 16 (5), pp 139-144. 1997.
- [Goodey al, 2000] Goodey, R. D., Brickley, M. R., Hill, C. M., Shepherd, J. P. *Controlled trial of three referral methods for patients with third molars*. Br. Dent. J., 189 (10), pp 556-560. 2000.
- [Grus al, 1999] Grus, F. H., Augustin, A. J. *Analysis of tear protein patterns by a neural network as a diagnostic tool for the detection of dry eyes*. Electrophoresis, 20 (4-5), pp 875-880. 1999.
- [Gurgen al, 1995] Gurgen, F. S., Sihmanoglu, M., Varol, F. G. *The assessment of LH surge for predicting ovulation time using clinical, hormonal, and ultrasonic indices in infertile women with an ensemble of neural networks*. Comput. Biol. Med., 25 (4), pp 405-413. 1995.
- [Guterman al, 1996] Guterman, H., Nehmadi, Y., Chistyakov, A., Soustiel, J. F., Feinsod, M. *A comparison of neural network and Bayes recognition approaches in the evaluation of the brainstem trigeminal evoked potentials in multiple sclerosis*. Int. J. Biomed. Comput., 43 (3), pp 203-213. 1996.
- [Guzzetti et al, 1996]. Guzzetti S., Signorini: M. G., Gogliati C., Mezzetti S., porta A, Cerrutti S., Malliani A, *A non linear dynamics and chaotic indices in heart rate variability of normal subject and heart transplanted patients*. Cardiovasc. RES., Vol. 31, pp 441-446, 1996.
- [Hagan et al, 1996] Hagan, M. T. Demut, H. B. Beale, M. H. *Neural Network design*. Boston: PWS publishing, 344 p. 1996
- [Haiying et al, 2004] Haiying W., Azuaje F., and Norman B.. *“An Integrative and Interactive Framework for Improving Biomedical Pattern Discovery and Visualization”*, IEEE Transaction on Information Technology in Biomedicine, Vol. 8, No. 1, pp. 16-27. 2004.
- [Hamidi, 1995] Hamidi S. *Analyse quantitative de l'ECG ambulatoire et etude de la dynamique spatio-temporelle de la repolarisation ventriculaire*. Thèse de doctorat en informatique et automatique appliquée. Institut National des sciences Appliquée de Lyon. 1995.
- [Hanley et al, 1982] Hanley, J. A., McNeil, B. J. *The meaning and use of the area under a receiver operating characteristic (ROC) curve*. Radiology, 143, pp 29-36. 1982.
- [Haraldsson et al, 2004] Haraldsson H., Edenbrandt L, Ohlsson M. *Detecting acute myocardial infarction in the 12-lead ECG using Hermite expansions and neural networks*, Artificial Intelligence in Medicine pp 127-135 2004.
- [Haykin, 1994] Haykin S. *Neural Networks: a comprehensive foundation*. New York. Macmillan., 263 pm 1994
- [Hebb, 1949] Hebb D. O., *The Organization of Behavior : A Neuropsychological Theory*, Wiley, New York, 1949.
- [Hedén et al, 1997] Hedén, B., Öhlin, H., Rittner, R., Edenbrandt, L. *Acute myocardial infarction detected in the 12-lead ACG by artificial neural networks*. Circulation, 96 (6), pp 1798-1802 1997.
- [Heinrich et al, 1999] Heinrich, H., Dickhaus, H., Rothenberger, A., Heinrich, V., Moll, G. H. *Single-sweep analysis of event-related potentials by wavelet networks-methodological basis and clinical application*. IEEE Biomed. Eng., 46 (7), pp 867-879. 1999.
- [Herman et al, 1957] Herman P., Schwan S., *Advances in Biological and Medical Physics*, Vol.5, Academic Press (New York), 1957.
- [Herman et al, 1992] Herman P., Schwan S., Takashima, *Electrical conduction and dielectric behavior in biological systems, Encyclopedia of Applied Physics*, VCH Pub.(Weinheim), 1992, Vol.5, pp 177-200.
- [Herrmann, 1998] Herrmann, W. M. *Analysis of quantitative EEG with artificial neural networks and discriminants analysis a methodological comparison*. Neuropsychobiology, 37 (1), pp 41-48. 1998.

- [Hilden, 2000] Hilden, J. *Prevalence-free utility-respecting summary indices of diagnostic power do not exist*. Stat. Med., 19, 431-440. 2000.
- [Hjorth, 1994] Hjorth J. S. U. *Computer Intensive Statistical Methods Validation, Model Selection, and bootstrap*. London: Chapman and Hall, 1994
- [Hopfield, 1982] Hopfield J.J., Proc. Nat. Acad. of Sciences, vol. 79, p. 2554, 1982
- [Hornik, 1994] Hornik K. *Neural Networks: more than statistics for amateurs*. In: Dutter, R. et Grossman, W. CMPASTAT. Physica Verlag, Heidelberg. Pp 223-235, 1994
- [Horwitz et al, 1995] Horwitz, B., McIntosh, A. R., Haxby, J. V., Furey, M., Salerno, J. A., Schapiro, M. B., Rapoport, S. I., Grady, C. L. *Network analysis of PET-mapped visual pathways in Alzheimer type dementia*. Neuroreport, 6 (17), pp 2287-2292. 1995.
- [Houghton et al, 1997] Houghton A. R. and Gray D., *Maîtriser l'ECG de la théorie à la clinique*, Masson ed, 1997.
- [Houghton et al, 2000] Houghton A. R., Gray D., *Maîtriser L'ECG de la théorie à la clinique*, Masson, PP. 1-30. 2000.
- [Ichinose et al, 1990] Ichinose N., Kobayashi T. *Guide Pratique des Capteurs*. Masson 1990.
- [Jain et al, 2000] Jain, A. K., Duin, R. P. W., Mao, J. *Statistical pattern recognition: a review*. IEEE-PAMI, 22 (1), 4-37. 2000.
- [Jalal, 1995] Jalal S., *Processeur de signal digital à architecture parallèle implémenté en FPGA, application à un système de surveillance à domicile de nourrissons à risque de MSIN*, Thèse de Doctorat, Rouen, 1995.
- [James et al] James A., Hanley et Brenda MacGibbon. *"Creating non-parametric bootstrap samples using Poisson frequencies"* in Computer Methods and Programs in Biomedicine
- [Jane et al, 1993] Jane R, Otmos S, Laguna P, Caminat P, *Adaptative hermites models for ECG data compression: performance and evaluation with automatique wave detection*. Proceed. of the computers in cardiology. IEEE computer society. 1993, pp 389-92.
- [Jeffrey et al, 2000] Jeffrey C., Naomi D, Michael P, *A study in electrocardiogram abnormality Pattern Recognition*. The Tell- tale Heart. May 2000, pp 1-11.
- [Jordan, 1995]. Jordan, M. I. *Why the logistic function? A tutorial on probabilities and neural networks*. MIT Computational cognitive Science Report 9503, <http://cs.berkeley.edu/jordan/papers/uai.ps.Z.1995>.
- [Josefson, 1997] Josefson, D. *Computers beat doctors in interpreting ECGs*. BMJ, 315, pp 763-766, 1997.
- [Kemeny et al, 1999] Kemeny, V., Droste, D. W., Hermes, S., Nabavi, D. G., Schulte-Altendorneburg, G., Siebler, M., Ringelstein, E. B. *Automatic embolus detection by a neural network*. Stroke, 30 (4), pp 807-810. 1999.
- [Kohn et al, 1999] Kohn, L. T., Corrigan, J. M., Donaldson, M. S. (Eds.). *To err is human: building a safer health system*. Washington, DC: National Academy Press. 1999.
- [Kohonen, 1977] Kohonen T., *Associative Memory: A System Theoretic Approach*, Springer-Verlag, Berlin, 1977.
- [Kothari et al, 1996] Kothari, R., Cualing, H., Balachander, T. *Neural network analysis of flow cytometry immunophenotype data*. IEEE Biomed. Eng., 43 (S), pp 803-810. 1996.

- [Kulikowski, 1998] Kulikowski, C. A. *Artificial intelligence in medical consultation systems: a review*. IEEE-Eng. in Med. and Biology Mag., pp 34-39. 1988.
- [Ledley et al, 1959] Ledley, R. S., Lusted, L. B. *Reasoning foundations of medical diagnosis*. Science, 130, pp 9-21. 1959.
- [Leschi, 1991] Leschi C. *Aspects fondamentaux et évolutive de la connaissance des formes*. Sciences appliqués de Lyon, 407p. 1991
- [Lepoutre et al, 2001] Lepoutre F. et al, *Systèmes et Microsystèmes pour la Caractérisation*, Hermès éd., Paris, vol2, pp 439-445. 2001.
- [Leon et al, 1997] Leon, M. A., Lorini, F. L. *Ventilation mode recognition using artificial neural networks*. Comput. Biomed. Res., 30 (5), pp 373-378. 1997.
- [Lindahl et al, 2000] Lindahl, D., Toft J., Hesse, B., Palmer, J., Ali, S., Lundin, A., Edenbrandt, L. *Scandinavian test of artificial neural network for classification of myocardial perfusion images*. Clin. Physiol.,20 (4), pp 253-261. 2000.
- [Lisboa, 2000] Lisboa, P. J. G., Ifeachor, E. C., & Szczepaniak, P. S. (Eds.) *Artificial neural networks in biomedicine*, New York: Springer 2000.
- [Lucas, (1997)] Lucas, P. J. F. *Model-based diagnosis in medicine*. Art. Int. Med., 10, 201-208 (Editorial). 1997.
- [Lunn, et al, 2000] Lunn, D. J., Thomas, A., Best, N. G., Spiegelhalter, D. J. WinBUGS. *A Bayesian modelling framework: concepts, structure and extensibility*. Statistics in Computing, 10, 321-333. 2000.
- [Marey, 1876] Marey E., *"Des variations électriques des muscles et du cœur en particulier, étudiées au moyen de l'électromètre de M. Lippmann"*, CR Acad Sci (Paris), vol. 82, pp. 975, 1876.
- [Mango et al, 1998] Mango, L. J., Valente, P. T. *Neural-network-assisted analysis and microscopic rescreening in presumed negative cervical cytologic smears. A comparison*. Acta Cytol, 42 (1), pp 227-232. 1998.
- [Maxwell, 1981] Maxwell J. C., *"A treatise on electricity and magnetism "*, 2ème édition, Edition Oxford : Clarendon Press, 1881.
- [Mc.Clelland et al, 1986] McClelland, Rumelhart, [Parallell Distributed Processing Volumes 1 & 2](#), The MIT Press, 1986
- [Mc Culloch et al, 1943] Mc Culloch G. et Pitts W. *A logical calculus of the ideas immanent in nervs activity*, bulletin of mathematical biophysics, V.5, pp 115-133. 1943.
- [McGuire et al, 1992] McGuire, W. L., Tandon, A. K., Allred, D. C., Chamness, G. C., Ravdin, P. M., Clark, G. M. *Treatment decisions in axillary node-negative breast cancer patients*. J. Natl. Cancer Inst. Monogr., (11), pp 173-180. 1992.
- [Meghriche et al, 2006] Meghriche S., Draa A., Boulemden M., Abada A., *"A Hybrid Neural Network for Detecting an AtrioVentricular Block (AVB).in ECG Signal,"* Proc. CSIT Jordan, pp 172-178, 2006.
- [Meghriche et al, 2007] Meghriche S., Draa A., Boulemden M. *A High Performance CNN Architecture for the Detection of AVB Carrying ECGs*. Asian Journal of Information Technology, Vol. 6, N° 4, pp 474-479. 2007.
- [Meghriche et al, 2008] Meghriche S., Draa A., Boulemden M. *On The Analysis of a Compound Neural Network for Detecting AtrioVentricular Heart Block (AVB) in an ECG Signal*. International Journal of Biological and Biomedical Sciences, WASET. Vol.1 N°1 pp 1-11. 2008.

- [Meghriche et al, 2008] Meghriche S., Boulemden M., Draa A., *Agreement Between Multi-Layer Perceptron and a Compound Neural Network on ECG Diagnosis of Atrioventricular Blocks*. WSEAS transaction on Biology and Biomedicine Vol. 5, N° 1, pp 12-22. 2008.
- [Meghriche et al, 2008] Meghriche S., Boulemden M., Draa A., *Two Neural Networks Architectures for Detecting AVB*. Proc. Multimedia Systems and signal processing, China, pp 193-199. 2008.
- [Michaels et al, 1998] Michaels, E. K., Niederberger, C. S., Golden, R. M., Brown, B., Cho, L., Hong, Y. *Use of a neural network to predict stone growth after shock wave lithotripsy*. Urology, 51 (2), pp 335-338. 1998.
- [Milgram, 1993] Milgram M. *Reconnaissance des formes: Méthodes numériques connexionnistes* Paris Armand Collin, 175 p. 1993
- [Minsky et al, 1969] Minsky , Papert, Perceptrons p. 231-232; 1969:
- [MIT-BIH] MIT-BIH Arrhythmia Database Directory
<http://www.physionet.org/physiobank/database/mitdbdir/mitdbdir.htm>.
- [Modai et al, 1996] Modai, I., Israel, A., Mendel, S., Hines, E. L., Weizman, R. *Neural network based on adaptive resonance theory as compared to experts in suggesting treatment for schizophrenic and unipolar depressed in-patients*. /. Med. Syst., 20 (6), pp 403-412. 1996.
- [More, 1977] More J. J. *The Levenberg-Marquardt algorithm implementation and theory*. Ln: Watson, G. A. Numerical Analysis, Lecture Notes in Mathematics 630 Heidelberg Springer Verlag, pp. 105-116, 1977
- [Nadal, 1993] Nadal J. P. *Réseaux de neurones. De la physique à la psychologie*. Paris Armand Collin, 152 p. 1993
- [Naguib, 1996] Naguib, R. N., Adams, A. E., Home, C. H., Angus, B., Sherbet, G. V., Lennard, T. W. *The detection of nodal metastasis in breast cancer using neural network techniques*. Physiol. Meas., 17 (4), pp 297-303. 1996.
- [Neal, 1996] Neal, R. M. *Bayesian learning for neural networks*, New York: Springer-Verlag. 1996.
- [Neuro Dimension, 2001] *Neuro Dimension. The Applications Corner*. [en ligne] disponible sur : Neuro Dimension, Inc. <http://www.nd.com/appcornr/purpose.htm> .2001
- [Orsier, 1995] Orsier B. *Etude et application des systèmes hybrides neurosymboliques*, thèse. Université Joseph Fourier Grenoble, 1995
- [Pesonen, 1997] Pesonen, E. *Is neural network better than statistical methods in diagnosis of acute appendicitis?* Stud. Health Technol. Inform., 43, 377-381. 1997.
- [Polak et al, 1997] Polak, M. J., Zhou, S. H., Rautaharju, P. M., Armstrong, W. W., Chaitman, B. R. *Using automated analysis of the resting twelve-lead ECG to identify patients at risk of developing transient myocardial ischemia-an application of an adaptive logic network*. Physiol. Meas., 18 (4), pp 317-325. 1997.
- [Reason et al, 2000] Reason, J. *Human error: models and management*. BMJ, 320, 768-770. 2000.
- [Reggia, 1993] Reggia, J. A. *Neural computation in medicine*. Artificial Intelligence in Medicine, 5, 143-157. 1993.
- [Renders et al, 1995] Renders X, De Leval N, *L'enfant au centre de la stratégie publicitaire: le phénomène du petit mannequin*. L'observateur. Rev.d'action sociale et médico-sociale, Liège, nov.1995, 1995.
- [Rfai, 2001] Rfai. *Apprentissage et validation*. [en ligne] disponible sur: Laboratoire de reconnaissance et analyse d'images. Université de tours. http://www.rfai.li.univ_tours.fr/validation/ .2001

- [Riedmiller et al, 1993] Riedmiller, Braun, *A direct adaptive method for faster backpropagation learning: The RPROP algorithm*, 586-591, <http://citeseer.nj.nec.com/riedmiller93direct.html> . 1993.
- [Rigaud et al, 1996] Rigaud B. Morrucci J.-P., Chauveau N. " *Bioelectrical impedance techniques in medicine. Part Bioimpedance measurement. Second section: Impedance spectrometry* ", Critical Reviews in Biomedical Engineering, Vol. 24 (4-6), p. 257-351, 1996.
- [Ripley, 1996] Ripley, B. D. *Pattern recognition neural network*. Cambridge university press. 1996.
- [Rosenblatt, 1961] Rosenblatt F. *Principales of neurodynamics: perceptron and the theory of brain mechanisms*. Washington: Spartan Books, 1961.
- [Rumelhart et al, 1986] Rumelhart, Daved E, McClelland, James L, *University of California, San Diego, and PDP Research Groupe. Parallel distributed processing explorations in the microstructure of cognition*. Cambridge, Mass: MIT Press, 1986.
- [Rutkowski, 1977] Rutkowski F, *CAN et CNA*, Electronique Applications, 3 pp 97-103, 1977.
- [Schwan et al, 1957] Schwan H. P., C. F. Kay, " *The conductivity of living tissues* ", Annals New York Academy of Sciences, pp. 1007-1013, 1957.
- [Schwan, 1992] Schwan H. P., " *Linear and nonlinear electrode polarization and biological materials* ", Annals of Biomedical Engineering, Vol. 20, pp. 269-288, 1992.
- [Schwartz, 1970] Schwartz, W. B. *Medicine and the computer: the promise and problems of change*. New Engl. J. Med., 283, pp 1257-1264, 1970.
- [Schwartz, et al 1987] Schwartz W. B. Patil R. S. Szolovits, P. *Sounding board: artificial intelligence--where do we stand?* N. Engl. J. Med., 316 685-688. 1987.
- [Schwartz et al, 2000] Schwartz G., Vach W., Schumacher M. *On the misuses of artificial neural networks for pronostic and diagnostic classification in oncology*. Stat. Med., 19, 541-551, 2000.
- [Selker et al, 1995] Selker, H. P., Griffith, J. L., Patil, S., Long, W. J., D'Agostino, R. B. *A comparison of performance of mathematical predictive methods for medical diagnosis: identifying acute cardiac ischemia among emergency department patients*. J. Investig. Med., 43 (5), pp 468-476. 1995.
- [Sherman et al, 1997] Sherman, M. E., Schiffman, M. H., Mango, L. J., Kelly, D., Acosta, D., Cason, Z., Elgert, P., Zaleski, S., Scott, D. R., Kurman, R. J., Staler, M., Lorincz, A. T. *Evaluation of PAPNET testing as an ancillary tool to clarify the status of the "atypical" cervical smear*. Mod. Pathol., 10(6), pp 564-571. 1997.
- [Shi et al, 2000] Shi, L. M., Fan, Y., Lee, J. K., Waltham, M., Andrews, D. T., Scherf, U., Paull, K. D., Weinstein, J. N. *Mining and visualizing large anticancer drug discovery databases*. Journal of Chemical Information and Computer Sciences, 40 (2), pp 367-379. 2000.
- [Shortliffe, 1976] Shortliffe, E. H. *Computer-base medical consultations: MYCIN*, New York: Elsevier. 1976.
- [Shortliffe, 1990] Shortliffe, E. H. *Clinical decision-support systems*. In E. H. Shortliffe, L. E. Perreault, G. Wiederhold L. M. Pagan, Medical informatics computer applications in health care, Reading, MA: Addison-Wesley. 1990.
- [Shortliffe, 1993] Shortliffe, E. H. *The adolescence of AI in medicine: will the field come of age in the '90s?* Artif. Intell. Med., 5, 93-106. 1993.
- [Si et al, 1998] Si, Y., Gotman, J., Pasupathy, A., Flanagan, D., Rosenblatt, B., Gottesman, R. *An expert system for EEG monitoring in the pediatric intensive care unit*. Electroencephalogr. Clin. Neurophysiol., 106 (6), pp 488-500. 1998.

- [Silbernagl et al, 1993] Silbernagl S., Despopoulos A. *"Atlas commenté de physiologie humaine pour étudiant et praticiens"*, Paris, janvier 1993.
- [Simpson, 1990] Simpson P. K. *Artificial Neural Systems - Foundations, Paradigms, Applications and Implementations*. Pergamon Press, 1 edition 1990.
- [Simpson et al, 1995] Simpson, H. W., McArdle, C., Pauson, A. W., Hume, P., Turkes, A., Griffiths, K. *A non-invasive test for the pre-cancerous breast*. Eur. J. Cancer, 31A (11), pp 1768-1772. 1995.
- [Smith et al, 1996] Smith, J. H., Graham, J., Taylor, R. J. *The application of an artificial neural network to Doppler ultrasound waveforms for the classification of arterial disease*. Int. J. Clin. Monit. Comput., 13 (2), pp 85-91. 1996.
- [Smith et al, 1998] Smith, B. P., Ward, R. A., Brier, M. E. *Prediction of anticoagulation during hemodialysis by population kinetics and an artificial neural network*. Artif. Organs, 22 (9), pp 731-739. 1998.
- [Sornmo et al, 1981] Sornmo L, Borjesson P, Nygard M, Pahlm O, *A method for evaluation of QRS shape features using a mathematical model for the ECG*, IEEE Trans. Biome. Ing. pp 713-7. 1981.
- [Spiegelhalter, et al, 1999] Spiegelhalter, D. J., Myles, J. J., Jones, D. R., Abrams, K. R. *An introduction to Bayesian methods in health technology*. BMJ, 319, 508-512. 1999.
- [Stock et al, 1994] Stock, A., Rogers, M. S., Li, A., Chang, A. M. *Use of the neural network for hypothesis generation in fetal surveillance*. Baillieres Clin. Obstet. Gynaecol, 8 (3), pp 533-548. 1994.
- [Szczepaniak et al, 2000] Szczepaniak, P. S., Lisboa, P. J. G., Kacprzyk, J. (Eds.) *Fuzzy systems in biomedicine*, Berlin: Springer-Verlag. 2000.
- [Tibshirani, 1996] Tibshirani, R. *A comparison of some error estimates for neural network models*. Neural Computation, 8, 152-163. 1996.
- [Trentelman, 1993] Trentelman H.L., *'Representation and learning in feedforward neural networks'* em CWI Quarterly, Vol. 6, No. 4, pp. 385-408, 1993.
- [Tretelman et al, 1993] Tretelman H. L. Willems J.C. eds *Essays on Control: Perspective in the Theory and its Applications*. Birkhäuser, Boston. 1993.
- [Verchure, 1993] Verchure P. *'Formal mind and biological brains'*. IEEE. oct 66-75. 1993.
- [Wagner, 1914]: Wagner K. W., *"Explanation of the dielectric fatigue phenomenon on the basis of Maxwell's concept"*, Arkiv für Electrotechnik - Edition Shering H. Berlin : Springer-Verlag, 1914.
- [Waller, 1893] Waller A., *An introduction to human physiology*. New-York: Longmans Green, 1893.
- [Warren, 2001] Warren S. S. *Donoho-johnstone Benchmarks: Neural net results* [en ligne] disponible sur: SAS Institute Inc. Cary, NC, USA. <ftp://ftp.sas.com/pub/neural/dojo/dojo.html>, 2001
- [Webster, 1997] Webster J. G, *Medical Instrumentation. Application and Design*, 1997
- [Wehrens et al, 2000] Wehrens R, Putter H, Buydens, L. *The bootstrap: Atutorial*. Chemometr Intell Lab Syst 54, pp 35-52; 2000.
- [Weingart et al, 2000] Weingart, S. N., Wilson, R., McL, Gibberd, R. W., Harrison, B. *Epidemiology of medical error*. BMJ, 320, 747-777. 2000.
- [Werbos, 1974] Werbos P. J. *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*. Thèse PhD, Harvard University. 1974

- [Wilson et al, 1995] Wilson R. M, Runciman W. B, Gibberd B. T Harrison, L. Newby, J. D.Hamilton, *The quality in Australian healthcare study*. Med. J. Aust., 163, 458-471. 1995.
- [Zurada, 1992] Zurada J. M., *Introduction to artificial neural system*. Boston PWS publishing company, 1992,
- [Zernikow et al, 1998] Zernikow, B., Holtmannspotter, K., Michel, E., Theilhaber, M., Pielemeier, W., Hennecke, K. H. *Artificial neural network for predicting intracranial haemorrhage in preterm neonates*. Acta Paediatr., 87 (9), pp 969-975. 1998.
- [Zernikow et al, 1999] Zernikow, B., Holtmannspotter, K., Michel, E., Hornschuh, F., Groote, K., Hennecke, K. H. *Predicting length-of-stay in preterm neonates*. Eur. J. Pediatr., 158 (1), 59-62. 1999.