

République Algérienne Démocratique et Populaire
Ministère de l'enseignement supérieur et de la recherche scientifique



Université Abou Bekr Belkaid
FACULTE DE TECHNOLOGIE
DEPARTEMENT DE GENIE BIOMEDICALE
LABORATOIRE DE RECHERCHE EN GENIE
BIOMEDICAL



THÈSE

Pour obtenir le titre de
Docteur en Génie Biomédical
De l'université de Tlemcen, Faculté de Technologie
Spécialité : "Electronique Biomédicale"

Présentée par

BENALI MEDJAHED Oussama

Modélisation et compression des signaux biomédicaux en vue d'une classification

Soutenue en 11 Février 2016, devant le jury composé de :

M. BEREKSI-REGUIG Fethi <i>Professeur, Université Abou-Bekr Belkaid de Tlemcen</i>	Président
M. HADJ SLIMANE Zine-Eddine <i>Professeur, Université Abou-Bekr Belkaid de Tlemcen</i>	Directeur de Thèse
M. CHOUAKRI Sid Ahmed <i>Professeur, Université de Sidi Belabbès</i>	Examineur
M. SEDDIKI Ali <i>Maître de conférences, Université de Sidi Belabbès</i>	Examineur

Dédicace

À mon Père et ma Mère

Aucune dédicace ne pourra traduire mon profond amour et gratitude pour l'affection que vous m'avez offerte. Les sacrifices illimités, encouragements, votre amour, soutien, bienveillance, conseil etc....

Que cette thèse soit l'expression de ma profonde tendresse et reconnaissance. J'espère être digne et à la hauteur de votre confiance et de vos espérances. Je prie Allah pour vous jouir de bonne santé toute la vie et que vos vœux soient exaucés.

À mon cher frère Imad- Eddine et ma chère sœur Wissame

Que cette thèse soit un témoignage de la profondeur des sentiments d'amour, de considération et de respect que j'éprouve à vos égards. Je prie Allah tout puissant de vous protéger et de vous accorder réussite et bonheur.

À mes meilleurs amis Nabil, Amine, Mourad, Saadi et Abdelfattah

À tous mes amis

Que vous trouvez dans ce travail l'expression de ma sincère reconnaissance pour votre disponibilité et votre gentillesse. Merci pour tout, bon courage et bonne continuation.

À tous ceux que j'aime et qui m'aiment

Remerciement

Nous remercions ALLAH le Tout-puissant de nous avoir donné le courage, la volonté et la patience de mener à terme le présent travail.

Je tiens tout d'abord à exprimer ma profonde gratitude à Monsieur le professeur HADJ SLIMANE Zine-Eddine pour avoir encadré et dirigé mes travaux de recherche, et pour le soutien apporté et la confiance accordée durant ces années de doctorat en étant toujours disponible et encourageant. Ses conseils, sa rigueur scientifique et ses valeurs humaines m'ont bien guidée.

Je tiens aussi à remercier Monsieur BEREKSI REGUIG Fethi professeur à l'université de Tlemcen et directeur de laboratoire de recherche Génie Biomédical (GBM) qui m'a fait l'honneur de présider ce jury. J'ai découvert aussi grâce à lui le monde de la recherche dans les meilleures conditions.

Je remercie vivement les membres du jury: Monsieur CHOUAKRI Sid Ahmed professeur de l'université de Sidi Belabbès et Monsieur SEDDIKI Ali, Maître de conférences à l'université de Sidi Belabbès qui ont accepté de faire partie des membres de jury.

Je remercie également : Monsieur KERAI Salim, chef département du génie biomédical à l'université de Tlemcen, de m'avoir guidé, encouragé, conseillé tout en me laissant l'initiative. Je tiens à le remercier spécialement pour la confiance qu'il m'a accordée.

Je ne saurais oublier mes parents, ma sœur et mon frère, pour leur soutien moral inconditionnel, pour leur aide et pour leur encouragement tout au long de mes études. Sans oublier les personnes avec qui j'ai eu à partager les années d'études dans le département du génie biomédical à l'université de Tlemcen.

Table des matières

Dédicace	i
Remerciements	ii
Table des matières	iii
Liste des figures.....	vii
Liste des tableaux	ix
Liste d'abréviations	x
Résumé	xiii
ملخص	xiv
Abstract	xv
INTRODUCTION GENERALE	1

Chapitre1 : Généralités théoriques sur les signaux biomédicaux

I.1.Introduction	4
I.2. Electrocardiographie	4
I.2.1. Anatomie du cœur	4
I.2.2. Système de conduction électrique cardiaque	5
I.2.3. L'Electrocardiogramme (ECG)	7
I.2.3.1.Technique enregistrement du signal ECG	7
I.2.3.1.1. Dérivations périphériques standard d'Einthoven	7
I.2.3.1.2. Dérivations périphériques unipolaires de Goldberger	8
I.2.3.1.3. Dérivations précordiales	9
I.2.3.2. Caractéristiques d'un ECG Normal	9
I.2.4. Pathologies cardiaques	11
I.2.4.1. Rythme sinusal	11
I.2.4.2. Troubles de la conduction cardiaque	12
I.2.4.2.a. Bloc Sino-Auriculaire (Bloc SA)	12
I.2.4.2.b. Blocs Auriculo-ventriculaire (BAV)	12
I.2.4.2.c. Blocs de branche	12
I.2.4.3. Troubles du rythme	12
I.2.4.3.a. La fibrillation auriculaire (FA)	13
I.2.4.3.b. Extrasystole ventriculaire (Contraction ventriculaire prématurée)	13
I.2.4.3.c. La tachycardie ventriculaire (TV)	13
I.2.4.3.d. Fibrillation ventriculaire (FV)	13
I.2.4.3.e. Extrasystoles supra-ventriculaires	13
I.2.4.3.f. La tachycardie supra-ventriculaire	14
I.3. La respiration	14
I.3.1. Anatomie du système respiratoire	14
I.3.2 Fonctionnement de l'appareil respiratoire	15
I.3.3. Les explorations fonctionnelles respiratoires	17

I.3.4. Représentation spirographique de la respiration	17
I.3.5. Les méthodes de mesure des volumes et débits respiratoires	19
I.3.5.1. Mesure flux d'air par thermistance naso-buccale	19
I.3.5.2. Pléthismographie respiratoire par inductance	20
I.4. Conclusion	21

Chapitre II : Techniques de compression du signal ECG

II.1. Introduction	23
II.2. Qualité de compression / décompression	24
II.2.1. Taux de compression	24
II.2.2. Fidélité de la reconstruction	24
II.2.3. La charge de calcul	25
II.3. Les Méthodes de Compression	25
II.3.1. Méthodes directes de compression de l'ECG	25
II.3.1.1. Méthode AZTEC	26
II.3.1.2. AZTEC modifié	26
II.3.1.3. L'algorithme TP	27
II.3.1.4. L'algorithme CORTES	28
II.3.1.5. La technique de FAN	29
II.3.1.6. La technique de SAPA	29
II.3.2. Compression de l'ECG par transformation du signal	30
II.3.2.1. transformation sinusoidales	31
II.3.2.1.1. La Transformée de Fourier Discrète	31
II.3.2.1.2. La Transformée en cosinus discrète (DCT)	32
II.3.2.1.3. La Transformée en sinus discrète (DST)	32
II.3.2.2. Transformées quasi spectrales	33
II.3.2.3. transformation en ondelettes	35
II.3.2.3.1. Exemples d'ondelettes	35
II.3.3. Compression par transformation polynomiales	39
II.4. Évaluation de la performance et résultats de compression par la DCT, DST, FFT et DWT (JD'13)	39
II.4.1. Résultats de la Compression par transformations sinusoidales (DCT, DST, FFT)	40
II.4.2. Résultats de Compression par transformations en ondelettes discrètes (DWT)	42
II.4.3. Discussion et résultats	45
II.5. Conclusion	46

Chapitre III : Modélisations polynomiales des signaux ECG

III.1. Introduction	48
III.2. Orthogonalité des fonctions	49
III.3. Polynômes orthogonaux	49
III.4. Familles de polynômes orthogonaux	50

III.4.1 Polynômes de Jacobi	50
III.4.1.1 Les polynômes de Legendre	51
III.4.1.2 Les polynômes de Tchebychev	51
III.4.2 Polynômes de Laguerre	53
III.4.3 Polynômes d’Hermite	54
III.5. Processus de modélisations polynômiales	55
III.5.1 Détection du complexe QRS	56
III.5.2 Segmentation en Blocs	56
III.5.3 Transposition dans [a, b]	58
III.5.4 Calcul de coefficients de décomposition	58
III.5.4.1 Transformation de Laguerre (LaT).....	58
III.5.4.2 Transformation de Tchebychev (TcT).....	59
III.5.4.3 Transformation d’Hermite (HeT).....	59
III.5.4.4 Transformation de Jacobi	59
III.6. Conclusion	60

Chapitre IV : Les réseaux de neurones artificiels

IV.1. Introduction	62
IV.2. Etats de l’arts sur la classification automatique des signaux ECG	62
IV.3. Les réseaux de neurones artificiels (RNA)	64
IV.3.1 Présentation	64
IV.3.2 Historique	64
IV.3.3. Neurone biologique	65
IV.3.4. Neurone artificiel (formel)	66
IV.3.5. Architecture des réseaux de neurones	68
IV.3.5.1. Les réseaux de neurones non bouclés	68
IV.3.5.2. Les réseaux de neurones bouclés (récurrents)	69
IV.3.6 Apprentissage des réseaux de neurones	70
IV.3.6.1 Type d’apprentissage	70
IV.3.6.1.a Apprentissage supervisé	70
IV.3.6.1.b Apprentissage renforcé	71
IV.3.6.1.c Apprentissage non supervisé	71
IV.3.6.2 Algorithme d’apprentissage	71
IV.3.6.2.a Algorithme de rétropropagation du gradient	72
IV.3.6.2.b Méthodes Quasi-Newton	72
IV.3.6.2.c Algorithme de BFGS	72
IV.3.7. Conception d’un réseau de neurones	72
IV.3.8. Les différentes applications de RNA	75
IV.3.8.1 Reconnaissance des formes	76
IV.3.8.2 Modélisation	76
IV.3.8.3 Traitement de la parole	76
IV.3.8.4 Détection d’anomalies en médecine	76
IV.4. Conclusion	79

Chapitre V : Extraction des caractéristiques à partir des signaux ECG et respiratoires pour la classification automatique supervisée des battements cardiaques

V.1 Introduction	79
V.2 Description de la base de données Apnea-ECG	80
V.3 Description des procédés de classification	82
V.4 Etape de traitement du signal	84
V.4.1 Détection des ondes du signal ECG	84
V.4.2 La détection des positions R_Q et R_S dans le signal respiratoire	85
V.4.3 Énergie du complexe QRS et du signal respiratoire	85
V.5 Extraction des paramètres caractéristiques	86
V.6 Compression du vecteur caractéristique par l'ACP	86
V.7 Les réseaux de neurones multicouches utilisés	87
V.8 Paramètres d'évaluation des performances	90
V.9 Résultats obtenus et discussion	91
V.10 Conclusion	93

Chapitre VI : Modélisation du signal ECG par les polynômes d'Hermite et Tchebychev en vue d'une classification de battements cardiaques

VI.1 Introduction	95
VI.2 Description de l'algorithme proposé	96
VI.2.1 La base de donnée MIT/BIH	97
VI.2.2 Les anomalies cardiaques traitées	98
VI.2.3 Choix des enregistrements de la base MIT-BIH	99
VI.2.4 Caractérisation des battements cardiaques	101
VI.2.5 Modélisation polynomiales du signal ECG	101
VI.2.6 Les réseaux de neurones multicouches utilisés	103
VI.3 Résultats obtenus et discussion	104
VI.4 Comparaison avec d'autres méthodes	106
VI.5 Conclusion	108
CONCLUSION GENERALE ET PERSPECTIVES	109
Bibliographie	112

Liste des figures

Figure I.1 : L'anatomie du cœur	5
Figure .I.2 : Circuits de conduction des excitations électriques dans le cœur	6
Figure I.3 : Dérivations bipolaires DI, DII, DIII	8
Figure I.4 : Dérivations unipolaires aVL, aVR, aVF	8
Figure I.5 : Dérivations précordiales unipolaires	9
Figure I.6 : Tracé ECG	10
Figure I.7: Système respiratoire de l'homme	14
Figure I.8: Poumons normaux	15
Figure I. 9 : Inspiration et expiration	16
Figure I. 10 : muscles respiratoires (inspiration et expiration)	16
Figure I.11 : Volume et la capacité pulmonaire chez l'homme	18
Figure I.12 : Mesure de flux d'air par thermistance naso-buccale	19
Figure I.13 : pléthysmographie respiratoire par inductance	20
Figure II.1 : Principe de l'algorithme AZTEC	26
Figure II.2 : Fonctionnement de l'algorithme TP	27
Figure II.3 : Fonctionnement de l'algorithme CORTES	28
Figure II.4 : Méthode FAN	29
Figure II.5 : Méthode SAPA	30
Figure II.6 : Principe général de la compression de l'ECG par transformation du signal	31
Figure II.7 : Quelques fonctions de Walsh	34
Figure II.8 : ondelette de Morlet	37
Figure II.9 : Ondelette chapeau mexicain	37
Figure II.10 : Ondelette de Haar	38
Figure II.11 : Ondelette de Daubechies (db4, db6)	38
Figure II.12 : Schéma bloc du système de compression utilisé	40
Figure II.13 : Résultats de compression par la DCT sur le signal 101	41
Figure II.14 : Résultats de compression par la FFT sur le signal 101	41
Figure II.15 : Résultats de compression par la DST sur le signal 101.....	42
Figure II.16 : Résultats de compression par la DWT utilisant l'ondelette de Daubechies (db7) sur le signal 101	44
Figure II.17 : Résultats de compression par la DWT utilisant l'ondelette Biorthogonale (bior4.4) sur le signal 101	44
Figure II.18 : Variation du PRD en fonction du taux de compression CR	45
Figure III.1: Courbes pour quelques polynômes de Legendre	51
Figure III.2 : Allures des polynômes de Tchebycheff	52
Figure III.3 : Les six premiers polynômes de Laguerre	53
Figure III.4 : Les six premiers polynômes d'Hermite	55
Figure III.5 : Schéma du processus de décomposition et de synthèse du signal ECG avec les polynômes orthogonaux	55
Figure III.6 : Différents types de segmentation du signal ECG en intervalles R-R, P-P, T-T, et P-QRS-T	57

Figure IV.1 : structure schématique d'un neurone	66
Figure IV.2 : Schéma d'un neurone artificiel	66
Figure IV.3 : Réseaux de neurones les plus utilisés	68
Figure IV.4 : Exemple d'un Réseau non bouclé	69
Figure IV.5 : Exemple d'un Réseau bouclé	70
Figure IV.6 : Organigramme de conception d'un réseau de neurones	75
Figure V.1 : Enregistrement a01erm de la base de données Apnea-ECG	81
Figure V.2 : Le signal respiratoire enregistré simultanément avec le signal ECG	81
Figure V.3 : Schéma bloc de l'algorithme proposé	83
Figure V.4 : Les différentes ondes et intervalles importants dans un signal ECG	84
Figure V.5 : Extraction des énergies du complexe QRS et du signal respiratoire	85
Figure V.6 : Structure générale d'un réseau de neurone artificiel multicouche	88
Figure V.7: Performance d'apprentissage des réseaux de neurones de type MLP	90
Figure V.8: Performance d'apprentissage des réseaux de neurones de type MLPR	90
Figure V.9: L'histogramme du CC_{moy} pour chaque réseau	92
Figure VI.1: Schéma bloc de l'algorithme proposé	97
Figure VI.2: ECG à des battements de type N et PVC	98
Figure VI.4: ECG à des battements de type BBD	99
Figure VI.3: ECG à des battements de type BBG	99
Figure VI.5: Processus de modélisation utilisé	102
Figure VI.6: Segmentation du signal 101 en segments P-QRS-T	102
Figure VI.8: l'histogramme du taux de classification pour chaque réseau	106

Liste des tableaux

Tableau I.1 : Critères de normalité du signal ECG	11
Tableau I.2 : Différents volumes et capacités pulmonaires	18
Tableau II.1 : Liste de famille d'ondelette	36
Tableau II.2 : La variation du PRD (%) en fonction de taux de compression CR	42
Tableau II.3 : La variation du PRD (%) en fonction de taux de compression CR et le niveau de décomposition pour chaque type d'Ondelette	43
Tableau II.4 : performance de différentes techniques de compression appliquées sur un ECG pathologique	41
Tableau III.1 : Intervalle de transposition pour chaque polynôme	58
Tableau IV.1 : Les fonctions d'activation	67
Tableau V.1: paramètres du vecteur d'entrée	86
Tableau V.2: Architecture des réseaux de neurones utilisés	90
Tableau V.3 : Résultats de la classification (Type MLP).....	91
Tableau V.4 : Résultats de la classification (Type MLPR)	91
Tableau V.5 : Taux de classification moyenne de chaque classifieur	92
Tableau VI.1 : Les enregistrements choisis de la base de données MIT-BIH	100
Tableau VI.2 : Distribution des battements ECG (apprentissage et test)	100
Tableau VI.3 : La topologie de différents classificateurs utilisées	104
Tableau VI.4 : Résultats de Classification sans coefficients de modélisation	105
Tableau VI.5 : Résultats de Classification avec coefficients (modèle de Tchebychev)	105
Tableau VI.6 : Résultats de Classification avec coefficients (modèle d'Hermite)	105
Tableau VI.7 : Taux de classification de chaque classifieurs	106
Tableau VI.8 : Comparaison des résultats obtenus avec autres méthodes	107

Liste des abréviations

ACP : Analyse en Composante Principale

AI : Artificial Intelligence

APC : Atrial Premature Contraction

ARP : Algorithme de RétroPropagation

ART : Adaptive Resonant Theory

AV : jonction Atrio-Ventriculaire

AZTEC : Amplitude Zone Time Epoch Coding

BAV : Blocs Auriculo-Ventriculaires

BBD : Blocs de Branche Droite

BBG : Blocs de Branche Gauche

BFGS : (algorithme d'apprentissage du nom de ses inventeurs : **B**royden, **F**letcher, **G**oldfarb et **S**hanno)

CC : Correct Classification

CORTES: COordinate Reduction Time Encoding System

CR: Compression Rate

CWT : Continuous Wavelet Transform

DI, DII, DIII : Dérivation Standard (D'EINTHOVEN) de l'ECG

DTCWT: Dual Tree Complex Wavelet Transform

DCT : Discrete Cosinus Transform

DFT : Discrete Fourier Transform

DST : Discrete Sinus Transform

DWT : Discrete Wavelet Transform

ECG : ElectroCardiogramme

EEG : ElectroEncéphaloGramme

EFR : Explorations Fonctionnelles Respiratoires

EMG : ElectroMyoGramme

ESSV : ExtraSystoles Supra-Ventriculaires

ESV : ExtraSystole Ventriculaire

FA : Fibrillation Auriculaire

FAN: Algorithme de compression de l'ECG (Eventail)

FFT : Fast Fourier Transform

FN : False Negative

FP : False Positive

FP : Faux Positifs

FV : Fibrillation Ventriculaire

HRV : Heart Rate Variability

HeT : Hermite Transform

IDCT : Inverse Discrete Cosinus Transform

IDFT : Inverse Discrete Fourier Transform

IRCO : Insuffisance Respiratoire Chronique Obstructive

IRCR : Insuffisance Respiratoire Chronique Restrictive

IDST : Inverse Discrete Sinus Transform

LaT : Laguerre Transform

LDA : Linear Discriminant Analysis

MART : Multi-Channel Adaptive Resonance Theory

MLP : MuLtilayer Perceptrons

MLPNNs : MuLtilayer Perceptrons Neuronal Networks

MRI: Magnetic Resonance Imager

N : Normal

NAV : Nœud Auriculo-Ventriculaire

NS : Nœud Sinusal

PAC : PACed beat

PNN : Probabilistic Neural Network

- PP** : Prédicativité
- PRD**: Percent **R**oot mean square **D**ifference
- PRI** : **P**léthysmographie **R**espiratoire par **I**nductance
- PVC** : Premature **V**entricular **C**ontraction
- QRS** (complexe) : région du signal ECG constituées des ondes Q, R et S
- RBF** : **R**adial **B**asis **F**unction
- RCE** : **R**estricted **C**oulomb **E**nergy
- RLE** : **R**un-**L**ength **E**ncoding
- RNA** : **R**éseaux de **N**eurons **A**rtificiels
- SA** : **B**locs **S**ino-**A**uriculaires
- SAPA**: **S**can **A**long **P**olygonal **A**pproximation
- SE** : **S**ensibilité
- SOM**: **S**elf **O**rganizing **M**ap (algorithme de classification automatique)
- SP** : **S**pécificité
- SVM** : **S**upport **V**ector **M**achine
- TcT** : **T**chebychev **T**ransform
- TP** : **T**rue **P**ositive
- TP**: **T**uning **P**oint
- TN** : **T**rue **N**egative
- TV** : **T**achycardie **V**entriculaire
- VABD** : **V**olumes changes of **A**BDomen
- VESC**: **V**entricular **E**SCape beat
- VLWAV**: **V**entricular flutter **W**AVe
- VTHO**: **V**olume changes of **T**Horacic cage

Résumé

La compression et la classification automatique des signaux Electrocardiogramme (ECG) constituent un des thèmes majeurs de la recherche biomédicale. Elles jouent un rôle important de nos jours pour accélérer le diagnostic des maladies cardio-vasculaires.

La compression des signaux ECG trouve un nouvel intérêt à cause de la télémédecine. Elle est nécessaire pour réduire la quantité de données à stocker et à transmettre vers un autre centre hospitalier à travers un réseau Internet ou Intranet. Aussi, la classification des battements du signal ECG en différents cas pathologiques est une tâche de reconnaissance très complexe.

L'étude abordée dans le cadre de cette thèse porte sur le développement, l'implémentation, et l'évaluation de plusieurs algorithmes de compression et de classification des signaux ECG.

Ces algorithmes concernent principalement :

- La compression des signaux ECG par une transformation sinusoidale et par une transformation en ondelettes ;
- La classification des battements cardiaques en deux classes (Normal et Anormal) par l'extraction des paramètres pertinents à partir du signal ECG et signal respiratoire ;
- Et enfin la modélisation polynomiale du signal ECG par les polynômes d'Hermite et Tchebychev , et l'exploitation des coefficients de la modélisation pour former des nouveaux descripteurs appliqués à l'entrée des classificateurs neuronaux multicouches pour la classification de quatre types de battements (N, PVC, BBD et BBG).

Les résultats expérimentaux obtenus en testant les différentes approches proposées sur les enregistrements ECG réels des bases de données MIT-BIH et Apnea-ECG démontrent l'efficacité de telles approches par rapport à d'autres méthodes existantes dans la littérature.

Mots Clés

Electrocardiogramme (ECG), Signal respiratoire, Compression, Classification, Modélisation, classificateurs neuronaux multicouches, Polynômes d'Hermite, Polynômes de Tchebychev.

ملخص الأطروحة

تقليص حجم بيانات إشارة المخطط الكهربائي للقلب (م ك ق) والتعرف التلقائي على أنماط ضرباته المختلفة هي واحدة من المواضيع الرئيسية للبحوث الطبية الحيوية التي تلعب دورا هاما في أيامنا هذه لتسريع تشخيص أمراض القلب والشرايين.

موضوع عملية تقليص حجم إشارة النشاط الكهربائي للقلب يعرف اهتماما متزايدا بسبب تطور التطبيب عن بعد. فمن الضروري تقليل كمية البيانات التي يتم تخزينها وإرسالها إلى مستشفى آخر من خلال الإنترنت أو الإنترنت. كما تعتبر عمليات تصنيف ضربات القلب إلى فئات مرضية محددة ومختلفة مهمة معقدة للغاية.

تناولت الدراسة في هذه الأطروحة العديد من خوارزميات تقليص حجم إشارة المخطط الكهربائي للقلب وتصنيف ضرباته، حيث تم تطويرها، تنفيذها و تقييمها.

هذه الخوارزميات تتمثل أساسا في :

- تقليص حجم بيانات إشارة النشاط الكهربائي للقلب عن طريق التحويلات الجيبية و تحويل المويجات؛
- تصنيف ضربات القلب إلى فئتين (العادية وغير العادية) عن طريق استخراج المعلومات ذات الصلة من إشارة تخطيط القلب وإشارة الجهاز التنفسي.
- وأخيرا، وضع نمذجة متعددة الحدود للإشارة النشاط الكهربائي للقلب بواسطة متعدد الحدود هيرميت وتشبيشيف، واستغلال معاملات النمذجة لتشكيل صفات جديدة تطبق على مداخل المصنفات العصبية متعددة الطبقات من أجل تصنيف أربعة أنواع من ضربات القلب (N، PVC، BBD و BBG).

النتائج التجريبية التي تم الحصول عليها عن طريق اختبار المناهج المختلفة المقترحة على الإشارات الحقيقية (م ك ق) من قاعدة البيانات لمعهد ماساتشوستس للتكنولوجيا أثبتت كفاءة هذه المناهج بالمقارنة مع الطرق الأخرى والمنشورة في مجلات علمية مشهورة.

الكلمات المفتاحية

إشارة المخطط الكهربائي للقلب، إشارة الجهاز التنفسي، تقليص ، تصنيف، نمذجة، المصنفات العصبية متعددة الطبقات، متعدد الحدود هيرميت، متعدد الحدود تشبيشيف.

Abstract

Compression and automatic classification of ECG signals is an important biomedical research area. They are considered as a useful tool to accelerate the diagnosis of heart disease.

Data compression of ECG signal is also used in many telemedicine applications. In fact, it reduces the stored data in order to transmit them to the hospital center through an Internet or intranet network.

About the classification of heartbeats into different pathologic categories, this is a very complex pattern recognition task.

This thesis focuses on the development, implementation, and evaluation of several algorithms of compression and classification of ECG signals.

These algorithms consist mainly in:

- ECG compression using sinusoidal and wavelet transforms;
- Classification of heartbeats into two classes (normal and abnormal) by extracting relevant parameters from ECG and respiratory signals;
- And finally, modeling of the ECG signals through Hermite and Tchebyshev polynomials and apply these models to generate new descriptors that will also be applied to multilayer neural classifiers for the classification of four types of beats (N, PVC, BBD and BBG).

Compared with other existing approaches, results obtained by testing the different approaches proposed on ECG data from MIT-BIH and Apnea-ECG databases, are very satisfactory.

Keywords

ECG (Electrocardiogram), Respiratory signal, Compression, Classification, Modeling, Multilayer neural classifiers, Hermite polynomials, Chebyshev polynomials.

INTRODUCTION GENERALE

L'électrocardiogramme (ECG) reste encore l'un des outils prédominants et les plus largement utilisés pour le diagnostic et l'analyse des arythmies cardiaques dans les services de cardiologie.

L'ECG regroupe plusieurs paramètres importants appelés ondes P, Q, R, S, T et U et un ensemble d'intervalles qui sont les suivants :

- L'intervalle RR ;
- L'intervalle QT ;
- L'intervalle PR ;
- Le segment ST ;
- Et le complexe QRS.

Toute l'information utile d'un signal ECG est contenue dans ses ondes, et le changement de ces intervalles représente un signe d'anomalies cardiaques. La modélisation, la compression et la classification des signaux médicaux, jouent un rôle très important dans l'aide au diagnostic des maladies cardiaques.

L'étude que nous abordons dans le cadre de cette thèse porte sur la modélisation et la compression des signaux ECG à travers les méthodes de transformations, en particulier les transformations polynomiales, et la possibilité de les utiliser pour réaliser la classification automatique des battements cardiaques.

Notre thèse se subdivise en six chapitres. L'objectif du premier chapitre est de donner une description des signaux ECG et respiratoires en partant de leurs origines anatomiques et physiologiques. Nous aborderons ensuite les différentes techniques d'acquisition de ces signaux, ensuite nous présenterons les différentes pathologies rencontrées dans un enregistrement électrocardiogramme.

Le deuxième chapitre est consacré à l'étude exhaustive des techniques de compression des signaux ECG. Nous aborderons ce chapitre par la présentation des différents critères d'évaluations de compression. Les méthodes de compression seront ensuite citées en insistant particulièrement sur les techniques directes de compression par transformations sinusoïdales et polynomiales.

Le troisième chapitre est consacré à l'étude des polynômes orthogonaux et leurs utilisations dans la modélisation et la compression des signaux ECG. D'abord nous allons présenter les propriétés et les caractéristiques principales des polynômes orthogonaux, les familles de polynômes orthogonaux les plus connus, ensuite nous décrirons le processus de modélisation polynomiale des signaux ECG. Ce processus commence par la segmentation d'un signal en fenêtres. Les durées de ces fenêtres devront coïncider avec celles des cycles cardiaques. La détection des complexes QRS est de première importance pour réaliser de telles segmentations. La transposition de ces segments dans les domaines de définition des polynômes puis le calcul des coefficients de décomposition seront utilisés pour réaliser la reconstitution du signal d'origine.

Dans le quatrième chapitre, une description des réseaux de neurones sera faite. Nous allons débiter par une exposition de l'historique de l'évolution de conception et l'utilisation des réseaux de neurones. Après, on se focalisera sur les types et la méthodologie d'apprentissage des réseaux de neurones artificiels. Nous présenterons aussi ; d'une manière générale ; les étapes de conception d'un réseau de neurone et les différents domaines de son utilisation.

Dans le chapitre V, un nouvel algorithme de classification des battements cardiaques en battement normaux et anormaux sera présenté. Les différents enregistrements utilisés pour le test (respiratoire et ECG) seront traités et analysés afin d'extraire les principales sources d'informations pertinentes. Une comparaison des résultats obtenus, par les différents classificateurs neuronaux multicouches utilisés, sera ensuite faite.

Dans le sixième et dernier chapitre, les résultats des études menées sur la modélisation polynomiale et qui ont été présentés lors du troisième chapitre seront exploités pour réaliser la compression et la classification des signaux ECG.

L'idée de compression est de sélectionner seulement un petit nombre de coefficients pour reconstruire le signal ; et pour la classification l'idée est d'utiliser les coefficients de modélisations polynomiales comme de nouveaux descripteurs d'un battement cardiaques pour classier les battements en différents classes. La classification est réalisée en utilisant aussi les réseaux de neurones multicouches et une méthode de compression de donnée (ACP) pour réduire et accélérer le système de classification. Nous allons évaluer notre algorithme selon des critères théoriques qui mesurent les taux de classification, de sensibilité et de la spécificité. Ce dernier chapitre s'achève sur une présentation d'un ensemble de propositions qui visent dans un premier temps à améliorer les résultats de classification et par la suite à ouvrir des perspectives pour la continuation de ce travail.



Chapitre I

Généralités théoriques sur les signaux
biomédicaux



Chapitre I : Généralités théoriques sur les signaux biomédicaux

I.1. Introduction

Les signaux biomédicaux sont des grandeurs physiques prélevés sur le corps humain au moyen de capteurs appropriés. Ils sont de nature électrique, on peut citer : l'électrocardiogramme (ECG), électroencéphalogramme (EEG), électromyogramme (EMG) ou de nature non-électrique à savoir : la respiration, les mouvements, etc. Tels signaux, contiennent des informations cachées qui sont très utiles aux cliniciens et aux médecins pour faire leur diagnostic et de les guider dans leur thérapeutique.

Dans ce chapitre, des notions de bases sur les signaux ECG et respiratoires seront présentées. Au début, une description de l'origine anatomique et physiologique du signal ECG sera faite. Nous décrivons ensuite le principe d'enregistrement, l'aspect normal d'un signal ECG et ces caractéristiques. L'origine anatomique ainsi que les techniques d'enregistrement du signal respiratoire seront présentés.

I.2. Electrocardiographie

L'électrocardiographie est la techniques de transcription de l'activité électriques et rythmique du cœur sous la forme d'un tracé appelé électrocardiogramme [Michel, 2001]. L'électrocardiographie est une technique relativement peu coûteuse, permettant à l'aide d'un examen indolore et sans danger, de surveiller l'appareil cardio-circulatoire, notamment pour la détection des troubles du rythme et la prévention de l'infarctus du myocarde [Hadj, 2006].

I.2.1. Anatomie du cœur

Le cœur est un muscle creux (figure I.1) contractile assurant la circulation sanguine, il éjecte environ 5 à 6 litres de sang à la minute [Sabatier, 2006] dans chaque contraction, il propulse le sang grâce aux contractions de son tissu musculaire appelé myocarde. Il se trouve dans le médiastin, entre les deux régions pleuro-pulmonaires ; il est à peu près de la taille d'un poing et pèse environ 350 gr. Une épaisse cloison (appelé spectre) sépare le cœur en deux parties indépendantes (cœur droite et cœur gauche) en donnant ainsi une « double pompe ».

Chaque partie est divisée en oreillette et en ventricule. La partie droite contient du sang pauvre en oxygène et assure la circulation pulmonaire; la partie gauche renferme du sang riche en oxygène et le propulse dans tous les tissus.

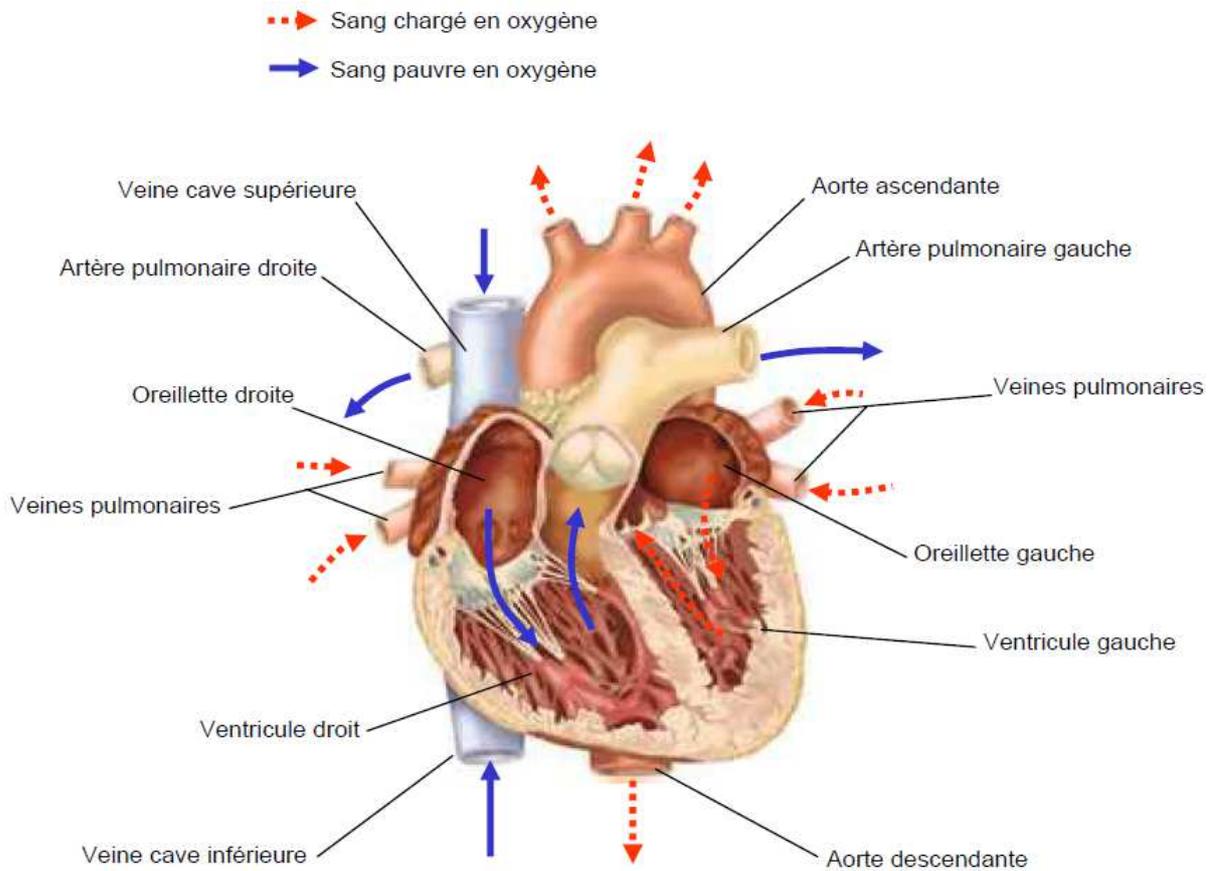


Figure I.1 : L'anatomie du cœur [Dubois, 2004]

I.2.2. Système de conduction électrique cardiaque

La contraction myocardique et l'éjection ventriculaire qui en résulte, nécessitent l'activation électrique préalable des cellules musculaires dans un ordre bien établi, afin que la contraction soit la plus efficace possible.

Le système spécialisé d'excitation/conduction électrique comprend (figure I.2):

- Le nœud sinusal ;
- Les voies spécialisées internodales ;
- Le nœud auriculo-ventriculaire (NAV) ;
- Le faisceau de His;
- Les branches droite et gauche ;
- Et les fibres de Purkinje.

- **Le nœud sinusal (NS)** : ou nœud de Keith et Flack, est le « pace maker » du rythme cardiaque. Il est situé au niveau de l'abouchement de la veine cave supérieure dans l'oreillette droite. Ce nœud est une masse de cellules musculaires, il est situé sous l'endocarde, irradie dans la musculature de l'oreillette droite et conduit l'excitation au moyen des voies spécialisées internodales jusqu'au nœud auriculo-ventriculaire.
- **Le nœud auriculo-ventriculaire (NAV)** ou nœud d'Aschoff et Tawara : joue un rôle de filtre en ralentissant la propagation de l'influx, il est situé dans l'oreillette droite, contre la cloison interauriculaire, à proximité de l'abouchement du sinus coronaire. Ce nœud se poursuit par le faisceau de His [Mellal, 2010].
- **Le faisceau de His** ou faisceau auriculo-ventriculaire : prolonge le nœud d'Aschoff et Tawara ; Il est situé dans la partie haute du septum interventriculaire et ses fibres traversent le tissu connectif (non excitable) qui sépare électriquement les oreillettes des ventricules. le faisceau de His se divise en deux branches, la gauche et la droite ;
- **la branche droite** : elle est située le long de la partie droite du septum interventriculaire et facilite la conduction de l'activité électrique dans le ventricule droit ;
- **la branche gauche** : cette branche se subdivise en deux hémibranches, l'une antérieure gauche et l'autre postérieure gauche
- **Les fibres de Purkinje** : Les branches du faisceau de His finissent dans un réseau de fibres qui arrivent dans les parois ventriculaires. Les fibres de Purkinje terminent en anastomoses avec les fibres myocardiques musculaires, facilitant leur excitation [Antoine, 2006].

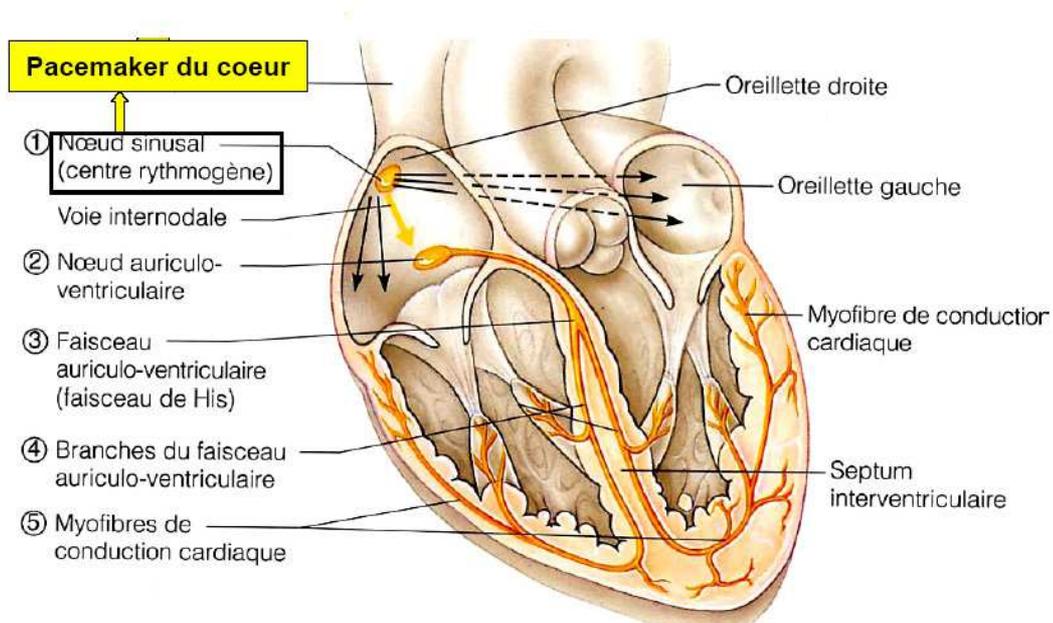


Figure .I.2 : Circuits de conduction des excitations électriques dans le cœur [Daniel, 2007]

I.2.3. L'Electrocardiogramme (ECG)

L'électrocardiogramme est un signal physiologique représentatif de l'activité électrique du muscle cardiaque, il exprime donc les événements électriques de l'excitation cardiaque (forces électromotrices) et peut renseigner sur l'état du cœur.

Le signal ECG peut être enregistré sur différents sites du corps d'un sujet par l'intermédiaire d'électrodes. Le signal est reçu par un appareil nommé « Electrocardiographe ».

I.2.3.1. Technique d'enregistrement du signal ECG

Des électrodes conductrices sont placées sur la peau du patient : à l'extrémité des quatre membres et sur le thorax. Selon leurs emplacements, on distingue différentes dérivations à savoir :

- Dérivations périphériques standard d'Einthoven ;
- Dérivations périphériques unipolaires de Goldberger ;
- Dérivations unipolaires précordiales.

I.2.3.1.1. Dérivations périphériques standard d'Einthoven

Elles sont au nombre de trois. Ces dérivations sont bipolaires. Elles permettent la mesure des différences de potentiel entre des points très éloignés au niveau du corps. On distingue (Figure I.3) :

- La dérivation I (DI) : Mesure bipolaire entre bras gauche et bras droit. Elle explore la paroi latérale gauche du ventricule gauche.
- La dérivation II (DII) : Mesure bipolaire entre jambe gauche et bras droit. Elle suit la cloison inter-ventriculaire et l'apex.
- La dérivation III (DIII) : Mesure bipolaire entre jambe gauche et bras gauche. Elle explore la région ventriculaire droite et diaphragmatique du cœur.

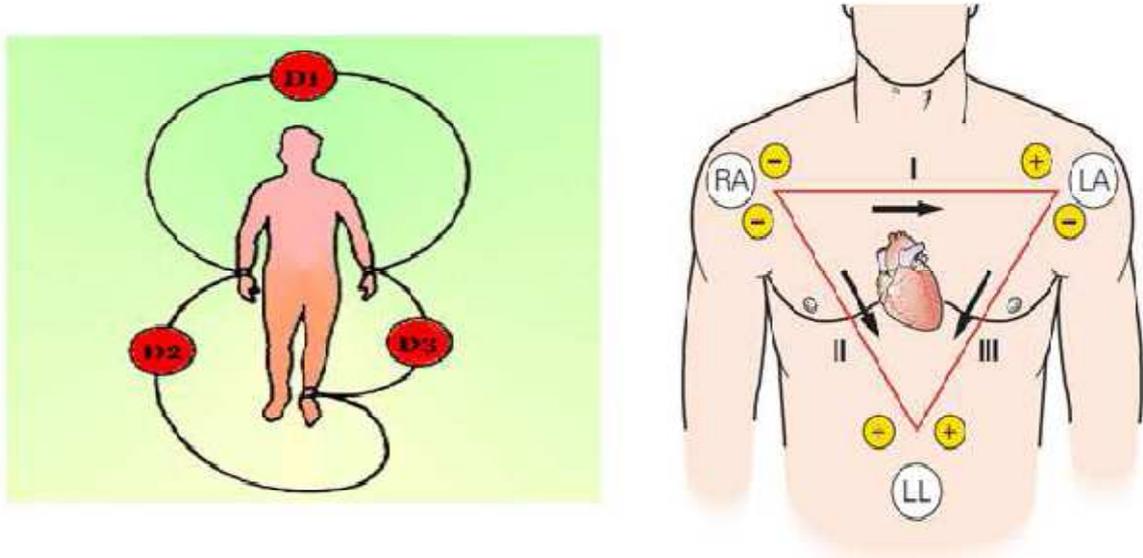


Figure I.3 : Dérivations bipolaires DI, DII, DIII

I.2.3.1.2. Dérivations périphériques unipolaires de Goldberger

Elles permettent de mesurer les variations de potentiel aux extrémités du corps au moyen d'une électrode exploratrice (pôle positif). Ce potentiel étant comparé à celui d'une électrode de référence (pôle négatif) dont le potentiel est nul (Figure I.4). Les dérivations sont connues par aVR, aVL et aVF ; où "a" : augmented voltage ; indique que le potentiel recueilli par chacune de ces dérivations est amplifié. Le "V" signifie qu'il s'agit d'une dérivation unipolaire. "R", "L", "F" est (Right, Left, Foot). aVR explore le potentiel endo-cavitaire, aVL explore la paroi latérale supérieure du ventricule gauche et aVF (jambe gauche) correspond à la partie inféro-diaphragmatique du cœur.

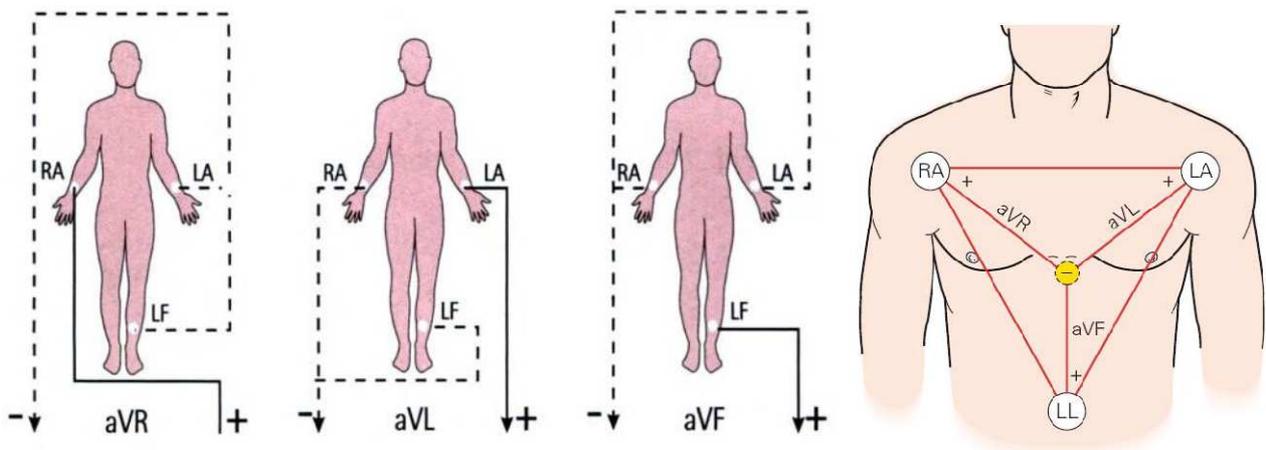


Figure I.4 : Dérivations unipolaires aVL, aVR, aVF.

I.2.3.1.3. Dérivations précordiales

Ce sont des dérivations unipolaires mises au point par Wilson (Wilson et al, 1944). Elles sont posées sur le thorax près du cœur, en des endroits précis dans six points (Figure I.5).et sont désignées par la lettre V suivie du numéro de leur emplacement (V1 à V6).

- V1 : électrode placée à la 4^{ème} espace intercostal droit, bord droit du sternum.
- V2 : électrode placée à la 4^{ème} espace intercostal gauche, bord gauche du sternum.
- V3 : électrode placée à mi-chemin entre V2 et V4.
- V4 : électrode placée à la 5^{ème} espace intercostal gauche, sur la ligne médio claviculaire.
- V5 : électrode placée en même horizontale que V4, la ligne axillaire antérieure.
- V6 : électrode placée en même horizontale que V4, la ligne axillaire moyenne.

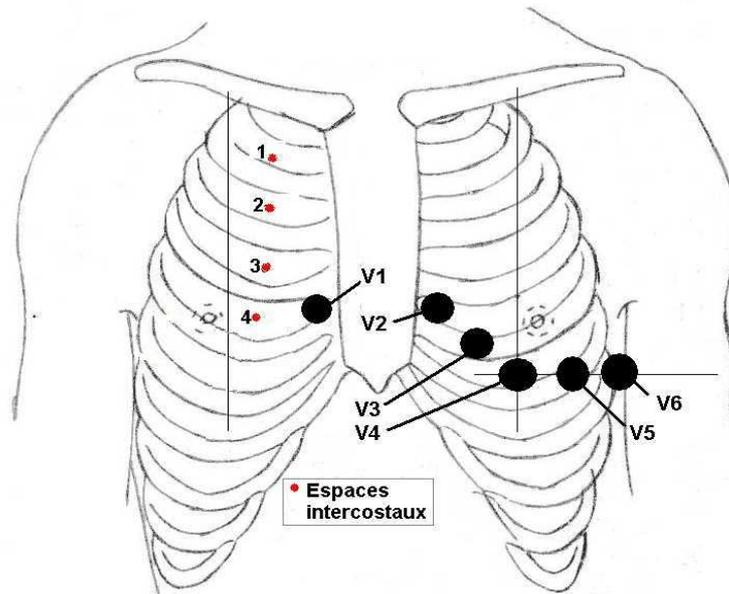


Figure I.5 : Dérivations précordiales unipolaires

I.2.3.2. Caractéristiques d'un signal ECG Normal

Le processus de dépolarisation et de repolarisation des structures myocardiques se présente dans l'ECG comme une séquence de déflexions ou ondes superposées à une ligne de potentiel zéro, appelée ligne isoélectrique ou ligne de base (Figure I.6). En examinant, un ECG, on reconnaît :

- **L'onde P:** correspond à la dépolarisation (et la contraction) des oreillettes, droite et gauche. C'est une onde de petite amplitude ;
- **Le complexe QRS:** correspond à la dépolarisation (et la contraction) des ventricules, droit et gauche. Il possède la plus grande amplitude de l'ECG. Il est constitué de trois ondes consécutives : l'onde Q qui est négative, l'onde R qui est positive dans un ECG normal et l'onde S qui est négative ;
- **L'onde T:** elle est le témoin électrique de la repolarisation ventriculaire, elle se développe en général dans le même sens que QRS par rapport à la ligne isoélectrique ;
- **L'onde U:** est une petite déflexion parfois observée après l'onde T. Habituellement positive, son origine est mal précisée. Il ne faut pas la confondre avec l'onde P.

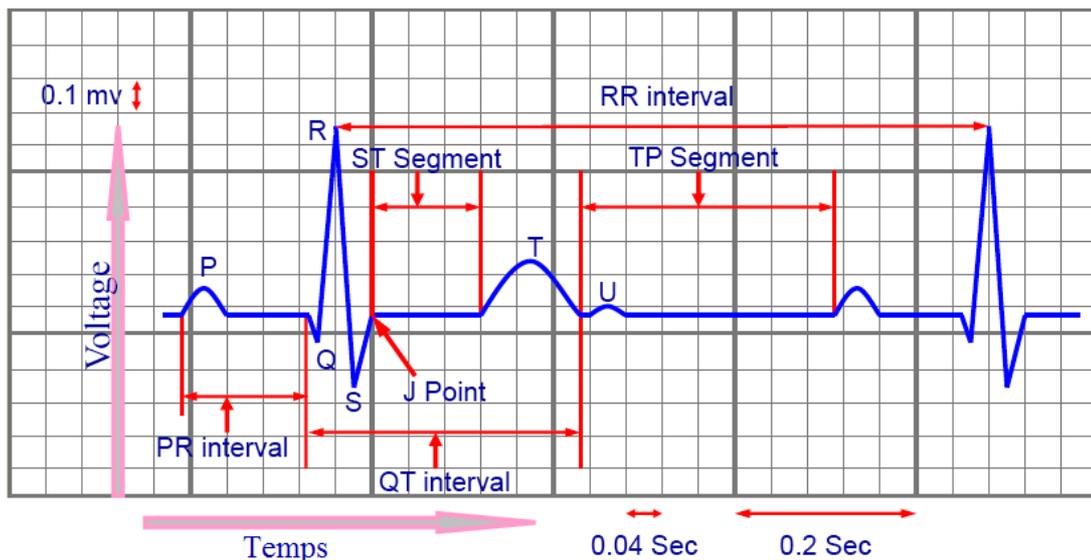


Figure I.6 : Tracé ECG

Le tracé électrique comporte aussi différents intervalles à savoir :

- **L'intervalle PR :** est le temps entre le début de P et le début du QRS. Cet intervalle représente le temps de conduction de l'activité électrique des oreillettes aux ventricules ;
- **L'espace QT :** mesuré du début du QRS à la fin de l'onde T correspond à l'ensemble de la dépolarisation et de la repolarisation ventriculaire (temps de systole électrique) ;
- **le segment ST :** correspond au temps séparant le début de la dépolarisation ventriculaire représentée par le complexe QRS et le début de l'onde T, il est généralement isoélectrique et suit horizontalement la ligne de base.

Une description détaillée sur les différents paramètres d'un signal ECG normal est faite dans le tableau I.1.

Onde P	<ul style="list-style-type: none"> ▪ Chaque onde P doit précéder un complexe QRS ▪ Forme identique à l'intérieur d'une même dérivation ▪ Positive en dérivation DI, DII, DIII, et V6 ▪ Moins de 0.12 s en largeur dans la dérivation DIII ▪ Biphase avec une composante dominante positive ou monophasique avec une déflexion positive en V1
Intervalle PR	<ul style="list-style-type: none"> ▪ Consistant en largeur ▪ La longueur est supérieure à 0.12 s et inférieure à 0.24 s
Complexes QRS	<ul style="list-style-type: none"> ▪ Moins de 0.12 s en largeur ▪ La plus grande déflexion en dérivation standard excède 5 mm de hauteur ▪ L'axe moyen en dérivation standard entre -30° et +90°
Onde Q	<ul style="list-style-type: none"> ▪ Petite et étroite, Q en DI, DII, aVF et V3-6, avec une hauteur moins que 25% de l'onde R du même complexe et d'une largeur moins de 0.04 s
Segment ST	<ul style="list-style-type: none"> ▪ Normalement isoélectrique ▪ La déflexion, si elle existe, ne doit pas dépasser 1mm en DI, DII, DIII et aVF ▪ L'élévation, si elle existe, ne doit pas excéder 2 mm en les mêmes Dérivations ▪ Elévations jusqu'à 4 mm possibles dans les dérivations V1-V3.
Onde T	<ul style="list-style-type: none"> ▪ Positive en DI, DII et V6 ▪ Normalement positive mais occasionnellement négative en DIII et aVF ▪ Doit être au moins 2 mm en hauteur en dérivation où elle est plus grande.
Onde U	<ul style="list-style-type: none"> ▪ Pas nécessairement présente, mais, si elle existe, elle devra : <ul style="list-style-type: none"> ○ être plus grande en V2-4 ○ positive en V1-2 et en dérivation avec l'onde T positive ○ normalement moins que 25% en hauteur par rapport à l'onde T qui précède, mais peut atteindre 2 mm en V2-4
Intervalle QT	<ul style="list-style-type: none"> ▪ On peut utiliser la formule de Bazett : $QT_{corrigé} = \frac{QT_{mesuré}}{\sqrt{RR}}$ on normalement $QT_{corrigé} \leq 0.44$

Tableau I.1 : Critères de normalité du signal ECG [Kom, 2001]

I.2.4. Pathologies cardiaques

Dans l'analyse de l'ECG, les pathologies ou anomalies sont détectées et classées en fonction de leur déviation par rapport au rythme idéal qu'est le rythme sinusal. Chaque déviation visible sur l'ECG peut être attribuée à une anomalie physiologique.

I.2.4.1. Rythme sinusal

Il correspond à une activation physiologique des oreillettes, puis des ventricules, à partir du nœud sinusal. Le rythme cardiaque normal est sinusal et régulier, si les espaces R-R consécutifs identiques et sa fréquence se situe entre 60 et 90/min.

I.2.4.2. Troubles de la conduction cardiaque [Aulagnier, 1998]

Il s'agit du ralentissement ou d'interruption de la conduction de l'influx électrique pouvant survenir à tous les étages du circuit électrique normal du cœur.

- Entre le nœud sinusal et les oreillettes, on parle de bloc sino-auriculaire ou de dysfonction sinusale ;
- Entre oreillettes et ventricules, on parle de bloc auriculo-ventriculaire ;
- Dans le réseau de Purkinje, on parle de bloc de branche ou d'hémibloc de branche en fonction de la structure touchée.

I.2.4.2.a. Blocs Sino-Auriculaires (Bloc SA)

Les blocs sino-auriculaires (BSA) sont des défauts de conduction entre le nœud sinusal (de Keith et Flack) et les oreillettes. L'activité du nœud sinusal n'étant pas visible sur l'électrocardiogramme, seule l'analyse de l'activité auriculaire permet d'en faire le diagnostic. Il s'agit à divers degrés de pauses et de ralentissements sinusaux.

I.2.4.2.b. Blocs Auriculo-Ventriculaires (BAV)

Les BAV sont des ralentissements ou un arrêt de la conduction nerveuse entre l'étage auriculaire et l'étage ventriculaire (blocs auriculo-ventriculaires : BAV). Ils sont classés en fonction du degré du bloc qui peut siéger dans différentes structures.

I.2.4.2.c. Blocs de branche

Un bloc de branche se définit comme un retard (bloc de branche incomplet) ou une interruption (bloc de branche complet) de la conduction dans une des branches du faisceau de His. On parle de bloc de branche droit (BBD) ou de bloc de branche gauche (BBG). Les deux ventricules ne sont donc plus activés de façon synchrone, mais l'un après l'autre (l'influx traverse la branche fonctionnelle, puis se propage à l'autre ventricule par proximité).

I.2.4.3. Troubles du rythme

Un trouble de rythme se définit comme une activité électrique anormale d'un des étages du cœur qui désorganise le rythme sinusal normal [Aulagnier, 1998]. Les troubles du rythme sont classés en fonction de leur lieu de formation et de leurs effets sur le rythme cardiaque. Si le trouble se déclare dans les oreillettes ou le nœud atrio-ventriculaire, on parlera d'arythmie supra-ventriculaire; s'il apparaît dans les ventricules, on parlera d'arythmie ventriculaire. Si une

arythmie accélère le rythme cardiaque, on parlera de tachycardie (tachy = rapide); si elle le ralentit, on parlera alors de bradycardie (Brady = lent) [Mackay, 2004].

I.2.4.3.a. La fibrillation auriculaire (FA)

La fibrillation auriculaire est la plus fréquente des arythmies, elle est définie comme la contraction anarchique des oreillettes, qui entraîne une contraction rapide et irrégulière des ventricules. Elle peut être paroxystique ou permanente. Elle est due à de nombreux foyers ectopique déchargeant à des fréquences variables, ce qui entraîne un rythme auriculaire chaotique et irrégulier [Rouquette, 2002].

I.2.4.3.b. Extrasystole ventriculaire (Contraction ventriculaire prématurée)

Les ESV sont des battements anormaux dus à la présence d'une zone irritative dans le ventricule qui ne se soumet pas à l'harmonie de l'activation cardiaque, ils s'observent sur quasiment tous les enregistrements. La présence d'un ESV n'indique aucune pathologie particulière, mais si, de façon récurrente, leur nombre par minute est supérieur à 6, elles peuvent être un signe précurseur d'une tachycardie ventriculaire, ce qui constitue une pathologie majeure [Ellrodt, 2003].

I.2.4.3.c. La tachycardie ventriculaire (TV)

La tachycardie ventriculaire a pour origine un ou plusieurs foyer(s) ectopique(s) ventriculaire(s) (qui se dépolarisent à tour de rôle). Les battements ont donc la forme d'extrasystoles ventriculaires très rapprochées qui dépassent 100bat/min [Dubois, 2004].

I.2.4.3.d. Fibrillation ventriculaire (FV)

La fibrillation ventriculaire est l'équivalent physiologique de la fibrillation auriculaire, mais transposée aux ventricules : les ventricules se déchargent alors de manière totalement désynchronisée, et il n'y a plus de systole cardiaque. Une fibrillation ventriculaire constitue donc une arythmie particulièrement grave, puisqu'elle est une menace de mort imminente. En effet le cœur n'assure plus du tout son travail de pompe, le sang ne circule plus, ce qui conduit à une asphyxie de tous les tissus du corps, dont le myocarde lui-même [Dubois, 2004].

I.2.4.3.e. Extrasystoles supra-ventriculaires

Les extrasystoles supraventriculaires (ESSV) sont des impulsions électriques prématurées naissant dans une région supraventriculaire (auriculaire ou de la jonction atrio-ventriculaire (AV)). Elles sont produites par divers mécanismes, notamment par l'augmentation de l'automatisme, l'activité déclenchée par des post potentiels, et la réentrée.

I.2.4.3.f. La tachycardie supra-ventriculaire

Lors de tachycardie paroxystique, le cœur s'emballé soudainement et bat très rapidement, jusqu'à 150 à 220 fois par minute. Ces épisodes peuvent durer quelques secondes ou se prolonger pendant plusieurs heures. Ils s'arrêtent aussi soudainement qu'ils sont apparus. Les tachycardies supra ventriculaires peuvent apparaître dès le très jeune âge et persister toute la vie. Après ces crises, le sujet se sent fatigué, mais ce type d'arythmie est rarement dangereux. Elles nécessitent néanmoins l'attention du médecin, car elles peuvent être gênantes et diminuer la qualité de vie [Khaddoumi, 2005].

I.3. La respiration

La respiration est l'ensemble des mouvements du corps servant à approvisionner l'organisme en oxygène (O₂) pour répondre aux besoins des organes qui en consomment pour leur activité. L'apport en oxygène est couplé avec l'élimination du gaz carbonique (CO₂) produit par les organes.

I.3.1. Anatomie du système respiratoire

Le système respiratoire regroupe l'ensemble des organes qui interviennent dans la respiration. Ce système est composé des voies aériennes supérieures comprenant notamment le nez, la bouche, les sinus, le pharynx, le larynx et la trachée, et de voies aériennes inférieures comprenant les poumons, les bronches, les bronchioles et les alvéoles (figure I.7).

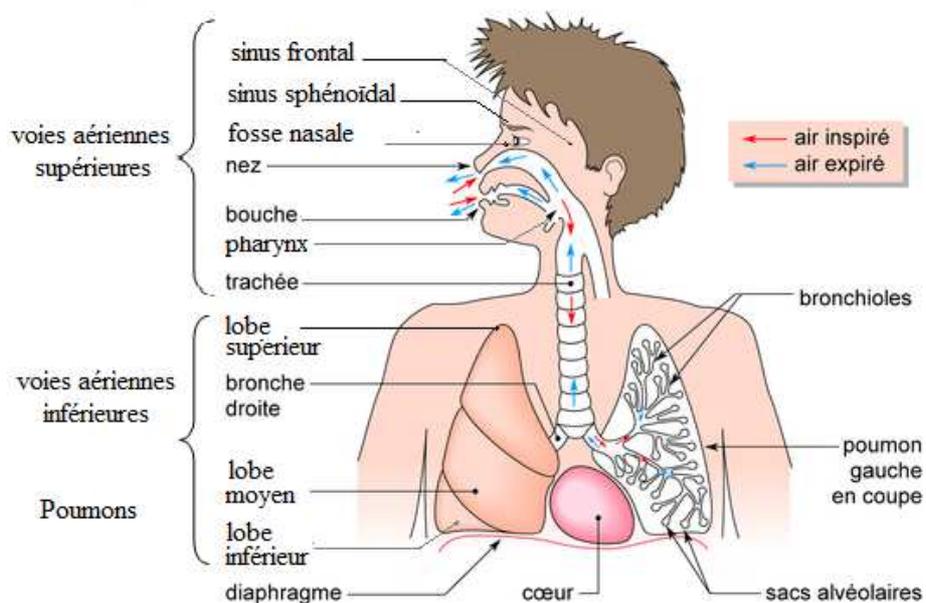


Figure I.7: Système respiratoire de l'homme.

I .3.2. Fonctionnement de l'appareil respiratoire

L'air entre par le nez et la bouche, puis descend dans la gorge jusqu'au larynx, où se situent les cordes vocales ; il pénètre ensuite dans la trachée, située au-dessous du larynx.

Les poumons ressemblent à un arbre inversé, dont la trachée serait le tronc. Ce tronc a environ 2.5 centimètres de diamètre chez l'adulte. La trachée se divise en deux bronches souches, l'une à droite, l'autre à gauche (figure I.8).

Les poumons sont entourés d'une enveloppe, la plèvre. Ils sont contenus dans la cage thoracique, constituée de côtes, de muscles et de ligaments, le diaphragme.

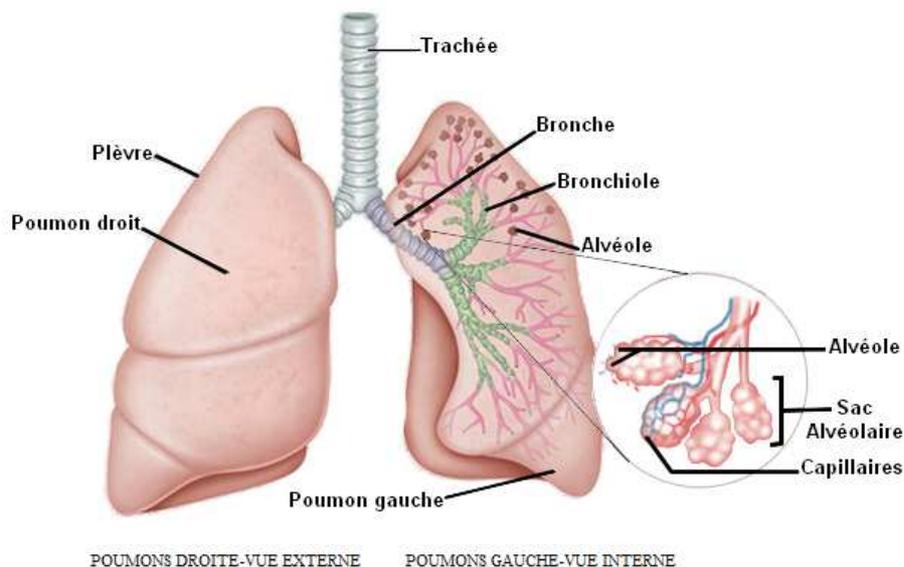


Figure I.8: Poumons normaux.

Lors de l'inspiration, le diaphragme s'abaisse et les muscles des côtes se contractent, ce qui a pour effet d'augmenter le volume de la cage thoracique et ainsi de diminuer la pression dans les poumons. Cela crée une dépression faisant entrer l'air dans les poumons. C'est une phase active. Le diaphragme, muscle principal de l'inspiration, est très résistant à la fatigue (il fonctionne en continu).

Lors de l'expiration, les muscles se relâchent (ceux des côtes et du diaphragme) qui baisseront la cage thoracique. Cela a pour effet d'augmenter la pression dans les poumons. L'air sera donc chassé vers l'extérieur. Cette phase est passive. Cette dernière phase peut devenir active s'il y a contraction des muscles abdominaux (figure I.9).

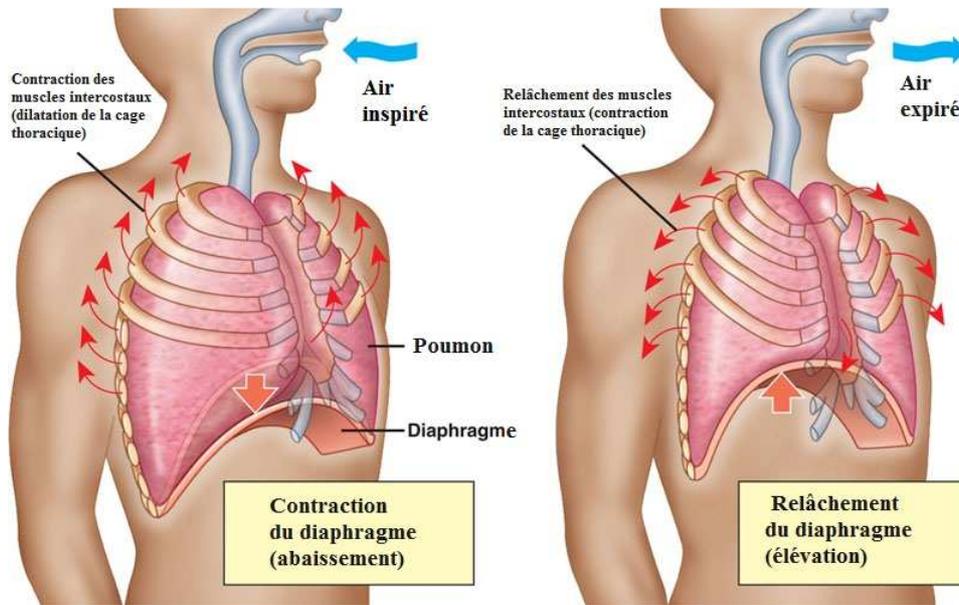


Figure I. 9 : Inspiration et expiration.

Les muscles de l'expiration sont les intercostaux internes, les abdominaux et les muscles lombaires situés à la base du Tronc (figure I. 10).

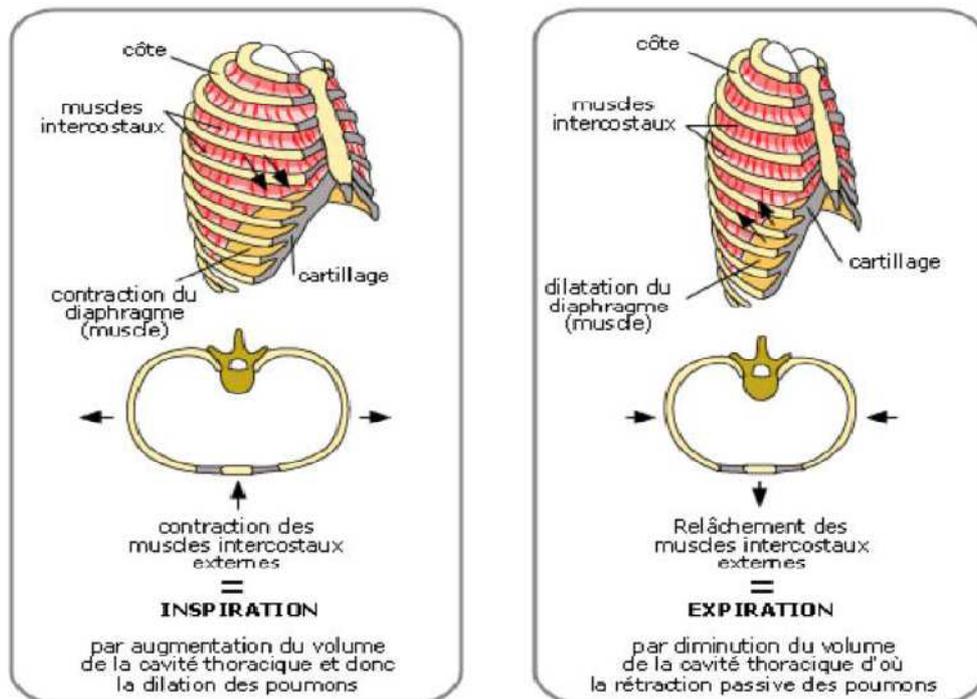


Figure I. 10 : muscles respiratoires (inspiration et expiration)

Chaque bronche souche se divise environ 25 fois en de plus petites bronches, appelées bronchioles (les branches de l'arbre). Celles-ci communiquent avec de petits sacs remplis d'air, les alvéoles, que l'on pourrait comparer aux feuilles de l'arbre.

Les alvéoles sont entourées de très petits vaisseaux sanguins.

Les poumons fournissent à notre corps l'oxygène (O₂) nécessaire à sa survie. Le gaz carbonique (CO₂), déchet constamment produit par notre organisme, est évacué par les poumons. L'oxygène respiré va de l'alvéole aux vaisseaux sanguins pour être transporté par le sang vers les cellules de notre corps. Le gaz carbonique passe des vaisseaux avant d'être rejeté à l'extérieur lors de l'expiration [Boutin, 1993].

I.3.3. Les explorations fonctionnelles respiratoires (EFR)

Elle évalue l'ensemble des processus physiologiques de la ventilation et des échanges gazeux et comprend [Leporrier, 2011] :

- a) l'étude du système ventilatoire, c'est-à-dire des volumes et débit gazeux pulmonaires ;
- b) l'étude de la mécanique respiratoire, c'est-à-dire du système qui assure le renouvellement de l'air au niveau de la zone des échanges gazeux. Il comprend un soufflet (la cage thoracique mobilisée par les muscles respiratoires), des conduits bronchiques (plus ou moins obstructifs) et un tissu pulmonaire interstitiel doué de propriétés élastiques rétractiles ;
- c) l'étude des échanges gazeux (oxygène et gaz carbonique). L'analyse des gaz du sang artériel peut mettre en évidence deux anomalies principales : l'hypoxémie et l'hypercapnie ;
- d) l'étude du contrôle central de la ventilation, notamment pendant sommeil.

Trois mesures de base sont généralement faites dans les fonctions respiratoires cliniques :

La ventilation : Les mesures sur le corps considéré comme pompe à air, déterminant son habilité à déplacer des volumes d'air et la vitesse avec laquelle ils sont déplacés. C'est le type de mesure le plus utilisé. Elle est faite à l'aide de spiromètres.

Mesure de distribution : Permettent d'indiquer les territoires de circulation intra pulmonaire des gaz dans le cas des IRCO (insuffisance respiratoire chronique obstructive) ou des IRCR (insuffisance respiratoire chronique restrictive). Elles quantifient le degré d'obstruction des poumons et déterminent aussi le volume résiduel (espace mort pathologique).

Mesure de diffusion : Teste l'habilité des poumons à échanger l'air avec le système circulatoire (échange au niveau alvéolaire).

I.3.4. Représentation spirographique de la respiration

Comme le cœur, les poumons ont des mouvements rythmiques. Mais à la différence du cœur, les poumons ne se contractent pas : ils suivent passivement les variations de volume de la cage

thoracique car ils sont solidaires de cette dernière par l'intermédiaire des plèvres. Les variations de volume de la cage thoracique peuvent être mesurées par enregistrement spirométrique (figure I.11), c'est-à-dire enregistrement des volumes d'air ventilés dans les poumons.

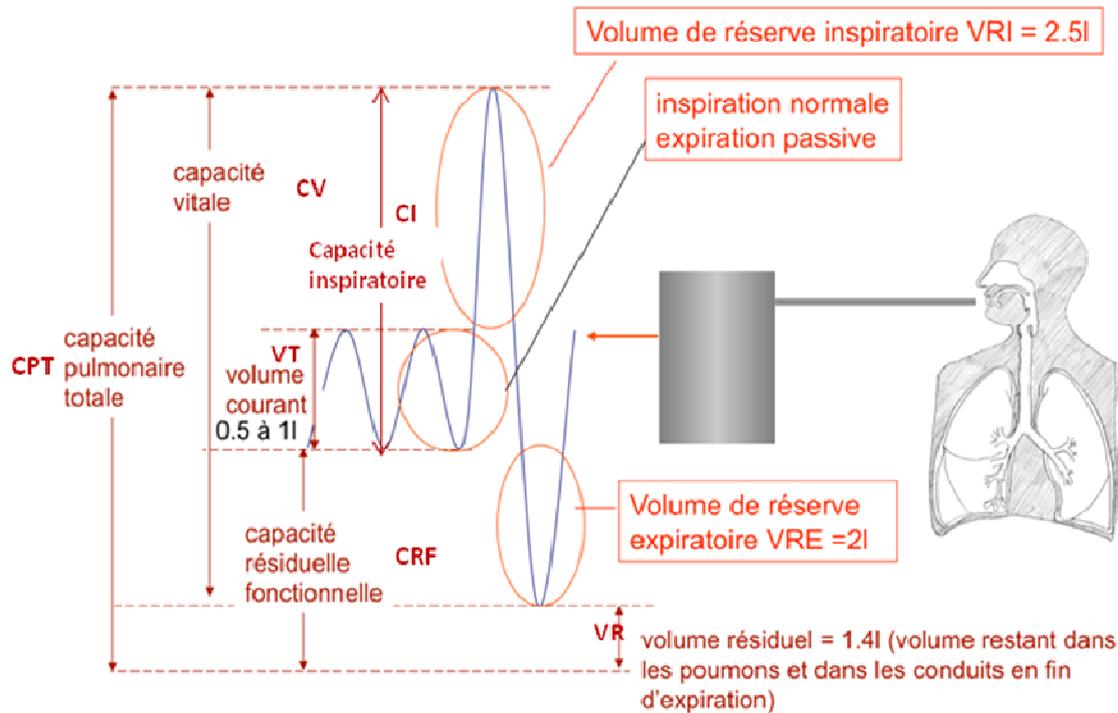


Figure I.11 : Volume et la capacité pulmonaire chez l'homme.

Le tableau I.2 résume les différents volumes mis en jeu par l'appareil respiratoire.

Volumes et capacités	Abréviations	Définition
Volume courant	VC	Volume mobilisé à chaque cycle respiratoire pendant une respiration normale. Valeur : 0,5 l d'air (500 ml)
Volume de réserve inspiratoire	VRI	Volume maximum pouvant être inspiré en plus du VC à l'occasion d'une inspiration profonde. Valeurs : chez l'homme, 3,1 l + 0,5 l (VC) = 3,6 l et chez la femme, 2 l + 0,5 l (VC) = 2,5 l
Volume de réserve expiratoire	VRE	Volume maximum pouvant être rejeté en plus du volume courant à l'occasion d'une expiration profonde
Volume résiduel	VR	Volume d'air se trouvant dans les poumons à la fin d'expiration forcée.
Capacité vitale	CV	VRI + VC + VRE
Capacité inspiratoire	CI	VC + VRI
Capacité résiduelle fonctionnelle	CRF	VRE + VR
Capacité pulmonaire totale	CPT	CV+VR

Tableau I.2 : Différents volumes et capacités pulmonaires.

I.3.5. Les méthodes de mesure des volumes et débits respiratoires

Il y'a un nombre important d'instrumentations qui sont utilisées pour mesurer les variables associés aux fonctions pulmonaires qui sont relatives au mesure de pression respiratoire , débit d'air , volume pulmonaire et concentration en gaz.

Parmi les techniques le plus souvent pratiqués, on peut trouver La spirométrie qui est la plus ancienne technique d'exploration ventilatoire. Cette technique permet d'évaluer les volumes mobilisables ainsi que les débits bronchiques.

Ils existent d'autres méthodes d'EFR qui sont très utilisées dans la clinique, dont le principal avantage réside dans le fait quelle sont non invasives, interfèrent peu avec le confort des sujets et utilisables dans des situations telles que le sommeil ; On peut citer :

- Méthode de mesure de débit aérien nasal et buccal par thermistance naso-buccale,
- et Plethysmographie respiratoire par inductance (PRI)

I.3.5.1. Mesure flux d'air par thermistance naso-buccale

Dans cette méthode, le flux aérien est enregistré le plus souvent à l'aide d'une thermistance naso-buccale, qui détecte les modifications de température entre l'air inspiré (plus froid) et l'air expiré (plus chaud). La thermistance est placée à mi-distance entre la lèvre supérieure et les narines afin de pouvoir enregistrer une respiration nasale ou buccale.

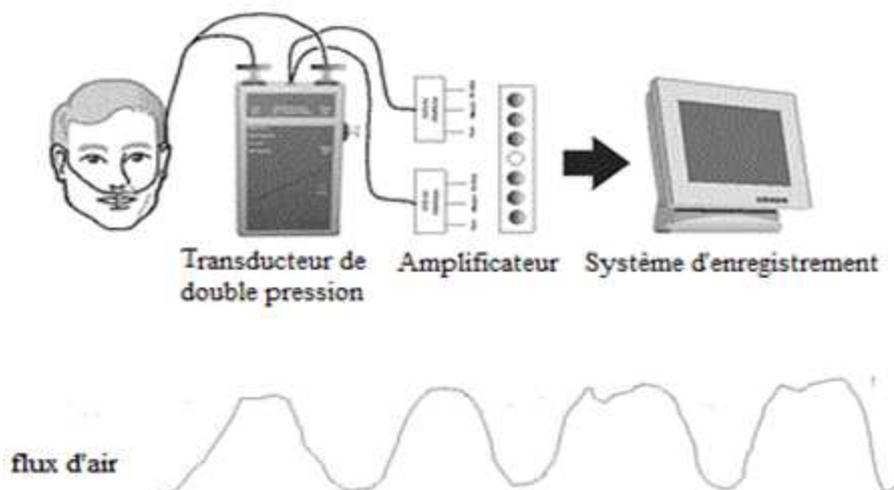


Figure I.12 : Mesure de flux d'air par thermistance naso-buccale

I.3.5.2. Pléthysmographie respiratoire par inductance [Sabil, 2005]

Konno et Mead (1967) ont montré que le thorax et l'abdomen se comportaient mécaniquement comme des éléments distincts, contribuant aux variations de volume du système respiratoire d'une façon indépendante. Ainsi, le volume ventilé peut être estimé comme une combinaison linéaire des variations de volumes thoracique et abdominal. Les variations du volume respiratoire mesurées à la bouche (système ouvert) sont égales à la somme des variations des volumes de la cage thoracique (VTHO) et de l'abdomen (VABD).

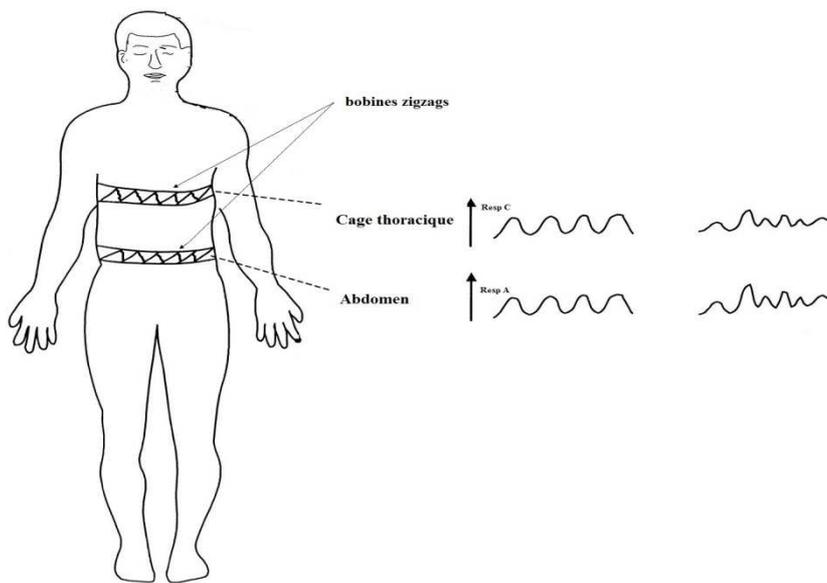


Figure I.13 : pléthysmographie respiratoire par inductance

La pléthysmographie respiratoire par inductance (PRI) est basée sur une mesure électromagnétique des variations de surface d'une section et fait appel aux propriétés des courants induits par un champ magnétique. En effet, le courant induit par un champ magnétique alternatif dans une bobine dépend de la surface encerclée par cette bobine. Les capteurs de la pléthysmographie sont deux spires d'inductance munies chacune d'un oscillateur (figure I.13). Ce sont des fils conducteurs, isolés, cousus en zigzag sur un tissu (souvent sous forme de bande) extensible, entourant le thorax à la hauteur des mamelons et l'abdomen à la hauteur de l'ombilic. Ce montage assure l'étirement des spires lors des variations de section des compartiments dues aux variations des volumes thoracique et abdominal.

I.4. Conclusion :

L'objectif de ce chapitre était de présenter l'origine des signaux ECG et respiratoires. Une description relativement détaillée a été faite sur l'anatomie du cœur, le système de conduction électrique, les techniques d'enregistrement de signal ECG et sur les différentes pathologies cardiaques. Dans la deuxième partie, une brève description sur le système respiratoire, son anatomie et son fonctionnement. Des notions de base sont données sur les explorations fonctionnelles respiratoires et les différentes méthodes de mesure.

Dans le chapitre suivant, les différentes méthodes sur la compression et la modélisation du signal électrocardiogramme seront décrites.



Chapitre II

Techniques de compression du signal ECG



Chapitre II : Techniques de compression du signal ECG

II.1. Introduction

La compression des signaux médicaux est devenue une technique très importante pour faciliter le stockage des données, de les analyser, de les traiter et enfin de les transmettre à travers les moyens de communications pour les utiliser dans l'aide au diagnostic médical.

La compression des signaux ECG a fait l'objet de nombreux travaux de recherche. Plusieurs méthodes et algorithmes ont été développés dans la littérature. En 1975, N. Ahmed et al ont présenté l'un des premiers travaux sur la compression de données électrocardiographique par transformations orthogonales [Ahmed, 1975]. En 1977, Womble ME et al. ont travaillé sur la compression des données ECG's / VCG's en vue du stockage et de la transmission de ces signaux [Womble, 1977].

La décennie 1990 a vu l'apparition de systèmes Holter de plus en plus miniaturisés et entièrement numérisés. Les dites systèmes sont équipés de mémoires statiques moins encombrantes et plus fiables que les anciennes bandes magnétiques [Lu, 2000].

En télécardiologie, Rollins et al. [Rollins, 2000] ont montré la possibilité de concevoir un enregistreur portable pour électrocardiogramme. Cette catégorie d'enregistreur autorise l'acquisition des signaux pour permettre la surveillance de l'activité cardiaque sur une période allant de quelques semaines à un mois. Istepanian et Petrosian ont aussi montré la nécessité de la compression du signal ECG en télécardiologie portable à travers le système GSM [Istepanian, 2000]. Kumar et al. ont mené des études en reconsidérant, dans un premier temps, les méthodes temporelles de compression de l'ECG (AZTEC, FAN, SAPA) et en y apportant par la suite des modifications substantielles afin d'obtenir de nouveaux algorithmes adaptés aux spécificités de la télémédecine [Kumar, 2006].

Ainsi, ce chapitre est divisé en trois parties essentielles :

- La première partie concerne les critères d'évaluation des techniques de compression ;
- La seconde partie concerne les différentes techniques directes de compression des signaux ECG ;

- Et dans la troisième partie, nous présenterons les différentes méthodes de compression par transformation existantes dans la littérature.

II.2. Qualité de compression / décompression

Trois paramètres permettent d'évaluer l'algorithme de compression, à savoir :

- le taux de compression;
- la fidélité du signal reconstruit par rapport au signal original;
- et la charge de calcul induite par la méthode.

II.2.1. Taux de compression

Le taux de compression noté τ_c ou CR, est le rapport entre la taille des données du signal original sur la taille des données du signal reconstruit. Il s'exprime par la relation suivante :

$$\tau_c = \frac{\text{Nb de d'échantillons signal original}}{\text{Nb de d'échantillons signal compressé}} \quad (II.1)$$

Si $\tau_c > 1$, le signal est compressé

Si $\tau_c < 1$, la taille du signal compressé serait plus importante que la taille du signal original.

Si $\tau_c = 1$, aucune compression n'a été réalisée.

II.2.2. Fidélité de la reconstruction

La fidélité de la reconstruction notée PRD, permet d'évaluer si le signal reconstruit après la compression est très proche du signal original ou bien si des déformations et distorsions sont apparues. Cette méthode est la plus utilisée dans le cas des signaux ECG ; le PRD est définie par le pourcentage de l'erreur relative normalisée en énergie :

$$PRD = \sqrt{\frac{\sum_{i=1}^N [x_{org}(i) - x_{rec}(i)]^2}{\sum_{i=1}^N x_{org}^2(i)}} \times 100 \quad (II.2)$$

Où :

x_{org} : échantillons du signal original

x_{rec} : échantillons reconstruits après décompression

N : est le nombre des échantillons

II.2.3. La charge de calcul

C'est le temps que met l'algorithme pour compresser le signal. Ce temps change en fonction de la machine utilisée.

II.3. Les Méthodes de Compression

Il existe deux types de méthodes de compression de données : les méthodes sans perte et avec pertes. Pour le cas du signal ECG, il n'est pas nécessaire d'utiliser une méthode de compression sans perte car beaucoup de parasites comme le bruit sont bien souvent inutiles à conserver. Donc nous s'intéressons aux méthodes de compression de données avec pertes ; Ces méthodes de compression d'ECG, sont habituellement classées en deux grandes catégories à savoir :

- Les méthodes directes qui interviennent sur le signal dans le domaine temporel ;
- Et les méthodes indirectes utilisant les transformées, c'est-à-dire accorder un modèle aux échantillons du signal.

II.3.1. Méthodes directes de compression de l'ECG

Les méthodes directes de compression du signal ECG sont basées sur la détection de la redondance dans l'analyse directe du signal au cours du temps. Ce sont des méthodes rapides que l'on peut implémenter en temps réel. Cependant, elles introduisent beaucoup de distorsions ; ce qui exige, en outre, un autre traitement après reconstruction. Sur le sujet, on peut trouver :

- La méthode AZTEC et AZTEC modifié;
- La méthode TP ;
- La méthode CORTES ;
- La méthode FAN ;
- Et la méthode SAPA.

II.3.1.1. Méthode AZTEC

La méthode AZTEC (Amplitude Zone Time Epoch Coding) [Cox, 1968] possède un bon taux de compression (CR=10) mais elle provoque trop de discontinuités et de distorsions lors de la reconstruction, particulièrement aux ondes P et T (PRD=28%). L'aspect visuel n'est pas acceptable à la vue des cardiologues [Kulkarni, 1997] [Jalaeddine, 1990] [Furth, 1988] [Abenstein, 1982].

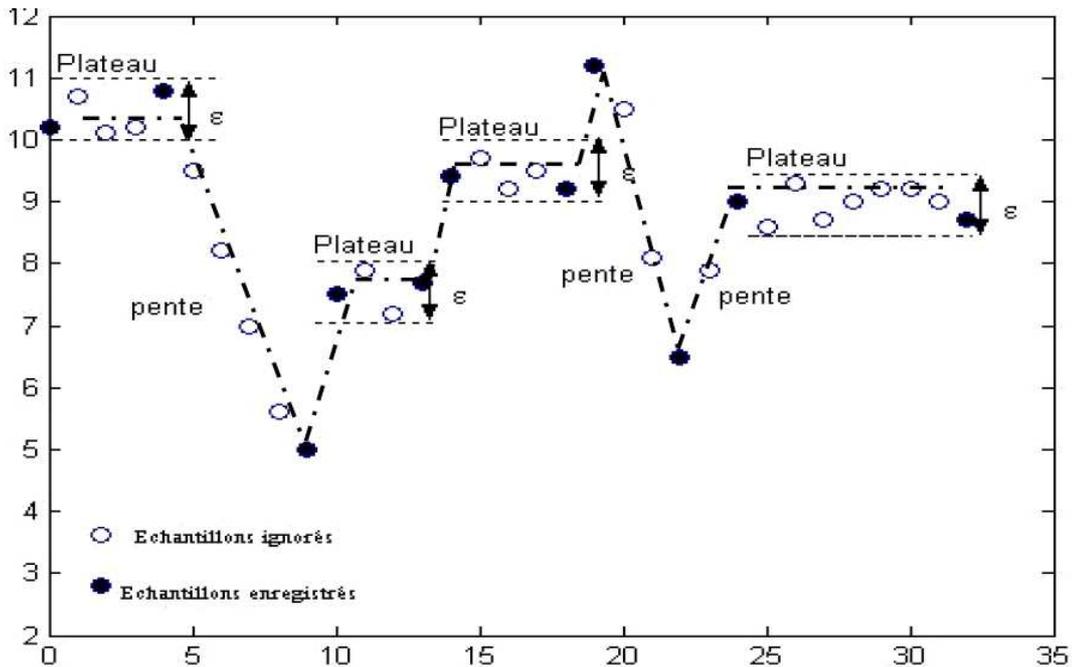


Figure II.1 : Principe de l'algorithme AZTEC

La segmentation du signal se fait en lignes horizontales (plateaux) et en pentes (figure II.1). Les lignes horizontales sont produites sur le principe de l'interpolation d'ordre zéro dont le niveau d'erreur est fixé au départ. L'information est codée par l'amplitude et le nombre d'échantillons de la ligne horizontale. Une pente est sélectionnée à chaque fois que le nombre d'échantillons pouvant former un plateau est inférieur à trois. La pente est codée par sa durée en nombre d'échantillons et l'amplitude du dernier point [Fontaine, 1999].

II.3.1.2. AZTEC modifié

Furth et Perez ont proposé une variante de l'algorithme AZTEC où le seuil de décision est rendu adaptatif. A cet effet, on calcule des paramètres statistiques du signal afin de réévaluer chaque valeur du seuil qui décroît normalement à l'approche des complexes QRS

et croît ensuite après ces complexes QRS ; les statistiques du signal (valeur moyenne, écart type et moment d'ordre 3) sont exploitées pour calculer automatiquement le seuil [Furth, 1988]. D'autres modifications sont apportées à l'algorithme AZTEC par Mammen et Ramamurth. Ces auteurs appliquent AZTEC simultanément sur plusieurs dérivations de l'ECG. Lorsque le seuil est dépassé dans une dérivation, deux informations sont enregistrées : la durée des lignes et un vecteur contenant la valeur moyenne des échantillons de chaque voie [Mammen, 1990].

II.3.1.3. L'algorithme TP

L'algorithme TP (Tuning Point) [Mueller, 1978], consiste à analyser la tendance du signal sur trois échantillons (un échantillon de référence et deux échantillons consécutifs) et à stocker un échantillon de chacune des paires d'échantillons consécutifs, ceci dépendant de l'échantillon préservant la tendance de la pente. Les extremums relatifs pour lesquels la pente du signal change, sont retenus. Le taux de compression est fixe (CR=2) puisque l'on conserve un échantillon sur deux.

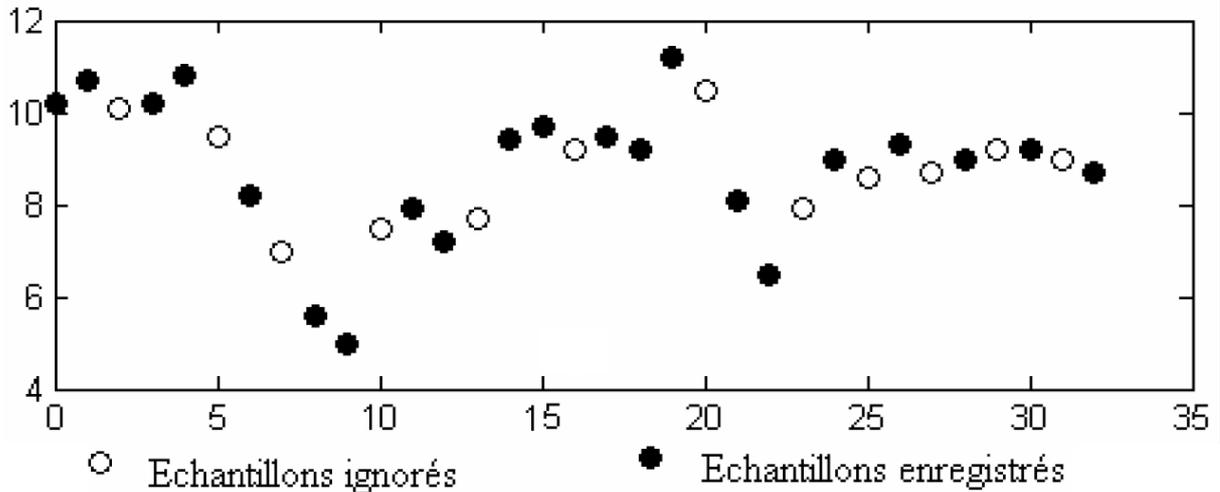


Figure II.2 : Fonctionnement de l'algorithme TP [Daniel, 2007]

L'algorithme TP a été développé à l'origine dans le but de réduire la fréquence d'échantillonnage d'un signal ECG de 200 Hz à 100 Hz sans diminuer l'amplitude du complexe QRS. Le signal reconstruit est quasi identique au signal original, sur lequel ont été ajoutées quelques distorsions (PRD=5,3%). Un inconvénient de la méthode TP réside dans le fait que les échantillons sauvegardés sont espacés d'intervalles de temps irréguliers,

mais ils sont considérés comme étant espacés d'intervalles de temps constants lors de la reconstruction du signal. En itérant ce processus de compression, on obtient un taux de compression de $2N_1$, N_1 étant le nombre d'itérations [Kulkarni, 1997] [Jalaeddine, 1990] [Furth, 1988] [Abenstein, 1982].

II.3.1.4. L'algorithme CORTES

L'algorithme CORTES (Coordinate Reduction Time Encoding System) est une combinaison de la technique AZTEC avec la méthode Turning Point (TP) [Abenstein, 1982]. La méthode AZTEC est utilisée pour les régions proches de la ligne isoélectrique (potentiel électrique du coeur au repos) et la méthode TP pour les régions comprenant des fréquences plus élevées (complexe QRS). Le choix de l'une ou l'autre méthode se fait en comparant la longueur d'un segment déterminé par la méthode AZTEC, à une longueur de référence. Si la longueur du segment est supérieure à la référence, alors on procède au stockage par la méthode AZTEC sinon par la méthode TP. Un marqueur est utilisé pour les transitions entre les deux méthodes. Seules les lignes horizontales de la méthode AZTEC sont générées, les pentes ne sont pas utilisées. Le taux de compression ($CR=4,8$) et la fidélité ($PRD=7\%$) sont aussi fonctions des deux méthodes [Furth, 1988] [Kulkami, 1997] [Jalaeddine, 1990].

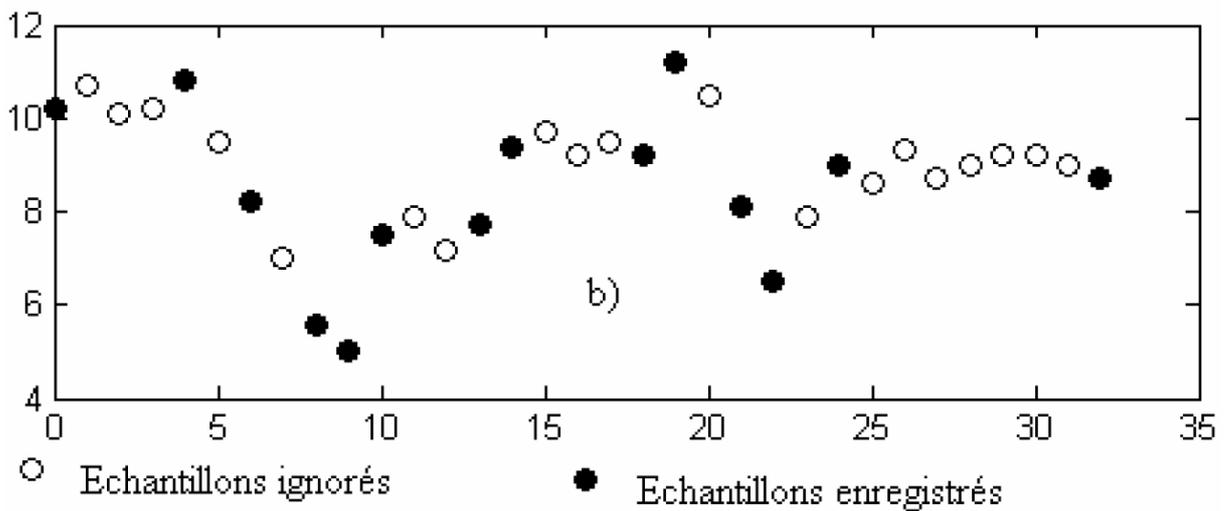


Figure II.3 : Fonctionnement de l'algorithme CORTES [Daniel, 2007]

II.3.1.5. La technique de FAN

La méthode FAN est basée sur l'interpolation du premier ordre avec deux degrés de liberté [Jalaleddine, 1990] [Saxena, 1997]. A chaque pas, deux droites sont calculées partant du dernier point enregistré : la droite supérieure qui passe au-dessus du point courant et la droite inférieure qui passe en dessous. La distance entre chacune des droites et l'échantillon courant est égale au seuil de tolérance prédéfini. Si l'échantillon qui suit le point courant se trouve encadré par ces droites, il devient le nouveau point courant et de nouvelles droites inférieure et supérieure sont générées. Le processus est répété jusqu'à ce qu'un point suivant tombe hors de l'éventail formé par les deux droites. Lors de la reconstruction du signal, les échantillons enregistrés consécutifs sont reliés par des droites [Daniel, 2007].

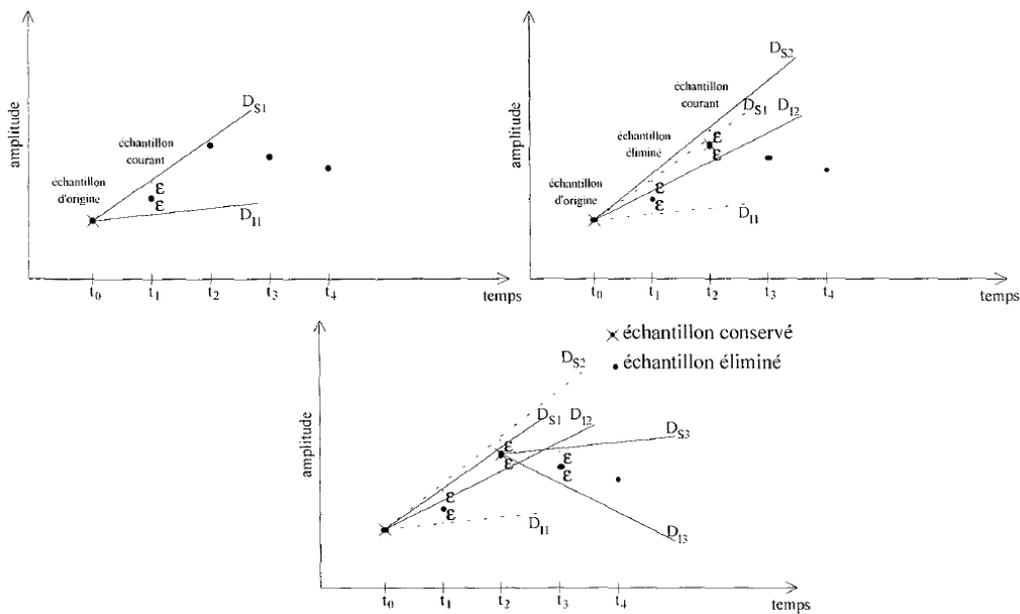


Figure II.4 : méthode FAN [Fontaine, 1999]

II.3.1.6. La technique de SAPA

La technique de SAPA (Scan Along Polygonal Approximation) est basée sur l'interpolation du premier ordre [Kulkarni, 1997] [Jalaleddine, 1990]. Elle fut originellement décrite par [Ishijima, 1983]. Les premiers travaux ayant contribué à l'élaboration de cette méthode furent l'approximation polygonale de courbes [Sklansky, 1980]. Un segment de droite est tracé entre le point courant et le dernier point sauvegardé pris comme référence, de

manière à ce que le segment se situe entièrement dans la zone délimitée par le signal muni d'une marge de tolérance ($\pm\epsilon$) fixée (voir figure II.5). La méthode, tout comme les performances, sont proches de la méthode FAN [Barr, 1985].

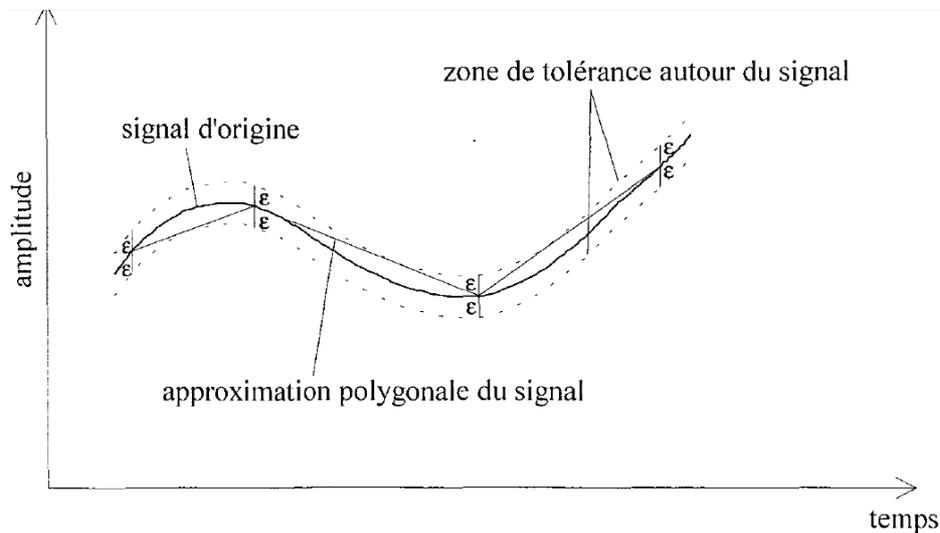


Figure II.5 : méthode SAPA

II.3.2. Compression de l'ECG par transformation du signal

Différentes techniques de compression par transformation ont été appliquées sur les signaux ECG. Ces méthodes se basent sur le principe de convertir le signal du domaine temporel à un autre domaine différent par une transformation linéaire sur une base orthogonale, dont le principe est de ramener les échantillons corrélés du signal ECG dans un espace où les données sont moins corrélées. Les coefficients générés après la transformation sont codés d'une manière appropriée pour compresser les données. Lorsque le signal est compressé, on peut reconstruire un signal d'origine approximé par une transformation inverse. (Figure II.6).

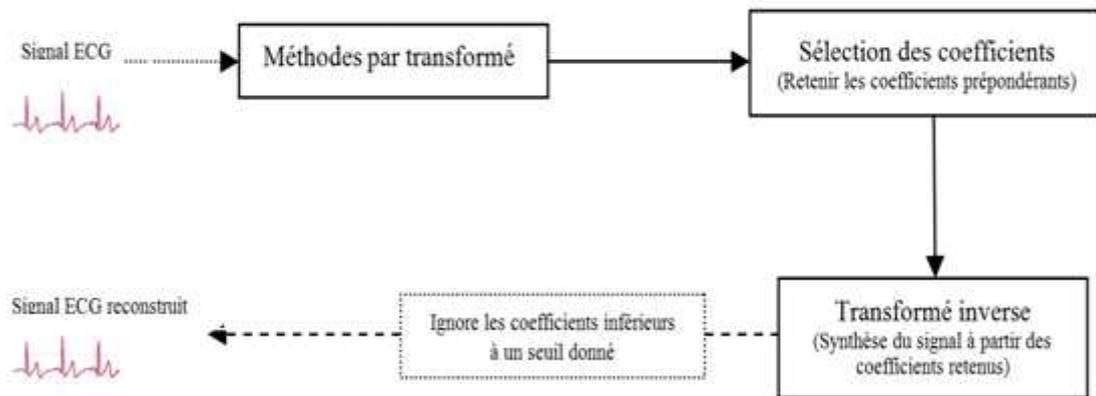


Figure II.6 : Principe général de la compression de l'ECG par transformation du signal

Parmi les méthodes de compression par transformation les plus courantes sont :

- La transformation de Karhunen-Loève ;
- La transformation sinusoïdale;
- Transformations quasi spectrales ;
- Transformation en ondelettes ;
- Et compression par transformation polynomiales.

II.3.2.1. transformation sinusoïdales

Ces transformations possèdent des algorithmes rapides; Elles sont très utilisées dans le domaine du traitement signal.

Les principales méthodes qu'on peut citer sont: La transformée de Fourier discrète (DFT), la transformée en cosinus discrète (DCT) et du sinus discrète (DST).

II.3.2.1.1 La Transformée de Fourier Discrète

La méthode de compression par la TFD utilise la détermination des coefficients de la transformée de Fourier sur un intervalle fermé du signal et ne conserve que les coefficients significatifs représentant le signal; il est donc possible de mettre à zéro une proportion importante des coefficients de Fourier et donc de coder le signal ECG à moindre coût.

La Transformée de Fourier Rapide FFT (Fast Fourier Transform) est simplement une TFD calculée selon un algorithme permettant de réduire le nombre d'opérations et, en particulier, le nombre de multiplications à effectuer.

La TFD est donnée par la relation suivante :

$$X(k) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-j2\pi \frac{nk}{N}} \quad (II.3)$$

La transformée inverse IDFT est donnée par :

$$x(n) = \frac{1}{N} \sum_{K=0}^{N-1} X(k) e^{j2\pi \frac{nk}{N}} \quad (II.4)$$

II.3.2.1.2. La Transformée en cosinus discrète (DCT)

La DCT est une variante de la TFD. Elle est largement utilisée dans le traitement du signal et de l'image et spécialement en compression. La DCT d'un vecteur $x(n)$ est définie par [George, 2002] :

$$C(k) = w(k) \sum_{n=0}^{N-1} 2x(n) \cos \left[\frac{\pi k(2n-1)}{2N} \right], k = 0, 1, \dots, N-1. \quad (II.5)$$

La transformée inverse IDCT est donnée par :

$$x(n) = \frac{1}{N} \sum_{K=0}^{N-1} w(k) C(k) \cos \left[\frac{\pi K(2n+1)}{2N} \right], n = 0, 1, \dots, N-1 \quad (II.6)$$

Avec :

$$w(k) = 0.5 \text{ pour } k = 0 \text{ et } k = 1 \text{ pour } k = 1, 2, \dots, N-1.$$

II.3.2.1.3. La Transformée en sinus discrète (DST)

La DST a été introduite dans le domaine du traitement de signal numérique par Jain [Jain, 1976] en 1976. Différents algorithmes ont été développés pour le calcul efficace de la DST. L'algorithme DST peut être calculé en utilisant l'algorithme de la FFT [George, 2002].

$$S(k) = \frac{2}{N} w(k) \sum_{n=1}^N x(n) \sin \left[\frac{\pi(2n+1)(k)}{2N} \right] \quad (II.7)$$

Avec :

$$\begin{cases} w(k) = \frac{1}{\sqrt{2}} ; \text{si } k = N \\ 1, \text{ ailleurs} \end{cases}$$

La transformée inverse IDST de S(K) est donnée par :

$$x(n) = \sum_{k=1}^N S(k) \sin \left[\frac{\pi(2n-1)(k\pi)}{2N} \right] \quad (II.8)$$

II.3.2.2. Transformées quasi spectrales

Ces transformations ne sont pas optimales au sens de la concentration de l'énergie du signal dans une faible proportion de coefficients, mais elles ont l'avantage de la simplicité des calculs ; la compression par ces transformées consiste à utiliser des fonctions comme base orthogonale de décomposition ; parmi ces fonctions on a celles de Walsh (Figure II.7).

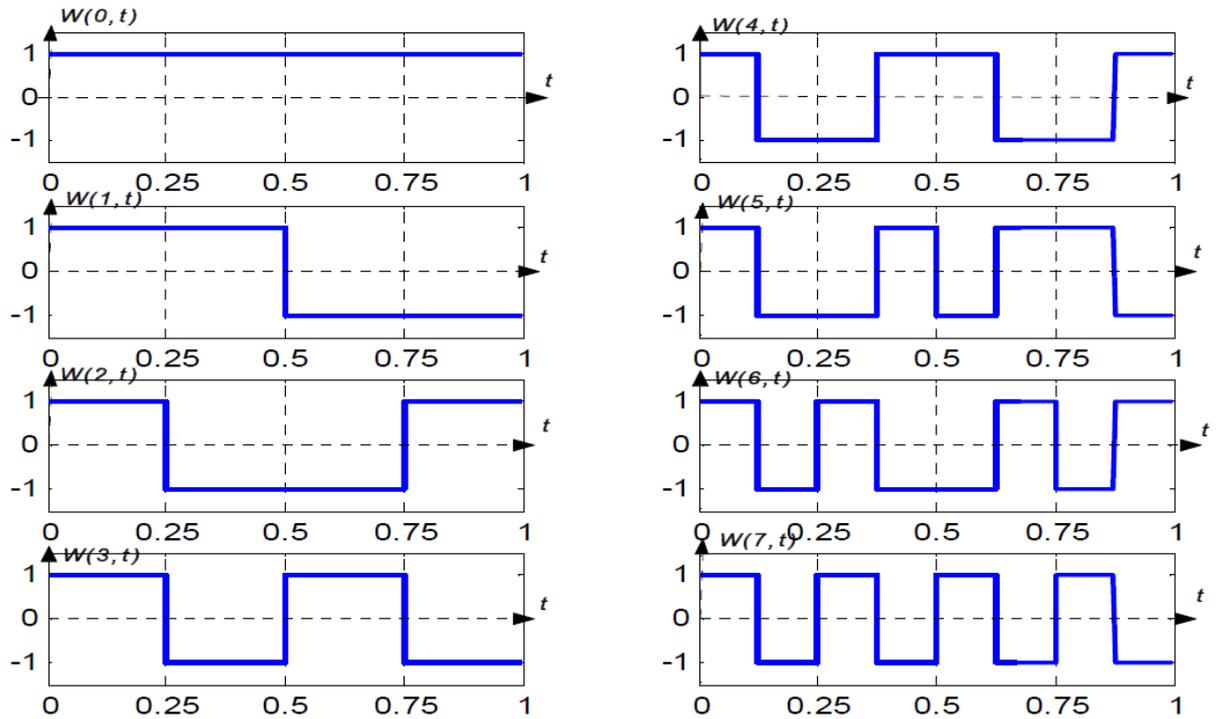


Figure II.7 : Quelques fonctions de Walsh

Ces dernières ne prennent que deux valeurs 1 ou -1 et changeant de signe k fois dans un intervalle ouvert $0 < t < T$, donc pour transformer le signal, il suffit d'additionner ou de soustraire des échantillons selon une suite particulière.

Les fonctions de Walsh sont décrites par l'expression algébrique suivante :

$$c(k) = \sum_{n=0}^{N-1} s(n)Wal(k, n) \quad (II.9)$$

Avec : $K = 0, 1, \dots, N$

N : est le nombre d'échantillons contenus dans le signal

$s(n)$: sont les valeurs des échantillons du signal

La transformation inverse est donnée par :

$$s(n) = \frac{1}{N} \sum_{K=0}^{N-1} C(k)Wal(k, n) \quad (II.10)$$

II.3.2.3. Transformation en ondelettes

La transformée en ondelettes constitue une suite logique des travaux abordés dans l'analyse temps fréquence. Elle est basée sur l'utilisation d'une famille d'atomes temps-fréquence obtenue en dilatant et en translatant une ondelette analysante.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (II.11)$$

Où : a est le facteur d'échelle de dilatation temporelle

b est le facteur de translation dans le temps

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

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

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \psi\left(\frac{t-b}{a}\right) x(t) dt \quad (II.12)$$

Où $\psi(t)$ est l'ondelette mère analysante.

- La transformée en ondelettes discrète (DWT) est issue de la version continue, à la différence de cette dernière, la DWT utilise un facteur d'échelle et une translation discrétisés $a = 2^j$ et $b = n2^j$.

$$W(i, m) = 2^{-\frac{i}{2}} \sum_{n \in \mathbb{Z}} x(n) \psi\left(\frac{n}{2^i} - m\right) \quad (II.13)$$

II.3.2.3.1 Exemples d'ondelettes

Il y a plusieurs types et familles d'ondelettes, le choix de l'ondelette optimale dépend de l'application envisagée. Le tableau 2.1 présente une liste de famille d'ondelettes usuelles avec leurs noms courts associés afin de faciliter la lecture [Misiti, 2003].

Nom de famille d'ondelette	Nom court
Ondelette de Haar	<i>haar</i>
Ondelette de Daubechies	<i>db</i>
Symlets	<i>sym</i>
Coiflets	<i>coif</i>
Ondelettes biorthogonales	<i>bior</i>
Ondelette de Meyer	<i>meyr</i>
Ondelette de Battle et Lemarié	<i>btlm</i>
Ondelettes gaussiennes	<i>gaus</i>
Chapeau mexicain	<i>mexh</i>
Ondelette de Morlet	<i>morl</i>
Ondelettes gaussiennes complexes	<i>cgau</i>
Ondelettes de Shannon complexes	<i>shan</i>
Ondelettes B-splines fréquentielles complexes	<i>fbsp</i>
Ondelettes de Morlet complexes	<i>cmor</i>

Tableau II.1 : Liste de famille d'ondelette

Les ondelettes les plus utilisées dans le traitement du signal : les ondelettes de Morlet, le chapeau mexicain, les ondelettes de Haar et les ondelettes de Daubechies.

- **L'ondelette de Morlet** : L'ondelette de Morlet est l'ondelette complexe la plus fréquemment utilisée. Elle est définie par :

$$\psi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2} e^{-i5\omega_0 x} \quad (II.14)$$

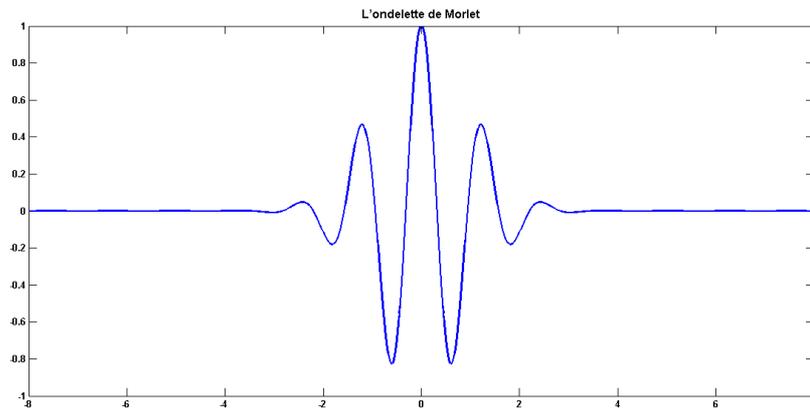


Figure II.8 : Ondelette de Morlet

- **Le chapeau mexicain :**

$$\psi(x) = \frac{2}{\sqrt{3}} \pi^{-\frac{1}{4}} (1 - x^2) e^{-\frac{x^2}{2}} \quad (II.15)$$

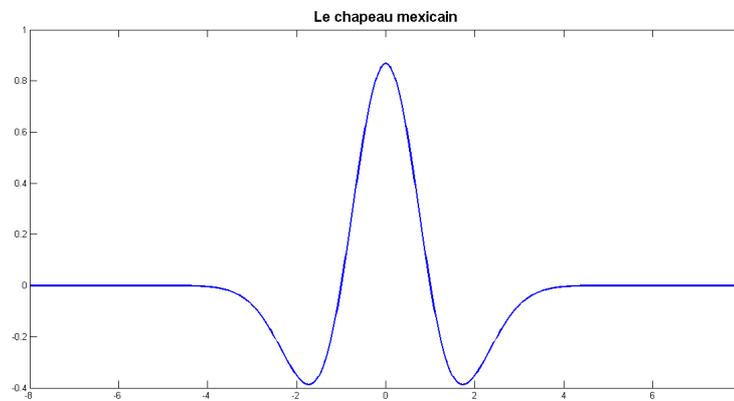


Figure II.9 : Ondelette chapeau mexicain

- **L'ondelette de Haar :** Cette ondelette est très simple et facile à implémenter. Elle est définie par :

$$\begin{cases} \psi(x) = 1 & \text{si } 0 < x < \frac{1}{2} \\ \psi(x) = -1 & \text{si } \frac{1}{2} < x < 1 \\ \psi(x) = 0 & \text{sinon} \end{cases} \quad (II.16)$$

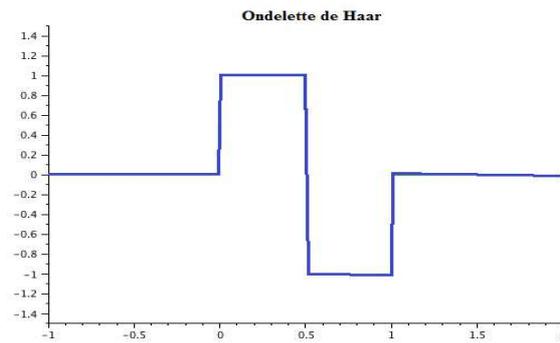


Figure II.10 : Ondelette de Haar

- **L'ondelette de Daubechies :** est la famille la plus connue des ondelettes orthogonales. Ses ondelettes sont généralement dénommées par le nombre de coefficients a_k non nuls, on parlera donc d'ondelettes Daubechies 4, Daubechies6, etc.

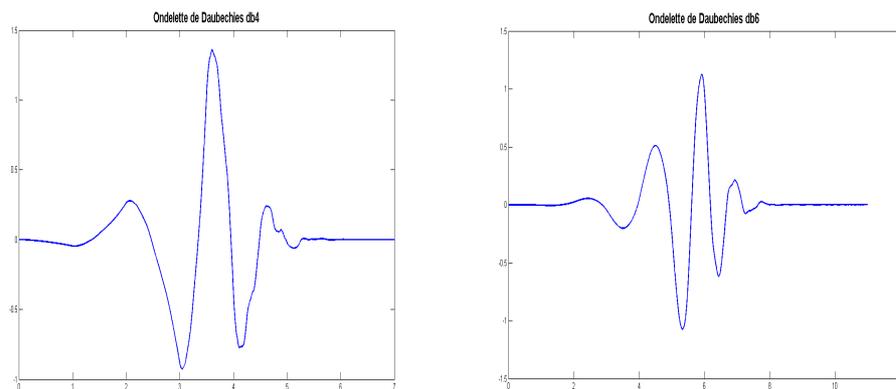


Figure II.11 : Ondelette de Daubechies (db4, db6)

Les ondelettes de Daubechies comme les montre la figure II.11 se ressemblent beaucoup au tracé d'un signal ECG. Pour cela la compression du signal ECG avec ce type d'ondelettes est très utilisée. L'une des premières utilisations est réalisée dans [Crowe, 1992].

II.3.2.4. Compression par transformation polynomiales

Le principe général de ces méthodes est de faire l'approximation d'un signal ECG par des polynômes de degré élevé sur un grand intervalle, la méthodologie de compression se réalise comme suit :

- Une segmentation du signal en fenêtres de durées coïncidant aux cycles cardiaques ;
- Transformations polynomiales est appliquées à ces fenêtres ;
- Conservation des coefficients de grandes valeurs en négligeant les coefficients de faibles niveaux d'énergie ;
- Et Reconstruction du signal à partir de ces coefficients.

L'un des premiers travaux de compression par transformations polynomiales a été réalisé en 1992 par W.PHILIPES et G. DE JOCHE dont le principe est de faire décomposer le signal ECG dans une base orthogonale de fonctions polynômiales de Legendre. Un grand nombre d'échantillons est représenté par un petit nombre de coefficients. Des codages entropiques appliqués à ces coefficients permettent d'accroître l'efficacité de la compression [Philips, 1992] [Philips, 1993]. Ces travaux ont été repris dans [Colomer, 1997], aussi une autre méthode de compression du signal ECG par les fonctions d'Hermite a été réalisée par Jane et al. [Jane, 1993]. D'autres travaux récents de compression basés sur la combinaison de deux transformateurs de signaux (Laguerre et Hermite) ont été réalisés en 2007 par D. TCHIOTSOP et al. [Daniel, 2007].

II.4. Évaluation de la performance et résultats de compression par la DCT, DST, FFT et DWT

Dans la partie suivante, une étude comparative sera faite entre les différentes méthodes de compression par transformations sinusoïdales citées dans ce chapitre (DCT, DST, FFT et DWT). Les algorithmes correspondants à chacune des méthodes de compression sont évalués en utilisant, d'une part, le taux de compression (CR) et d'autre part, le PRD comme critères de performances.

Le schéma bloc du système de compression utilisé par les dites méthodes est représenté sur la figure II.12.

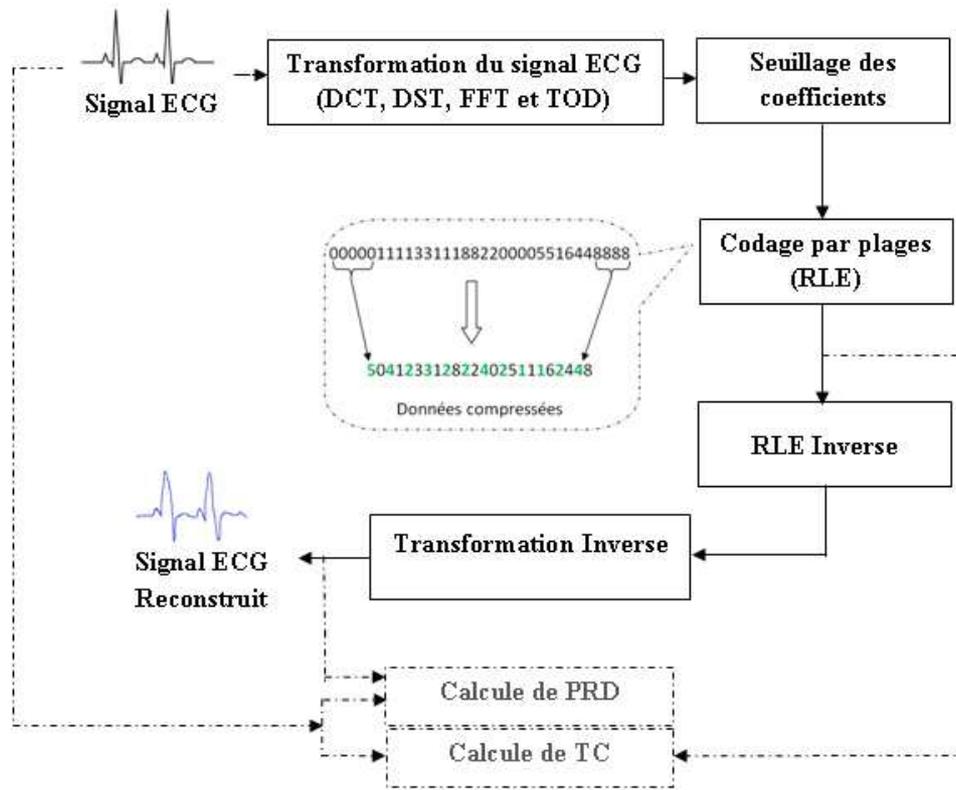


Figure II.12 : Schéma bloc du système de compression utilisé.

II.4.1. Résultats de la Compression par transformations sinusoïdales (DCT, DST, FFT) :

Les méthodes de compression par transformation sinusoïdales DCT, DST et FFT sont appliquées sur un signal ECG réel « 101 » échantillonné à 360 Hz avec une résolution de 11bits/échantillon de la base de donnée MIT-BIH. Le processus de compression se résume comme suit :

- Réaliser une transformation sinusoïdale sur le signal ECG ;
- Garder uniquement les basses fréquences des coefficients de la transformée, c'est-à-dire on supprime (mettre à zéro) les coefficients haute fréquence qui sont proches de zéro.
- Une compression de données résultantes par l'algorithme RLE.
- Le signal reconstruit est calculé à partir des coefficients retenus de la transformée après le décodage des données.

Les résultats obtenus, suite à l'application de ces algorithmes sur les 4096 premiers échantillons du signal ECG « 101 », sont représentés respectivement sur les figures II.13, II.14 et II.15.

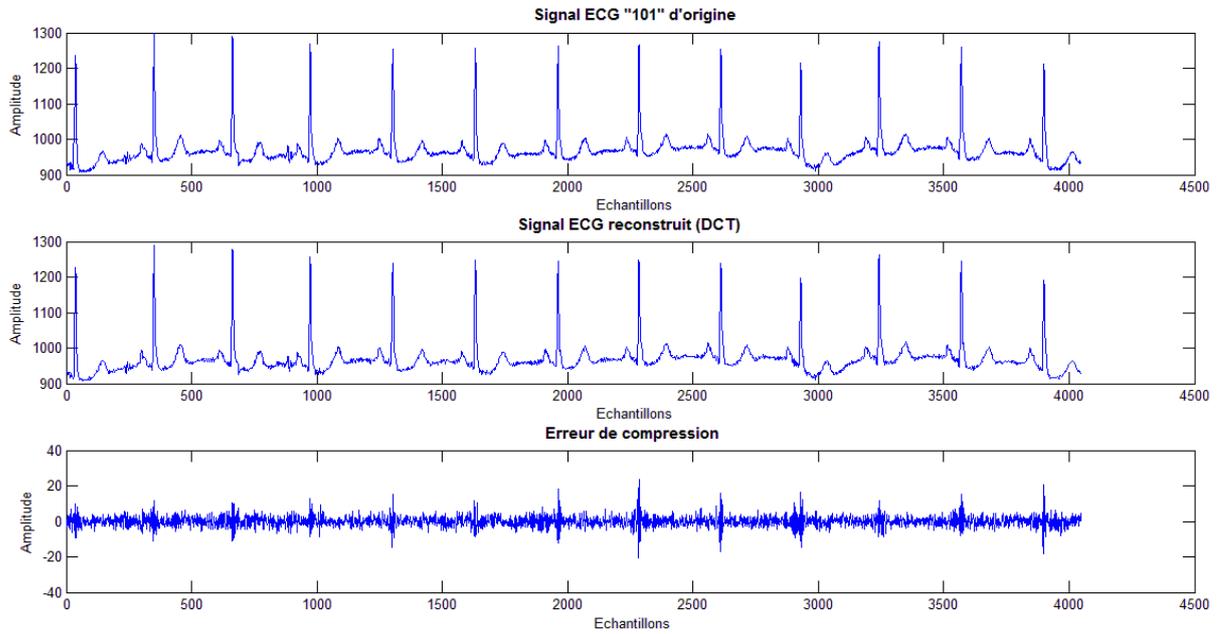


Figure II.13 : Résultat de la compression par la DCT du signal 101
(CR=2, PRD=0.2921)

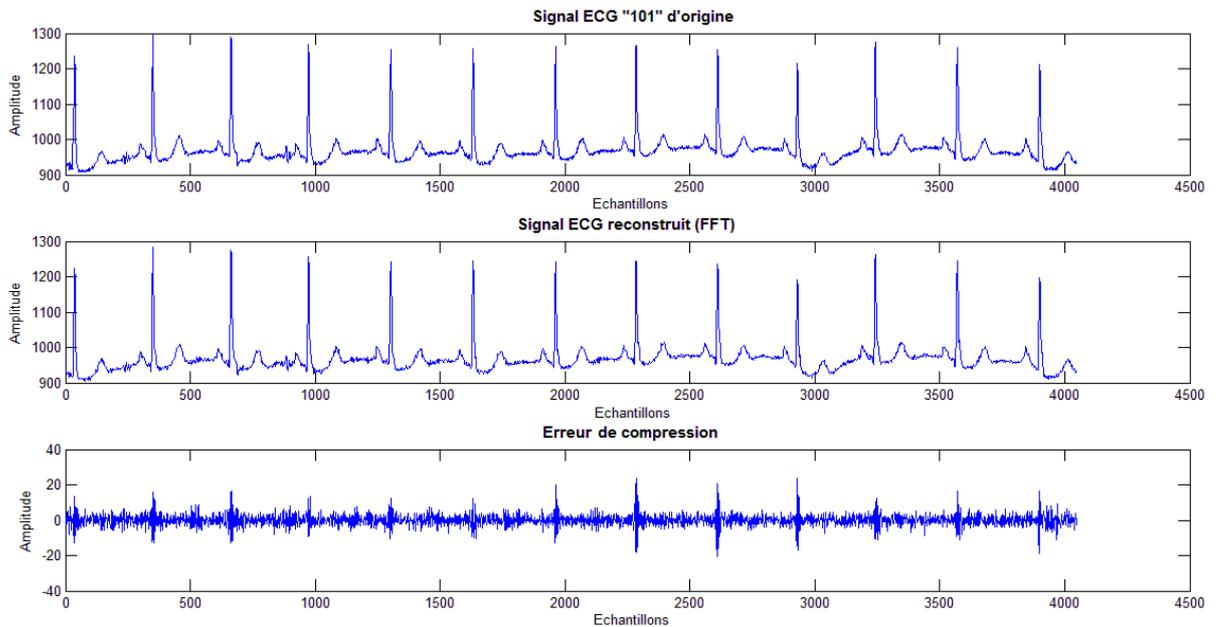


Figure II.14 : Résultat de compression par la FFT du signal 101
(CR=2, PRD= 0.3286)

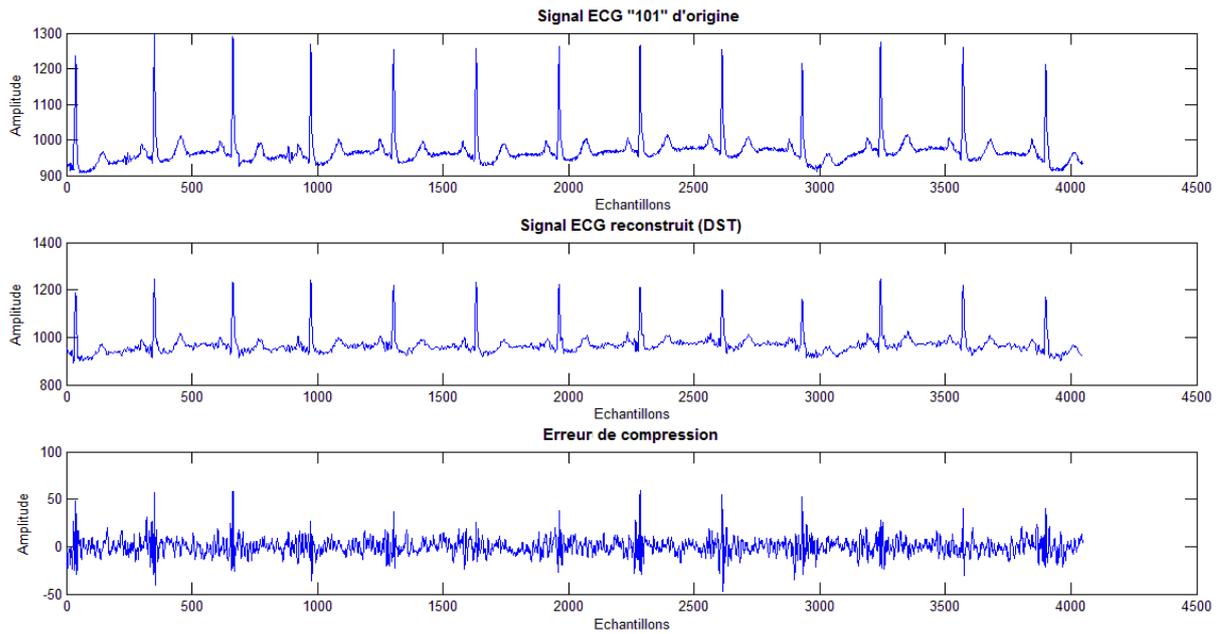


Figure II.15 : Résultat de compression par la DST du signal 101
(CR=2, PRD= 1.4893)

Pour vérifier l’efficacité des ces méthodes utilisées, nous avons calculé le PRD pour chaque taux de compression (CR) obtenus. Le tableau II.2 représente les résultats obtenus :

CR		2	4	6.02	8	10	13.16	16.13	19.24
PRD (%)	TCD	0.2921	1.0697	1.6332	2.0465	2.3587	2.6684	2.9681	3.1699
	FFT	0.3220	1.3472	2.0668	2.6662	2.9299	3.2058	3.3572	3.5211
	TSD	1.4893	2.7171	3.6673	4.4276	5.0032	5.7348	6.2427	6.7366

Tableau II.2 : La variation du PRD (%) en fonction du taux de compression CR

II.4.2. Résultats de Compression par transformations en ondelettes discrètes (DWT) :

De même, Les méthodes de transformations par DWT sont appliquées sur le signal ECG « 101 » de la base de données MIT-BIH. Le processus consiste en les étapes suivantes :

- Effectuer le développement en DWT du signal par différents types d’ondelettes connus et différents niveaux de décomposition;
- Conserver les coefficients prépondérants supérieurs a un seuil choisi ;
- Codage des données par l’algorithme RLE ;
- Réaliser Le décodage RLE puis la DWT inverse à partir des coefficients retenus;
- Soustraire les résultats du signal original.

Pour l'analyse et la reconstruction des signaux ECG par DWT, nous avons utilisé les ondelettes orthogonales de Daubechies (db) et les ondelettes biorthogonales (Bior4.4). Nous avons effectué plusieurs essais pour chaque niveau de décomposition.

Les résultats obtenus, suite à l'application des différents algorithmes sur les 4096 premiers échantillons du signal « 101 », sont représentés sur le tableau suivant :

Type d'Ondelette	Taux de compression (CR)	PRD (%)		
		Niveau 5	Niveau 6	Niveau 7
db1	3	0.3383	0.3402	0.3402
	6.02	0.8250	0.8127	0.8250
	10	1.6274	1.4093	1.4340
db7	3	0.2359	0.2386	0.2422
	6.02	0.6152	0.6581	0.6946
	10	1.9813	1.7234	1.6658
db9	3	0.2376	0.2404	0.2461
	6.02	0.7328	0.7923	0.8882
	10	2.2807	2.1638	2.1600
bior4.4	3	0.2241	0.2248	0.2273
	6.02	0.4889	0.5068	0.5175
	10	1.3820	1.0779	1.1088

Tableau II.3 : La variation du PRD (%) en fonction du taux de compression CR et le niveau de décomposition pour chaque type d'Ondelette

D'après le tableau II.3, la transformation en ondelette biorthogonale (bior4.4) donne un meilleur compromis entre le PRD et le CR par rapport aux autres types d'ondelettes. De plus, il est à noter que le 5ème niveau de décomposition est le plus adapté en terme d'avoir un PRD très faible.

Les résultats obtenus de compression pour un $CR=2$ utilisant db7 et bior4.4 au 5ème niveau de décomposition sont représentés sur les figures II.16 et II.17.

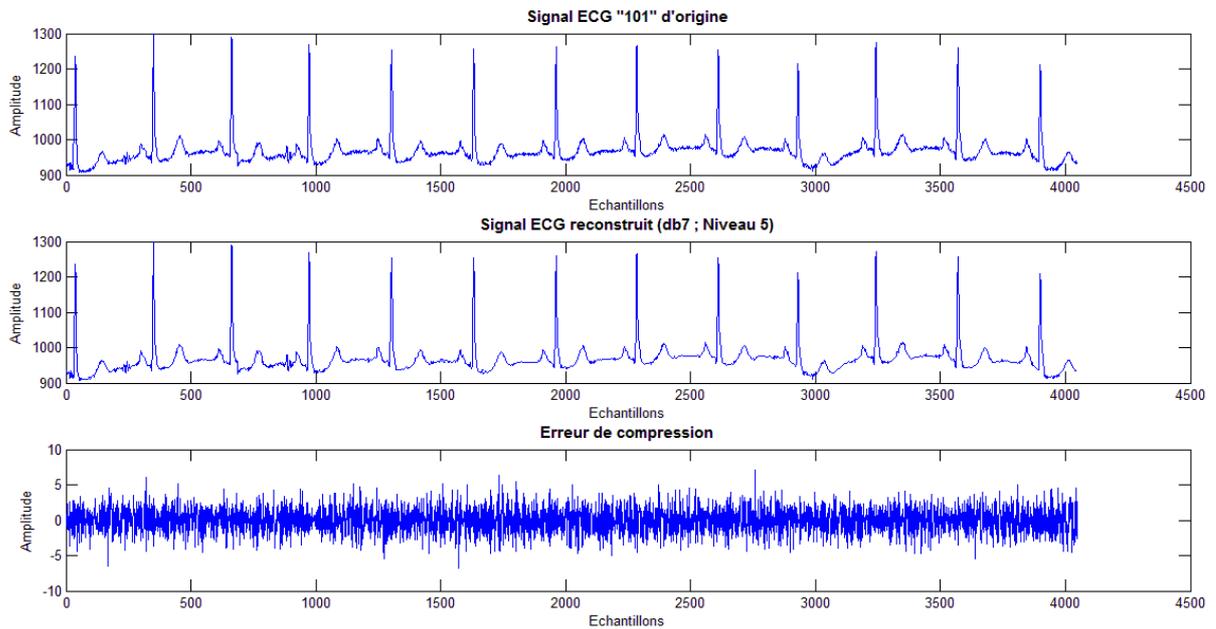


Figure II.16 : Résultat de compression par la DWT utilisant l'ondelette de Daubechies (db7) du signal 101 ($CR=2$, $PRD= 0.1809$)

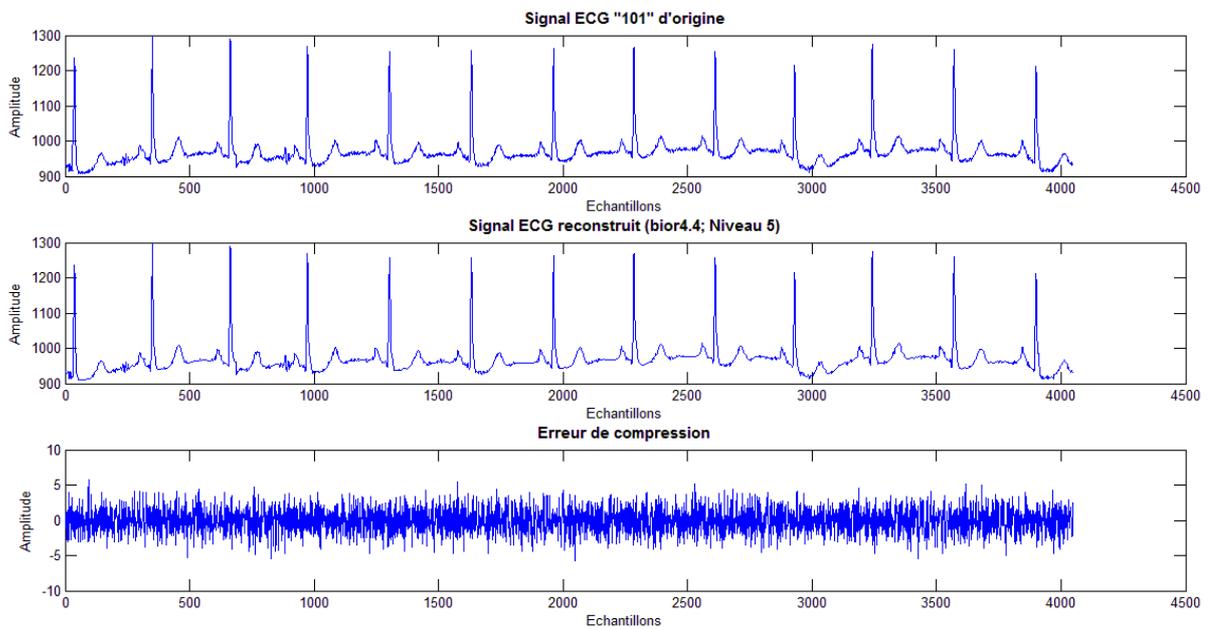


Figure II.17 : Résultat de compression par la DWT utilisant l'ondelette Biorthogonale (bior4.4) du signal 101 ($CR=2$, $PRD= 0.1758$)

Les performances de ces algorithmes sont évidemment évaluées par la courbe CR-PRD, que l'on représente sur la figure II.18.

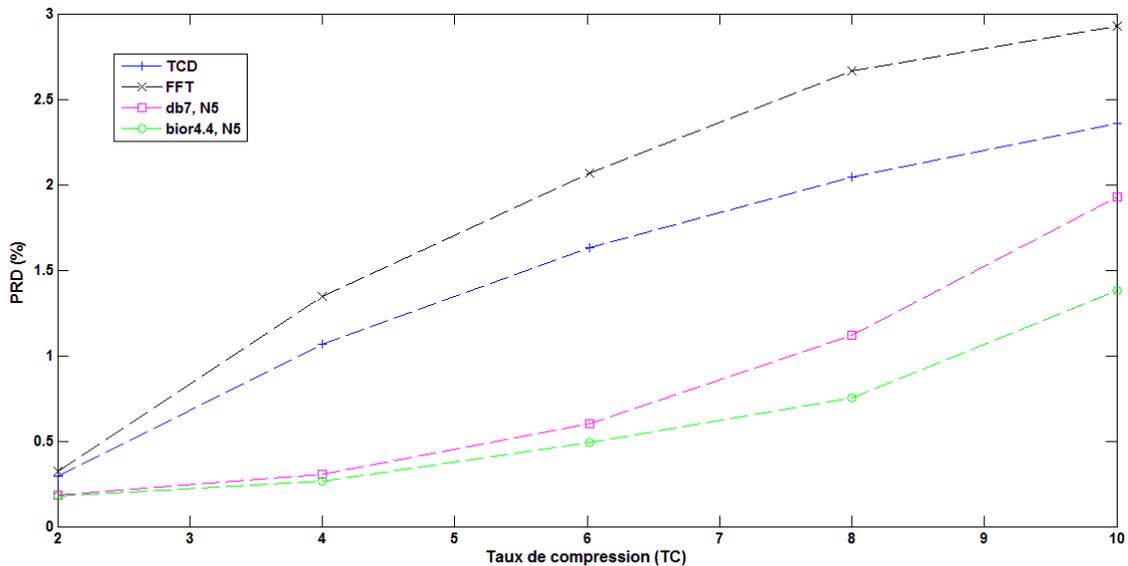


Figure II.18. Variation du PRD en fonction du taux de compression CR

II.4.3. Discussion et résultats :

En observant ces différentes courbes (Figure II.18), on peut conclure que le PRD augmente lorsque le Taux de Compression (CR) augmente. La méthode de compression par la DWT paraît meilleure par rapport à la DCT, FFT et la DST, et la compression par l'ondelette biorthogonale (bior4.4) donne un meilleur taux de compression avec un minimum de PRD.

Les algorithmes proposés, garanti la qualité acceptable d'une manière clinique et aussi la conservation de l'information considérable après la reconstruction (CR, PRD et l'observation visuelle) soit pour le cas d'un signal normal ou bien pathologique.

II.5. Conclusion

Dans ce chapitre, nous avons présenté les critères d'évaluation des algorithmes de compression et les différentes méthodes et algorithmes de compression du signal ECG existantes dans la littérature.

Nous avons distingué deux grandes catégories de méthodes :

- Les méthodes de compression directes qui interviennent sur le signal dans le domaine temporel ; elles possèdent des algorithmes rapides mais l'inconvénient de ce type de méthodes est les fortes distorsions qui apparaissent sur le signal reconstruit, ce qui nécessite l'implémentation des opérations de filtrage.
- Les méthodes de compression par transformation qui ramènent les signaux dans un domaine transformé après décomposition dans une base de fonctions.

Dans le chapitre suivant, une présentation des fondements mathématiques des polynômes orthogonaux et de leurs utilisations dans le domaine de modélisation et compression des signaux ECG seront faites.



Chapitre III

Modélisations polynomiales des signaux ECG



Chapitre III : Modélisations polynomiales des signaux ECG

III.1. Introduction

En traitement du signal, la modélisation est l'une des étapes les plus importantes pour faciliter l'analyse et la compréhension du comportement d'un système. On peut trouver la modélisation dans les domaines suivants :

- Le domaine du biomédical et de la biologie;
- Les systèmes de communications numériques ;
- Et dans d'autres domaines de la science et de la technologie.

La représentation du signal biomédical par les paramètres d'un modèle mathématique constitue une étape très importante dans le processus d'identification du signal en question.

Dans le cas d'un signal ECG ; modéliser ; c'est trouver une représentation mathématique, aussi simple et compacte que possible, de la forme de chaque onde constitutive du battement cardiaque. Cela constitue une étape primordiale dans le diagnostic de différentes pathologies cardiaques.

Dans ce contexte, la sélection du modèle peut s'avérer délicate. La conception d'approche d'estimation du signal ECG constitue aussi un enjeu majeur.

Ainsi, différentes modèles sont proposées dans la littérature à savoir :

- l'utilisation des modèles de Markov pour faciliter l'interprétation automatique de l'ECG [Coast, 1990] ;
- la modélisation avec les polynômes d'Hermite pour la classification des complexes QRS [Sornmo, 1981] [Lagerholm, 2000] ;
- Modélisations polynomiales des signaux ECG appliquées à la compression [Daniel, 2007].
- Modélisation paramétrique et non paramétrique en vue de l'identification de système cardiaque proposé par Baakek et al. [Baakek, 2015].

Dans ce chapitre, une étude sur la modélisation du signal ECG par polynômes orthogonaux sera faite. Nous commencerons d'abord par définir la notion d'orthogonalité des fonctions. Nous présenterons par la suite, les propriétés de différents polynômes orthogonaux avant d'envisager leur utilisation dans la modélisation et la compression des signaux ECG.

III.2. Orthogonalité des fonctions

Soient deux fonctions $g(x)$ et $h(x)$ définies sur un intervalle réel ou complexe $[a, b]$. On définit leur produit scalaire par :

$$\langle g, h \rangle = \int_a^b g(t) \bar{h}(t) dt \quad (III.1)$$

Où $\bar{h}(t)$ est le conjugué de $h(t)$

Les fonctions $g(t)$ et $h(t)$ sont orthogonales si leur produit scalaire est nul.

III.3. Polynômes orthogonaux

Les polynômes orthogonaux sont très largement utilisés dans beaucoup de domaines. A titre d'exemple :

- En physique, les polynômes d'Hermite et Laguerre sont utilisés pour déterminer des solutions des cas particuliers des équations de Schrödinger ;
- Dans le domaine du traitement du signal; les polynômes orthogonaux sont largement utilisés dans le domaine de la modélisation et de la compression de données.

Définition d'orthogonalité

Soit un intervalle de temps $[a, b]$, a et b pouvant prendre respectivement les valeurs $-\infty$ ou $+\infty$. Un ensemble de fonction :

$$\Phi(t) = \{\varphi_i(t), i \in N, t \in [a, b]\}$$

est dit orthogonal, si il existe une fonction poids $\omega(t)$ définie positive sur $[a, b]$, telle que :

$$\forall (i, j) \in N^2, \int_a^b \omega(t) \varphi_i(t) \varphi_j(t) dt = r_i \delta_{ij} \quad (III.2)$$

Si de plus :

$$\forall i \in N, \int_a^b \omega(t) f(t) \varphi_i(t) dt = 0 \Rightarrow f(t) = 0 \quad (III.3)$$

III.4. Familles de polynômes orthogonaux

On distingue trois grandes familles de polynômes orthogonaux classiques : les polynômes de Jacobi, les polynômes de Laguerre et les polynômes d’Hermite.

III.4.1 Polynômes de Jacobi [Pagé, 2006]

Les polynômes de Jacobi sont définis sur l’intervalle $[-1,1]$.

Soit $\alpha, \beta > -1$. Les polynômes de Jacobi (nommés ainsi car c’est Jacobi qui les introduits en 1859) par l’équation suivante :

$$P_n^{(\alpha,\beta)}(x) = \frac{(-1)^n}{2^n n!} (1+x)^{-\beta} \frac{d^n}{dx^n} ((1-x)^{n+\alpha} (1+x)^{n+\beta}) \quad (III.4)$$

En effectuant la dérivée du produit, nous obtenons une formule explicite pour les $P_m^{(\alpha,\beta)}(x)$:

$$P_m^{(\alpha,\beta)}(x) = \frac{1}{2^m} \sum_{k=0}^m \binom{m+\alpha}{m-k} \binom{m+\beta}{k} (x-1)^k (x+1)^{m-k} \quad (III.5)$$

Cette équation met en lumière le fait que $P_n^{(\alpha,\beta)}(x)$ est un polynôme de degré n et de coefficient dominant.

$$k_n^{(\alpha,\beta)} = \frac{1}{2^n} \binom{2n+\alpha+\beta}{n} \quad (III.6)$$

Les polynômes de Jacobi sont orthogonaux pour la fonction de poids $(1-x)^\alpha (1+x)^\beta$ sur l’intervalle $(-1,1)$

On peut distinguer deux classes particulières de polynômes de Jacobi : Les polynômes de Legendre avec $P_n(t) = P_n^{(0,0)}(x)$ et les polynômes de Tchebychev.

III.4.1.1. Les polynômes de Legendre

Les polynômes de Legendre sont des cas particuliers des polynômes de Jacobi, $P_n(t) = P_n^{(0,0)}(t)$. Les figures III.1.a à III.1.d représente l'allure des courbes correspondantes aux différentes valeurs de n du polynôme de Legendre.

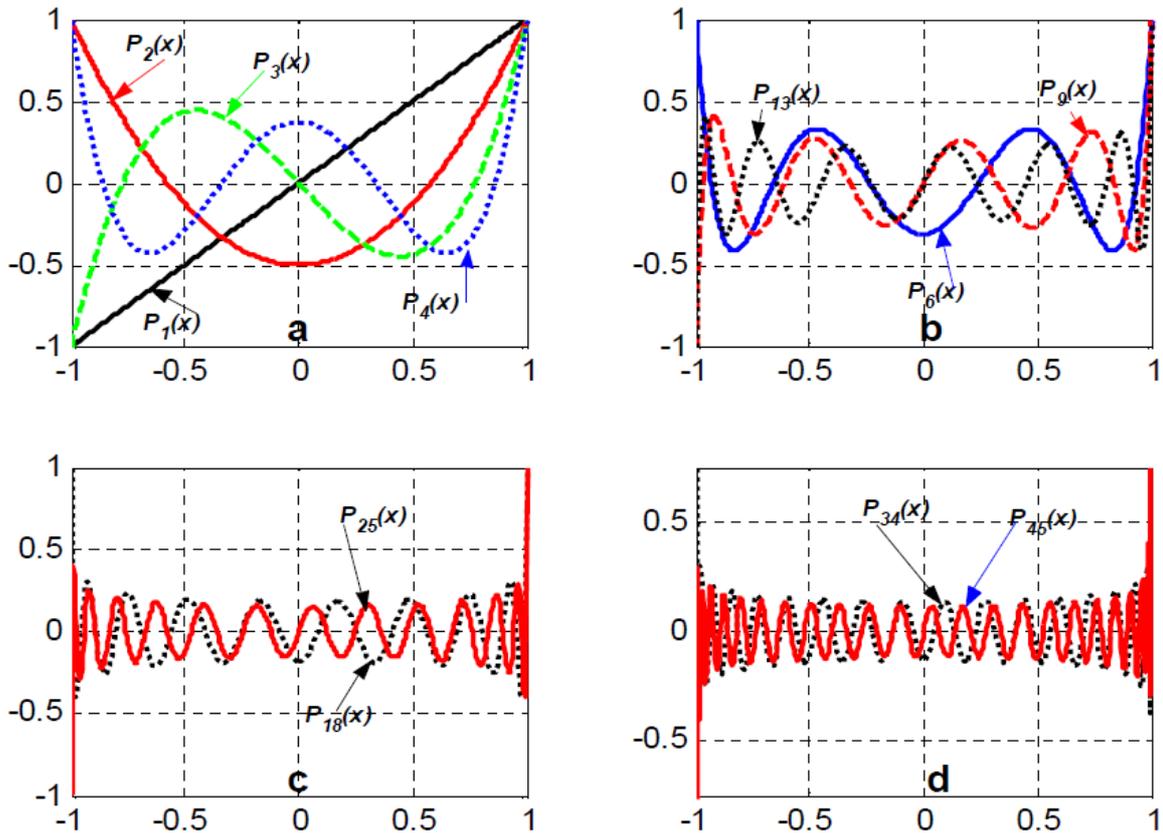


Figure III.1: Courbes pour quelques polynômes de Legendre

- a) : Polynômes de faibles degrés ;
- b) polynômes de degré 8, 9 15 ;
- c) et d) : Polynômes de degré relativement élevés.

III.4.1.2. Les polynômes de Tchebychev

Les polynômes de Tchebychev de première sorte ne diffèrent que par une constante des polynômes de Jacobi avec $\alpha = \beta = -\frac{1}{2}$:

$$T_n(x) = \frac{n!}{\left(\frac{1}{2}\right)_n} P_n^{\left(-\frac{1}{2}, -\frac{1}{2}\right)}(x) \quad (III.7)$$

L'équation de récurrence pour générer ces polynômes est la suivante :

$$T_n(x) = 2xT_n(x) - T_{n-1}(x) \quad (III.8)$$

Les polynômes de Tchebychev de seconde sorte s'obtiennent de façon similaire :

$$U_n(x) = \frac{(n+1)!}{\left(\frac{3}{2}\right)_n} P_n\left(\frac{1}{2}, \frac{1}{2}\right)(x) \quad (III.9)$$

Ces polynômes se définissent également à l'aide des fonctions trigonométriques, de façon analogue à ceux de la première sorte :

$$U_n(x) = \frac{\sin(n+1)\theta}{\sin\theta} \quad (III.10)$$

Où $x = \cos\theta$. Ils satisfont la récurrence à trois termes

$$U_n(x) = 2xU_{n-1}(x) - U_{n-2}(x) \quad (III.11)$$

La figure III.2 représente les allures de quelques polynômes de Tchebychev

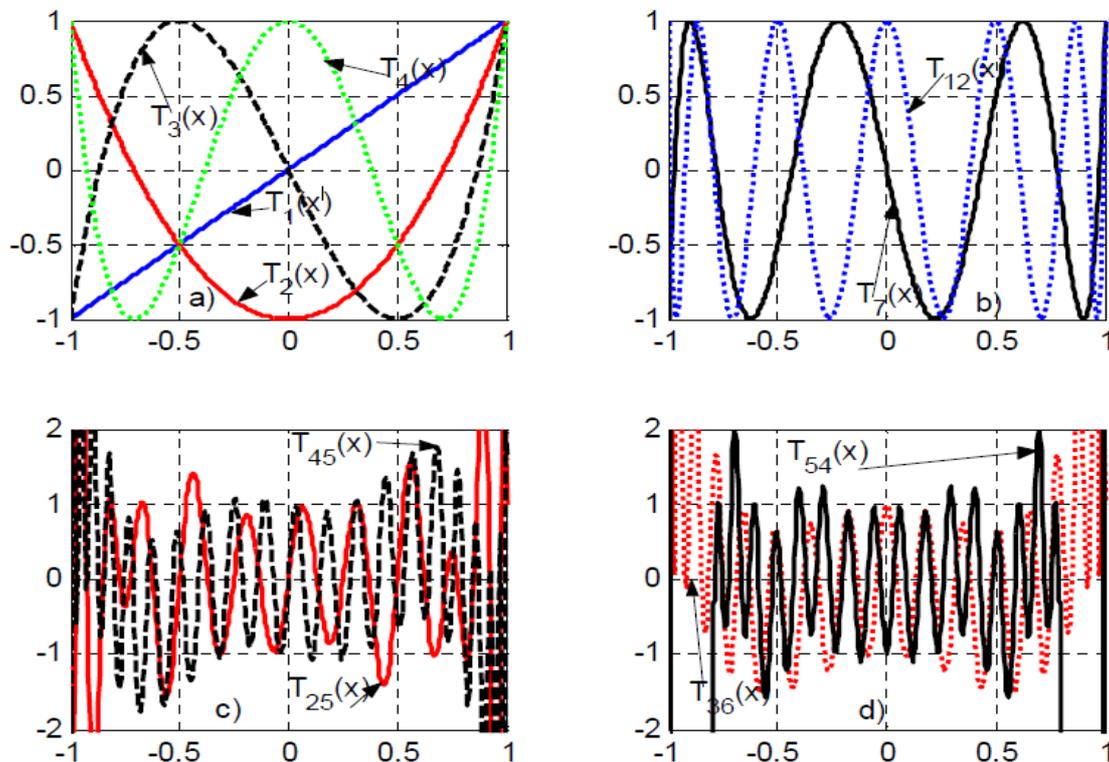


Figure III.2 : Allures des polynômes de Tchebycheff [Daniel, 2007]

a) : Polynômes de faibles degrés ;

b) polynômes de degré 8, 9 15 ;

c) et d) : Polynômes de degré relativement élevés.

III.4.2 Polynômes de Laguerre

Les polynômes de Laguerre $L_n^\alpha(x)$ définis sur l'intervalle $[0, +\infty[$, On appel polynôme de Laguerre, $L_n^\alpha(x)$ avec $\alpha \neq -1, -2, -3, \dots$:

$$L_n^\alpha(x) = \frac{1}{n!} x^{-\alpha} e^x \frac{d^n}{dx^n} (x^{n+\alpha} e^{-x}) \quad (III.12)$$

En effectuant la dérivée dans III.12 nous obtenons une expression explicite pour $L_n^\alpha(x)$:

$$\sum_{k=0}^n \binom{n+\alpha}{n-k} \frac{(-x)^k}{k!} \quad (III.13)$$

Nous calculons, à l'aide de cette formule explicite, que

$$\frac{d}{dx} L_n^\alpha(x) = -L_{n-1}^{\alpha+1}(x) \quad (III.14)$$

Ceci implique que les dérivées des polynômes de Laguerre forment une famille de polynômes orthogonaux.

La fonction poids est : $w(x) = x^\alpha e^{-x}$ (III.15)

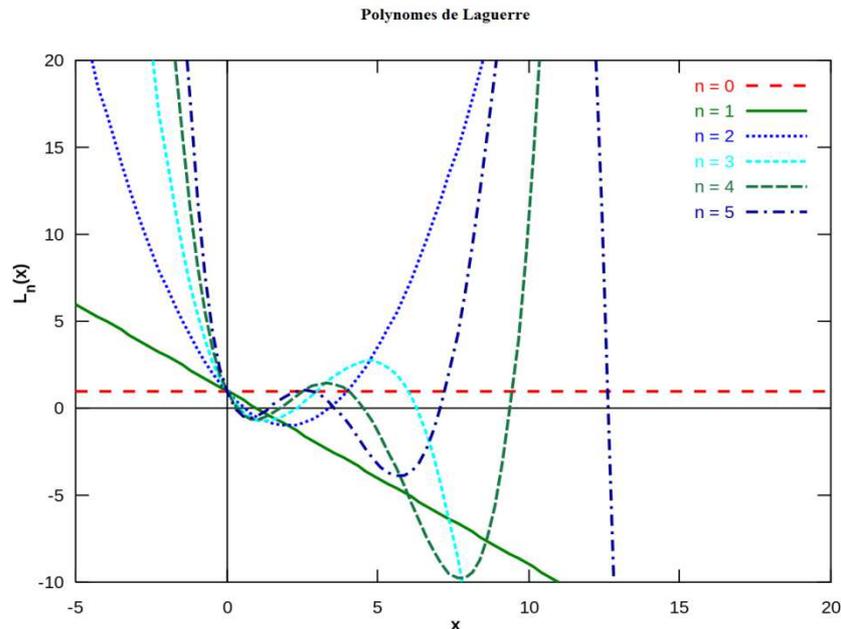


Figure III.3 : Les six premiers polynômes de Laguerre

III.4.3 Polynômes d'Hermite

Les polynômes d'Hermite $H_n(x)$ sont définis sur l'intervalle $] -\infty, +\infty[$. On appelle polynôme d'Hermite, $H_n(x)$

$$H_n(x) = (-1)^n e^{x^2} \frac{d^n}{dx^n} e^{-x^2} \quad (III. 16)$$

Les polynômes d'Hermite peuvent être introduits via la fonction génératrice suivante :

$$\sum_{n=0}^{\infty} H_n(x) \frac{w^n}{n!} = e^{2xw-w^2} \quad (III. 17)$$

Ce qui nous permet d'obtenir une formule explicite pour les $H_n(x)$. Attardons-nous à une certaine renormalisations des polynômes d'Hermite $\bar{H}_n(x)$, donnée par :

$$H_n(x) = 2^{\frac{n}{2}} \bar{H}_n(x) (\sqrt{2x}) \quad (III. 18)$$

de fonction génératrice :

$$\sum_{n=0}^{\infty} \bar{H}_n(x) \frac{w^n}{n!} = e^{xw - \frac{1}{2}w^2} \quad (III. 19)$$

La fonction de poids est :

$$w(x) = e^{-x^2} \quad (III. 20)$$

L'équation de récurrence est donnée par :

$$H_{n+1}(x) = 2xH_n(x) - 2nH_{n-1}(x) \quad (III. 21)$$

Dans la pratique, les fonctions d'Hermite sont plus utilisées que les polynômes. Ces fonctions sont déterminées par :

$$h_n(x) = \frac{H_n(x)e^{-x^2/2}}{\sqrt{\sqrt{\pi}2^n n!}} \quad (III. 22)$$

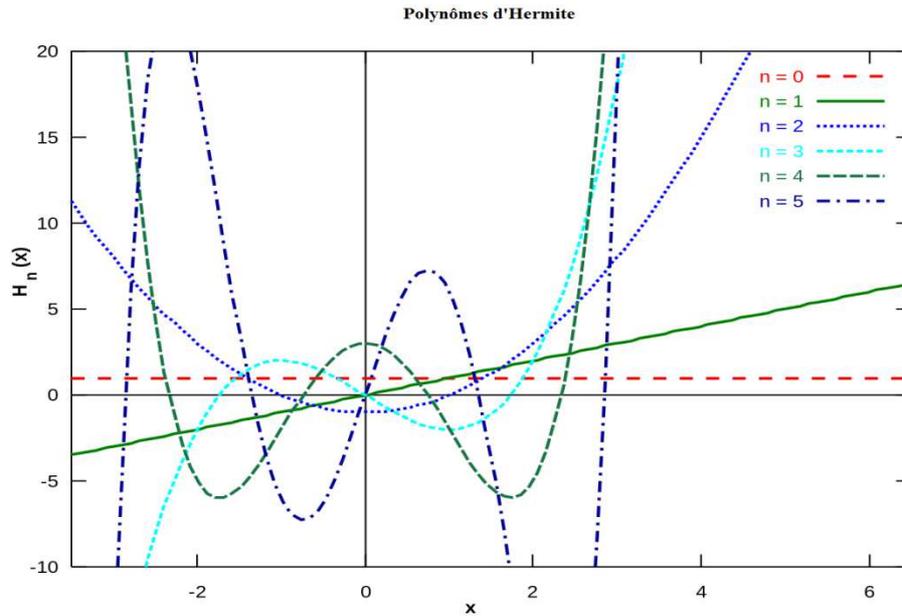


Figure III.4 : Les six premiers polynômes d’Hermite

III.5. Processus de modélisations polynomiales

Le principe général de ces méthodes consiste à décomposer le signal dans des bases polynomiales orthogonales et d’utiliser les coefficients obtenus après décomposition pour les caractériser (figure III.5)

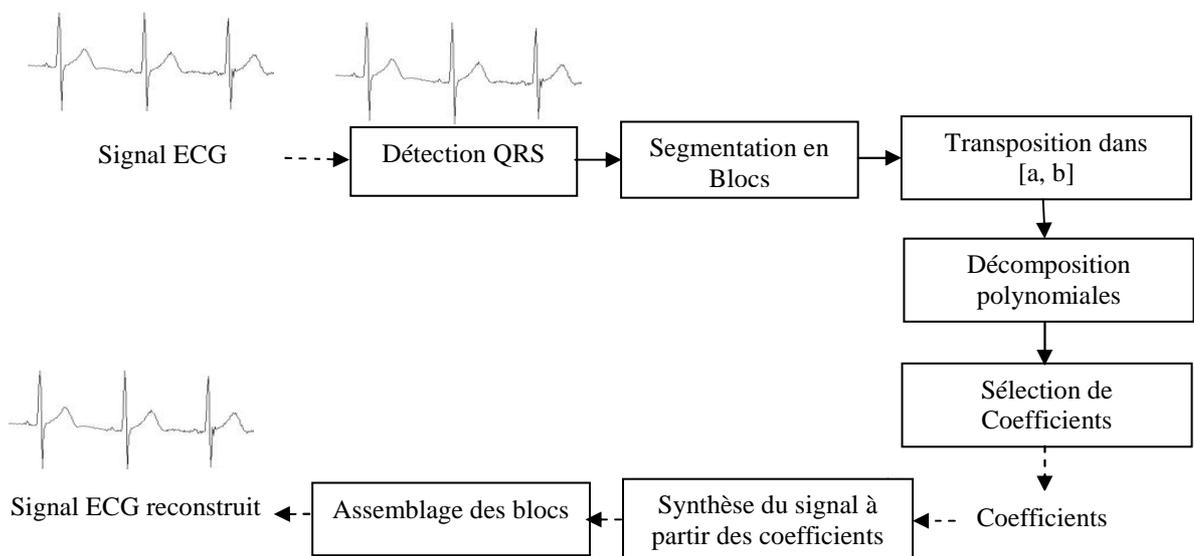


Figure III.5 : Schéma du processus de décomposition et de synthèse du signal ECG avec les polynômes orthogonaux

III.5.1. Détection du complexe QRS

La détection robuste des complexes QRS constitue le préalable à toute analyse du signal ECG. Lorsque les complexes QRS sont identifiés et leurs positions repérées, il devient facile d'évaluer d'autres paramètres du signal tels que la durée du cycle cardiaque, la durée du segment ST...etc.

Beaucoup d'études ont été développées dans la littérature afin de trouver un algorithme fiable et fonctionnant en temps réel pour la détection du complexe QRS. Chacune de ces méthodes possède des avantages et des inconvénients en termes de performance et de complexité.

La majorité des algorithmes de détection des complexes QRS reposent sur :

- Filtrage du signal ECG ;
- Une transformation non linéaire ;
- et une règle de décision qui consiste à établir des critères de seuillage;

Parmi ce type de méthodes on peut citer:

- La méthode de Pan & Tompkins [Pan, 1985], qui est la méthode la plus classique et la plus connue; Elle a été améliorée par la suite par Fokapu et Girard [Fokapu, 1993] ;
- La méthode de Hadj Slimane. Z [Hadj, 2010] qui utilise la décomposition modale empirique comme une étape dans le processus de détection des complexes QRS;
- D'autres méthodes plus récentes, sont basées sur l'utilisation des réseaux de neurones [Adnene, 2010] où ils exploitent la théorie des ondelettes ; comme les travaux présentés dans [Li, 1993], [Li, 1995], [Senhadji, 2002] et [Dumont, 2005].

III.5.2. Segmentation en Blocs

Dans cette phase, le signal ECG sera divisé en fenêtres de durée égale à celle du cycle cardiaque. On peut segmenter le signal en intervalles P-P, Q-Q, R-R, S-S, T-T, ou du cycle cardiaque centré sur le complexe QRS.

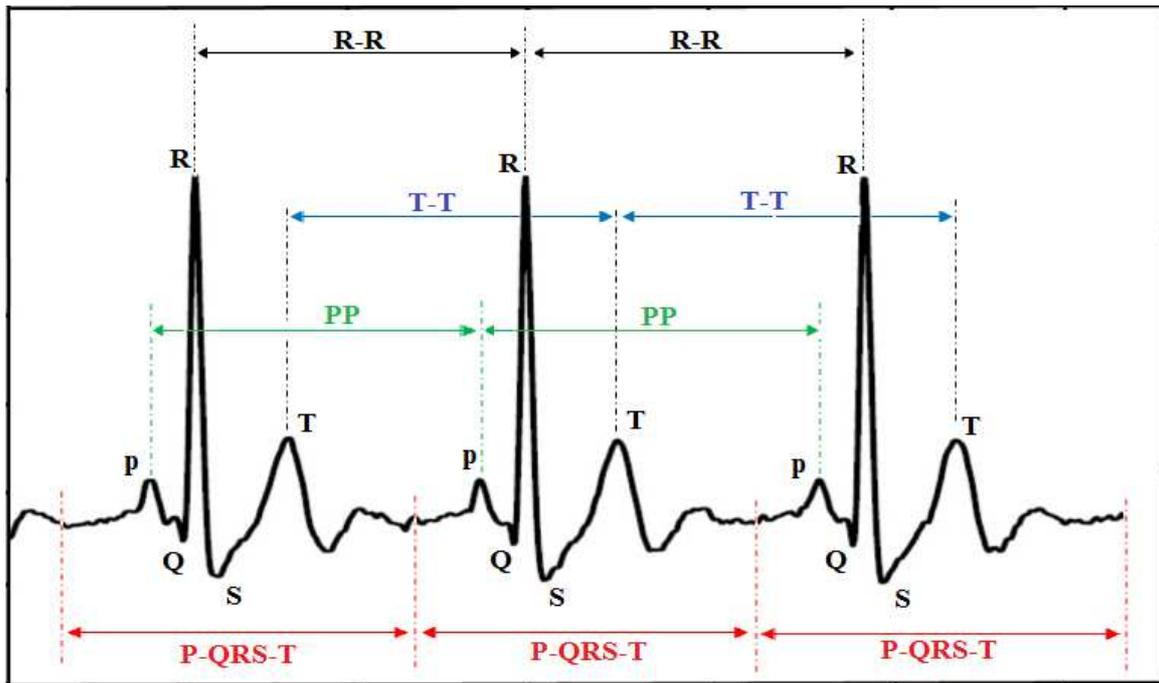


Figure III.6 : Différents types de segmentation du signal ECG en intervalles R-R, P-P, T-T, et P-QRS-T.

Le choix de la fenêtre de segmentation a une grande influence sur la qualité du signal reconstruit, il dépend du domaine d'utilisation et du polynôme utilisé.

- **Cas de Polynôme de Legendre et Jacobi :** Philips et De Jonghe ont démontré théoriquement et vérifié expérimentalement que l'intervalle R-R est le meilleur choix lorsqu'on l'utilise comme base de fonctions, les polynômes de Legendre [Philips, 1992] et dans une certaine mesure n'importe quelle autre classe dans la famille des polynômes de Jacobi [Philips, 1993].
- **Cas de Polynôme de Laguerre :** T. Daniel fait de nombreuses expériences de décomposition des signaux ECG dans les bases des polynômes de Laguerre, sur différents types d'intervalles (RR, P-P, Q-Q, T-T, centrées sur QRS, sur P ou sur T). Il a été constaté que les intervalles S-S et T-T produisaient les meilleures modélisations avec les polynômes de Laguerre, aussi bien en termes de conservation d'énergie que de déviation maximale d'amplitude [Daniel, 2007].
- **Cas de fonction d'Hermite :** T. Daniel a utilisé les fonctions et non les polynômes d'Hermite. Ces fonctions ont d'ailleurs été très sollicitées pour la modélisation des complexes QRS en vue de leur classification ([Sörnmo, 1981], [Lagerholm, 2000]). Les fenêtres de signaux dans lesquelles le complexe QRS occupe une position

médiane produisant les meilleures décompositions à base des fonctions d’Hermite [Daniel, 2007].

III.5.3 Transposition dans $[a, b]$

L’intervalle $[a, b]$ de la transposition dépend aussi du polynôme utilisé. Le tableau suivant représente le domaine de définition de chaque polynôme.

Polynôme	L’intervalle de transposition $[a, b]$
Polynôme de Jacobi	$] - 1, 1[$
Polynôme de Laguerre	$[0, +\infty [$
Polynôme d’Hermite	$] - \infty, +\infty[$

Tableau III.1 : Intervalle de transposition pour chaque polynôme

III.5.4 Calcul de coefficients de décomposition

III.5.4.1 Transformation de Laguerre (LaT)

Pour calculer les coefficients de décomposition par polynômes de Laguerre, il faut d’abord coïncider l’intervalle de la fenêtre du signal ECG à l’intervalle de temps $[0, +\infty[$ qui représente le domaine de définition $[a, b]$ des polynômes de Laguerre. Cet intervalle est de durée finie et égale à la durée d’un cycle cardiaque.

T. Daniel propose de faire l’augmentation de la durée de la fenêtre du signal par un prolongement. Trois possibilités sont proposées :

- Insérer une longue suite d’échantillons à valeurs nulles à la fin de la fenêtre ;
- procéder à de nombreuses répétitions périodiques de la même fenêtre de signal ;
- procéder à plusieurs répétitions symétriques de cette fenêtre.

Le développement d’un signal $g(x)$ en série de polynômes de Laguerre sera fait comme suit :

$$g(x) = \sum_{n=0}^{\infty} C_{n,L} L_n(x) \quad (III.23)$$

Avec :

$$C_{n,L} = \frac{1}{(n!)^2} \int_0^{+\infty} g(x) L_n(x) e^{-x} dx \quad (III.24)$$

III.5.4.2 Transformation de Tchebychev (TcT)

Le signal $g(t)$ devient $g(x)$ sur l'intervalle $[-1,1]$. Son développement en série de polynômes de Tchebychev est donné sous la forme suivante:

$$g(x) = \sum_{n=0}^{\infty} C_{n,T} T_n(x) \quad (III. 25)$$

Avec :

$$C_{0,T} = \frac{1}{\pi} \int_{-1}^1 \frac{g(x)}{\sqrt{1-x^2}} dx \quad (III. 26)$$

$$C_{n,T} = \frac{2}{\pi} \int_{-1}^1 \frac{g(x)T_n(x)}{\sqrt{1-x^2}} dx \quad \text{si } n \geq 1 \quad (III. 27)$$

III.5.4.3 Transformation d'Hermite (HeT)

L'étude de la modélisation par polynôme d'Hermite est semblable à celle des polynômes de Laguerre.

$$g(x) = \sum_{n=0}^{\infty} C_{n,H} H_n(x) \quad (III. 28)$$

Avec :

$$C_{n,H} = \frac{1}{2^n n! \sqrt{\pi}} \int_0^{\infty} g(x) H_n(x) e^{-x^2} dx \quad (III. 29)$$

III.5.4.4 Transformation de Jacobi

Le développement d'un signal $g(x)$ en série de polynômes de Jacobi est donné par :

$$g(x) = \sum_{n=0}^{\infty} C_{n,J} P_n^{(\alpha,\beta)}(x) \quad (III. 30)$$

Avec :

$$C_{n,J} = \frac{\int_{-1}^1 g(x) P_n^{(\alpha,\beta)}(x) (1-x)^\alpha (1+x)^\beta dx}{\|P_n^{(\alpha,\beta)}\|^2} \quad (III. 31)$$

III.6. Conclusion

Dans ce chapitre, une présentation a été faite sur les différentes familles de polynômes orthogonaux et la possibilité de leurs utilisations dans le processus de modélisation des signaux ECG. Le processus en question a été décrit en détail.

Pour obtenir une bonne modélisation, il a été prouvé que le choix de la fenêtre de segmentation joue un rôle important sur la qualité du signal reconstruit. En effet, dans le cas du polynôme d'Hermite, la fenêtre de segmentation utilisée est le cycle cardiaque centré sur QRS. Par contre, d'autres types de fenêtres de segmentation sont envisagés pour d'autres types de polynômes.



Chapitre IV

Les réseaux de neurones artificiels



Chapitre IV : Les réseaux de neurones artificiels

IV.1. Introduction

La reconnaissance automatique d'arythmies cardiaques est devenue un domaine de recherche très active capable d'aider les médecins à faire le diagnostic. De nombreuses méthodes proposées par différents chercheurs seront présentés dans ce chapitre.

Ainsi, le présent chapitre sera réparti comme suit :

- Nous présenterons les différents travaux existantes dans la littérature sur la classification automatique des signaux ECG;
- Une brève description des réseaux de neurones artificiels sera ensuite faite;
- Nous exposant par la suite les types et la méthodologie d'apprentissage ;
- Nous présenterons aussi, d'une manière générale, les étapes de conception d'un réseau de neurones ;
- Et enfin, nous terminerons ce chapitre par la présentation des diverses applications des réseaux de neurones artificiels.

IV.2. Etats de l'arts sur la classification automatique des signaux ECG

Les travaux de recherches pour la classification du signal cardiaque remontent à 1957 où les premières approches étaient principalement basées sur l'utilisation de la méthode des arbres de décision et la méthode statistique. Par la suite et grâce à des méthodes mathématiques et de la révolution informatique notamment l'intelligence artificielle (AI), de nombreuses techniques ont été développées pour améliorer et augmenter la précision du système de détection des arythmies tels que :

- La règle de K plus proche voisin (Kth) ([Christov, 2006], [Kutlu, 20012]) ;
- Les algorithmes génétiques et Support Vector Machines (SVM) ([Yu, 2007], [Khazae, 2010]) ;
- l'utilisation de la transformée en ondelettes pour l'analyse et la classification des signaux ECG [Chazal, 2000].

Les réseaux de neurones artificielles sont les plus souvent utilisés ; ils peuvent fournir une solution intéressante pour les problèmes de classification des anomalies cardiaques ; à cause de leur excellente possibilité d'apprendre le rapport entre les entrées-sorties d'un ensemble de données sans n'importe quelle connaissance antérieure.

Beaucoup de travaux de recherche pour la classification des battements cardiaques, basés sur les réseaux de neurones, ont été développés, parmi ces travaux :

- Celui de Mark et al. [Jansen, 1997] qui montrent que les techniques de réseaux de neurones multicouches MLP et la carte auto-organisatrice (SOM) sont utilisées dans la classification du signal ECG ;
- Olmez et al. [Olmez, 1997], dans leurs travaux sur la classification des formes d'ondes de l'ECG, ont pu classer quatre types de battement tels que les battements normaux, le bloc de branche gauche, la contraction ventriculaire prématurée, et les battements de type P en utilisant un réseau de neurone RCE (Restricted Coulomb Energy) et les algorithmes génétiques.
- ART (Adaptive Resonant Theory) a été appliqué à une variété de domaines allant des applications médicales, telles que la classification des modèles ECG [Silipo, 1998], au traitement sémantique des données.
- Barro et al, [Barro, 1998] ont utilisé la théorie MART (Multi-Channel Adaptive Resonance Theory) pour classer les signaux ECG.
- Al-Fahoum et al [Al-Fahoum, 1999] ont utilisé des transformations en ondelette (continue et discrète) dans la phase d'extraction des paramètres. Le vecteur résultant des paramètres est utilisé ensuite comme entrée d'un réseau de neurones de type RBF dans le but de la détection automatique des arythmies.
- Les auteurs Acharya et al. dans leurs travaux [Acharya, 2004] ont classé les battements cardiaques en huit classes. Ils ont utilisé trois paramètres extraits du signal HRV (variation de rythme cardiaque) à l'entrée d'un classificateur à RNA et autre classificateur flou.

IV.3. Les réseaux de neurones artificiels (RNA)

IV.3.1 Présentation

Le cerveau capable d'apprendre et de réaliser des raisonnements complexes est constitué d'un très grand nombre de neurones (environ 10^{15}) reliés entre eux (entre 10^3 et 10^4 connexions par neurones).

Les réseaux de neurones artificiels (RNA) sont des modèles de calcul dont la conception est très schématiquement inspirée du fonctionnement des neurones biologiques. Ils sont considérés comme l'une des composantes importantes du domaine de l'intelligence artificielle.

IV.3.2 Historique

Les réseaux de neurones ont été étudiés depuis les années 40 mais l'origine de l'inspiration des réseaux de neurones artificiels remonte à 1890 quand W. James, célèbre psychologue américain, introduit le concept de mémoire associative. Il propose ce qui deviendra une loi de fonctionnement pour l'apprentissage des réseaux de neurones, connu plus tard sous le nom de loi de Hebb.

Dans l'année 1943, le chercheur en neurologie J. Mc Culloch et le mathématicien W. Pitts montrent que les réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes (tout au moins au niveau théorique).

En 1949, le physiologiste américain D. Hebb s'attaque au problème de l'apprentissage dans son ouvrage "The Organization of Behavior". Deux neurones entrant en activité simultanément vont être associés (c'est à dire que leurs contacts synaptiques vont être renforcés). On parle de loi de Hebb et d'associationnisme.

Dans les années 50, des chercheurs ont commencé à développer des modèles software mais aussi hardware pour simuler les fonctions de bas niveaux du système nerveux. L'un des premiers succès on été trouvé en 1957 par F. Rosenblatt qui développe un modèle du Perceptron. Il construit le premier neuroordinateur basé sur ce modèle et l'applique au domaine de la reconnaissance de formes.

En 1960, B. Widrow et T.Hoff développent le modèle AdaLiNe (Adaptative Linear Neuron). Dans sa structure, le modèle ressemble au Perceptron, cependant la loi d'apprentissage est différente.

En 1969, Les recherches sur les réseaux de neurones ont été pratiquement abandonnées lorsque M. Minsky et S. Papert ont publié leur livre « Perceptrons » (1969) et démontré les limites théoriques du perceptron, en particulier, l'impossibilité de traiter les problèmes non linéaires par ce modèle.

Les réseaux de neurone vont renaître dans les années 80 avec les travaux de physicien J.J. Hopfield en 1982 qui présente une théorie du fonctionnement et des possibilités des réseaux de neurones à travers un article court, clair et bien écrit [Hopfield, 1982]. En 1986, Mc Clelland, Rumelhart et Hinton introduisent l'algorithme de retropropagation, puis en 1982, Kohonen introduit les cartes auto-organisatrices à apprentissage non supervisé.

Enfin, en 1989 Moody et Darken exploitent quelques résultats de l'interpolation multi variables pour proposer le Réseau à Fonctions de base Radiales (RFR), connu sous l'appellation anglophone 'Radial Basis Function network' (RBF). Ce type de réseau se distingue des autres types de réseaux de neurones par sa représentation locale.

De nos jours, l'utilisation des réseaux de neurones dans divers domaines ne cesse de croître. Les applications en sont multiples et variées.

IV.3.3. Neurone biologique

Le neurone biologique (figure IV.1) comprend [Borne, 2007]:

- le corps cellulaire, qui fait la somme des influx qui lui parviennent ; si cette somme dépasse un certain seuil, il envoie lui-même un influx par l'intermédiaire de l'axone ;
- l'axone, qui permet de transmettre les signaux émis par le corps cellulaire aux autres neurones ;
- les dendrites, qui sont les récepteurs principaux du neurone, captant les signaux qui lui parviennent ;
- les synapses, qui permettent aux neurones de communiquer avec les autres via les axones et les dendrites.

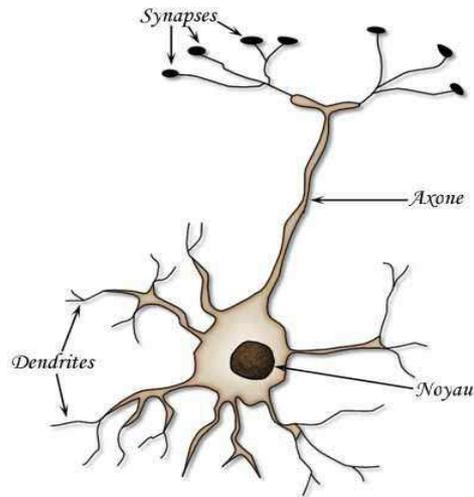


Figure IV.1 : structure schématique d'un neurone

IV.3.4. Neurone artificiel (formel)

Le neurone formel (figure IV.2) est l'approche mathématique du neurone biologique, il se compose de :

- Un ensemble de valeurs d'entrée $\{A_1, A_2, \dots, A_n\}$
- Un ensemble de poids réels entre les neurones $\{w_1, w_2, \dots, w_n\}$
- Une fonction de sommation Σ qui calcule la somme pondérée (sous-entendu pondérée par les poids) des entrées :

$$x = \sum_{i=1}^n A_i w_i$$

- Une fonction f appelée fonction d'activation ou fonction de transfert du neurone

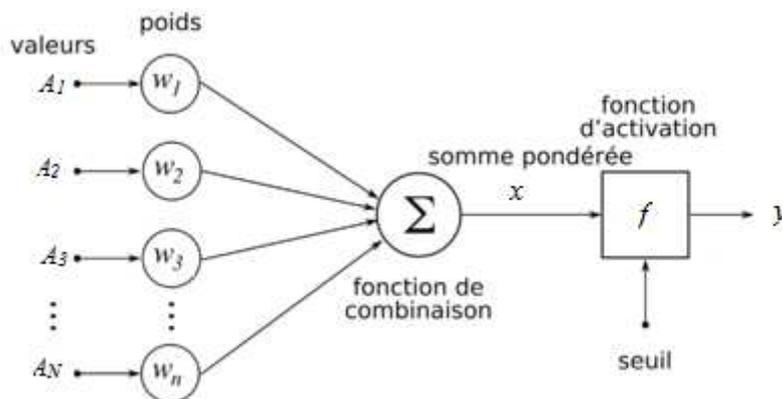


Figure IV.2 : Schéma d'un neurone artificiel

Il existe de nombreuses formes possibles pour la fonction de transfert. Les plus communément utilisées sont présentées dans le tableau suivant :

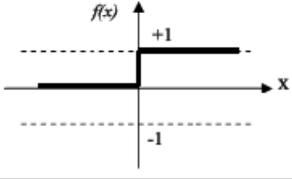
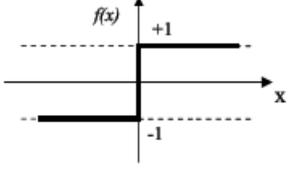
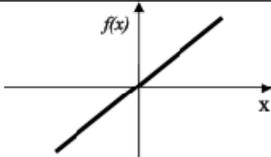
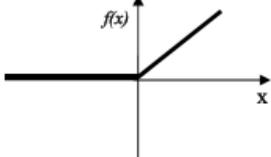
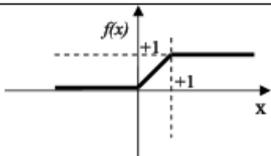
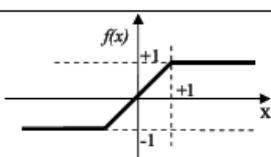
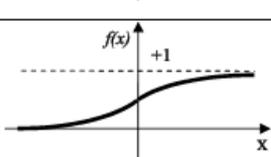
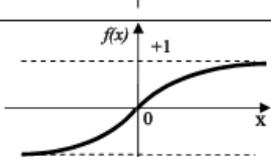
Catégorie	Type	Equation	Allure
Seuil	Binaire (fonction de Heaviside)	$f(x) \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$	
	Signe	$f(x) \begin{cases} 1 & \text{si } x > 0 \\ -1 & \text{si } x \leq 0 \end{cases}$	
Linéaire	Identité	$F(x) = x$	
Linéaire	Linéaire positif	$f(x) \begin{cases} 1 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$	
	Saturé positif	$f(x) \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 1 \\ x & \text{si non} \end{cases}$	
	Saturé symétrique	$f(x) \begin{cases} -1 & \text{si } x \leq -1 \\ 1 & \text{si } x \geq 1 \\ x & \text{si non} \end{cases}$	
Non linéaire	Logistique (sigmoïde)	$f(x) = \frac{1}{1 + e^{-x}}$	
	Tan-sigmoïde (tanh)	$f(x) = \frac{2}{1 + e^{-x}} - 1$	

Tableau IV.1 : Les fonctions d'activation

IV.3.5. Architecture des réseaux de neurones

Les connexions entre les neurones qui composent le réseau décrivent la topologie du modèle.

On distingue deux grandes familles de réseaux de neurones: les réseaux non bouclés et les réseaux bouclés [Dreyfus, 1998], les plus utilisés dans la littérature sont représentés sur la figure (IV.3).

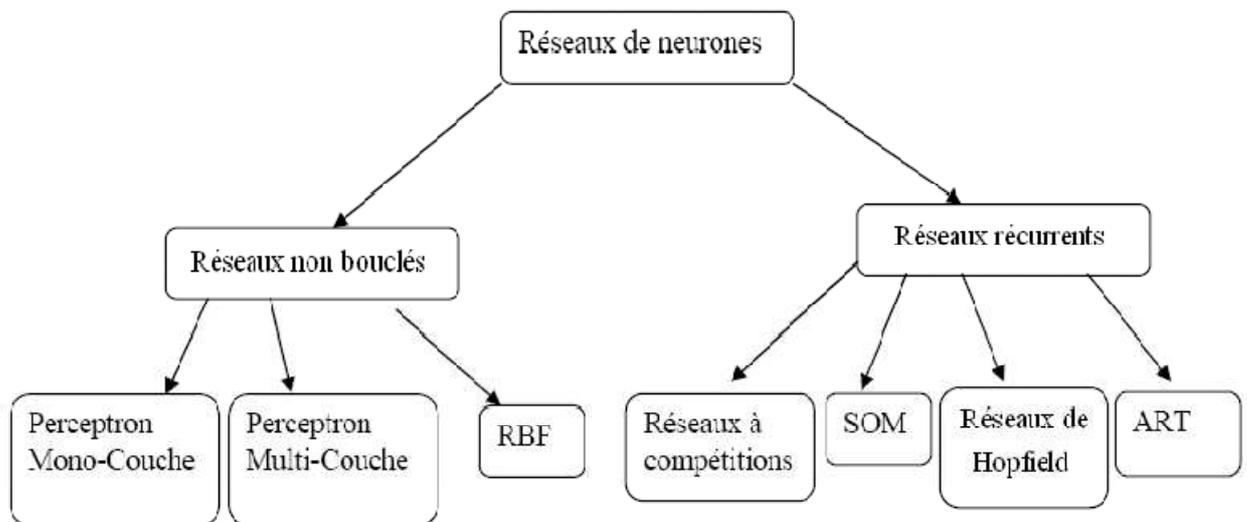


Figure IV.3 : Réseaux de neurones les plus utilisés

IV.3.5.1. Les réseaux de neurones non bouclés

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonctions algébriques de ses entrées, par composition des fonctions réalisées par chacun de ses neurones.

Un réseau de neurones non bouclé est représenté graphiquement par un ensemble de neurones "connectés" entre eux, l'information circulant des entrées vers les sorties sans "retour en arrière"; si l'on représente le réseau comme un graphe dont les nœuds sont les neurones et les arêtes les "connexions" entre ceux-ci, le graphe d'un réseau non bouclé est acyclique.

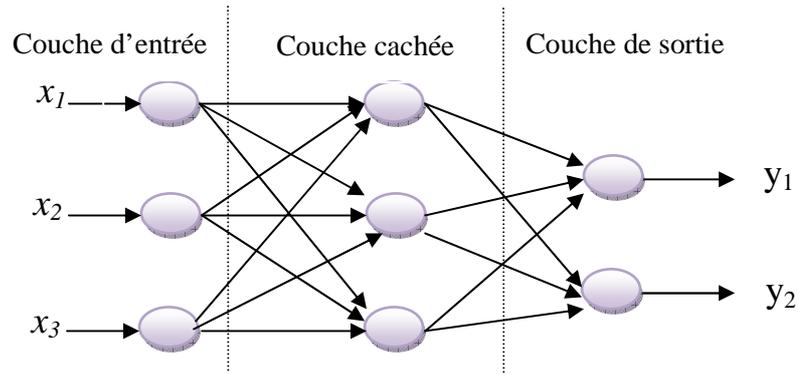


Figure IV.4 : Exemple d'un Réseau non bouclé

Ce type de réseau comprend deux groupes d'architectures: les réseaux monocouches et les réseaux multicouches. Ils diffèrent par l'existence ou non de neurones intermédiaires appelés neurones cachés entre les unités d'entrées et les unités de sorties appelées nœuds sources ou nœuds d'entrée et nœuds de sortie respectivement.

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

Les réseaux les plus fréquemment utilisés de cette catégorie sont les perceptrons multicouches (Multilayer Perceptrons, MLP).

IV.3.5.2. Les réseaux de neurones bouclés (récurrents)

Les réseaux de neurones bouclés, appelé aussi réseau récurrent ou dynamique peuvent avoir une topologie de connexions quelconque, comprenant notamment des boucles qui ramènent aux entrées la valeur d'une ou plusieurs sorties, Ce type de réseau est notamment utilisé pour la modélisation dynamique de processus non linéaires.

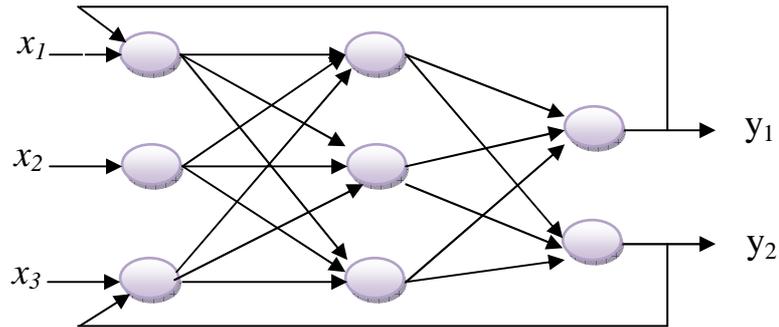


Figure IV.5 : Exemple d'un Réseau bouclé

IV.3.6 Apprentissage des réseaux de neurones [Ammar, 2007]

L'apprentissage est la caractéristique principale des réseaux de neurones ; Il s'agit d'une procédure adaptative par laquelle les connexions des neurones sont ajustées face à une source d'information.

IV.3.6.1 Type d'apprentissage

Il existe de nombreux types de règles d'apprentissage qui peuvent être regroupées en trois catégories : les règles d'apprentissage supervisé, non supervisé, et renforcé.

IV.3.6.1.a Apprentissage supervisé

Un apprentissage est dit supervisé lorsque l'on force le réseau à converger vers un état final précis, en même temps qu'on lui présente un motif. Ce genre d'apprentissage est réalisé à l'aide d'une base d'apprentissage, constituée de plusieurs exemples de type entrées-sorties.

La procédure usuelle dans le cadre de la prévision est l'apprentissage supervisé (ou à partir d'exemples) qui consiste à associer une réponse spécifique désirée à chaque signal d'entrée. La modification des poids s'effectue progressivement jusqu'à ce que l'erreur (ou l'écart) entre les sorties du réseau (ou résultats calculés) et les résultats désirés soient minimisés.

Cet apprentissage n'est possible que si un large jeu de données est disponible et si les solutions sont connues pour les exemples de la base d'apprentissage.

IV.3.6.1.b Apprentissage renforcé

L'apprentissage renforcé est une technique similaire à l'apprentissage supervisé à la différence qu'au lieu de fournir des résultats désirés au réseau, on lui accorde plutôt un grade (ou score) qui est une mesure du degré de performance du réseau après quelques itérations.

Les algorithmes utilisant la procédure d'apprentissage renforcé sont surtout utilisés dans le domaine des systèmes de contrôle ([White et Sofge, 1992]; [Sutton, 1992]).

IV.3.6.1.c Apprentissage non supervisé

L'apprentissage non supervisé consiste à ajuster les poids à partir d'un seul ensemble d'apprentissage formé uniquement de données. Aucun résultat désiré n'est fourni au réseau.

Qu'est-ce que le réseau apprend exactement dans ce cas ? L'apprentissage consiste à détecter les similarités et les différences dans l'ensemble d'apprentissage. Les poids et les sorties du réseau convergent, en théorie, vers les représentations qui capturent les régularités statistiques des données ([Fukushima, 1988]; Hinton, 1992). Ce type d'apprentissage est également dit compétitif et (ou) coopératif [Grossberg, 1988]. L'avantage de ce type d'apprentissage réside dans sa grande capacité d'adaptation reconnue comme une autoorganisation, « self-organizing » [Kohonen, 1987]. L'apprentissage non supervisé est surtout utilisé pour le traitement du signal et l'analyse factorielle.

IV.3.6.2 Algorithme d'apprentissage

L'algorithme d'apprentissage est la méthode mathématique qui va modifier les poids de connexions afin de converger vers une solution qui permettra au réseau d'accomplir la tâche désirée.

Plusieurs algorithmes itératifs peuvent être mis en œuvre, parmi lesquels on note : l'algorithme de rétropropagation, la Méthode Quasi-Newton, Algorithme de BFGS

IV.3.6.2.a Algorithme de rétropropagation du gradient

L'algorithme de rétropropagation (ARP) ou de propagation arrière « backpropagation » est l'exemple d'apprentissage supervisé le plus utilisé. La technique de rétropropagation du gradient est une méthode qui permet d'apprendre par mises à jour des poids des différentes couches afin de calculer le gradient de l'erreur pour chaque neurone du réseau, de la dernière couche vers la première.

Le principe de la rétropropagation peut être décrit en trois étapes fondamentales :

- Acheminement de l'information à travers le réseau;
- Rétropropagation des sensibilités et calcul du gradient;
- Ajustement des paramètres par la règle du gradient approximé.

IV.3.6.2.b Méthodes Quasi-Newton

Cet algorithme nécessite la connaissance des valeurs de la fonction objective à minimiser et du vecteur des dérivées premières au point solution courant. Le vecteur des dérivées est évalué analytiquement.

IV.3.6.2.c Algorithme de BFGS

L'algorithme de BFGS (du nom de ses inventeurs : Broyden, Fletcher, Goldfarb et Shanno) prend implicitement en compte les dérivées secondes et s'avère donc nettement plus performante que la méthode de rétropropagation. Le nombre d'itérations est nettement plus faible et les temps de calcul réduits d'autant.

IV.3.7. Conception d'un réseau de neurones

La conception d'un réseau de neurones est l'un des tâches les plus compliqué à réaliser dans l'intelligence artificiel, les étapes suivantes représentent le guide de création d'un réseau de neurones artificiel :

- la collecte et l'analyse des données pour l'apprentissage et l'évaluation des performances du réseau de neurones ;
- la détermination des entrées et des sorties pertinentes ;
- le choix et l'élaboration de la structure du réseau ;
- l'apprentissage ;

- et la validation.
 - **La collecte des données pour l'apprentissage et l'évaluation**

Le processus d'élaboration d'un réseau de neurones commence toujours par le choix et la préparation des échantillons de données. Il est souvent préférable d'effectuer une analyse des données de manière à déterminer les caractéristiques discriminantes pour détecter ou différencier ces données. Ces caractéristiques constituent l'entrée du réseau de neurones, il appartient à l'expérimentateur de déterminer le nombre de classes auxquelles ses données appartiennent et de déterminer pour chaque donnée la classe à laquelle elle appartient. Pour cela, il est nécessaire de disposer de deux bases de données : une base pour effectuer l'apprentissage et une autre pour tester le réseau obtenu et déterminer ses performances.

- **La détermination des entrées pertinentes**

Deux points essentiels sont pris en considération pour la détermination des entrées :

- la dimension du vecteur des entrées doit être aussi petite que possible, en d'autre terme, la représentation des entrées doit être la plus compacte possible, tout en conservant pour l'essentiel la même quantité d'information, et en gardant à l'esprit que les différentes entrées doivent être indépendantes ;
- En second lieu, toutes les informations présentées dans les entrées doivent être pertinentes pour la grandeur que l'on cherche à classer.

- **Le choix et l'élaboration de la structure du réseau**

Il existe un grand nombre de types de réseaux de neurones, chacun à des avantages et des inconvénients. Le choix d'un réseau peut dépendre sur plusieurs facteurs, parmi ces facteurs on peut citer :

- la tâche à effectuer (classification, association, contrôle de processus, séparation aveugle de sources...) ;
- les différents types de réseaux de neurones disponibles dans le logiciel de simulation que l'on compte utiliser (à moins de le programmer) ;
- type des échantillons.

Pour des algorithmes de classification comme notre cas, il est préférable d'utiliser les réseaux de neurone multicouches, il faudra aussi bien choisir le nombre de couches cachées et le nombre de neurones dans cette couche.

- **Nombre de couches cachées**

Mis à part les couches d'entrée et de sortie, il faut décider du nombre de couches intermédiaires ou cachées. Sans couche cachée, le réseau n'offre que de faibles possibilités d'adaptation. Néanmoins, il a été démontré qu'un Perceptron Multicouches avec une seule couche cachée pourvue d'un nombre suffisant de neurones, peut approximer n'importe quelle fonction avec la précision souhaitée (Hornik, 1991).

- **Nombre de neurones cachés**

Chaque neurone peut prendre en compte des profils spécifiques de neurones d'entrée. Un nombre plus important permet donc de mieux "coller" aux données présentées mais diminue la capacité de généralisation du réseau. Il faut alors trouver le nombre adéquat de neurones cachés nécessaire pour obtenir une approximation satisfaisante.

Il n'existe pas, à ce jour, de résultat théorique permettant de prévoir le nombre de neurones cachés nécessaires pour obtenir une performance spécifique du modèle, compte tenu des modèles disponibles. Il faut donc nécessairement mettre en œuvre une procédure numérique de conception de modèle.

- **Apprentissage**

Tous les modèles de réseaux de neurones requièrent un apprentissage. Plusieurs types d'apprentissages peuvent être adaptés à un même type de réseau de neurones. Les critères de choix sont souvent la rapidité de convergence ou les performances de généralisation.

Le critère d'arrêt de l'apprentissage est souvent calculé à partir d'une fonction de coût, caractérisant l'écart entre les valeurs de sortie obtenues et les valeurs de références (réponses souhaitées pour chaque exemple présenté).

- **Validation et Tests**

Une fois le réseau de neurones entraîné (après apprentissage), des tests s'imposent afin de vérifier la qualité des prévisions du modèle neuronal.

Cette dernière étape doit permettre d'estimer la qualité du réseau obtenu en lui présentant des exemples qui ne font pas partie de l'ensemble d'apprentissage. Une validation rigoureuse du modèle développé se traduit par une proportion importante de prédictions exactes sur l'ensemble de la validation. Si les performances du réseau ne sont pas satisfaisantes, il faudra, soit modifier l'architecture du réseau, soit modifier la base d'apprentissage.

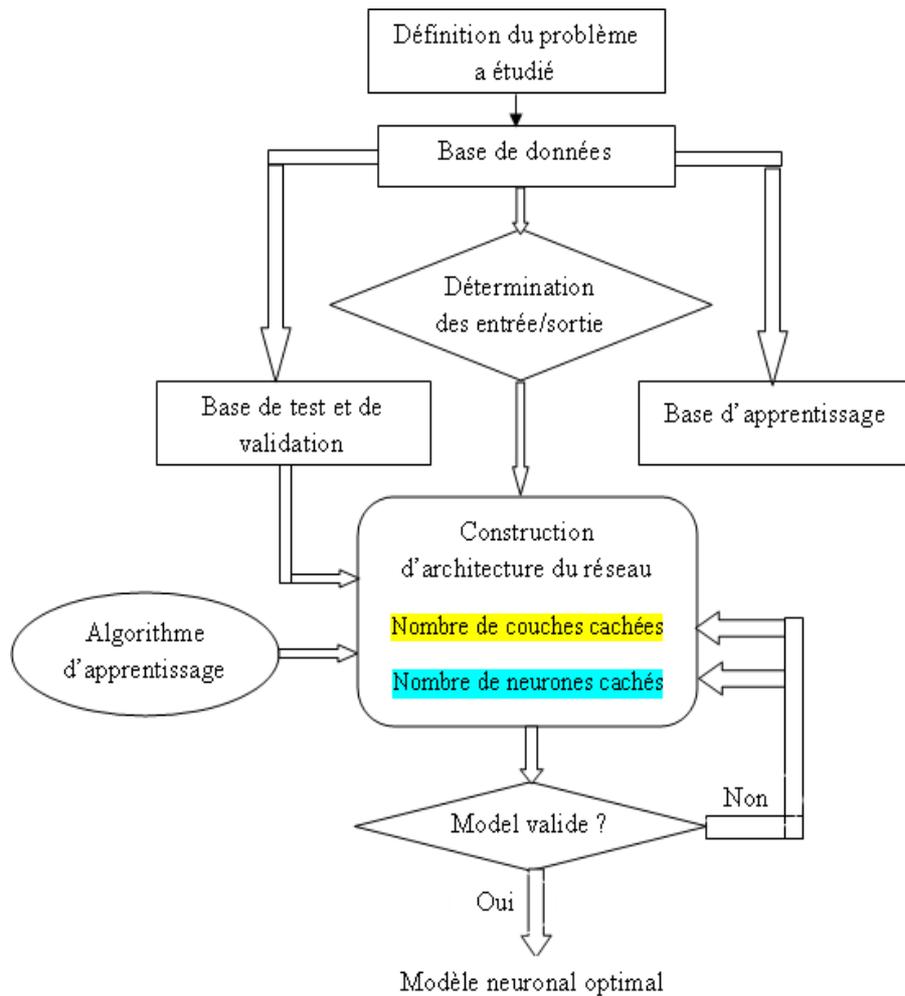


Figure IV.6 : Organigramme de conception d'un réseau de neurones.

IV.3.8. Les différentes applications de RNA

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

IV.3.8.1 Reconnaissance des formes

Le premier modèle dans cette thématique a été développé aux laboratoires AT&Bell dans la reconnaissance des codes postaux.

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

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

IV.3.8.2 Modélisation

L'une des applications répondeuses des RNA est la modélisation. Nous pouvons citer comme exemples: Modélisation financière, modélisation des processus de fabrication et de production, modélisation en biomédecine.

IV.3.8.3 Traitement de la parole

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

IV.3.8.4 Détection d'anomalies en médecine

Ceci est une dérivation des reconnaissances de formes. On apprend à un réseau une image du fonctionnement normal d'un système et celui-ci sera ainsi capable d'indiquer tout état

de dysfonctionnement quand certains paramètres engendrent une image anormale. Parmi les applications en médecine nous pouvons citer:

- Cardiologie
- Traitement des images MRI (Magnetic Resonance Imager)
- Psychologie, psychiatrie et sociologie
- Ophtalmologie

IV.4.Conclusion

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

Nous avons terminé ce chapitre par les différentes applications des réseaux de neurones artificiels et spécialement l'utilisation des RNA dans la classification des arythmies cardiaques.



Chapitre V

*Extraction des caractéristiques des signaux
ECG et respiratoires pour la classification
automatique supervisée des battements
cardiaque*



Chapitre V : Extraction des caractéristiques des signaux ECG et respiratoires pour la classification automatique supervisée des battements cardiaque

V.1. Introduction

L'électrocardiogramme ECG, représente l'activité électrique du cœur. Un signal ECG contient trois paramètres importants caractérisant l'activité cardiaque: l'onde P, le complexe QRS, et l'onde T, et aussi une autre onde U qui apparaît parfois mais elle n'est pas utilisée pour le diagnostic (Fig. I.6).

Le signal respiratoire, enregistré simultanément avec le signal ECG (Fig. V.1 et Fig. V.2), peut être considéré comme un outil très important pour le diagnostic de certains pathologie cardiaques.

Il existe différentes approches proposées dans la littérature pour la classification des signaux ECG en battements normaux (N) ou anormaux (V), à titre d'exemple :

- Le travail de Rai et al. , qui se base sur l'utilisation des coefficients de la transformée en ondelettes discrète et un classifieur à base de réseaux de neurones [Rai, 2013] ;
- De même, Mitra et al. ont proposé différentes techniques de sélection des paramètres caractéristiques d'un battement cardiaque pour la classification du signal ECG en battement normal et anormal dans un ECG. Les dites techniques utilisent un classifieur neuronal [Mitra, 2013] ;
- Un autre travail récent a été présenté par Subbiah et al. ; qui utilise trois types de classifieurs : Support Vector Machines (SVM), Extern Learning Machine (ELM) et Back Propagation Neural Network (BPN) [Subbiah, 2015].

Dans notre travail, il a été constaté qu'il existe une relation importante et significative entre le complexe QRS et le signal respiratoire en particulier dans le cas pathologique. Pour cela les deux signaux (ECG et respiratoires) seront utilisés pour améliorer la performance de nos classificateurs. Les battements cardiaques seront classés en deux classes (classe normale et anormale). La méthode ACP sera utilisée pour réduire le vecteur d'entrée des paramètres pertinents extraits des deux signaux appliqués à l'entrée du classifieur.

Le classificateur utilisé est un perceptron multi-couche (MLPNNs). Notre système a été validé sur des signaux réels des différents patients extraits de la base de données Apnea-ECG [Penzel, 200].

L'évaluation des performances du système proposé, est basée sur la sensibilité (SE), la spécificité (SP), la prédictivité (PP) et le taux de classification (CC).

V.2. Description de la base de données Apnea-ECG

La collection d'une base de données est l'une des tâches les plus importantes en traitement du signal. Dans notre travail, la base de données Apnea-ECG en PhysioBank a été utilisée.

PhysioBank est un ensemble d'enregistrements de signaux et de données physiologiques dédiés à l'utilisation dans le domaine de la recherche biomédicale.

La base de données Apnea-ECG se compose de 70 enregistrements de durée variant entre 7h à 10h. Chaque enregistrement comprend un signal ECG échantillonné à 100 Hz. Aussi chaque complexe QRS et chaque présence d'apnée sont annotés. En outre, huit enregistrements sont accompagnés de quatre signaux supplémentaires enregistrées simultanément sont :

- **Resp C** and **Resp A** : sont des signaux d'effort respiratoire respectivement thoraciques et abdominales obtenus en utilisant la méthode de pléthysmographie par inductance (voir chapitre1);
- **Resp N** : est le flux d'air oronasal (oral/nasal) mesuré en utilisant des thermistances nasales ;
- et **SpO2**, la saturation en oxygène.

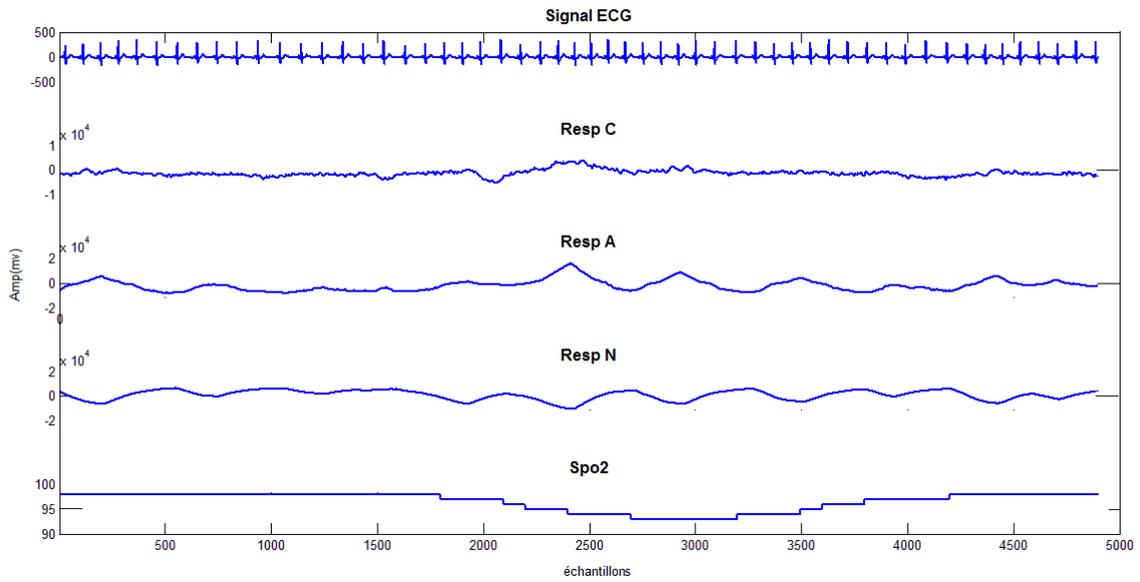


Figure V.1 : Enregistrement a01erm de la base de données Apnea-ECG

Deux bases de données ont été créées à partir de cette base de données: une pour l'apprentissage, et l'autre pour le test des classificateurs développés. Les enregistrements choisis sont ceux qui contiennent les deux signaux électrocardiogramme (ECG) et respiratoire (Resp N), les signaux utilisés sont : a01erm, a02erm, a03erm, a04erm, b01erm, c01erm, et c02erm.

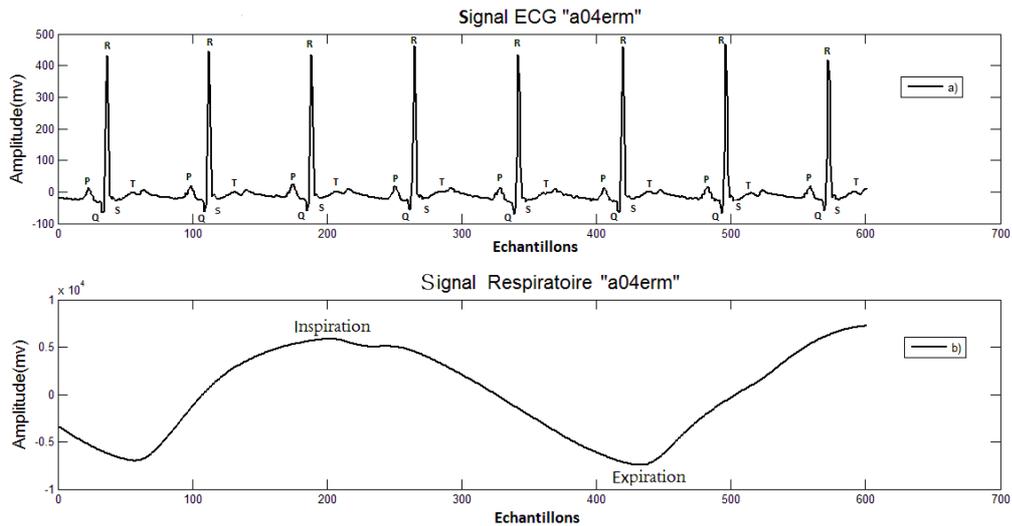


Figure V.2: le signal respiratoire enregistré simultanément avec le signal ECG.

V.3 Description des procédés de classification

Le schéma bloc de l'algorithme proposé est illustré sur la figure V.3. L'algorithme se résume comme suit :

- Une étape de traitement du signal ECG ;
- Détection de différentes ondes tel que le complexe QRS, onde P, et onde T. Cette phase est nécessaire pour l'extraction des caractéristiques pertinents qui caractérisent les battements cardiaques dans le signal ECG et le signal respiratoire ;
- La méthode ACP est appliquée pour réduire les dimensions du vecteur d'entrée pour chaque classificateur utilisé.
- Et enfin, l'étape d'apprentissage et classification.

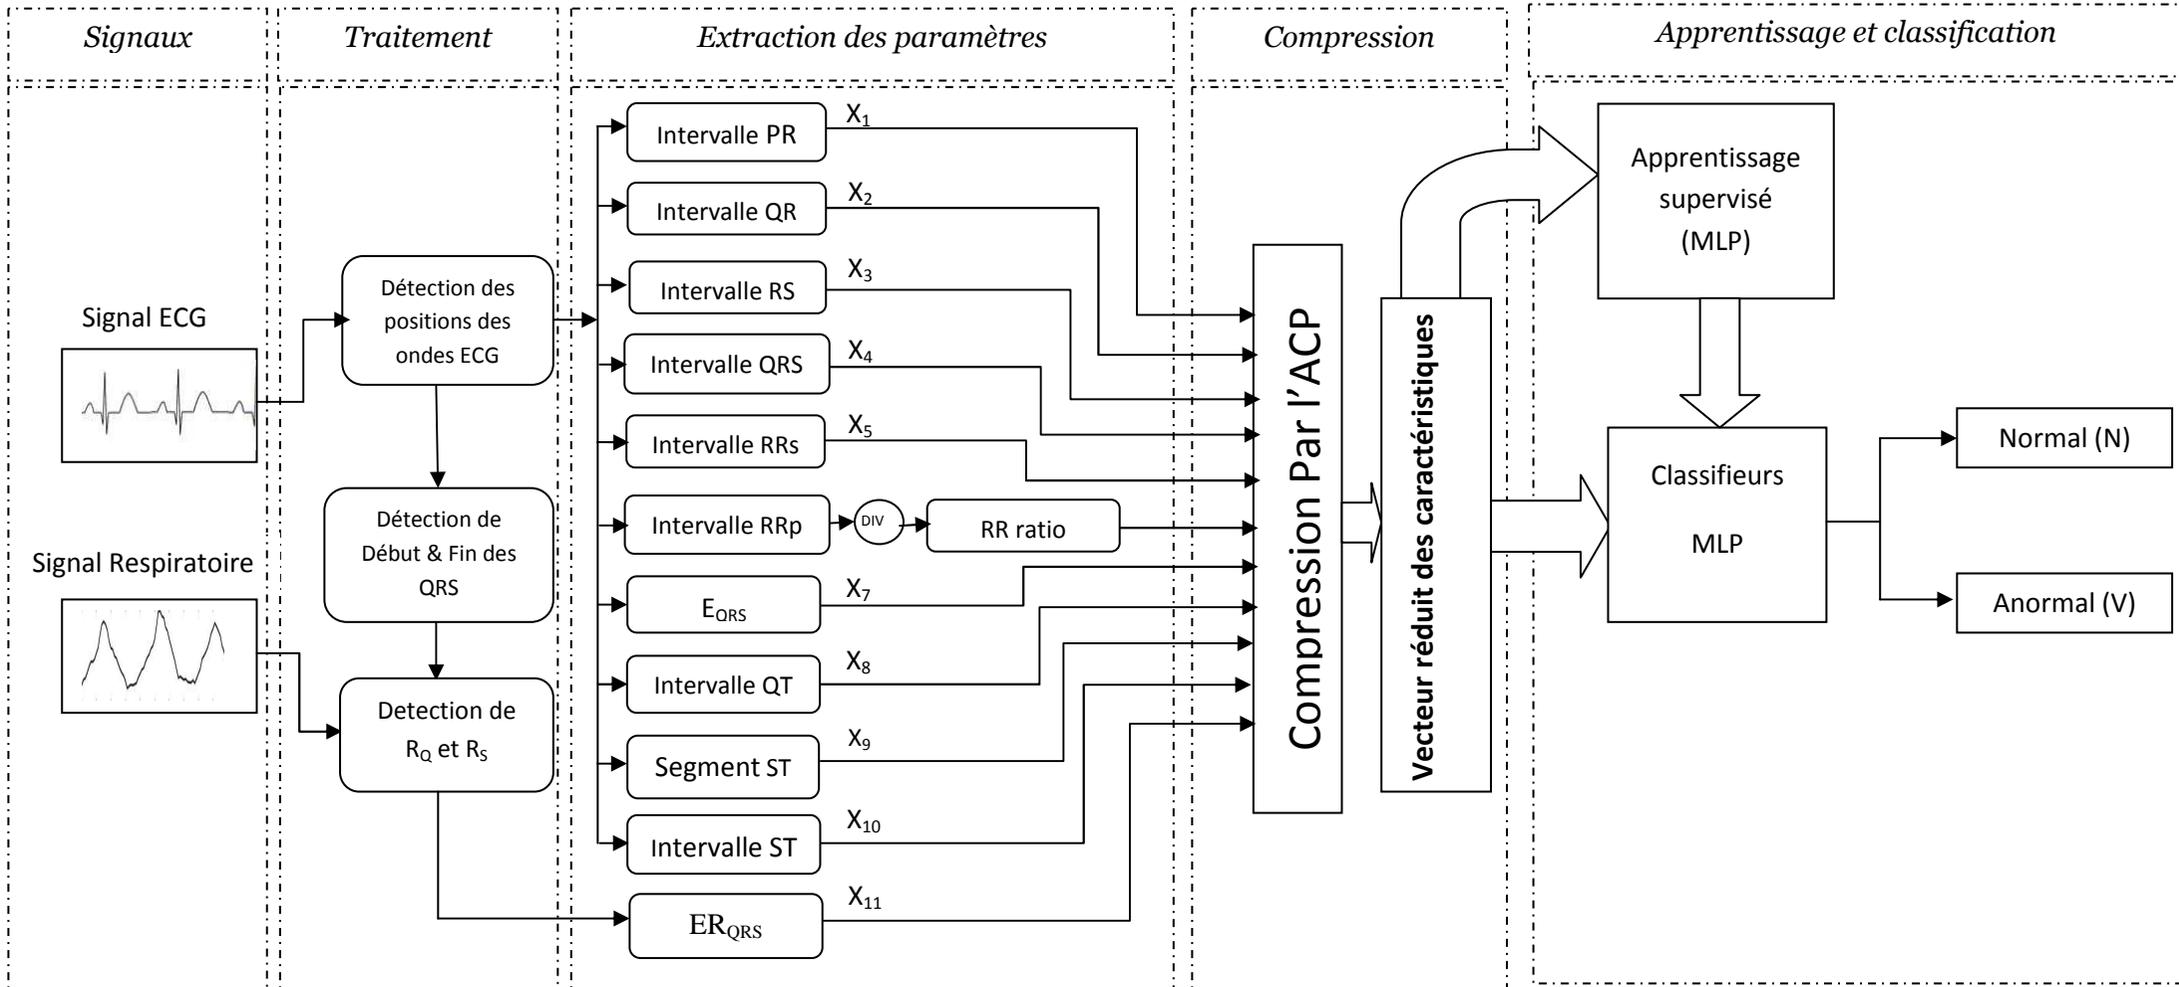


Figure V.3: Schéma bloc de l'algorithme proposé

V.4. Etape de traitement du signal

V.4.1. Détection des ondes du signal ECG

Les signaux électrocardiogramme (ECG) peuvent être considérés comme la périodisation d'un motif composé de plusieurs ondes successives notés P, QRS et T. Différents intervalles de temps définis par le début et la fin de ces ondes sont importants dans le diagnostic électrocardiographique. Les plus importants de ces intervalles sont : l'intervalle RR, l'intervalle PQ, la durée du complexe QRS, le segment ST, et l'intervalle QT (figure V.4).

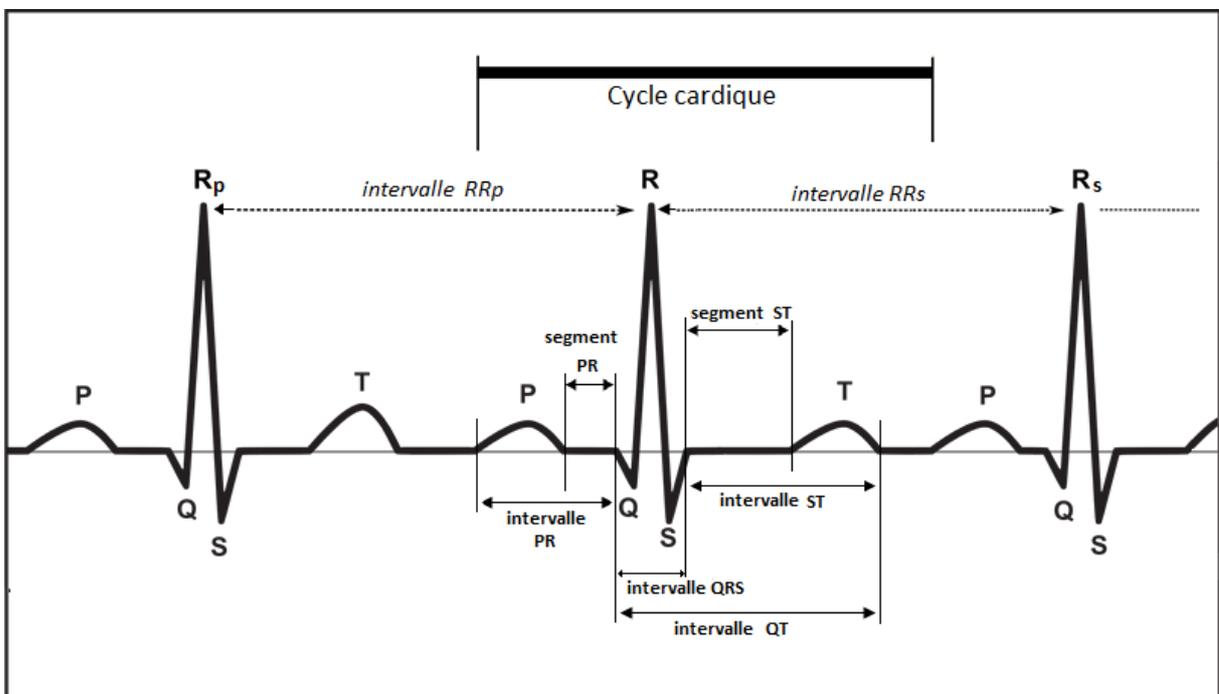


Figure V.4 : les différentes ondes et intervalles dans un signal ECG

La détection des pics et la détermination de limites de ces ondes sont très importantes pour l'interprétation médicale du signal ECG. Les travaux de la détection et de la délimitation automatisée est lancée dans le début des années 1960 [Friedeman, 1961].

Dans ce travail, on a utilisé les algorithmes rapportés en détails dans les réf. [Hadj, 2008], [Hadj, 2010], [Bachir, 2013]. L'algorithme en question comprend les étapes suivantes: un filtrage passe-haut, la décomposition du signal en modes empiriques, la détection des positions des ondes P, T et complexe QRS et enfin la mesure des différentes ondes détectées.

V.4.2. La détection des positions R_Q et R_S dans le signal respiratoire

Dans cette partie, on va déterminer les points R_Q et R_S qui ont définies par la projection des points Q et S du signal ECG sur le signal respiratoire (figure V.5).

V.4.3. Énergie du complexe QRS et du signal respiratoire:

L'énergie du complexe QRS est définie par :

$$E_{QRS} = \sum_{n=Q_p}^{S_p} |ECG(n)|^2 \quad (V.1)$$

Tel que : S_p et Q_p sont respectivement le début et le fin de complexe QRS

L'énergie du signal respiratoire est définie par :

$$ER_{QRS} = \sum_{n=R_Q}^{R_S} |Resp(n)|^2 \quad (V.2)$$

Où : R_Q et R_S sont respectivement la projection de point Q et point S sur le signal respiratoire

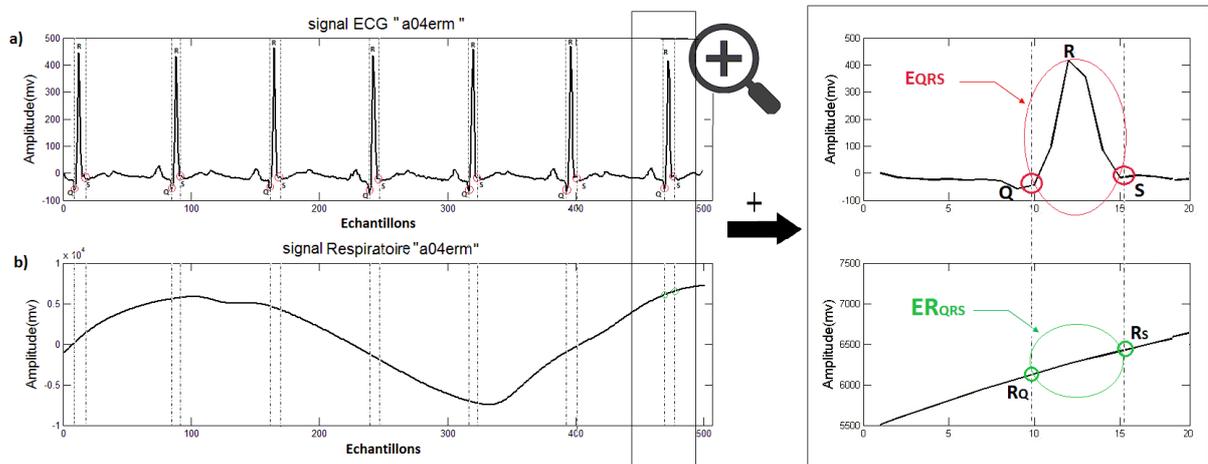


Figure V.5: Extraction des énergies du complexe QRS et du signal respiratoire

V.5 Extraction des paramètres caractéristiques

Pour chaque battement cardiaque du signal ECG et pour chaque partie correspondante du signal respiratoire, un vecteur de paramètres pertinents est extrait.

Dans notre travail, des paramètres temporels et des énergies sont utilisés pour le processus de classification. Ces paramètres sont décrits dans le tableau V.1. Au total, nous avons utilisé 11 paramètres pour construire le vecteur d'entrée des classificateurs.

Désignation	Description	vecteur
Intervalle R-R	Durée entre deux QRS successifs	X_1
Intervalle Q-R	Durée entre le pic R et le début du complexe QRS	X_2
Intervalle RS	Durée entre la fin de complexe QRS et le pic R	X_3
Complexe QRS	Durée entre la fin et le début du complexe QRS	X_4
Intervalle RR_S	Durée entre le pic R présent et le pic R suivant	X_5
Rapport RR	$RR_{rapp} = RR_S/RR_p$	X_6
E_{QRS}	Energie du complexe QRS	X_7
Intervalle QT	Durée entre la fin de l'onde T et le début du complexe QRS	X_8
Segment ST	Durée entre le début de l'onde T et la fin du complexe QRS	X_9
Intervalle ST	Durée entre la fin du complexe QRS et de la fin de l'onde T	X_{10}
ER_{QRS}	Energie du signal respiratoire	X_{11}

Tableau V.1: paramètres du vecteur d'entrée

La concaténation des vecteurs X_1 à X_{11} , nous donne un seul vecteur X qui sera utilisée comme entrée de notre classifieur, tel que:

$$[X] = [X_1 \ X_2 \ \dots \ \dots \ \dots \ \dots \ X_{11}] \quad (V.3)$$

On obtient une simple expression pour $[X_i] \quad i = 1..11$

$$[X_i] = (X_i[0] \ X_i[1] \ X_i[2] \ \dots \ \dots \ \dots \ X_i[L - 1])^T \quad (V.4)$$

Où L est le numéro du complexe QRS de chaque partie traité .

Ainsi, nous pouvons déduire que la longueur du vecteur $[X]$ est $11L$.

V.6. Compression du vecteur caractéristique par l'ACP

L'ACP ou l'Analyse en composantes principales, est largement utilisé dans l'extraction de caractéristiques pour réduire la dimensionnalité des données d'origine par une

transformation linéaire. L'ACP permet d'extraire les caractéristiques dominantes (composants principaux) d'un ensemble de données multivariées. PCA est également utilisé pour la compression de données ECG [Chawla, 2009].

Dans notre travail, la méthode d'analyse par composantes principales (ACP) n'est pas appliquée à l'ECG ou aux signaux respiratoires mais sur le vecteur caractéristique [X]. Il réduit la taille du vecteur [X] dans le but d'améliorer la performance de notre classifieur neuronal.

V.7 Les réseaux de neurones multicouches utilisés

Les réseaux de neurones sont des composantes importantes du domaine de l'intelligence artificielle. Les réseaux de neurones multicouches sont les plus utilisés surtout dans les domaines du traitement des signaux biomédicaux et spécialement l'électrocardiogramme. Les réseaux de neurones se diffèrent entre eux par plusieurs paramètres comme la topologie des connexions entre les neurones, la fonction de seuillage utilisée et l'algorithme d'apprentissage.

Dans notre travail, six réseaux de neurone multicouches (MLPNNs) sont utilisés, ils sont différents par :

- le vecteur des entrées pertinentes,
- le nombre de neurones cachés ;
- et la fonction d'activation des couches cachées et couche de sortie.

Les MLPNNs utilisées sont divisées en deux groupes ; le premier groupe contient les classificateurs neuronaux notés MLPR1, MLPR2, et MLPR3, utilisant comme vecteur d'entrée X_i qui est un ensemble de 11 vecteurs représentant les paramètres pertinents extraits des deux signaux (respiratoire et ECG); Le deuxième groupe contient les classificateurs neuronaux notés MLP1, MLP2 et MLP3, utilisant comme vecteur d'entrée X_i qui est un ensemble de 10 vecteurs représentant les paramètres pertinents extraits seulement du signal électrocardiogramme (ECG).

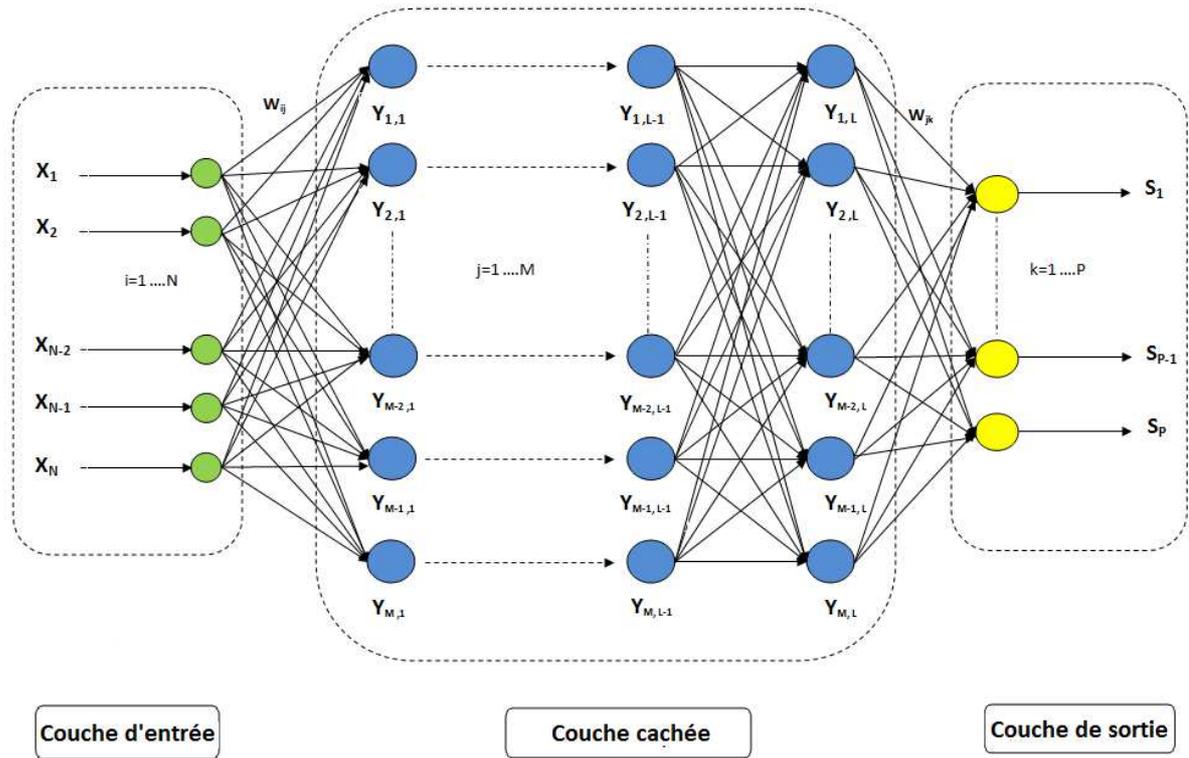


Figure V.6: Structure générale d'un réseau de neurone artificiel multicouche

Les MLPNNs utilisées contiennent 6 couches cachées ($L=6$) et un seul neurone de sortie. Les réseaux de neurones multicouches MLPR1 et MLP1 contiennent 15 neurones dans chaque couche cachée ($M=15$) et utilisent la tangente hyperbolique (tansig) comme une fonction d'activation dans la couche d'entrée, couches cachées et couche de sortie.

Les réseaux de neurones multicouches MLPR2 et MLP2 contiennent 10 neurones dans chaque couche cachée ($M=10$) et utilisent la fonction sigmoïde (logsig) comme une fonction d'activation dans la couche d'entrée, couches cachées et couche de sortie.

Les réseaux de neurones multicouches MLPR3 et MLP3 contiennent 15 neurones dans chaque couche cachée ($M=15$) et utilisent la fonction sigmoïde (logsig) comme une fonction d'activation dans la couche d'entrée et la couches cachées, et la tangente hyperbolique (tansig) dans la couche de sortie. Le tableau V.2 résume la topologie de chaque réseau de neurone multicouche utilisée.

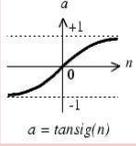
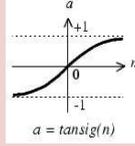
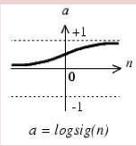
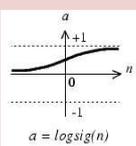
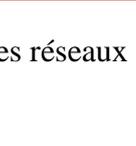
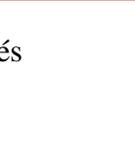
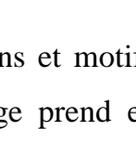
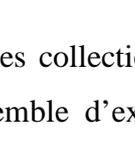
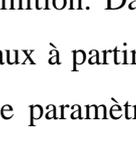
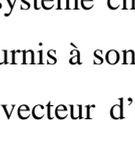
MLPNN	Neurones d'entrées	Couches cachées	Fonction d'activation	Nombre de neurones	Couches de sortie (fonction d'activation)
MLPR1	Paramètres ECG et respiration	6		15	
MLP1	Paramètres ECG				10
MLPR2	Paramètres ECG et respiration			15	
MLP2	Paramètres ECG				
MLPR3	Paramètres ECG et respiration				
MLP3	Paramètres ECG				

Tableau V.2: Architecture des réseaux de neurones utilisés

Apprentissage et test

L'apprentissage vise à découvrir les relations et motifs cachés dans des collections des données brutes. Un système d'apprentissage prend en entrée un ensemble d'exemples (cycles cardiaques) dont il cherche une définition. Dans notre cas, le système cherche à apprendre les formes des battements anormaux à partir des exemples fournis à son entrée. Ces exemples sont présentés sous forme de paramètres (éléments du vecteur d'entrée). L'algorithme d'apprentissage utilisé est l'algorithme de la rétropropagation du gradient (déjà présenté dans le quatrième chapitre).

Nous avons constaté que l'enregistrement c03erm montre très clairement les deux classes N et V. Pour cette raison, nous l'avons choisi pour la phase d'apprentissage en utilisant 100 battements normaux et 100 battements de type V.

Dans cette expérience, nous avons utilisé 7 enregistrements de la base de données Apnea-ECG pour discriminer les battements de type N ou V parmi un grand nombre de battements cardiaques.

Les figures (figure V.7 et V.8) ci-dessous présentent les performances de chaque réseau de neurones multicouches utilisé au cours de l'apprentissage.

Les Performances d'apprentissage sont données par la variation de l'erreur quadratique moyenne en fonction du nombre d'itérations.

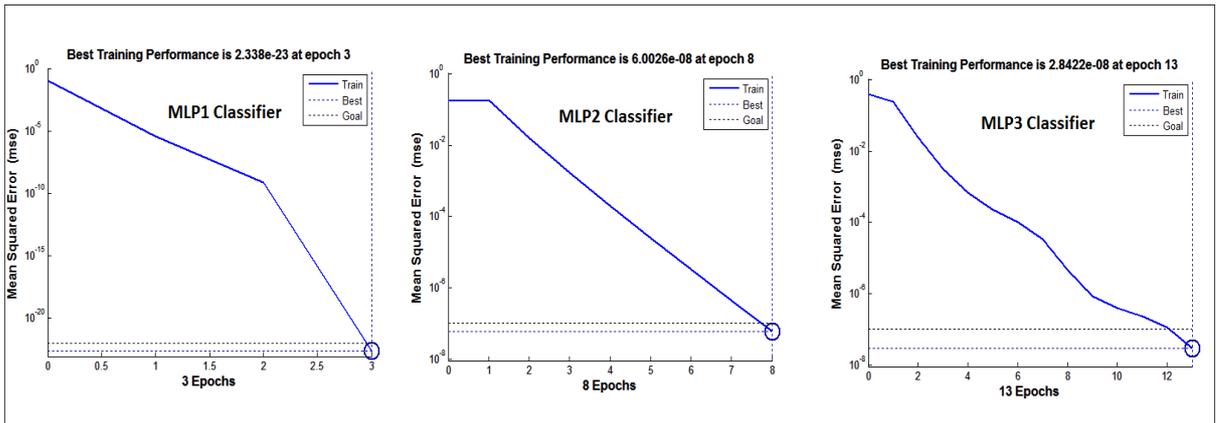


Figure V.7: Performances d'apprentissage des réseaux de neurones de type MLP

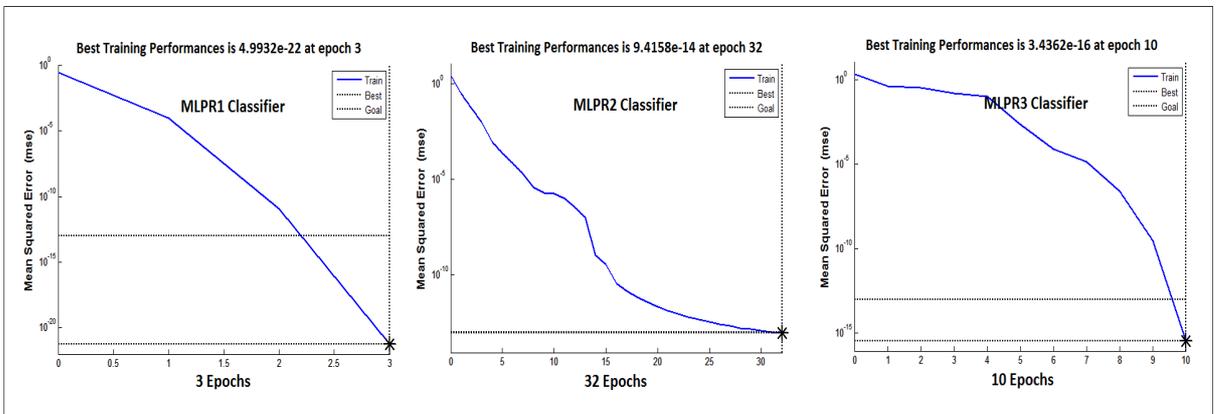


Figure V.8: Performances d'apprentissage des réseaux de neurones de type MLPR

V.8 Paramètres d'évaluation des performances

Pour évaluer nos classificateurs, nous avons utilisé trois lois statistiques basés sur la reconnaissance des catégories mutuellement exclusive de TP (true positive), FP (false positive), TN (true négative), FN (false négative).

- La sensibilité : c'est la fraction de cas réel visés correctement reconnus sur tous les cas réels visés.

$$SE = \frac{TP}{TP+FN} \quad (V.5)$$

- La spécificité : c'est la fraction de cas réel non visés correctement rejeté

$$SP = \frac{TN}{TN + FP} \quad (V.6)$$

- La classification correct: c'est le taux de classification correct (calculé par la méthode statistique).

$$CC = \frac{TN + TP}{TP + TN + FN + FP} \quad (V.7)$$

V.9. Résultats obtenus et discussion

Les différents classifieurs sont implémentés dans le logiciel Matlab 7.1 et sont testés sur un PC Intel® Core™ i5 CPU 2.5Ghz, avec 4.00 Go de RAM.

Les résultats de la classification des deux types de battements cardiaques (N, V) obtenus pour chaque enregistrement sont illustrés dans les deux tableaux (V.3 et V.4) ci-dessous.

Record/ Classifiers	MLPR1			MLPR2			MLPR3		
	Accuracy (%)	Sensitivity (%)	Specificity (%)	Accuracy (%)	Sensitivity (%)	Specificity (%)	Accuracy (%)	Sensitivity (%)	Specificity (%)
a01erm	98	100	96	98	100	96	96	97,89	94.11
a02erm	97	100	94	97	100	94	95	97,89	92.11
a03erm	96	100	92	96	100	92	96	100	92
a04erm	98	100	96	98	100	96	96	98,91	93.09
b01erm	97	98,91	95,33	98	98,94	97,33	93	96,63	89,37
c01erm	97	98,91	95,33	98	98,91	97,33	95	95,50	94,5
c02erm	95	97,80	92	98	98,91	97,33	92	95,24	88,76

Tableau V.3 : Résultats de la classification (Type MLPR)

Record/ classifiers	MLP1			MLP2			MLP3		
	Accuracy (%)	Sensitivity (%)	Specificity (%)	Accuracy (%)	Sensitivity (%)	Specificity (%)	Accuracy (%)	Sensitivity (%)	Specificity (%)
a01erm	96	100	92	98	100	96	96	100	92
a02erm	95	100	90	97	100	94	95	100	90
a03erm	94	100	88	97	100	94	94	100	88
a04erm	96	100	92	98	100	96	96	100	92
b01erm	95	98,76	91,24	96	97,67	94,33	90	93,10	86,9
c01erm	95	98,76	91,24	96	97,67	94,33	89	92,13	85,87
c02erm	92	97,5	86,5	92	95,29	88,71	87	91,46	82,54

Tableau V.4 : Résultats de la classification (Type MLP)

A partir des résultats présentés dans les deux tableaux V.3 et V.4, nous remarquons que les classifieurs de type MLPR donnent de meilleurs résultats par rapport aux classifieurs de type MLP, ce qui montre que notre algorithme proposé qui se base sur la combinaison entre les paramètres extraits à partir du signal ECG et du signal respiratoire améliore la classification des battements cardiaques par rapport à ceux qui utilisent seulement les paramètres pertinents extraits à partir du signal ECG.

Pour bien évaluer et interpréter les résultats de la précision de la classification obtenue pour chaque classifieur, nous avons calculé le taux de classification moyenne (CC_{moy}) de tous les MLPNNs utilisées. Les résultats sont montrés dans le Tableau V.5 et représentés sur la figure V.9.

Classifieur	CC_{moy} (%)	Classifieur	CC_{moy} (%)
MLP1	94,71	MLPR1	96,86
MLP2	96,28	MLPR2	97,57
MLP3	92,42	MLPR3	94,71

Tableau V.5 : Taux de classification moyen de chaque classifieur

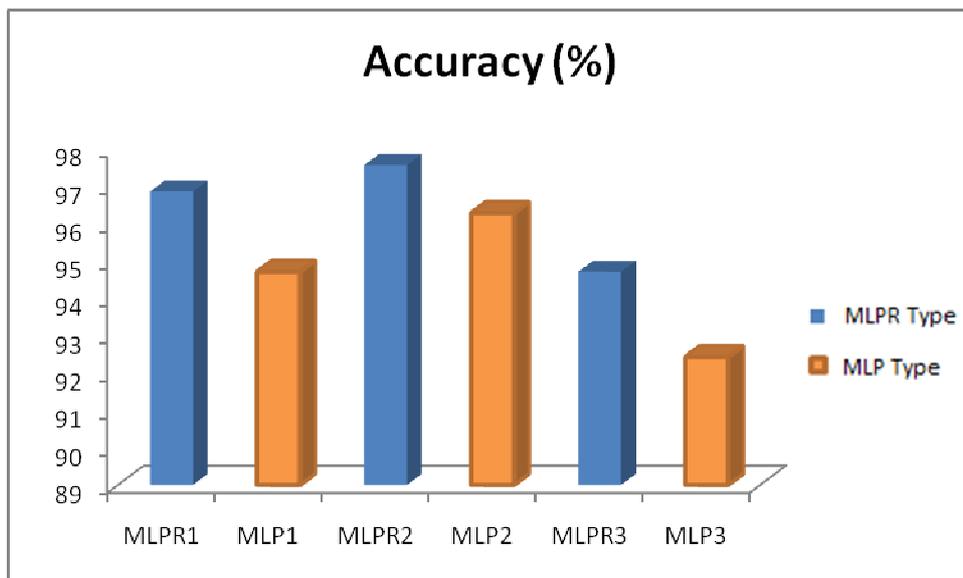


Figure V.9: l’histogramme du CC_{moy} pour chaque réseau

D'après le tableau V.5 et la figure V.7, on remarque que le classifieur MLPR2 donne un taux de classification moyenne ($CC_{moy}=97,57\%$) meilleur à celui obtenu par tous les autres classificateurs utilisés. Le classifieur MLP2 donne aussi un taux de classification moyenne ($CC_{moy}=96,28\%$) meilleur par rapport à celui obtenu par les autres classificateurs de type MLP (94.71% pour MLP1 et 92.42% pour MLP3). Ce qui montre aussi que le choix de la fonction d'activation, et le nombre de neurones de la couche caché affectent la reconnaissance des battements cardiaques.

V.10. Conclusion

Dans ce chapitre, nous avons présenté et discuté les résultats obtenus par l'application d'une nouvelle méthode de classification des battements cardiaques (N et V) par les réseaux de neurones multicouches. Cette méthode est basée sur l'exploitation du signal respiratoire enregistré simultanément avec le signal ECG comme une source d'information additive pour améliorer la classification. Notre algorithme a été validé sur des enregistrements extraits de la base de données Apnea-ECG. Les résultats obtenus par la méthodologie de classification proposée sont très satisfaisants.



Chapitre VI

*Modélisation du signal ECG par les
polynômes d'Hermite et Tchebychev en vue
d'une classification de battements cardiaques*



Chapitre VI : Modélisation du signal ECG par les polynômes d'Hermite et Tchebychev en vue d'une classification de battements cardiaques

VI.1. Introduction

Les maladies cardiaques constituent un problème majeur de santé publique. Elles sont l'une des principales causes de décès dans la plupart des pays du monde. La détection de ces pathologies est une tâche nécessaire pour la prévention et le suivi des patients à risques.

Dans la littérature, plusieurs techniques ont été développées avec succès pour mettre en évidence les pathologies cardiaques.

Toutes ces méthodes existantes se différencient par le choix des types et le nombre de paramètres significatifs qui caractérisent l'arythmie en question ainsi le type et l'architecture du classifieur utilisé.

Dans ce dernier chapitre, Nous proposons différents modèles de classificateurs neuronaux multicouches destinés à l'identification automatique de quatre types de battements cardiaques qui sont les suivants:

- N : Normal ;
- PVC : Contractions Ventriculaire Prématuurées;
- BBG : Bloc de Branche Gauche ;
- Et BBD : Bloc de Branche Droite.

La caractérisation de ces battements et l'extraction des paramètres pertinents à partir des enregistrements électrocardiogrammes qui sont relativement volumineux constituent une étape primordiale.

Dans notre travail, les paramètres pertinents extraits du signal ECG sont des paramètres morphologiques et temporels. Les coefficients obtenus à partir de la modélisation polynomiale du signal électrocardiogramme, seront ajoutés comme paramètres additifs pour améliorer le taux de classification.

Dans cette optique, trois expériences réalisées seront décrites dans ce chapitre :

- La première consiste à l'utilisation de paramètres temporels et morphologiques pertinents extraits du signal ECG comme vecteur d'entrée pour les deux différents types de classificateurs neuronaux multicouches (MLP) ;
- Dans la deuxième expérience, on utilise un vecteur d'entrée contenant les coefficients de la modélisation polynômiale du signal ECG par le polynôme d'Hermite en ajoutant les paramètres temporels et morphologiques pertinents extraits précédemment ;
- La troisième expérience utilise comme vecteur d'entrée, les coefficients de la modélisation polynômiale du signal ECG par polynômes de Tchebychev et les paramètres temporels et morphologiques pertinents.

A partir des différentes expériences citées ci-dessus, nous pourrons avoir une idée très claire sur l'influence de l'architecture du réseau neuronale et les paramètres d'entrée choisis sur le processus de classification.

VI.2. Description de l'algorithme proposé

Le schéma bloc de l'algorithme proposé est illustré dans la figure VI.1. L'algorithme est divisé en quatre parties qui sont :

- Un traitement du signal ECG ;
- Une détection des différents paramètres du signal ECG ;
- Extraction des caractéristiques pertinentes;
- Compression des données par l'ACP ;
- Et enfin apprentissage et classification.

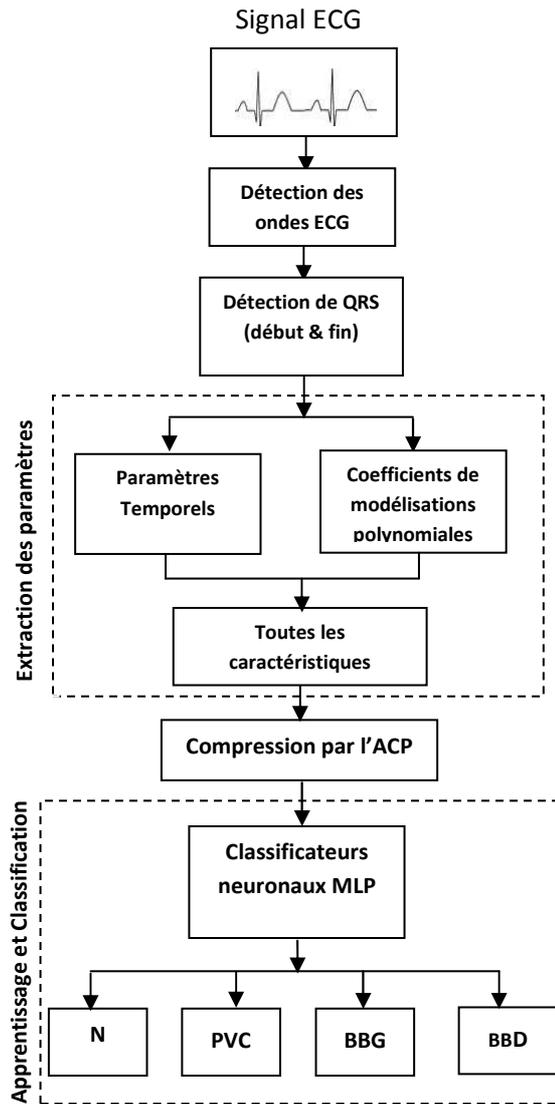


Figure VI.1: Schéma bloc de l'algorithme proposé

VI.2.1. La base de donnée MIT/BIH

La base de données MIT-BIH est une base universelle qui contient 48 enregistrements d'une durée d'une demi-heure sur deux voies (DII et V5) échantillonnés à une fréquence de 360 Hz. Elle a été collectée par des chercheurs afin d'être utilisée comme une référence pour la validation et la comparaison des algorithmes sur le signal ECG.

L'avantage majeur de cette base est qu'elle contient un grand nombre de pathologies cardiaques, ce qui permet de valider les algorithmes sur un grand nombre de cas de signaux ECG.

La base de données contient 23 enregistrements numérotés entre 100 et 124 pour le premier groupe; et de 25 enregistrements numérotés entre 200 et 234 pour le deuxième groupe. Le premier groupe contient les signaux qui comportent une variété de formes d'ondes ; le deuxième groupe est choisi pour inclure une variété de cas pathologiques.

Les sujets étaient 25 hommes âgés de 32 à 89 ans, et 22 femmes âgées de 23 à 89 ans. Les enregistrements de MIT/BIH sont tous annotés; L'annotation correspond au l'instant d'apparition du pic R du complexe QRS et au type du QRS (N, PVC, etc.). Typiquement, un fichier d'annotation pour un enregistrement MIT/BIH contient environ 2000 annotations ([Mit, 1992], [Mark, 1997]).

VI.2.2. Les anomalies cardiaques traitées

Une arythmie correspond à toute perturbation dans l'activité rythmique régulière du cœur (amplitude, la durée et la forme du rythme). Du point de vue du diagnostic d'arythmie, l'information la plus importante est contenue dans le complexe QRS. Les méthodes proposées dans ce travail sont utilisées pour classifier quatre catégories différentes de battements cardiaques (Voir chapitre I) qui sont : les battements normaux (N), les blocs de branche gauche (BBG), les blocs de branche droite (BBD), et les contractions ventriculaire prématurées (PVC).

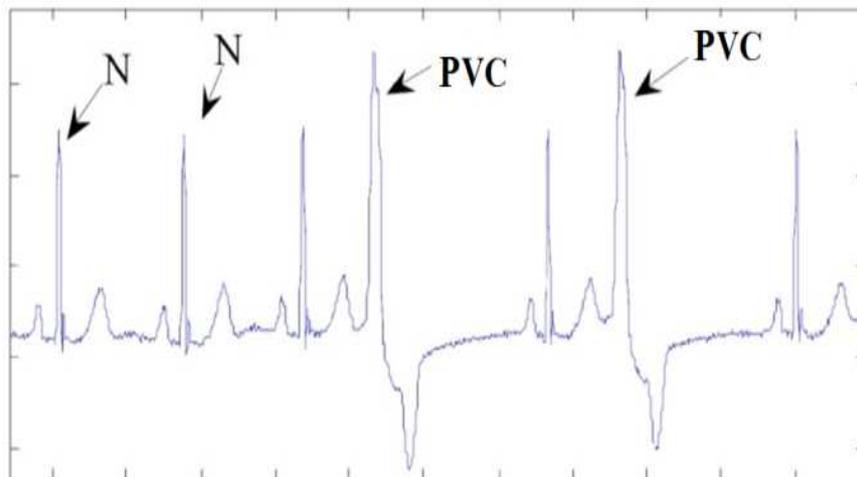


Figure VI.2: ECG à des battements de type N et PVC

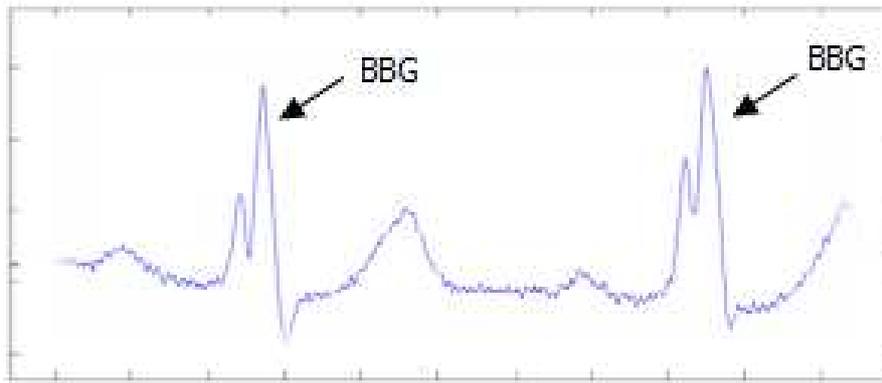


Figure VI.3: ECG à des battements de type BBG

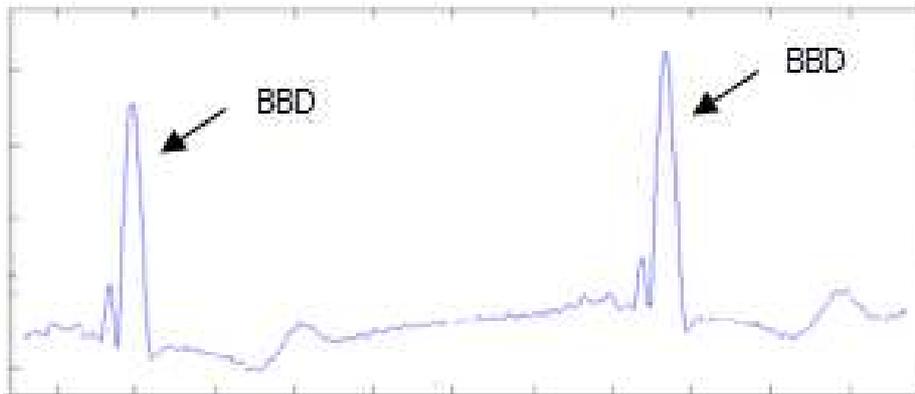


Figure VI.4: ECG à des battements de type BBD

VI.2.3. Choix des enregistrements de la base MIT-BIH

Tous les battements utilisés sont extraits à partir des enregistrements de la base de données MIT-BIH.

Les différents types de ces battements et leurs répartitions sur les enregistrements choisis sont illustrés dans le Tableau VI.1

Battements	Enregistrement	Patient, Age	Nombre de battements par patient
Normal (N)	101	Female, 75	1860
	105	Female, 73	2526
	115	Female, 39	1953
	121	Female, 83	1861
	122	Male, 51	2476
	123	Female, 63	1515
	202	Male, 68	2061
	205	Male, 59	2571
	234	Female, 56	2700
contraction ventriculaire prématurée (PVC)	119	Female, 51	444
	200	Male, 64	826
	208	Female, 23	992
	233	Male, 57	831
Bloc de branche gauche (BBG)	109	Female, 64	2492
	111	Female, 47	2115
	207	Female, 89	1457
	214	Male, 53	2003
Bloc de branche droite (BBD)	118	Male, 69	2168
	124	Male, 77	1531
	212	Female, 32	1825
	231	Female, 72	1254

Tableau VI.1 : Les enregistrements choisis de la base de données MIT-BIH

Pour chaque catégorie, 50% de battements cardiaques ont été utilisés pour l'apprentissage et les 50% qui restent ont été utilisés pour la phase de test des performances de la classification (comme illustré dans le tableau VI.2).

Type de Battements cardiaques	Nombre Total	Base d'apprentissage (50%)	Base de test (50%)
N	19523	9761	9762
PVC	3093	1547	1546
BBG	8067	4033	4034
BBD	6778	3389	3389
Total	37461	18730	18731

Tableau VI.2 : Distribution des battements ECG (apprentissage et test)

VI.2.4. Caractérisation des battements cardiaques

La classification automatisée des battements cardiaques nécessite logiquement un détecteur automatique des descripteurs de chaque battement cardiaque. Pour cela, nous avons utilisé les mêmes algorithmes utilisés dans le chapitre V et rapporté en détails dans ([Hadj, 2008], [Hadj, 2010], [Bachir, 2013]).

Dans notre travail, les deux premiers classificateurs utilisent seulement les paramètres temporels et morphologiques pertinents extraits du signal ECG (Figure V.4). Ces paramètres sont décrits déjà dans le tableau V.1 du chapitre précédent. Au total, nous avons utilisé 10 paramètres pour construire le vecteur d'entrée des classificateurs (X_1, X_2, \dots, X_{10}).

Les quatre autres classificateurs utilisent les mêmes paramètres que les précédents sauf que l'on ajoute un autre paramètre (X_{11}) qui représente les coefficients de modélisation polynomiale du signal ECG.

Deux types de coefficients sont utilisés dans ce travail, les coefficients de la modélisation du signal ECG par les polynômes de Tchebychev [Benali, 2015] et les coefficients de la modélisation du signal ECG par les polynômes d'Hermite [Benali.M, 2015].

La méthode ACP est appliquée pour réduire le vecteur d'entrée dans les deux cas avec ou sans coefficients de modélisation.

VI.2.5 Modélisation polynomiales du signal ECG

Comme indiqué lors du chapitre III, la première étape du processus de modélisation est la segmentation du signal ECG en fenêtres. Les durées de ces fenêtres devront coïncider avec celles des cycles cardiaques. Chaque fenêtre est ensuite transposée dans le domaine de définition $[a, b]$ qui dépend du domaine de définition du polynôme choisis.

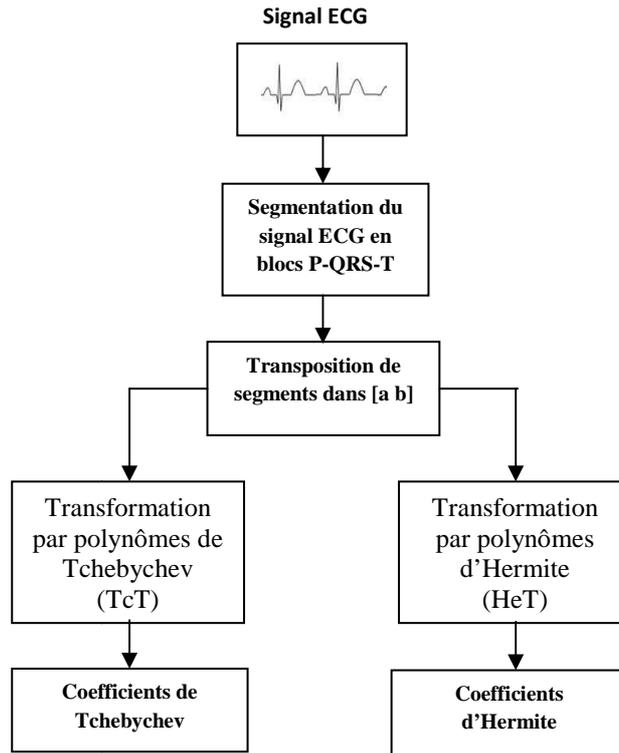


Figure VI.5: Processus de modélisation utilisé

Pour notre cas, et selon les études présentées dans le chapitre III, on va segmenter les différents signaux en cycles centrés sur le complexe QRS (figure VI.6) afin d'obtenir une bonne modélisation polynomiale du signal ECG.

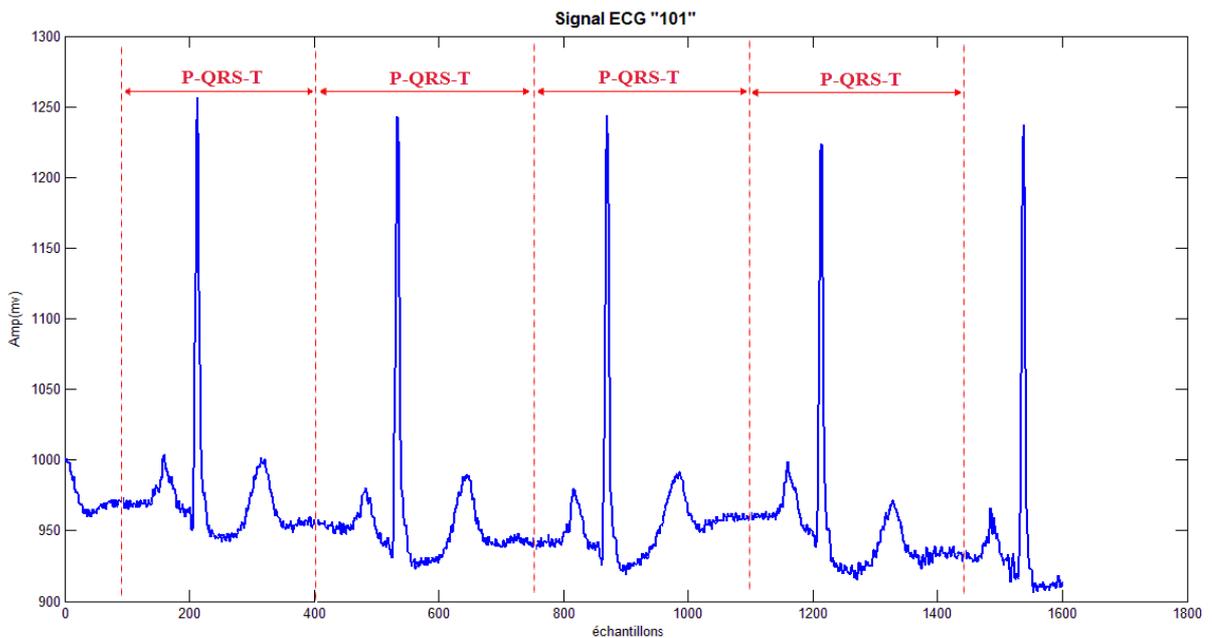


Figure VI.6: Segmentation du signal 101 en segments P-QRS-T

VI.2.6. Les réseaux de neurones multicouches utilisés

Les classificateurs neuronaux multicouches utilisés sont divisés en deux groupes :

- Le premier groupe contient les classificateurs neuronaux notés MLP1 et MLP2. Ces dites classificateurs utilisent comme vecteur d'entrée, les paramètres temporels et morphologiques du signal ECG (voir Tableau V.1) ;
- Le deuxième groupe utilise comme vecteur d'entrée les paramètres pertinents temporels (X_1, X_2, \dots, X_{10}). Le paramètre X_{11} qui représente les coefficients de modélisations polynomiales du signal ECG sera ajouté au vecteur d'entrée. Le vecteur X_{11} en question représente les coefficients de modélisation du signal ECG par polynômes de Tchebychev pour les classificateurs notés MLPC1 et MLPC2. Le même vecteur X_{11} va représenter les coefficients de modélisation par polynômes d'Hermite dont les classificateurs seront notés MLPH1 et MLPH2.

Les MLPNNs utilisées contiennent 6 couches cachées ($L=6$) et trois neurones de sortie. Les réseaux de neurones multicouches MLP1, MLPC1 et MLPH1 contiennent 10 neurones ($M=10$) dans chaque couche cachée. La fonction sigmoïde (logsig) sera utilisée comme une fonction d'activation dans la couche d'entrée, couches cachées et couche de sortie.

Les réseaux de neurones multicouches MLP2, MLPC2 et MLPH2 contiennent 15 neurones dans chaque couche cachée ($M=15$). La fonction sigmoïde (logsig) comme une fonction d'activation dans la couche d'entrée et la couches cachées, et la tangente hyperbolique (tansig) dans la couche de sortie.

Le tableau VI.3 résume la topologie de chaque réseau de neurone multicouche utilisé.

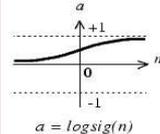
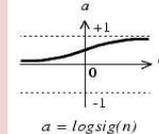
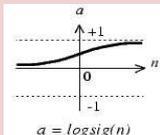
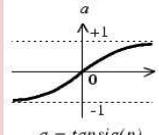
MLPNN	Neurones d'entrées	Couches cachées	Fonction d'activation	Nombre de neurones	Couches de sortie (fonction d'activation)
MLP1	Paramètres ECG	6	 $a = \text{logsig}(n)$	10	 $a = \text{logsig}(n)$
MLPC1	Paramètres ECG + Coefficients TcT				
MLPH1	Paramètres ECG + Coefficients HeT				
ML2	Paramètres ECG		 $a = \text{logsig}(n)$	15	 $a = \text{tansig}(n)$
MLPC3	Paramètres ECG + Coefficients TcT				
MLH3	Paramètres ECG + Coefficients HeT				

Tableau VI.3 : La topologie de différents classificateurs utilisées

VI.3. Résultats obtenus et discussion

Les différents classificateurs sont implémentés dans le logiciel Matlab 7.1 et testé sur un PC Intel® Core™ i5 CPU 2.5Ghz, avec 4.00 Go de RAM.

La mise en œuvre de notre nouvel algorithme est réalisée sur les différents enregistrements de la base de données d'arythmie MIT-BIH présentés dans le tableau VI.1.

L'algorithme d'apprentissage utilisé est l'algorithme de la rétropropagation du gradient (déjà présenté dans le quatrième chapitre).

L'évaluation des classificateurs de RN a été faite par le calcul de la spécificité (SP), la sensibilité (SE), et le taux de classification TC (Classification Correcte CC) dont ont été décrits lors du chapitre V.

Les résultats de la classification des quatre types de battements cardiaques (N, PVC, BBD et BBG) obtenus pour chaque classificateur sont illustrés dans les tableaux ci-dessous.

Classifieurs	MLP1		MLP2	
types de battement	Paramètres d'évaluation		Paramètres d'évaluation	
NORMAL	Spécificité (%)	99,11	Spécificité (%)	99,02
PVC	Sensibilité (%)	99,02	Sensibilité (%)	98,77
BBG		98,90		98,70
BBD		98,97		98,81
Average	Taux de classification	99,03	Taux de classification	98,90

Tableau VI.4 : Résultats de Classification sans coefficients de modélisation

Classifieurs	MLPC1		MLPC2	
types de battement	Paramètres d'évaluation		Paramètres d'évaluation	
NORMAL	Spécificité (%)	99,71	Spécificité (%)	99,62
PVC	Sensibilité (%)	99,28	Sensibilité (%)	99,09
BBG		99,05		98,90
BBD		98,97		98,97
Average	Taux de classification	99,40	Taux de classification	99,30

Tableau VI.5 : Résultats de Classification avec coefficients (modèle de Tchebychev)

Classifieurs	MLPH1		MLPH2	
types de battement	Paramètres d'évaluation		Paramètres d'évaluation	
NORMAL	Spécificité (%)	99,84	Spécificité (%)	99,77
PVC	Sensibilité (%)	99,35	Sensibilité (%)	99,15
BBG		99,11		98,99
BBD		99,01		99,01
Average	Taux de classification	99,49	Taux de classification	99,39

Tableau VI.6 : Résultats de Classification avec coefficients (modèle d'Hermite)

A partir des résultats présentés dans les trois tableaux (VI.4, VI.5 et VI.6), nous remarquons que les classifieurs qui utilisent les coefficients de modélisations polynomiales avec les autres paramètres caractéristiques donnent de meilleurs résultats par rapport à ceux qui ne les utilisent pas. Ce qui montre que l'ajout des coefficients obtenus par la modélisation polynomiale améliore la classification des battements cardiaques.

Classifieur	CC (%)	Classifieur	CC (%)
MLP1	99,03	MLP2	98,90
MLPC1	99,40	MLPC2	99,30
MLPH1	99,49	MLPH2	99,39

Tableau VI.7 : Taux de classification de chaque classifieur

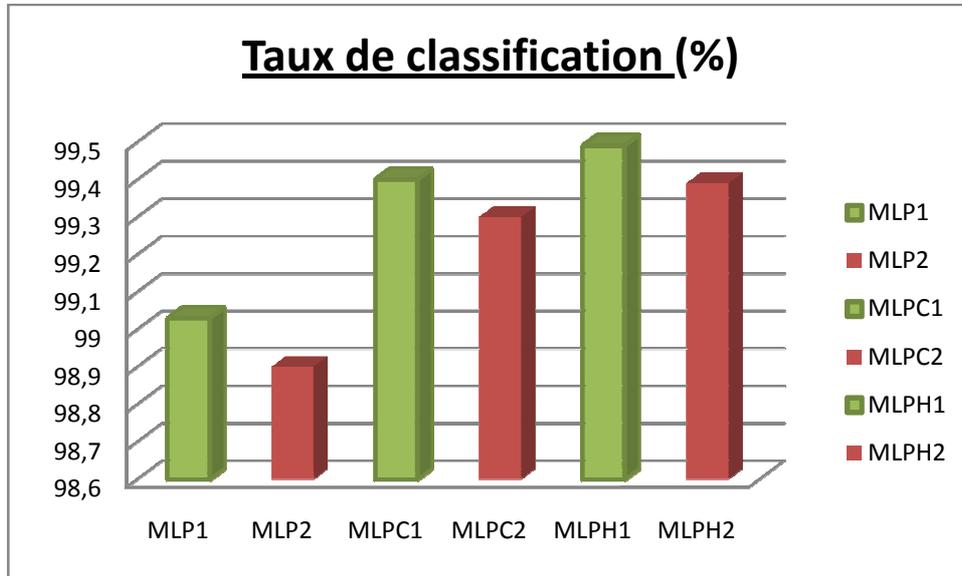


Figure VI.8: l’histogramme du taux de classification pour chaque réseau

A partir des résultats mentionnés dans le tableau VI.7 et la figure VI.8, on remarque que le réseau de neurone multicouche MLPH1 donne de meilleurs résultats par rapport aux autres classificateurs neuronaux, ce qui implique que la modélisation et la reconnaissance des formes de QRS avec les polynômes d’Hermite est plus approprié pour résoudre des problèmes de modélisation et de classification.

Le bon choix de descripteurs d’entrée et le bon choix de l’architecture des réseaux (fonction de transfert, le nombre de couches cachée) améliore le taux de classification.

VI.4. Comparaison avec d’autres méthodes

La comparaison des résultats obtenus de la classification des battements cardiaques avec les résultats rapportés est une tâche difficile ; la plupart des méthodes ont été testées sur différents ensembles de signaux, quantité différente de battements, différentes bases de données, et sur différentes type de battements. Donc, il est difficile de trouver des résultats testés sur les mêmes classes et la même base de données.

Pour l'évaluation de nos résultats obtenus de la classification des battements cardiaques, une étude comparative a été faite. Toutes les méthodes choisies dans cette étude ont été testées sur la même base de données MIT-BIH.

Le Tableau VI.8 résume les résultats obtenus pour la classification des arythmies cardiaques par la méthode proposée et les autres méthodes.

Référence	Méthode	Taux de classification (%)	Battements	
			Nombre	Types
Méthode proposée 1 (MLPC1)	Tchebychef + MLP	99.40	37461	4 classes N, BBD, BBG, PVC
Méthode proposée 2 (MLPH1)	Hermite + MLP	99.49		
[Zhang, 2005]	PCA + SVM	99.17	6243	
[Ben, 2012]	WT+WNN	98.78	27280	5 classes N, PVC, BBG, BBD, APC
[Rai, 2014]	RBFNN	99.6	500	5 classes
[Thomas, 2014]	DTCWT	97.80	26480	N, BBR, BBD, PAC, PVC
[Benali, 2015]	Tchebychef + MLP	99.92	860	
[Wang, 2012]	PCA+LDA+PNN	99.71	9800	8 classes N, PVC, PAC, BBD, BBR, APC, VLWAV, VESC

Tableau VI.8 : Comparaison des résultats obtenus avec autres méthodes

A partir du Tableau VI.8, On remarque que nos résultats obtenus sont relativement satisfaisants vis-à-vis des résultats des travaux existants dans la littérature.

Ce qu'on peut constater avec les résultats obtenus par application de nos méthodes 1 et 2, et avec une quantité élevés de battement cardiaque utilisée en test et en apprentissage, les deux méthodes en question présentent un taux de classification moins important si l'on compare avec celui obtenu avec l'autre méthode proposée par nos soins et qui est décrite dans la référence [Benali, 2015]. En effet, les coefficients obtenus à partir de la modélisation polynomiale du signal électrocardiogramme, et qui ont été ajoutés comme paramètres additifs dans le processus de la classification ont contribué énormément à une amélioration très significative du taux de classification.

VI.5. Conclusion

Dans ce chapitre, nous avons présenté des classificateurs neuronaux multicouches (MLP) destinés à l'identification de quatre types de battements cardiaques (Normal, PVC, BBG et BBD).

Des nouveaux paramètres ont été introduits à l'entrée des classifieurs. Ils représentent les coefficients obtenus par modélisation du signal ECG soit par polynômes de Tchebychev, ou par polynômes d'Hermite.

Les résultats obtenus ; très satisfaisante en taux de classification ; démontrent l'intérêt d'utiliser les coefficients de modélisations polynomiales du signal ECG dans la discrimination des battements cardiaques.

CONCLUSION GENERALE ET PERSPECTIVES

Cette thèse a été consacrée à l'analyse et synthèse de méthodes de compression et de modélisation polynomiales du signal Electrocardiogramme dans le but d'améliorer le taux de compression et obtenir un meilleur résultat de classification automatique des battements cardiaques.

Une revue de la littérature sur les méthodes de compression des signaux ECG a été menée. Nous avons appliqué différents algorithmes de compression sur des signaux réels; ces algorithmes de compression sont basés sur les transformations sinusoïdales ou les transformations en ondelettes ; la méthodologie de ces méthodes de compression se résume dans les étapes suivantes :

- Transformation appliquée sur le signal ECG ;
- Calcul des coefficients de transformation ;
- Mettre en zéro les coefficients inférieur à un seuil choisi et garder les coefficients prépondérants supérieurs au seuil;
- Codage de données résultantes par l'algorithme RLE.
- Réaliser le décodage RLE puis la transformé inverse;
- Le signal reconstruit est calculé à partir des coefficients retenus de la transformée après le décodage des données.

Les résultats obtenus par nos algorithmes de compression sont très promoteurs, tant que garanti la qualité acceptable d'une manière clinique du signal et aussi la conservation de l'information considérable après la reconstruction.

Nous avons abordé aussi le problème de la modélisation et la reconnaissance automatique des battements cardiaques à travers le développement et l'implémentation des méthodes combinant plusieurs paramètres pertinents appliqués à l'entrée des réseaux de neurones.

Dans la première partie, deux algorithmes ont été implémentés pour faire la distinction entre un battement cardiaque normal et anormal. Le premier algorithme utilise les paramètres pertinents extraits du signal ECG seulement à l'entrée des classificateurs neuronaux. Pour le deuxième algorithme ; il est basée sur la combinaison de plusieurs

paramètres pertinents extraits à partir des deux signaux enregistrés simultanément à savoir : l'ECG et le signal respiratoire. Une méthode de compression et de réduction de la taille des données extraites est appliquée pour stocker les paramètres caractéristique et accélérer le système de classification.

La deuxième partie concerne l'exploitation de la modélisation polynomiale par les polynômes de Tchebychev et Hermite pour résoudre des problèmes de compression et de classification des signaux ECG.

Le processus de modélisation d'un signal ECG se résume comme suite :

- Segmentation du signal en fenêtres de durées égales des cycles cardiaques ;
- Transposition de ces segments dans les domaines de transposition des polynômes utilisés ;
- Calcul des coefficients de décomposition.

Pour la phase de classification ; différents classificateurs neuronaux multicouches ont été implémentés pour faire la distinction entre quatre classes de battements cardiaques. Deux classificateurs utilisent à l'entrée, les paramètres pertinents temporels extraits du signal ECG ; les autres utilisent comme vecteur d'entrée, une combinaison de paramètres pertinents temporels et coefficients de modélisation obtenus par transformation polynomiales par polynômes de Tchebychev ou polynômes d'Hermite, de même, une méthode de compression est appliquée pour réduire la taille des données extraites.

Dans le module d'extraction de caractéristiques, un algorithme de détection des complexes QRS à partir du signal ECG par une approche basée sur la décomposition modale empirique a été appliqué. Il permet d'extraire les paramètres représentatifs de chaque battement cardiaque. La caractérisation des battements cardiaques par des paramètres pertinents constitue une étape primordiale afin d'avoir une meilleure classification.

Les résultats obtenus à travers l'exploitation du signal respiratoire ont montré une bonne distinction entre les battements pathologiques et les battements normaux. Ainsi l'exploitation des coefficients issus de processus de modélisations polynomiales de l'ECG donne aussi une très bonne distinction entre les différentes classes des battements pathologiques.

Les travaux effectués dans le cadre de cette thèse nous a permis de réaliser plusieurs publications et communications ; Les résultats obtenus par ces différents travaux sont intéressants et ouvre de large perspectives dont notamment :

- Exploitation des outils de compressions définis au cours de nos recherches à la compression des autres signaux biomédicaux tel que : EEG, EMG, PPG, et image.
- Travailler sur des données multi-sources reflétant un même phénomène telles que les différentes dérivations d'un électrocardiogramme, signal de pression artérielle et signal respiratoire.
- L'utilisation de différents types de fonctions paramétrables comme fonctions d'activation des neurones pour spécifier la bonne fonction adaptée au problème de classification des battements cardiaques par les réseaux de neurones.
- L'association des réseaux de neurones avec d'autres méthodes de classification pour améliorer le taux de classifications.
- L'optimisation des paramètres des classificateurs.
- Faire la compression et la classification en temps réel.

Références bibliographique

A

[Abenstein, 1982] ABENSTEIN J.P., TOMPKINS W.J., “A new data reduction algorithm for real time ECG analysis”, IEEE Transactions on Biomedical Engineering, vol. 29, pp. 43-48, 1982 AHA.

[Acharya, 2004] R. Acharya, A. Kumar, P. S. Bhat, C. M. Lim, S. S. Iyengar, N. Kannathal, S. M. Krishnan, “Classification of cardiac abnormalities using heart rate signals”, Medical & Biological Engineering and Computing, 288–293, 2004.

[Ahmed, 1975] Ahmed.N, Milne PJ, Harris SG., “Electrocardiographic data compression via orthogonal transforms”, IEEE Trans Biomed Eng 1975;BME-22(6):484–7.

[Al-fahoum, 1999] A. S. Al-Fahoum, I. Howitt, “Combined wavelet transformation and radial basis neural networks for classifying life-threatening cardiac arrhythmias”, Medical & Biological Engineering and Computing, 566–573, 1999.

[Ammar, 2007] M. Y. Ammar, “Mise en œuvre de réseaux de neurones pour la Modélisation de cinétiques réactionnelles en Vue de la transposition batch/continu”, Thèse doctorat en Génie des procédés et de l’Environnement, soutenu en juillet 2007 à l’institut National polytechnique de Toulouse

[Antoine, 2006] Antoine Defontaine, “Modélisation multirésolution et multiformalisme de l’activité électrique cardiaque”, thèse de doctorat en Traitement du Signal et Télécommunications, Soutenue en février 2006 à l’Université de Rennes 1.

[Aulagnier, 1998] Florence Aulagnier, “Cardiologie: DE infirmier”, De Boeck Secundair, 1998, 240 pages.

B

[Baakek, 2015] BAAKEK Y.N, “Modélisation paramétrique et non paramétrique en vue de l’identification de système cardiaque”, soutenue en Mars 2015 au Département de génie biomédicale, spécialité Electronique Biomédical Université Abou Bekr Belkaid, Tlemcen.

[Bachir, 2013] M. Bachir, Z.E. Hadj Slimane. “A real-time interval measurement algorithm. 2nd International Conference on Signal, Image, Vision and Their Applications (SIVA’13)”, November 18-20, 2013, Guelma, Algeria.

[Barr, 1985] Barr R.C., Blanchard S.M., Dipersio D.A., “SAPA-2 is the FAN”, IEEE Trans. Biomed. Eng., vol. BME-32, p. 337, May 1985.

[Barro, 1998] S. Barro, M. Fernandez, “Classifying multi-channel ECG patterns with adaptive neural network”, IEEE EMB Mag., 45–55, 1998.

[Ben, 2012] Benali R., Bereksi Reguig F., Hadj Slimane Z. ,“Automatic Classification of Heartbeats Using Wavelet Neural Network”, Journal of Medical Systems April 2012, Volume 36, Issue 2, pp 883-892.

[Benali, 2015] Benali Medjahed O, Bachir M’hamed S and Hadj Slimane Z, “Chebyshev polynomials Transform for abnormalities detection using Artificial Neural Network classifier”, International Journal of Applied Engineering Research ISSN 0973-4562 Volume 10, Number 14 (2015) pp 34410-34415.

[Benali.M, 2015] Benali Medjahed O and Hadj Slimane Z,” Cardiac pathologic detection based on the Coefficients of Hermite polynomials and neuronal network”, 3rd International Conference on Signal, Image, Vision and their Applications (SIVA’15), 23th to the 25th of November, 2015, Guelma, Algeria.

[Borne, 2007] P. Borne, M. Benrejeb, J. Haggège, “ Les réseaux de neurones: présentation et application ”, Editions OPHRYS, 2007, 152 pages

[Boutin, 1993] Hélène Boutin, Louis-Philippe Boulet, “Comprendre et maîtriser l'asthme”, illustrée, Presses Université Laval, 1993,93 pages

C

[Chawla, 2009] Chawla, M.P.S., 2009. “A comparative analysis of principal component and independent component techniques for electrocardiograms”. Neural Comput. Applic., 18: 539-556.

[Chazal, 2000] P. de Chazal, B.G. Celler, R.B. Rei, “Using wavelet coefficients for the classification of the electrocardiogram”, in: Proceedings of the 22nd Annual EMBS International Conference, Chicago IL, July 23–28, 2000.

[Christov, 2006] I. Christov, G. Gomez-Herrero, V. Krasteva, I. Jecova, A. Gotchev, “Comparative study of morphological and time–frequency ECG descriptors for heartbeat classification”, Medical Engineering and Physics (28) (2006) 876–887.

[Coast, 1990] D. A. Coast, R. M. Stern, G. G. Cano, S. A. Briller, “An approach to cardiac arrhythmia analysis using hidden Markov models”, IEEE Transactions on Biomedical Engineering, 826–836, 1990.

[Colomer, 1997] A. A. Colomer, “Adaptive ECG Data Compression Using Discrete Legendre Transform”, Digital Signal Processing, N° 7, 1997, pp. 222-228.

[Cox, 1968] J. R. Cox, F. M. Nolle, H. A. Fozzard, G.C. Olivier, "AZTEC a Preprocessing Program for Real time ECG Rhythm Analysis", IEEE Trans. Biomed. Eng. Vol. BME-15, pp. 128-129, April 1968.

D

[Daniel, 2007] Daniel TCHIOTSOP, "Modélisations polynomiales des signaux ECG. applications à la compression", soutenue en novembre 2007 au Département de Formation Doctorale en Automatique, Institut National Polytechnique de Lorraine.

[Dubois, 2004] R. Dubois, "Application des nouvelles méthodes d'apprentissage à la détection précoce d'anomalies cardiaques en électrocardiographie", thèse doctorat en électronique 2004, soutenu en janvier 2004.

[Dumont, 2005] Dumont J, Hernandez A, Carrault G., "Parameter optimization of a wavelet-based electrocardiogram delineator with an evolutionary algorithm", Computers in Cardiology IEEE Computer Society 2005; 707-710.

E

[Ellrodt, 2003] A. ELLRODT, "Urgences Médicales", 5^Édition, Édition ESTEM, 89, boulevard Auguste Blanqui, 75013, Paris, 04/2003. ISBN: 978 2 84371 335 4.

F

[Fokapu, 1993] Fokapu O, al: "A new approach for P wave detection using analytic signal", IEEE Engineering in Medicine and Biology Conference, page 400-401, 1993.

[Fontaine, 1999] Ludovic Fontaine, " Traitement des signaux à échantillonnage irrégulier Application au suivi temporel de paramètres cardiaques", thèse de doctorat Soutenue en novembre 1999, Spécialité Automatique et Traitement Numérique du Signal, l'Institut National Polytechnique de Lorraine.

[Friedemann, 1961] Friedemann W. S., and Hubert V. P., "Automatic Recognition of Electrocardiographic Waves by Digital Computers". Circulation Research, v.9, pp. 1138-1143, 1961.

[Fukushima, 1988] K. Fukushima, "A neural network for pattern recognition", IEEE Computer Magazin, Vol. 21, No. 3, 1988, pp. 65-75.

[Furth, 1988] FURTH B., PEREZ A., "An adaptive real-time ECG compression algorithm with variable threshold", IEEE Transactions on Biomedical Engineering, vol. 35, pp. 489-494, 1988.

G

[George, 2002] George J. Miao, Mark A. Clements, “Digital Signal Processing and Statistical Classification”, Artech House, 2002, 492 page.

[Grossberg, 1988] S. Grossberg, “Neural Networks and Natural Intelligence”, 1988 :MIT Press.

H

[Hadj, 2006] Z. Hadj Slimane, “Analyse et synthèse de méthodes de détection du complexe QRS du signal électrocardiogramme”, Thèse de doctorat en électronique- Option : Traitement du signal, soutenue en juin 2006 au Département d’Electronique, Faculté des sciences de l’Ingénieur- université de Tlemcen.

[Hadj, 2008] Z.E. Hadj Slimane, F. Bereksi Reguig, “A real-time QT interval detection algorithm”, Journal of Mechanics in Medicine and Biology 8 (2) (June 2008)251–263.

[Hadj, 2010] Z.E.Hadj Slimane and A. Nait-Ali, “QRS complex detection using Empirical Mode Decomposition”. 2010, Digital Signal Process., 20: 1221-1228.

[Hopfield, 1982]J. J. Hopfield, “Neural networks and physical systems with emergent collective computational abilities”, Proc. Nat. Acad. Sci., 2554–2558, 1982.

I

[Ishijima, 1983] Ishijima M., Shin S., Hostetter G.H., Sklansky J., “Scan-along polygonal approximation for data compression of electrocardiograms”, IEEE Transactions on Biomedical Engineering, vol. 30, pp. 723-729, 1983.

[Istepanian , 2000] Istepanian RSH, Petrosian AA., “Optimal zonal wavelet-based ECG data compression for a mobile telecardiology system”, IEEE Trans Information Technol Biomed 2000; 4(3):200–11.

J

[Jain, 1976] Jain, A. K., “A Fast Karhunen-Loeve Transform for a Class of Stochastic Process,” IEEE Trans, on Communication, Vol. COM-24, PP. 1023-1029, 1976.

[Jalaleddine, 1990] S. M. S. Jalaleddine, C. G. Hutchens, R. D. Strattan, and W. A. Coberly, “ECG data compression techniques & mdash, A unified approach”, IEEE Trans. Biomed. Eng., vol. 37, no. 4, pp.329 -343 1990.

[Jane, 1993] R. Jane., S. Osmos , P. Laguna, P. Caminal , “Adaptive Hermite Models for ECG Data Compression and Evaluation with Automatic Wave Detection”, Proc. Computers in Cardiology, pp. 389-392, 1993.

[Jansen, 1997] V. G. Mark, H. Jansen, “Using artificial neural network for classifying ICU patient states”, IEEE EMB Mag., 41–47, 1997.

K

[Khaddoumi, 2005] Balkine Khaddoumi, “ Analyse et modélisation de l'activité électrique du cœur dans le cas de pathologies ventriculaires”, Thèse de doctorat en Automatique et Traitement de Signal et des Images, soutenue le 10 juin 2005 à l’université de nice-sophia antipolis - ufr sciences.

[Khazae, 2010] A. Khazae, A. Ebrahimzadeh, “Classification of electrocardiogram signals with support vector machines and genetic algorithms using power spectral features”, Biomedical Signal Processing and Control (5) (2010) 252–263.

[Kohonen, 1987] T. Kohonen, "Adaptive, associative, and self-organization functions in neural computing", Applied Optics, vol. 26, pp.4910 -4918 1987.

[Kom, 2001] M. Kom, "Electrocardiographie haute amplification ", Thèse de doctorat d’Etat, Université de Ydé I ; spécialité Physique Appliquée, Mai 2001.

[Kulkarni, 1997] Kulkarni P.K., Vinod kumar, Verma H.K., “Direct data compression techniques for ECG signais: effect of sampling frequency on performances”, International Journal of Systems Science, vol. 28, fasc. 3, pp. 217-228, 1997.

[Kumar, 2006] Kumar V, Saxena SC, Giri VK, “Direct data compression of ECG signal for telemedicine”, Int J Syst Sci 2006; 37(1):45–63.

[Kutlu, 2012] Y. Kutlu, D. Kuntalp, “Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients”, Computer Methods and Programs in Biomedicine 105 (3) (2012) 257–267.

L

[Lagerholm, 2000]: Lagerholm M, Peterson C, Braccin G, Edenbran L, Sörnmo DTL. “Clustering ECG complexes using hermite functions and self-organizing maps”. IEEE Trans Biomed Eng 2000; 47(7):838–47.

[Leporrier, 2011] Michel Leporrier, “Petite encyclopédie médicale Hamburger: Guide de pratique médicale”, Lavoisier, 2011,1887 pages.

[Li, 1993] C. Li & C. Zheng (1993), “QRS detection by wavelet transform”, Proceedings of Annual Conference on Eng .in Med. and Biol., vol. 15, pp.330-331.

[Li, 1995] C. Li, C. Zheng, and C. Tai, "Detection of ECG characteristic points using wavelet transforms", IEEE Trans. Biomed. Eng, vol. 42, pp.21 -28 1995

[Lu, 2000]: Lu Z, Kim DY, Pearlman WP, "Wavelet Compression of ECG Signals by the Set Partitioning in Hierarchical Trees Algorithm", IEEE Trans Biomed Eng 2000;47(7):849–55.

M

[Mackay, 2004] J. Mackay, G. Mensah, "THE ATLAS OF HEART DISEAS AND STROCK", Organisation Mondiale de la Santé, 2004.

[Mammen, 1990] MAMMEN, RAMAMURTHI, "Vector Quantization for compression of multichannel ECG", IEEE Trans. Biomed. Eng. Vol. 37, N° 4, 1993.

[Mark, 1997] R. Mark and G. Moody, "MIT-BIH Arrhythmia Database," 1997, <http://ecg.mit.edu/dbinfo.html>.

[Mellal, 2010] Ahmed Mellal, "Application pratique de l'anatomie humaine: Viscères du tronc", Editions Publibook, 2010, 255 pages.

[Michel, 2001] Michel Collet, Gérard Le Bobinnec, "Electrocardiographie et rythmologie canines", Wolters Kluwer France, 2001, 243 pages.

[Misiti, 2003] M. Misiti, Y. Misiti, G. Oppenheim, and J.M. Poggi, "Les ondelettes et leurs applications". Edition Hermès Science, Paris, 2003.

[Mit, 1992] MIT-BIH Arrhythmia Database Directory, Harvard University- Massachusetts Institute of Technology Division of Health Sciences and Technology, July 1992.

[Mitra, 2013] M. Mitra and R. Samanta, "Cardiac arrhythmia classification using neural networks with selected features", Procedia Technology, vol. 10, pp. 76-84, 2013

[Mueller, 1978] MUELLER W.C., "Arrhythmia detection software for an ambulatory ECG monitor", Biomed. Science Instrument., vol. 14, pp. 81-85, 1978

O

[Olmez, 1997] T. Olmez, "Classification of ECG waveforms using RCE neural network and genetic algorithm", Electronics Letters, 1561–1562, 1997.

P

[Pagé, 2006] M. PAGÉ, " Polynômes orthogonaux et polynômes de Macdonald», mémoire présenté comme exigence partielle de la maîtrise en mathématiques, novembre 2006, université du Québec à Montréal.

[Pan, 1985] J. Pan and W. J. Tompkins, “A Real-Time QRS Detection Algorithm,” IEEE Trans. Biomed. Eng., vol. BME-32, pp.230-236, March 1985.

[Penzel, 2000] Penzel, T., G.B. Moody, R.G. Mark, A.L. Goldberger and J.H. Peter, 2000. “The apnea-ECG database”. Comput. Cardiol., 27: 255-258.

[Philips, 1992] W. PHILIPS, G. DE JONGHE; “Data Compression of ECG’s by High-Degree Polynomial Approximation”, IEEE Transactions on Biomedical Engineering, Vol. 39, N° 4, April 1992, pp. 330-337.

[Philips, 1993] W. PHILIPS, “ECG Data Compression with Time-Warped Polynomials”, IEEE Transactions on Biomedical Engineering, Vol. 40, N° 11, November 1993, pp. 1095-1101.

R

[Rai, 2013] : H. Mohan Rai, A. Trivedi and S. Shukla, “ECG signal processing for abnormalities detection using multi-resolution wavelet transform and Artificial Neural Network classifier”, Measurement, vol. 46, (2013), pp. 3238–3246.

[Rai, 2014] H. M. Rai , A. Trivedi, K. Chatterjee, S. Shukla, “R-Peak Detection using Daubechies Wavelet and ECG Signal Classification using Radial Basis Function Neural Network”, J. Inst. Eng. India Ser. B (January–March 2014) 95(1):63–71

[Rollins, 200] Rollins DL, Killingsworth CR, Walcott GP, Justice RK, Ideker RE, “A telemetry system for the study of spontaneous cardiac arrhythmias”. IEEE Trans Biomed Eng 2000;47:887–92.

[Rouquette, 2002] Claude Rouquette, “ Médecine, chirurgie et soins infirmiers”, Éditeur Wolters Kluwer France, 2002 ,495 pages.

S

[Sabatier, 2006] A. Sabatier, “Études sur le cœur et la circulation centrale dans la série des vertébrés: et physiologie comparées, philosophie naturelle”, ed. : C. Coulet, Université d'Oxford, 26 mai 2006.

[Sabil, 2005] Abdelkebir Sabil, “La pléthysmographie respiratoire par inductance sans étalonnage. développements en exploration, surveillance et assistance respiratoires ”, thèse de doctorat Soutenue en décembre 2005, spécialité Modèles et Instruments en Médecine et Biologie, UNIVERSITE JOSEPH FOURIER-GRENOBLE 1.

[Saxena, 1997] SAXENA S.C., SHARMA A., CHAUD HARY S.C., “Data compression and feature extraction of ECG signals”, International Journal of Systems Science, vol. 28, fasc. 5, pp. 483-498, 1997.

[Senhaji, 2002] Senhaji L., Wang F., Hernandez A. I. and Carrault G., “Wavelets Extrema Representation for QRS-T Cancellation and P Wave Detection”, *IEEE Computers in Cardiology* 2002; 29:37-40.

[Silipo, 1998] R. Silipo, C. Marchesi, “Artificial neural networks for automatic ECG analysis”, *IEEE Trans. Signal Processing*, 1417–1425, 1998.

[Sklansky, 1980] Sklansky J., Gonzalez V., “Fast polygonal approximation of digitized curves, *Pattern Recognition*”, vol. 12, pp. 327-331, 1980.

[Sörnmo, 1981]: Sörnmo L, Börjesson PO, Nygard ME, Pahlm O. “A method for evaluation of QRS shape feature using a mathematical model for ECG”. *IEEE Trans Biomed Eng BME* 1981; 28:713–7.

[Subbiah, 2015] S. Subbiah, R. Patro, P Subbuthai, “feature Extraction and Classification for ECG Signal Processing based on Artificial Neural Network and Machine Learning Approche”, *International Conference on Inter Disciplinary Research in Engineering and Technology* (2015):50-57.

T

[Thomas, 2014] M. Thomas, M. K. Das and S. Ari, "Classification of Cardiac Arrhythmias based on Dual-tree Transform", *IEEE International Conference on Communications and Signal Processing (ICCSP)*, pp.729 -733, 2014.

W

[Wang, 2012] J.-S. Wang, W.-C. Chiang, Y.-L. Hsu, and Y.-T. C Yang, "ECG arrhythmia classification using a probabilistic neural network with a feature reduction method", *Neuro computing*, 2012. doi:10.1016/j.neucom.2011.10. 045.

[Womble, 1977]: Womble ME, Halliday JS, Mitter SK, Lancaster MC, Triebwasser JH, “Data Compression for Storing and Transmitting ECG’s/VCG’s”, *Proc IEEE* 1977;65(5):703–6.

Y,Z

[Yu, 2007] S.N. Yu, Y.H. Chen, “Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network”, *Pattern Recognition Letters* (28) (2007) 1142–1150.

[Zhang, 2005] Hao Zhang; Li-Qing Zhang, "ECG analysis based on PCA and Support Vector Machines", *Neural Networks and Brain, 2005(ICNN&B'05)*, International Conference, pp. 743-747, 2005.

Résumé

La compression et la classification automatique des signaux Electrocardiogramme (ECG) constituent un des thèmes majeurs de la recherche biomédicale. Elles jouent un rôle important de nos jours pour accélérer le diagnostic des maladies cardio-vasculaires.

La compression des signaux ECG trouve un nouvel intérêt à cause de la télémédecine. Elle est nécessaire pour réduire la quantité de données à stocker et à transmettre vers un autre centre hospitalier à travers un réseau Internet ou Intranet. Aussi, la classification des battements du signal ECG en différents cas pathologiques est une tâche de reconnaissance très complexe.

L'étude abordée dans le cadre de cette thèse porte sur le développement, l'implémentation, et l'évaluation de plusieurs algorithmes de compression et de classification des signaux ECG.

Ces algorithmes concernent principalement :

- La compression des signaux ECG par une transformation sinusoïdale et par une transformation en ondelettes ;
- La classification des battements cardiaques en deux classes (Normal et Anormal) par l'extraction des paramètres pertinents à partir du signal ECG et signal respiratoire ;
- Et enfin la modélisation polynomiale du signal ECG par les polynômes d'Hermite et Tchebychev , et l'exploitation des coefficients de la modélisation pour former des nouveaux descripteurs appliqués à l'entrée des classificateurs neuronaux multicouches pour la classification de quatre types de battements (N, PVC, BBD et BBG).

Les résultats expérimentaux obtenus en testant les différentes approches proposées sur les enregistrements ECG réels des bases de données MIT-BIH et Apnea-ECG démontrent l'efficacité de telles approches par rapport à d'autres méthodes existantes dans la littérature.

Mots Clés

Electrocardiogramme (ECG), Signal respiratoire, Compression, Classification, Modélisation, classificateurs neuronaux multicouches, Polynômes d'Hermite, Polynômes de Tchebychev.

ملخص الأطروحة

تقليص حجم بيانات إشارة المخطط الكهربائي للقلب (م ك ق) والتعرف التلقائي على أنماط ضرباته المختلفة هي واحدة من المواضيع الرئيسية للبحوث الطبية الحيوية التي تلعب دورا هاما في أيامنا هذه لتسريع تشخيص أمراض القلب والشرايين. موضوع عملية تقليص حجم إشارة النشاط الكهربائي للقلب يعرف اهتماما متزايدا بسبب تطور التطبيب عن بعد. فمن الضروري تقليل كمية البيانات التي يتم تخزينها وإرسالها إلى مستشفى آخر من خلال الإنترنت أو الإنترنت. كما تعتبر عمليات تصنيف ضربات القلب إلى فئات مرضية محددة ومختلفة مهمة معقدة للغاية.

تناولت الدراسة في هذه الأطروحة العديد من خوارزميات تقليص حجم إشارة المخطط الكهربائي للقلب وتصنيف ضرباته، حيث تم تطويرها، تنفيذها و تقييمها. هذه الخوارزميات تتمثل أساسا في :

- تقليص حجم بيانات إشارة النشاط الكهربائي للقلب عن طريق التحويلات الجيبية و تحويل الموجات؛
- تصنيف ضربات القلب إلى فئتين (العادية وغير العادية) عن طريق استخراج المعلومات ذات الصلة من إشارة تخطيط القلب وإشارة الجهاز التنفسي.
- وأخيرا، وضع نمذجة متعددة الحدود للإشارة النشاط الكهربائي للقلب بواسطة متعدد الحدود هيرميت وتشيبشيف، واستغلال معاملات النمذجة لتشكيل صفات جديدة تطبق على مداخل المصنفات العصبية متعددة الطبقات من أجل تصنيف أربعة أنواع من ضربات القلب (N، PVC، BBD و BBG).

النتائج التجريبية التي تم الحصول عليها عن طريق اختبار المناهج المختلفة المقترحة على الإشارات الحقيقية (م ك ق) من قاعدة البيانات لمعهد ماساتشوستس للتكنولوجيا أثبتت كفاءة هذه المناهج بالمقارنة مع الطرق الأخرى والمنشورة في مجلات علمية مشهورة.

الكلمات المفتاحية

إشارة المخطط الكهربائي للقلب، إشارة الجهاز التنفسي، تقليص ، تصنيف، نمذجة، المصنفات العصبية متعددة الطبقات، متعدد الحدود هيرميت، متعدد الحدود تشيبشيف.

Abstract

Compression and automatic classification of ECG signals is an important biomedical research area. They are considered as a useful tool to accelerate the diagnosis of heart disease.

Data compression of ECG signal is also used in many telemedicine applications. In fact, it reduces the stored data in order to transmit them to the hospital center through an Internet or intranet network.

About the classification of heartbeats into different pathologic categories, this is a very complex pattern recognition task.

This thesis focuses on the development, implementation, and evaluation of several algorithms of compression and classification of ECG signals.

These algorithms consist mainly in:

- ECG compression using sinusoidal and wavelet transforms;
- Classification of heartbeats into two classes (normal and abnormal) by extracting relevant parameters from ECG and respiratory signals;
- And finally, modeling of the ECG signals through Hermite and Tchebyshev polynomials and apply these models to generate new descriptors that will also be applied to multilayer neural classifiers for the classification of four types of beats (N, PVC, BBD and BBG).

Compared with other existing approaches, results obtained by testing the different approaches proposed on ECG data from MIT-BIH and Apnea-ECG databases, are very satisfactory.

Keywords

ECG (Electrocardiogram), Respiratory signal, Compression, Classification, Modeling, Multilayer neural classifiers, Hermite polynomials, Chebyshev polynomials.