

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



**Université Batna 2 – Mostefa Ben Boulaïd**  
**Faculté de Technologie**  
**Département d'Electronique**



**Thèse**

Préparée au sein du Laboratoire d'Automatique Avancée  
et d'Analyse des Systèmes : LAAAS

Présentée pour l'obtention du titre de :  
**Docteur en Sciences en électronique**  
**Option : Communication**

Sous le Thème :

**Modélisation, Débruitage, Extraction des caractéristiques  
et Classification des signaux électrocardiogrammes ECG**

Présentée par :

**OUALI Mohammed Assam**

**Devant le jury composé de :**

M. BOUGUECHAL Noureddine	Prof.	Université de Batna-2	Président
M. CHAFAA Kheireddine	Prof.	Université de Batna-2	Rapporteur
M. BOULKROUNE Abdesselem	Prof.	Université de Jijel	Examineur
M. SAIGAA Djamel	Prof.	Université de M'sila	Examineur
M. TOUBA Mostefa	MCA.	Université de Biskra	Examineur
M. GHOGGALI Noureddine	MCA.	Université de Batna-2	Examineur

**Soutenue le 10 Juillet 2018**

---

---

## Remerciements

---

*Soyons reconnaissants aux personnes qui nous donnent  
du bonheur ; elles sont les charmants jardiniers  
par qui nos âmes sont fleuries.*

**Marcel Proust**

*Le temps met tout  
en lumière.*

**Thalès**

Le seul moyen de se délivrer d'une tentation, c'est d'y céder parait-il ! Alors j'y céder en disant en grand merci aux personnes qui ont cru en moi et qui m'ont permis d'arriver au bout de cette thèse.

Je tiens à exprimer mes plus vifs remerciements au **Pr : CHAFAA Kheireddine** qui fut pour moi un directeur de thèse attentif et disponible malgré ses nombreuses charges. Sa compétence, sa rigueur scientifique et sa clairvoyance m'ont beaucoup appris. Ils a été et reste de moteur de mon travail de recherche.

J'exprime tous mes remerciements à l'ensemble des membres de mon jury : Messieurs : **BOUGUECHAL Noureddine, BOULKROUNE Abdesslem, SIGAA Djamel, TOUBA Mostefa et GHOGGALI Noureddine.**

J'adresse toute ma gratitude à tous mes ami(e)s et à toutes les personnes qui m'ont aidé dans la réalisation de ce travail. Je remercie Monsieur : **ELMOATAZ Abderrahim et CHAHIR Youssef** pour m'avoir accueilli dans l'unité de recherche GREYC-Caen (France) et de m'avoir permis de travailler dans de bonnes conditions.

Enfin, les mots les plus simples étant les plus forts, j'adresse toute mon affection à ma famille, et en particulier à mes parents qui m'ont fait comprendre que la vie n'est pas faite que de problèmes qu'on pourrait résoudre grâce à des formules mathématiques et des algorithmes, leur intelligence, leur confiance, leur tendresse, leur amour me portent et me guident tous les jours. Merci pour avoir fait de moi ce que je suis aujourd'hui.

*à mes parents,  
et à tous ceux que je ne nomme pas, mais qui se reconnaîtront.*

**OUALI Mohammed Assam**

---

---

## Résumé

---

*La promesse de la chenille  
n'engage pas le papillon.*

**André Gide**

### Résumé

Les travaux de recherche présentés dans cette thèse de doctorat portent essentiellement sur deux axes : 1/ développement d'une technique de modélisation et d'identification intelligente, où la logique floue type-2 avec les algorithmes métaheuristiques ont été utilisés dans le but d'obtenir des modèles efficaces pour les signaux électrocardiogrammes, 2/ développement d'un système expert pour le diagnostic automatique des maladies cardiaques. Pour cette fin plusieurs points ont été traités à savoir : le débruitage des signaux électrocardiogrammes où plusieurs types de bruit ont été considérés : les bruits à hautes fréquences et les bruits à basses fréquences, l'extraction des caractéristiques et la classification des battements cardiaques selon le type d'arythmie. Deux techniques à base de logique floue type-1 et le filtre de kalman étendu optimisées par l'algorithme d'optimisation BBO, ont été proposées pour éliminer les bruits à hautes fréquences. Une troisième technique pour éliminer les bruits à hautes fréquences à base de la décomposition en valeurs singulières a été aussi discutée. La détection des Pics R du signal électrocardiogramme avec l'interpolation par Splines cubiques ont été utilisés pour éliminer le bruit basse fréquence (déformation de la ligne de base). La logique floue type-2 et la transformée en ondelettes ont été utilisées pour l'étape d'extraction des caractéristiques avec machine à apprentissage extrême (ELM) comme classificateur.

## Abstract

The research works presented in this dissertation focuses on two axes : 1/ development of an intelligent modeling and identification technique, where type-2 fuzzy logic with metaheuristic algorithms have been used in order to obtain efficient models for electrocardiogram signals, 2 / development of an expert system for the automatic diagnosis of heart disease. For this purpose, several points have been dealt : denoising of the electrocardiogram signals where several types of noise were considered : the high frequency noises and the low frequency noises, feature extraction and classification of the heart beats according to the type of arrhythmia. Two techniques based on type-1 fuzzy logic and extended Kalman filter optimized by the BBO were used to eliminate high-frequency noise. A third technique for eliminating high-frequency noise-based on the singular values decomposition has also been discussed. Detection of R-pics of the electrocardiogram signal with Cubic Spline interpolation was used to eliminate low-frequency noise (baseline deformation). Type-2 fuzzy logic and wavelet transform were used for the features extraction step with Extreme Learning Machine (ELM) as a classifier.

## ملخص

نعرض في أطروحة الدكتوراه هذه مجموعة من الأبحاث والتي يمكن لنا أن نقسمها الي قسمين رئيسيين: قسم أول يحتوي اقتراح طريقة جديدة تعتمد على منطق الغموض نوع-2 حيث تمكنا من التعرف على الإشارات والأنظمة الغير الخطية. والقسم الثاني كان من أجل تطوير نظام خبير للتشخيص التلقائي لأمراض القلب. في القسم الأول قمنا باقتراح طريقة جديدة تجمع بين منطق الغموض نوع-2 والخوارزميات الميتا استدلالية، حيث قمنا باقتراح فكرة النمذجة باستخدام وحدة الخطأ. بالنسبة للقسم الثاني، التشخيص هو الخطوة الأخيرة من سلسلة كاملة من الاستحواذ التي تبدأ بالكشف عن ضربات القلب، والترشيح وأخيرا التشخيص باستعمال نظام خبير يحتوي على قاعدة بيانات. بالنسبة للكشف عن ضربات القلب قمنا باستعمال الإشارات القلبية الموجودة على قاعدة البيانات MIT-BIH. بالنسبة لعملية الترشيح والتي من شأنها ان تكون خطوة أساسية للخطوة التالية قمنا بتطوير عدة مرشحات تعتمد على منطق الغموض، مرشح كالمان وطريقة جبرية بحتة تعتمد على طريقة التحليل الي قيم فردية وأخيرا نزع الضجيج المنخفض التردد باستخدام طريقة تعتمد عن الاستيفاء في الخطوط المكعبة. وأخيرا التشخيص الذي يعتمد على استخراج خصائص ضربات القلب وتصنيفها وفقا لنوع عدم انتظام ضربات القلب، لاستخراج الخصائص قمنا باقتراح طريقة تعتمد على المزج بين منطق الغموض نوع-2 وتحويل الموجات، بالنسبة للتصنيف قمنا باستعمال آلة التعلم القصى.

---

---

## Liste des tableaux

---

1.1	Annotations de la base de données MIT-BIH PhysioBank. . . . .	24
1.2	Standards de l'AAMI et correspondance avec le système utilisé pour notre base de données [69]. . . . .	24
3.1	Performances statistiques de 20 essais indépendants avec 200 itérations. . .	74
3.2	Valeurs moyennes et les intervalles de confiance du $83^{ieme}$ paramètre de 20 essais indépendants. . . . .	74
3.3	Performances statistiques de 20 essais indépendants avec 200 itérations. . .	84
3.4	Valeurs moyennes et les intervalles de confiance du $83^{ieme}$ . . . . .	85
3.5	Performance avec différents nombre de règles et d'itérations en termes d' $MSE$ et $TC$ . . . . .	89
3.6	Comparaison de la méthode proposée avec plusieurs méthodes de références	90
4.1	Comparaison des résultats de débruitage de l'artefact EMG dans le signal 115.dat de la base de données MIT-BIH PhysioBank [129]. . . . .	112
4.2	Comparaison des résultats de débruitage dans le cas d'un WGN de 5dB pour plusieurs signaux réels de la base de données MIT-BIH PhysioBank [129]. .	112
4.3	Comparaison des résultats de débruitage dans le cas d'un WGN de 5dB pour plusieurs signaux réels de la base de données MIT-BIH PhysioBank [129]. .	112
4.4	Comparaison en terme de $SNR_{imp}$ des résultats de débruitage dans le cas d'un WGN de 5dB pour plusieurs signaux réels de la base des données Physio Bank [129]. . . . .	113
4.5	Résultats de comparaison entre le FAF, AFD, EEMD et EMD pour le débruitage du signaux ECGs bruités (10 dB) [129] en terme de $MSE$ . . . . .	113
4.6	Résultats de comparaison en termes de $MSEPWRD$ du FAF, MP-EKF, EKF et EKF en présence du bruit blanc Gaussien et les artefacts musculaire . . .	114
4.7	Paramètres du modèle d'ECG. . . . .	119

4.8 Résultats de comparaison de la méthode proposée avec d'autres méthode de références. . . . .	144
5.1 Enregistrements ECG et nombres de battements utilisés dans cette étude. . .	151

---

---

## Table des figures

---

1	Les étapes de classification du signal ECG. . . . .	4
1.1	Emplacement du coeur. . . . .	8
1.2	Structure interne du coeur. . . . .	9
1.3	Le processus de dépolarisation : (a) une seule cellule est dépolarisée, (b) une onde se propage de cellule en cellule, (c) jusqu'à ce que tous soient dépolarisés, (d) repolarisation. . . . .	10
1.4	Les cinq phases du potentiel d'action et les transferts ioniques au niveau cellulaire [62]. . . . .	11
1.5	(a) Circuit nodal, (b) Formes des potentiels d'action dans les différentes parties du coeur, et séquence temporelle de la propagation de l'activité électrique du coeur analogie avec les ondes de l'ECG. . . . .	11
1.6	Signal ECG et ses ondes. . . . .	13
1.7	Montage d'Einthoven pour l'enregistrement des dérivations bipolaires des membres. . . . .	14
1.8	Montage de Goldberger pour l'enregistrement des dérivations unipolaires membres augmentés. . . . .	15
1.9	Positions des électrodes recommandées pour l'enregistrement du système de dérivations unipolaires précordiales (d'après [1]). . . . .	16
1.10	Schéma de principe montrant les principales sources du bruit en électrocardiographie. . . . .	17
1.11	Le spectre d'amplitude de Fourier d'un signal ECG : Les interférences de ligne électrique de 60 Hz et le bruit de la dérive du potentiel de référence (à environ 0 Hz) sont identifiables. . . . .	17
1.12	Signal ECG avec la déformation de la ligne de base. . . . .	19
1.13	Signal ECG contaminé par bruit EMG. . . . .	20
1.14	différents fichiers de la base de données MIT-BIH PhysioBank. . . . .	22

1.15	Fichier <i>.hea</i> de l'enregistrement 100.dat de la base de données MIT-BIH PhysioBank. . . . .	23
1.16	L'enregistrement 233.dat de la base de données MIT-BIH PhysioBank. . . . .	23
2.1	Comparaison d'un ensemble classique et d'un ensemble flou. . . . .	29
2.2	Fonction d'appartenance : (a) Triangulaire, (b) Singleton, (c) Gaussienne. . . . .	30
2.3	Système d'inférence floue (SIF). . . . .	32
2.4	(a) Représentation tridimensionnelle d'un ensemble flou type-2 Gaussien. (b) Degré d'appartenance flou correspondant à $x = 4.25$ . . . . .	36
2.5	Structure d'un système flou type-2. . . . .	38
2.6	Fonctionnement général d'un GA. . . . .	44
2.7	Déplacement d'une particule. . . . .	46
2.8	Courbes de migration linéaire pour BBO où $\lambda$ est le taux d'immigration et $\mu$ le taux d'émigration. . . . .	52
3.1	Ensemble flou type-2 Gaussien avec : (a) déviation standard incertaine, (b) moyenne incertaine (centre). . . . .	62
3.2	Structure de la méthode proposée pour l'identification du signal ECG. . . . .	65
3.3	Chronogrammes relatifs aux cycles <i>ON – OFF</i> des commutateurs de la Figure 3.2. . . . .	66
3.4	Résultats de modélisation du signal ECG synthétique basé sur PSO, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale. . . . .	69
3.5	Résultats de modélisation du signal ECG synthétique basé sur BBO, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale. . . . .	69
3.6	Résultats de modélisation du signal ECG synthétique basé sur FA, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale. . . . .	70
3.7	Résultats de modélisation du signal ECG synthétique basé sur GA, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale. . . . .	70
3.8	Comparaison entre les erreurs de modélisation du signal ECG synthétique en utilisant PSO, BBO, FA et GA. . . . .	71
3.9	Résultats de modélisation du signal ECG réel (18177.dat) basé sur PSO, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale. . . . .	71

3.10 Résultats de modélisation du signal ECG réel (18177.dat) basé sur BBO, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale. . . . .	72
3.11 Résultats de modélisation du signal ECG réel (18177.dat) basé sur FA, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale. . . . .	72
3.12 Résultats de modélisation du signal ECG réel (18177.dat) basé sur GA, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale. . . . .	73
3.13 Comparaison entre les erreurs de modélisation du signal ECG réel (18177.dat) en utilisant PSO, BBO, FA et GA. . . . .	73
3.14 Barres d'erreur des paramètres du modèle primaire, (a) PSO, (b) BBO, (c) FA, (d) GA. . . . .	75
3.15 Barres d'erreur des paramètres du modèle d'erreur, (a) PSO, (b) BBO, (c) FA, (d) GA. . . . .	75
3.16 Modélisation du signal ECG réel bruité, (a) signal ECG réel bruité, (b) Modèle du signal ECG réel bruité ( $MSE = 1.215e - 006$ ). . . . .	76
3.17 Structure de la méthode proposée pour l'identification des systèmes dynamiques non linéaires. . . . .	79
3.18 Chronogrammes relatifs aux cycles <i>ON – OFF</i> des commutateurs de la Figure 3.17. . . . .	79
3.19 Résultats de modélisation du système dynamique non linéaire (Équation 3.16) basé sur PSO, (a) Modèle primaire, (b) Validation, (c) Modèle de l'erreur de modélisation, (d) Modèle final. . . . .	81
3.20 Résultats de modélisation du système dynamique non linéaire (Équation 3.16) basé sur BBO, (a) Modèle primaire, (b) Validation, (c) Modèle de l'erreur de modélisation, (d) Modèle final. . . . .	81
3.21 Résultats de modélisation du système dynamique non linéaire (Équation 3.16) basé sur FA, (a) Modèle primaire, (b) Validation, (c) Modèle de l'erreur de modélisation, (d) Modèle final. . . . .	82
3.22 Résultats de modélisation du système dynamique non linéaire (Équation 3.16) basé sur GA, (a) Modèle primaire, (b) Validation, (c) Modèle de l'erreur de modélisation, (d) Modèle final. . . . .	82
3.23 Comparaison entre le modèle primaire et final en termes d'erreur avec (a) PSO, (b) BBO, (c) FA, (d) GA. . . . .	83
3.24 Barres d'erreur des paramètres du modèle primaire (a) PSO, (b) BBO, (c) FA, (d) GA. . . . .	84

3.25 Barres d'erreur des paramètres du modèle d'erreur (a) PSO, (b) BBO, (c) FA, (d) GA. . . . .	85
3.26 Résultats de modélisation du système dynamique non linéaire (Équation 3.23) : (a) PSO, (b) BBO, (c) FA, (d) GA. . . . .	87
3.27 Résultats de modélisation du système dynamique non linéaire (Équation 3.28) : (a) PSO, (b) BBO, (c) FA, (d) GA. . . . .	88
4.1 Structure du filtre flou adaptatif. . . . .	105
4.2 Filtrage typique du FAF pour le signal ECG 18177.dat avec un bruit blanc Gaussien additif (WGN) ( $SNR_{input} = 3dB$ ). . . . .	108
4.3 Filtrage typique du FAF pour le signal ECG 18177.dat avec l'artefact de l'électromyogramme (MA) ( $SNR_{input} = 3dB$ ). . . . .	109
4.4 Filtrage typique du FAF pour le signal ECG 18177.dat avec l'artefact de mouvement des électrodes ( $SNR_{input} = 3dB$ ). . . . .	109
4.5 Filtrage typique du FAF pour le signal ECG 18177.dat avec les trois types de bruit (WGN+MA+EM) électrodes . . . . .	110
4.6 Mesures des performances du FAF par rapport aux différents SNR d'entrée pour le cas d'un bruit blanc Gaussien, (a) SNR de sortie, (b) facteur d'amélioration, (c) Erreur quadratique moyenne, (d) Racine de l'erreur quadratique moyenne. . . . .	110
4.7 Mesures des performances du FAF par rapport aux différents SNR d'entrée pour le cas d'un bruit MA, (a) SNR de sortie, (b) facteur d'amélioration, (c) Erreur quadratique moyenne, (d) Racine de l'erreur quadratique moyenne. . . . .	111
4.8 Mesures des performances du FAF par rapport aux différents SNR d'entrée pour le cas d'un EM, (a) SNR de sortie, (b) facteur d'amélioration, (c) Erreur quadratique moyenne, (d) Racine de l'erreur quadratique moyenne. . . . .	111
4.9 (a) Trajectoire circulaire, (b) Intervalle RR. . . . .	117
4.10 Trajectoire typique produite par le modèle dynamique dans l'espace 3-D. . . . .	118
4.11 Signal électrocardiogramme synthétique. . . . .	119
4.12 Structure du filtre de kalman étendu adaptatif. . . . .	120
4.13 Signal électrocardiogramme quasi-réel. . . . .	122
4.14 Résultat de filtrage du signal électrocardiogramme synthétique. . . . .	125
4.15 Résultat de filtrage du signal électrocardiogramme synthétique. . . . .	126
4.16 Résultat de filtrage du signal électrocardiogramme synthétique. . . . .	126
4.17 (a) Signal ECG synthétique propre, (b) Signal ECG synthétique bruité ( $variance = 0.05mV$ ). . . . .	134

4.18 Résultats de filtrage, (a) Avec un opérateur de projection $P_6$ , (b) Avec un opérateur de projection $P_4$ , (c) Avec un opérateur de projection $P_2$ . . . . .	135
4.19 Modèle de suivi des signaux ECGs mère-foetus . . . . .	135
4.20 Signal ECG composé (ECG mère+ECG foetus) . . . . .	137
4.21 Résultats de séparation (a) signal ECG de la mère, (b) signal ECG du foetus	138
4.22 Structure de la méthode proposée pour retirer la déformation de la ligne de base. . . . .	138
4.23 Suppression de la déviation de la ligne de base d'un signal ECG synthétique.	141
4.24 Suppression de la déviation de la ligne de base d'un signal ECG réel. . . . .	141
4.25 (a) Signal ECG réel 105.dat sans ligne de base artificielle (b) Signal ECG réel 105.dat avec ligne de base artificielle d'amplitude 100 (c) Signal ECG réel 105.dat corrigé. . . . .	142
4.26 (a) Signal ECG réel avec la déviation de la ligne de base (b) Signal ECG réel corrigé. . . . .	143
4.27 Contenu spectrale du signal ECG original avec une déviation de la ligne de base de fréquence $f_r = 0.25Hz$ . . . . .	143
4.28 Contenu spectrale du signal ECG corrigé (sans déviation de la ligne de base). . . . .	144
5.1 Organigramme de la procédure adoptée. . . . .	152
5.2 LightWaVE. . . . .	153
5.3 Table récapitulatif du signal 100. dat en utilisant l'application LightWaVE. .	153
5.4 Exemple d'extraction d'une sous classe. . . . .	154
5.5 Organigramme de l'étape d'extraction des caractéristiques en utilisant la logique floue type-2. . . . .	155
5.6 Décomposition : Transformée en ondelette discrète. . . . .	156
5.7 Vue dans le domaine fréquentiel de la décomposition en ondelette discrète .	156
A.1 Méthode d'Euler . . . . .	167
A.2 Approximation linéaire d'une fonction non linéaire . . . . .	168
A.3 Approximation non linéaire d'une fonction non linéaire . . . . .	169

---

---

## *Liste des abréviations*

---

**ECG** : Électrocardiogramme

**OD** : Oreillette droite

**OG** : Oreillette Gauche

**VCS** : Veine cave supérieur

**VCI** : Veine cave inférieur

**VPG** : Veine pulmonaire gauche

**VPD** : Veine pulmonaire droite

**VG** : Ventricule gauche

**VD** : Ventricule droite

**Ao** : Aorte

**AP** : Artère pulmonaire

**VM** : Valve mitrale

**VT** : Valve tricuspide

**VSP** : Valvule sigmoïde pulmonaire

**VASo** : Valvule sigmoïde aortique

**EMG** : Electromyogramme

**AAMI** : Association for the advancement of medical instrumentation

**ARMA** : Auto regressive moving average

**AR** : Auto regressive

**GA** : Genetic algorithm

**PSO** : Particle swarm optimisation

**FA** : Firfly algorithm

**BBO** : biogeography based optimisation

**SIF** : Système d'inférence floue

**HSI** : Habitat suitability index

**SIV** : Suitability index variable

**STD** : Standard déviation

**MSE** : Mean square error

**APE** : Average percentage error

**RMSE** : Root mean square error

**SNR** : Signal to noise ration

**MSEWPRD** : Multiscal entropy based weighted distortion measure

**TC** : Taux de convergence

**CI** : Confidence intervalle

**T2FPM** : Type-2 fuzzy primary model

**T2FEM** : Type-2 fuzzy error model

**FAF** : Fuzzy adaptatif filtre

**EKF** : Extended kalman filtre

**EM** : Elctrode motion artifact

**MA** : Muscle artifact

**WGN** : White gaussien noise

**DWT** : Discret wivelete transform

**mRMR** : Mimimum-redundancy maximum-relevancy

**ELM** : Extreme learning machine

---

---

# Table des matières

---

<i>INTRODUCTION GÉNÉRALE</i>	1
<b>1 ANATOMIE DU COEUR ET SIGNAL ÉLECTROCARDIOGRAMME</b>	7
1.1 Introduction . . . . .	8
1.2 Concept de base . . . . .	8
1.2.1 Le coeur humain . . . . .	8
1.2.2 Fonctionnement électrique du coeur . . . . .	9
1.2.3 Le potentiel d'action . . . . .	10
1.2.4 Propagation de l'influx électrique à l'intérieur du coeur . . . . .	11
1.3 Électrocardiogramme . . . . .	12
1.3.1 Définition . . . . .	12
1.3.2 Ondes et intervalles de l'ECG . . . . .	12
1.3.3 Dérivations cardiaques . . . . .	14
1.3.3.1 Dérivations sur le plan frontale . . . . .	14
1.3.3.2 Dérivations sur le plan horizontal (précordiales) . . . . .	15
1.3.4 Bruit et variabilité du signal ECG . . . . .	16
1.3.4.1 Interférences de ligne électrique . . . . .	16
1.3.4.2 Contact de l'électrode et le mouvement . . . . .	18
1.3.4.3 Bruit de l'électromyogramme (EMG) . . . . .	19
1.3.4.4 Bruit des instruments . . . . .	20
1.4 Standards AAMI . . . . .	21
1.4.1 La base de données MIT-BIH PhysioBank . . . . .	21
1.4.1.1 Le fichier de données (.dat) . . . . .	22
1.4.1.2 Le fichier (.hea) . . . . .	22
1.4.1.3 Le fichier (.atr) . . . . .	22
1.4.2 Correspondance entre les standards de l'AAMI et la base de données MIT-BIH PhysioBank . . . . .	24
1.5 Conclusion . . . . .	25

<b>2</b>	<b>LOGIQUE FLOUE ET ALGORITHMES METAHEURISTIQUES</b>	<b>27</b>
2.1	Introduction . . . . .	28
2.2	Logique floue type-1 . . . . .	29
2.2.1	Ensembles flous type-1 . . . . .	29
2.2.2	Opérations de base sur les ensembles flous . . . . .	30
2.2.3	Variables linguistiques . . . . .	31
2.2.4	Système d'inférence floue . . . . .	32
2.2.5	Exemple d'un système flou type-1 . . . . .	32
2.3	Logique floue type-2 . . . . .	33
2.3.1	Représentation d'un ensemble flou type-2 . . . . .	34
2.3.1.1	<i>Exemple</i> . . . . .	34
2.3.2	Types d'ensembles flous type-2 . . . . .	35
2.3.2.1	<i>Ensemble type-2 Intervalle</i> . . . . .	35
2.3.2.2	<i>Ensemble type-2 Gaussien</i> . . . . .	35
2.3.2.3	<i>Ensemble type-2 Triangulaire</i> . . . . .	35
2.3.3	Opération sur les ensembles flous type-2 . . . . .	35
2.3.4	Structure d'un système flou type-2 . . . . .	38
2.3.4.1	<i>Fuzzification</i> . . . . .	38
2.3.4.2	<i>Base des règles</i> . . . . .	38
2.3.4.3	<i>Inférence</i> . . . . .	39
2.3.4.4	<i>Réduction de type</i> . . . . .	40
2.3.4.5	<i>Défuzzification</i> . . . . .	41
2.4	Algorithmes métaheuristiques . . . . .	41
2.4.1	Problème d'optimisation . . . . .	41
2.4.2	Les types de problèmes d'optimisation . . . . .	42
2.4.3	Les méthodes métaheuristiques classiques . . . . .	43
2.4.3.1	<i>Les algorithmes génétiques</i> . . . . .	44
2.4.4	L'intelligence en essaims ou Swarm Intelligence . . . . .	45
2.4.4.1	<i>L'optimisation par essaim particulière</i> . . . . .	45
2.4.4.2	<i>L'algorithme des essaims de luciole</i> . . . . .	48
2.4.5	Autres méthodes évolutionnaires pour l'optimisation . . . . .	49
2.4.5.1	<i>L'algorithme à base de biogéographie</i> . . . . .	49
2.5	Conclusion . . . . .	52
<b>3</b>	<b>MODÉLISATION ET IDENTIFICATION DU SIGNAL ÉLECTROCARDIOGRAMME</b>	<b>55</b>
3.1	Introduction . . . . .	56
3.2	Etat de l'art sur la modélisation du signal ECG . . . . .	57

3.2.1	Méthodes temporelles . . . . .	57
3.2.2	Méthodes mathématiques . . . . .	58
3.2.3	Méthodes intelligentes . . . . .	58
3.3	Contribution . . . . .	60
3.4	Méthode proposée pour la modélisation du signal ECG . . . . .	61
3.4.1	Paramètres du système flou type-2 à ajuster . . . . .	61
3.4.2	Fonction objectif . . . . .	62
3.4.3	Identification du modèle primaire . . . . .	63
3.4.4	Identification du processus d'erreur . . . . .	63
3.4.5	Conception du modèle final . . . . .	64
3.4.6	Résultats de simulation . . . . .	65
3.4.6.1	<i>Paramètres des algorithmes métaheuristiques</i> . . . . .	66
3.4.6.2	<i>Modélisation du signal électrocardiogramme synthétique</i> . . . . .	67
3.4.6.3	<i>Modélisation du signal électrocardiogramme réel</i> . . . . .	68
3.4.7	Essais de validation et de généralisation . . . . .	74
3.4.7.1	<i>Modélisation des données bruitées</i> . . . . .	76
3.4.7.2	<i>Modélisation des systèmes dynamiques non linéaires</i> . . . . .	76
3.4.8	Étude comparative . . . . .	88
3.5	Conclusion . . . . .	90
<b>4</b>	<b>PRÉ-TRAITEMENT DU SIGNAL ÉLECTROCARDIOGRAMME</b>	<b>93</b>
4.1	Introduction . . . . .	94
4.2	État de l'art sur le filtrage du signal électrocardiogramme . . . . .	95
4.2.1	Travaux qui s'intéressent au bruit haute fréquence . . . . .	95
4.2.1.1	<i>Méthodes non basées sur des modèles mathématiques</i> . . . . .	95
4.2.1.2	<i>Méthodes basées sur des modèles mathématiques</i> . . . . .	98
4.2.2	Travaux qui s'intéressent au bruit basse fréquence . . . . .	99
4.2.3	Travaux qui s'intéressent à la séparation des signaux électrocardio-grammes mère-foetus . . . . .	100
4.3	Contributions . . . . .	102
4.4	Filtrage du signal ECG par le filtre flou adaptatif . . . . .	103
4.4.1	Filtre flou adaptatif . . . . .	103
4.4.2	Conception du filtre flou adaptatif basé sur l'algorithme BBO . . . . .	104
4.4.3	Résultats de simulation . . . . .	106
4.4.3.1	<i>Filtrage du signal ECG réel</i> . . . . .	107
4.4.3.2	<i>Étude Comparative</i> . . . . .	109
4.5	Filtrage du signal ECG par le filtre de Kalman étendu adaptatif . . . . .	115

4.5.1	Filtre de kalman étendu . . . . .	115
4.5.2	Modèle dynamique du signal ECG . . . . .	117
4.5.3	Conception du filtre de Kalman étendu adaptatif basé sur l'algorithme BBO . . . . .	120
4.5.4	Résultats de simulation . . . . .	124
4.6	Filtrage du signal ECG par la décomposition en valeurs singulières . . . . .	125
4.6.1	La décomposition en valeurs singulières . . . . .	125
4.6.2	Pseudo inverse . . . . .	127
4.6.3	Hypothèse de filtrage par SVD . . . . .	128
4.6.3.1	Calcul de l'opérateur de projection . . . . .	129
4.6.4	Méthode de filtrage du signal ECG par SVD et résultats de simulation . . . . .	132
4.7	Séparation des signaux ECG Mère-Foetus par SVD . . . . .	134
4.8	Suppression de la déformation de la ligne de base . . . . .	137
4.8.1	Résultats de simulation . . . . .	140
4.8.2	Étude comparative . . . . .	142
4.9	Conclusion . . . . .	144
<b>5</b>	<b>EXTRACTION DES CARACTÉRISTIQUES ET CLASSIFICATION DES BATTEMENTS CARDIAQUES</b>	<b>147</b>
5.1	Introduction . . . . .	148
5.2	État de l'art sur l'extraction des caractéristiques et la classification des battements cardiaques . . . . .	148
5.3	Contribution . . . . .	151
5.4	Préparation des bases de données . . . . .	151
5.5	Extraction des caractéristiques . . . . .	152
5.5.1	Extraction des caractéristiques par la logique floue type-2 . . . . .	153
5.5.2	Extraction des caractéristiques par la transformée en ondelettes discrète DWT . . . . .	154
5.6	Sélection des caractéristiques par la méthode mRMR . . . . .	157
5.7	Normalisation des paramètres . . . . .	157
5.8	Classification . . . . .	158
5.9	Résultat et discussion . . . . .	159
5.10	Conclusion . . . . .	160
	<b>CONCLUSION GÉNÉRALE</b>	<b>160</b>
	<b>ANNEXE</b>	<b>164</b>
	<b>BIBLIOGRAPHIE</b>	<b>178</b>

---

---

## INTRODUCTION GÉNÉRALE

---

**L**es maladies cardiovasculaires constituent un problème majeur de santé publique, elles sont les premières causes de mortalité dans le monde. Les facteurs de risques sont multiples : tabac, sédentarité, obésité, hypertension artérielle, diabète, facteurs génétiques aussi parfois.

Le coeur est l'organe central du système cardiovasculaire, il peut être affecté de nombreuses pathologies qui peuvent être bénignes, comme certaines tachycardies par exemple, soit s'avère très sérieuses, comme l'infarctus du myocarde. Avec l'évolution des techniques, les médecins disposent aujourd'hui d'outils performants pour observer le fonctionnement du muscle cardiaque et dresser ainsi leur diagnostic. Parmi les examens cardiologiques possibles, l'électrocardiogramme (ECG) est l'examen le plus couramment effectué [1].

L'électrocardiogramme (ECG) est la mesure de l'activité électrique durant la contraction du coeur, il est caractérisé par des ondes appelées P, Q, R, S et T. Les ondes Q, R et S forment le complexe QRS. L'invention de l'ECG a valu à Willem Einthoven le prix de Nobel de médecine en 1924. De nos jours, l'ECG est largement utilisé et présente jusqu'à douze paires d'électrodes d'enregistrement. La différence de potentiel enregistrée entre chaque paire d'électrodes constitue le signal qui représente l'activité électrique du coeur depuis plusieurs points de vue. La fréquence d'échantillonnage de tels ECG modernes se situe entre 250 et 500  $Hz$ . Néanmoins, ce type de procédures est uniquement utilisé pour des mesures très courtes. Malheureusement, une mesure de l'ECG de courte durée ne peut permettre le diagnostic de certaines pathologies comme les arythmies cardiaques des épisodes ischémiques transitoires ou des ischémies silencieuses du myocarde. Dans ce genre de situations, les médecins ont recours à un enregistrement ECG de long terme en utilisant moins d'électrodes (seulement deux ou trois) : le Holter [2, 3].

La technologie utilisée en milieu clinique devenant de plus en plus complexe, les médecins se retrouvent devant toujours plus de données générées par différentes modalités. Ces données peuvent être très intéressantes pour diverses tâches comme les interfaces homme-

machine, le suivi des fonctions physiologiques et le diagnostic de certaines maladies. En particulier, il peut s'agir de signaux physiologiques comme l'enregistrement de l'activité électrique du muscle cardiaque ou électrocardiogramme (ECG). Ceux-ci sont parfois acquis durant de très longues périodes jusqu'à plusieurs jours (Ex : examen d'Hotler pour un bon diagnostic) et sont de nos jours interprétés visuellement par des experts. Dans le cas de l'électrocardiogramme, ce sont plus de 100 000 battements par jour qui doivent être analysés. Cette tâche peut être longue et donc très coûteuse, notamment dans le diagnostic de nombreuses maladies cardiaques et dans les essais cliniques.

Les travaux de recherches qui seront présentés dans cette thèse portent essentiellement sur deux axes :

- ✘ *Modélisation et identification du signal électrocardiogramme.*
- ✘ *Diagnostic des maladies cardiaques.*

## I. Modélisation du signal électrocardiogramme

La modélisation des battements cardiaques est une étape essentielle pour l'identification automatique des ondes de l'électrocardiogramme, c'est un sujet très intéressant qui a attiré l'attention de plusieurs chercheurs et scientifiques. Dans la littérature de la modélisation et l'identification trois types de modèles peuvent être rencontrés : il y'a ceux qui considèrent le signal électrocardiogramme comme une succession de segments ou de courbes. Cette dernière est basée sur la recherche des pentes, des débuts et des fins de ces segments, en utilisant des techniques d'estimation, d'interpolation ou même d'extrapolation [4, 5, 6, 7, 8, 9, 10]. Le deuxième type de modèles sont les modèles mathématiques, ces derniers sont constitués d'un ensemble d'équations différentielles. Parmi les plus intéressants dans ce type de modèles on trouve le modèle dynamique du signal électrocardiogramme qui a été réalisé dans l'espace d'état. Ce modèle est basé sur la théorie des équations différentielles et plus précisément la théorie des équations différentielles chaotiques [11]. La troisième catégorie est basée sur l'utilisation de l'intelligence artificielle (Ex : logique floue, réseaux de neurones artificiels,....,etc), on appelle ce type de modèles : « Modèles intelligents ». Plusieurs approches ont été développées dans la littérature pour la modélisation des séries temporelles en utilisant l'intelligence artificielle, que l'on peut appliquer pour la modélisation du signal électrocardiogramme [12, 13, 14, 15, 16, 17, 18, 19].

Dans cette recherche nous avons beaucoup travaillé sur la modélisation et l'identification intelligente où un modèle des signaux électrocardiogrammes basé sur la théorie de la logique floue et les algorithmes métaheuristiques, a été développé. La théorie de la logique floue a été introduite par L. Zadeh en 1965. Cette logique permet la représenta-

tion et le traitement de connaissances imprécises ou approximatives. Ceci est dû au fait que la logique floue est exprimée usuellement par des règles linguistiques de la forme *IF – THEN* ; elle est utilisée pour résoudre les problèmes de décision en contrôle ou bien pour décrire le comportement dynamique d'un système inconnu ou mal défini. La logique floue et les algorithmes métaheuristiques ont récemment été combinés et étudiés de manière approfondie pour prouver leur efficacité [20, 21, 22, 23]. De notre part les algorithmes métaheuristiques ont été introduits pour ajuster les paramètres (les centres des fonctions d'appartenance et les intervalles de conséquence des règles floues *IF – THEN*) du modèle flou proposé.

## II. Diagnostic des maladies cardiaques

Le deuxième objectif de la présente thèse est la conception d'un système expert pour le diagnostic des pathologies ou des arythmies cardiaques. La détection de ces arythmies est un sérieux problème sur le plan clinique et technologique (moyens et approches). Elles sont variées et les manières de les aborder sont également variées, souvent cela dépend de quel point de vue où on se place. Il est possible de définir les arythmies cardiaques par l'irrégularité des battements cardiaques ou comme un groupe de battements irréguliers. Elles forment deux groupes : le premier comprend la fibrillation et la tachycardie ventriculaires qui sont dangereuses et nécessitent une thérapie immédiate avec un défibrillateur ; le second concerne les arythmies non dangereuses mais qui exigent une thérapie préventive d'autres problèmes. Ces troubles cardiaques sont aussi classés suivant la fréquence et le rythme décrit par le nombre de cycles ou contractions ventriculaires (dépolariation des ventricules) par minute, repérés sur l'ECG par le nombre de complexe QRS [24].

Un certain nombre de travaux ont été réalisés avec succès pour mettre en évidence les arythmies [24, 25, 26, 27, 28, 29, 30, 31], mais ils diffèrent par le choix du type et du nombre de paramètres significatifs qui caractérisent l'arythmie en question. Ces paramètres peuvent être morphologiques, temporels ou statistiques ou les deux. Aussi l'intervalle RR a été exploité pour chercher plusieurs arythmies. Mais dans la majorité des cas les paramètres sont mesurés autour du complexe QRS (largeur, forme et amplitude,...,etc) et plus particulièrement la détection de l'onde R qui est un paramètre dominant, spécialement pour les arythmies auriculaires (fibrillation auriculaire). D'autres part plusieurs méthodes de classification ont été proposées dans la littérature [26, 27, 32] pour classer les battements anormaux.

L'une des étapes essentielles qui précède l'opération d'extraction des caractéristiques et la classification, est le pré-traitement contenant le filtrage du signal électrocardiogramme. Durant l'étape d'enregistrement du signal électrocardiogramme il est souvent contaminé

par des bruits internes et externes. Bien qu'il existe de nombreuses sources de ces bruits, celles qui présentent le plus d'intérêt sont les bruits d'instruments, l'interférence entre les différents signaux du corps, le bruit de contact des électrodes, les artefacts de mouvement et respiration du patient et les interférences de ligne d'alimentation. Évidemment, tout bruit qui apparaît sur la trace de l'électrocardiogramme peut compliquer le diagnostic et l'analyse d'identification. Par conséquent, il est nécessaire de comprendre et supprimer les effets du bruit sur le signal électrocardiogramme afin d'extraire les caractéristiques d'identification requises du signal ECG. Les données d'identification requises peuvent être masquées par des artefacts introduits par le bruit. Les performances du classificateur dépendent du choix des paramètres significatifs pour discriminer les battements normaux des pathologiques. Donc les performances des classificateurs sont fortement liées à la qualité d'extraction des indicateurs de pathologies. C'est pourquoi, le pré-traitement du signal électrocardiogramme est nécessaire avant d'extraire ces paramètres avec exactitude. Le pré-traitement consiste à la suppression du bruit et les signaux parasites. Dans la littérature on trouve plusieurs travaux qui traitent ce genre de problèmes. Ces travaux peuvent être classés en deux groupes : ceux qui s'occupent des bruits haute fréquence, et ceux qui s'occupent des bruits basse fréquence. Pour les techniques de filtrage des bruits haute fréquence on trouve celles qui se basent sur des modèles mathématiques [33, 34, 35] et celles qui ne se basent pas sur des modèles mathématiques [36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 48, 49, 50]. Plusieurs autres travaux ont été développés dans l'espoir de supprimer les bruits basse fréquence (bruit de la ligne de base) [51, 52, 53, 54, 55, 56, 57].

Dans notre thèse tout un système expert pour le diagnostic des maladies cardiaques sera présenté en détail, ce système est présenté dans la Figure 1. Pour la première étape qui est la détection des battements cardiaques, la base de données MIT-BIH PhysioBank (MIT-BIH Arrhythmia Database) sera utilisée [58].

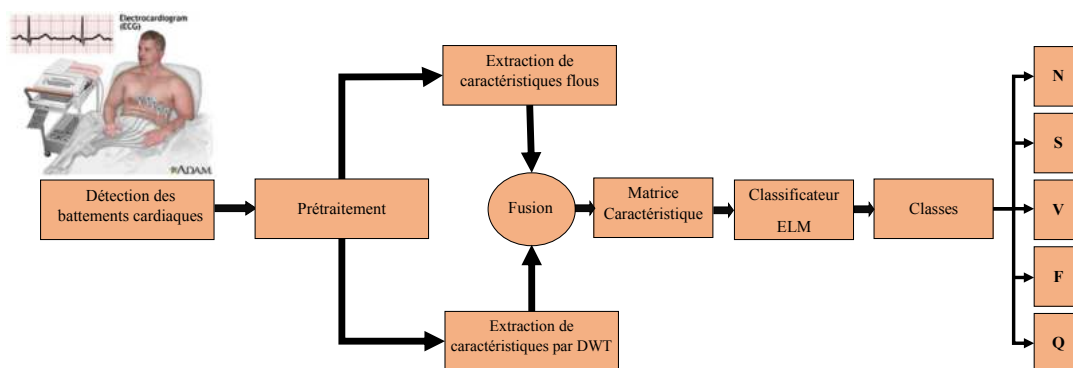


FIGURE 1 – Les étapes de classification du signal ECG.

Après la détection des battements cardiaques, une étape de pré-traitement sera nécessaire. Dans notre travail plusieurs outils de traitement du signal ont été développés afin de filtrer le signal électrocardiogramme à savoir : le filtrage du signal électrocardiogramme en utilisant la logique floue, le filtrage du signal électrocardiogramme par le filtre de kalman étendu, le filtrage du signal électrocardiogramme par la décomposition en valeurs singulières et la suppression de la dérive de la ligne de base (les artefacts de mouvement et respiration du patient) par la détection des pics R et l'interpolation par splines cubiques.

Après l'étape de pré-traitement la tâche suivante sera l'extraction des caractéristiques et la classification. Pour pouvoir classifier les battements cardiaques, il faut commencer par définir des classes. Dans notre cas, c'est la classification recommandée par l'AAMI « *Association for the Advancement of Medical Instrumentation* », qui sera utilisée, les classes sont au nombre de cinq à savoir : les battements normaux (N), les battements anormaux (S, V et F), et les battements non connus (Q). Pour l'extraction des caractéristiques des battements cardiaques de ces différentes classes, deux méthodes seront utilisées afin de fusionner les caractéristiques trouvées pour avoir la matrice caractéristique : la première méthode se base sur la logique floue type-2 et la deuxième sur la transformée en ondelettes discrète (DWT). La dernière étape de notre système sera la classification automatique de ces caractéristiques selon le type d'arythmie atteinte, cette étape sera réalisée par un classificateur baptisé EML « *Extreme Learning Machine* » qui est une version de réseaux de neurones artificiels.

Le présent document est reparti en cinq chapitres :

- ✦ Le premier chapitre présente brièvement le fonctionnement du système cardiovasculaire, et notamment le coeur. Il permet en particulier de comprendre l'anatomie du coeur et l'origine et la nature des signaux électrocardiogrammes, et présente les différents genres du bruit qui peuvent contaminer ce signal (ECG) et aussi les différentes classes des arythmies cardiaques.
- ✦ Dans le deuxième chapitre nous présenterons le fondement théorique ainsi que les notions de base de la logique floue type-1 et type-2, tels que, concepts des ensembles flous type-1 et type-2, représentation des ensembles flous type-1 et type-2, opérations sur ces ensembles et les systèmes flous type-1 et type-2, comme nous présenterons une étude détaillée sur les algorithmes métaheuristiques à savoir le GA, PSO, FA et BBO.
- ✦ Dans le troisième chapitre nous allons présenter une méthode pour la modélisation et l'identification du signal électrocardiogramme en utilisant la logique floue type-2 et les algorithmes métaheuristiques, cette méthode sera utilisée dans le chapitre cinq pour l'extraction des caractéristiques des battements cardiaques.
- ✦ Dans le chapitre quatre nous présenterons les méthodes de filtrage du signal élec-

trocardiogramme en utilisant la logique floue type-1, le filtre de kalman étendu, la décomposition en valeurs singulières et l'interpolation par splines cubiques.

- ✦ Finalement l'extraction des caractéristiques en utilisant la logique floue type-2 et la transformée en ondelettes discrète sera présentée dans chapitre cinq avec le classificateur ELM.

***ANATOMIE DU COEUR ET SIGNAL  
ÉLECTROCARDIOGRAMME***

---

*Le travail proposé dans cette thèse touche le signal électrocardiogramme ECG de différents angles tels que sa modélisation, son dé-bruitage et son diagnostic. Nous exposons dans ce premier chapitre l'anatomie du coeur à fin de comprendre la genèse de ces signaux (ECG). En outre, la morphologie du signal électrocardiogramme et ses caractéristiques.*

**Sommaire**

---

<b>1.1 Introduction</b>	<b>8</b>
<b>1.2 Concept de base</b>	<b>8</b>
1.2.1 Le coeur humain	8
1.2.2 Fonctionnement électrique du coeur	9
1.2.3 Le potentiel d'action	10
1.2.4 Propagation de l'influx électrique à l'intérieur du coeur	11
<b>1.3 Électrocardiogramme</b>	<b>12</b>
1.3.1 Définition	12
1.3.2 Ondes et intervalles de l'ECG	12
1.3.3 Dérivations cardiaques	14
1.3.4 Bruit et variabilité du signal ECG	16
<b>1.4 Standards AAMI</b>	<b>21</b>
1.4.1 La base de données MIT-BIH PhysioBank	21
1.4.2 Correspondance entre les standards de l'AAMI et la base de données MIT-BIH PhysioBank	24
<b>1.5 Conclusion</b>	<b>25</b>

---

## 1.1 Introduction

**L**e coeur et le système vasculaire (sang, vaisseaux sanguins) constituent le système cardiovasculaire. Sa fonction principale est d'assurer la circulation du sang dans l'organisme afin de satisfaire aux besoins énergétiques et renouvellement cellulaire. Dans ce premier chapitre plusieurs points essentiels seront présentés à savoir :

- ✓ Anatomie du coeur ainsi que les potentiels d'activation électrique.
- ✓ Genèse du signal électrocardiogramme et ses caractéristiques.
- ✓ Variabilité du signal électrocardiogramme.
- ✓ Norme de classification des battements cardiaques.

## 1.2 Concept de base

### 1.2.1 Le coeur humain

Le coeur est un muscle creux (poids 270g chez l'adulte), à contraction rythmique dont la fonction est d'assurer la progression du sang à l'intérieur des vaisseaux. Le coeur est situé dans le thorax entre les deux poumons (cf., [Figure 1.1](#)), il repose sur le diaphragme dans le médiastin antérieur, derrière le sternum et en avant de la colonne vertébrale. Le coeur est sous forme pyramidale triangulaire [1].




FIGURE 1.1 – Emplacement du coeur.

Le coeur se compose de deux ventricules et de deux oreillettes (cf., [Figure 1.2](#)). Chaque oreillette droite et gauche communique avec le ventricule correspondant. Dans l'oreillette droite (OD) arrivent les deux veines caves, la veine cave supérieur (VCS) et la veine cave inférieur (VCI) et dans l'oreillette gauche (OG), les quatre veines pulmonaires, les veines pulmonaires gauches (VPG) et les veines pulmonaires droites (VPD) qui amènent le sang au coeur, le sang est expulsé du ventricule gauche (VG) par l'aorte (Ao), et du ventricule droite (VD) par l'artère pulmonaire (AP).

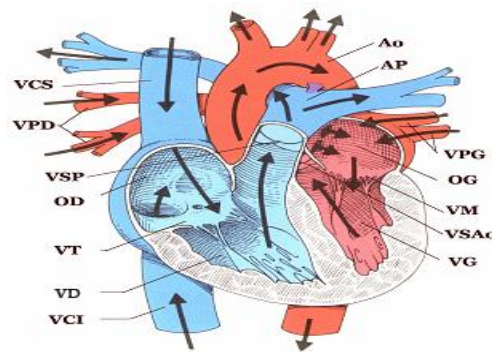


FIGURE 1.2 – Structure interne du coeur.

Les artères, les veines et les capillaires forment les tubes conducteurs ou vaisseaux [59, 60]; chaque oreillette droite et gauche communique avec le ventricule correspondant par des orifices auriculo-ventriculaires munis d'un système valvulaire; celui-ci est composé de deux valves, à gauche la valve mitrale (VM) et à droite la valve tricuspide (VT); l'artère pulmonaire est pourvue d'un système anti-reflux : les trois valvules sigmoïdes pulmonaires (VSP). L'artère est aussi pourvue d'un système valvulaire sigmoïde : les valvules sigmoïdes aortiques (VSAo). Ces appareils valvulaires n'autorisent le passage du sang que des oreillettes aux ventricules.

### 1.2.2 Fonctionnement électrique du coeur

Le coeur compose un réseau intrinsèque de cellules qui produisent et propagent des impulsions, ainsi que des cellules qui répondent à ces impulsions par une contraction [1, 61]. Donc l'activité du coeur est en fait la somme de l'activité électrique de toutes les cellules myocardiques, chacune se comportant comme un dipôle électrique, avec un pôle positif et un pôle négatif.

A l'état de base, les cellules cardiaques (comme toutes les cellules de l'organisme) sont polarisées, à cause d'une répartition particulière des ions de l'organisme entre l'extérieur et l'intérieur de la cellule. En effet, il existe plus d'ions positifs ( $Na^+$ ,  $Ca^{2+}$ , ...) à l'extérieur que à l'intérieur de la cellule (cf., Figure 1.3). La dépolarisation cellulaire correspond à une entrée d'ions positifs (ou sortie d'ions négatifs) dans la cellule. Cette phase va se propager de proche en proche aux autres cellules cardiaques pour induire une contraction du muscle cardiaque (systole). La repolarisation (retour vers l'état initial) cellulaire suit la dépolarisation cellulaire et correspond à une sortie d'ions positifs (ou entrée d'ions négatifs) de la cellule. Cette phase va permettre au coeur de se relâcher (diastole) pour qu'une nouvelle dépolarisation puisse se produire et ainsi de suite.




FIGURE 1.3 – Le processus de dépolarisation : (a) une seule cellule est dépolarisée, (b) une onde se propage de cellule en cellule, (c) jusqu'à ce que tous soient dépolarisés, (d) repolarisation.

### 1.2.3 Le potentiel d'action

Un autre élément fondamental de la compréhension de l'électrophysiologie cardiaque est la représentation d'un potentiel d'action d'une cellule myocardique. Il s'agit du courant électrique enregistré au niveau d'une cellule cardiaque, qui est généré par la dépolarisation et la repolarisation, il existe cinq phases dans le potentiel d'action d'une cellule cardiaque (cf., [Figure 1.4](#)) :

- **La phase 0 ou dépolarisation rapide** : durant laquelle la pente du potentiel est maximale, après une excitation électrique au dessus du seuil d'activation de la cellule au repos, les potentiels mesurés présentent une inversion rapide de la polarité suite à l'ouverture de canaux transmembranaires permettant l'entrée d'ions  $Na^+$  à l'intérieur de la cellule.
- **La phase 1 ou début de la repolarisation** : qui est caractérisée par une repolarisation rapide et de courte durée, due à l'inactivation des canaux  $Na^+$  et au flux d'ions  $K^+$  de l'intérieur vers l'extérieur de la cellule.
- **La phase 2 ou plateau** : qui correspond à la phase de repolarisation lente. Le plateau est dû principalement à l'ouverture des canaux calciques, qui permettent une diffusion lente et passive d'ions  $Ca^+$  vers l'intérieur de la cellule, en atténuant l'influence des canaux  $K^+$ , et en diminuant ainsi la vitesse de repolarisation.
- **La phase 3 ou repolarisation rapide** : qui correspond à la phase de repolarisation finale et qui se caractérise par la fermeture des canaux ioniques spécifiques, ce qui ramène la cellule au potentiel de repos originel. Il se produit également dans la dernière partie de cette phase, une activation des canaux de potassium qui permet l'expulsion active de ces ions, facilitant le retour à la négativité originelle du

potentiel d'action.

- **La phase 4** : qui correspond au potentiel de repos, où la cellule devient plus facilement excitable [61].




FIGURE 1.4 – Les cinq phases du potentiel d'action et les transferts ioniques au niveau cellulaire [62].

#### 1.2.4 Propagation de l'influx électrique à l'intérieur du coeur

L'influx électrique cardiaque naît au niveau du noeud sinusal, qui se trouve à la jonction entre l'oreillette droite et l'abouchement de la veine cave supérieur. Cet influx va ensuite se propager dans les deux oreillettes, de l'oreillette droite vers l'oreillette gauche avant de se diriger vers le noeud auriculo-ventriculaire ou noeud de aschoff-tawara, qui se trouve dans la partie basse de la cloison interauriculaire.

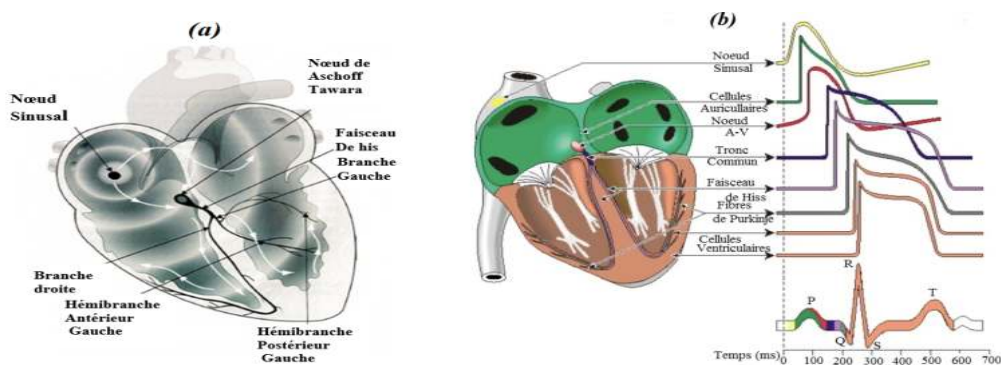


FIGURE 1.5 – (a) Circuit nodal, (b) Formes des potentiels d'action dans les différentes parties du coeur, et séquence temporelle de la propagation de l'activité électrique du coeur analogie avec les ondes de l'ECG.

A ce niveau l'influx électrique transite sans dépolariser de structure cardiaque et arrivé au niveau du faisceau de His qui se trouve dans la partie haute du septum interventriculaire. Le faisceau de His se divise en deux branches : La branche droite destinée au ventricule droit et la branche gauche destinée au ventricule gauche (cf., [Figure 1.5 \(a\)](#)). La branche gauche va se diviser en deux hémibranches : l'hémibranche antérieure gauche et l'hémibranche postérieure gauche. La branche droite et les deux hémibranches gauche vont se diviser dans chacun des ventricules en deux nombreux petits filets nerveux pour former le réseau de Purkinje. L'électrocardiogramme va représenter l'ensemble de ce trajet de conduction électrique comme montre la [Figure 1.5\(b\)](#) [62].

## 1.3 Électrocardiogramme

### 1.3.1 Définition

L'ElectroCardioGramme (ECG) est la représentation graphique du potentiel électrique qui commande l'activité musculaire du cœur. Ce potentiel est recueilli par des électrodes à la surface de la peau. Ces potentiels naissent à la limite entre les zones excitées et celles non excitées du myocarde, et sont mesurés entre deux points de la surface du corps [2, 3].

### 1.3.2 Ondes et intervalles de l'ECG

L'ECG enregistre le processus de dépolarisation et la repolarisation du massif musculaire auriculaire et du massif musculaire ventriculaire. Ce processus est enregistré comme une séquence de déflexions ou ondes superposées à une ligne de potentiel zéro, appelée ligne isoélectrique ou ligne de base. Ces déflexions sont dites positives si elles sont situées au-dessus de la ligne isoélectrique, et négative si non.

Pour chaque battement cardiaque l'ECG comporte plusieurs ondes, et différents intervalles entre ces ondes (cf., [Figure 1.6](#)) [1, 59, 63, 64] :

- **L'onde P** : elle est liée à la dépolarisation auriculaire. C'est une onde de petite amplitude, arrondie. Le rythme physiologique est dit sinusal. Dans ce cas les ondes P auriculaires précèdent régulièrement les complexes ventriculaires. Les ondes P dites *sinusals* sont toujours positives.
- **L'intervalle PR** : (ou PQ) est le temps entre le début de P et le début du QRS. Il est le témoin du temps nécessaire à la transmission de l'influx électrique des oreillettes aux ventricules.
- **Segment PR** : c'est un court segment isoélectrique qui sépare l'onde P du complexe ventriculaire.




FIGURE 1.6 – Signal ECG et ses ondes.

- **Le Complexe QRS** : il témoigne de la dépolarisation ventriculaire, et se compose de plusieurs déflexions rapides :
  - ✓ **L'onde Q** : physiologiquement, elle est de faible amplitude (moins du tiers du complexe QRS).
  - ✓ **L'onde R** : elle est par définition la première onde positive, qu'elle soit ou non précédée d'une onde Q.
  - ✓ **L'onde S** : est une onde négative qui fait suite à une onde R.
- **Segment ST** : il correspond au début de la repolarisation ventriculaire. Il suit horizontalement la ligne de base.
- **L'onde T** : elle est le témoin électrique de la repolarisation ventriculaire. Sa durée est imprécise du fait de sa fin progressive. Elle est généralement dirigée dans le même sens que le complexe QRS. Sa forme est asymétrique, avec un premier versant en pente faible, un sommet arrondi et un deuxième versant descendant en pente rapide.
- **L'intervalle QT** : mesuré du début de complexe QRS à la fin de l'onde T, correspond à l'ensemble de la dépolarisation et de la repolarisation cardiaque.

Les durées normales des différentes composantes de l'ECG chez un patient sain sont les suivantes : onde P < 0.12s, complexe QRS = 0.06 à 0.10s, onde T = 0.2s environ, intervalle PR = 0.12 à 0.20s, segment ST = 0 à 0.16s, intervalle QT = 0.33 à 0.43s.

Les amplitudes des ondes P, Q, S et T normales sont de quelque  $0.1\text{ mV}$  ; l'onde R peut parfois dépasser  $1\text{ mV}$ . La fréquence cardiaque s'évalue à partir de la mesure d'un espace RR.

### 1.3.3 Dérivations cardiaques

L'électrocardiogramme s'enregistre à partir de divers points (dérivations) donnant naissance à des courbes de morphologies différentes, toujours dans l'ordre : onde P, complexe QRS et onde T. La courbe électrocardiographie va présenter des morphologies différentes selon l'emplacement des électrodes [62, 63].

On distingue deux types d'électrodes :

- **Les électrodes périphériques** : (appelées D) qui sont placées sur les quatre membres et qui explorent le plan frontal du coeur.
- **Les électrodes précordiales** : (appelées V) qui sont placées sur le thorax du patient pour explorer le plan transversal du coeur.

D'après ces électrodes l'électrocardiogramme standard est enregistré sur douze dérivations (six dérivations des membres et six précordiales) [1, 63, 64].

#### 1.3.3.1 Dérivations sur le plan frontale

##### A. Dérivations bipolaires des membres

Les dérivations bipolaires enregistrent l'activité cardiaque entre deux points du corps, elles sont placées sur les bras droite et gauche, ainsi que sur le pied gauche. On relève ainsi les différences de potentiel entre les bras gauche et droite (I), pied gauche et bras droite (II) et pied et bras gauche (III). Ces dérivations ont été déterminées par Einthoven au début du vingtième siècle et restent encore utilisées aujourd'hui [62].




FIGURE 1.7 – Montage d'Einthoven pour l'enregistrement des dérivations bipolaires des membres.

Soit VL le potentiel sur le bras gauche, VR le potentiel sur le bras droite et VF le potentiel sur la jambe gauche, les trois dérivation sont :

- ✓ **D1**(dérivation I) : dont la différence de potentiel respecte l'équation  $DI=VL-VR$ .
- ✓ **DII**(dérivation II) : avec  $DII=VF-VR$ .
- ✓ **DIII**(dérivation III) : avec  $DIII=VF-VL$ .

Ces trois dérivation constituent le triangle d'Einthoven et chaque dérivation est une arête du triangle (cf., [Figure 1.7](#)).

#### B. Dérivations unipolaires des membres

Les trois dérivation unipolaires aVR, aVL et aVF (a = augmented, R = right, L = left, F = foot). Ont chacune des lignes allant d'un pôle positif à un pôle négatif en passant par le centre d'un triangle, chaque électrode est prise comme pôle positif avec pour référence négative les deux autres électrodes. Les trois dérivation sont (cf., [Figure 1.8](#)) :




FIGURE 1.8 – Montage de Goldberger pour l'enregistrement des dérivation unipolaires membres augmentés.

- ✓ **aVL** =  $VL-VR+VF/2 = 1.5VL$  (loi de Kirchhoff  $VL+VR+VF=0$ ).
- ✓ **aVR** : avec  $aVR=1.5VR$ .
- ✓ **aVF** : avec  $aVF=1.5VF$ .

#### 1.3.3.2 Dérivations sur le plan horizontal (précordiales)

Les dérivation du plan horizontal (dérivation de Wilson) constituent les dérivation unipolaires et sont au nombre de six (V1 à V6). Ces dérivation ont une partie positive, là où elle est placée l'électrode exploratrice, et une négative, qui correspond à la région opposée. L'électrode exploratrice est placée sur divers points précordiaux. En plus des dérivation V1 à V6, on peut utiliser dans certaines occasions les dérivation plus droites (V1R à V4R) ou plus gauches (V5 à V6) [1].




FIGURE 1.9 – Positions des électrodes recommandées pour l'enregistrement du système de dérivations unipolaires précordiales (d'après [1]).

### 1.3.4 Bruit et variabilité du signal ECG

Le signal électrocardiogramme (ECG) est obtenu en utilisant des électrodes placées sur la peau au voisinage du coeur. Durant l'étape d'enregistrement, le signal ECG peut être contaminé par plusieurs sources de bruit, ceux qui sont d'intérêt principal sont [65] :

- ✓ Interférences de ligne électrique (le secteur) ;
- ✓ Le contact de l'électrode ;
- ✓ Le mouvement et la respiration du patient ;
- ✓ L'électromyogramme (EMG) ;
- ✓ Bruit des instruments.

Un diagramme de blocs présente chacune de ces sources du bruit est représenté sur la Figure 1.10. Les différents signaux de bruit présentés dans cette figure seront caractérisés plus en détail dans cette section.

#### 1.3.4.1 Interférences de ligne électrique

Le spectre d'amplitude de Fourier d'un signal ECG typique (cf., Figure 1.11) révèle diverses contenues fréquentiels du signal ECG. Plusieurs caractéristiques intéressantes sont facilement identifiables :

- ✓  $1.2\text{ Hz}$  : l'information de battement du coeur (environ 72 battements par minute).
- ✓  $60\text{ Hz}$  : interférences de ligne électrique.

L'interférence de ligne électrique se fait par deux mécanismes : couplage capacitif et inductif. Le couplage capacitif fait référence au transfert d'énergie entre deux circuits au moyen d'une capacité de couplage présente entre les deux circuits. La valeur de la capacité de couplage diminue avec la séparation croissante des circuits. Le couplage inductif, d'autre part, est causé par une inductance mutuelle entre deux conducteurs. Lorsque le courant circule à travers les fils, il produit un flux magnétique, qui peut induire un courant dans les circuits adjacents. La géométrie des conducteurs ainsi que la séparation entre eux détermine la valeur de l'inductance mutuelle, et donc le degré de couplage inductif.

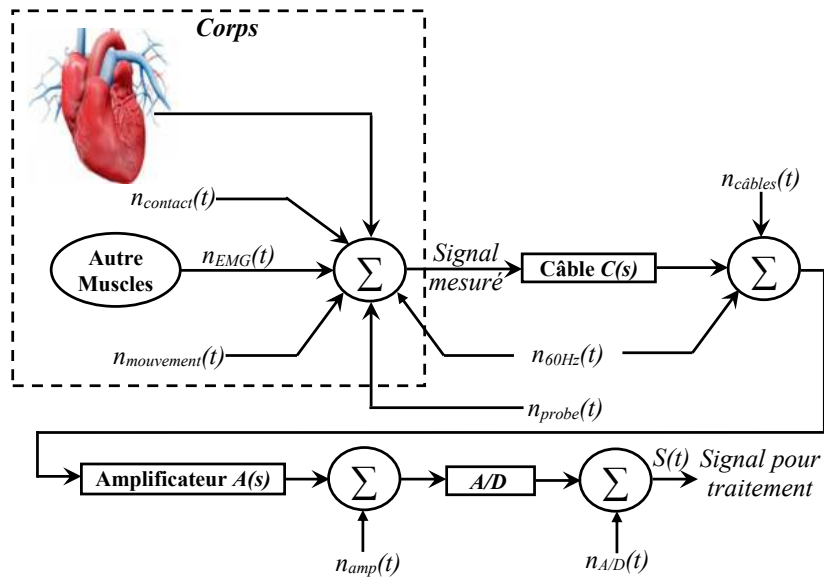


FIGURE 1.10 – Schéma de principe montrant les principales sources du bruit en électrocardiographie.




FIGURE 1.11 – Le spectre d'amplitude de Fourier d'un signal ECG : Les interférences de ligne électrique de 60 Hz et le bruit de la dérive du potentiel de référence (à environ 0 Hz) sont identifiables.

Typiquement, le couplage capacitif est responsable du bruit à haute fréquence alors que le couplage inductif introduit du bruit basse fréquence. Pour cette raison, le couplage inductif est le mécanisme dominant de l'interférence de ligne électrique dans l'électrocardiogramme. Nous devons toujours s'assurer que les électrodes sont appliquées correctement, et que tous les composants ont un blindage adéquat ce qui devraient aider à limiter la quantité d'interférence de ligne électrique.

L'artefact du bruit de ligne électrique peut être modélisé par :

$$n_{60Hz}(t) = A \times \sin(2\pi \cdot 60 + \Omega). \quad (1.1)$$

La valeur de crête moyenne,  $A$ , du bruit dépend de la quantité de couplage entre l'équipement de l'ECG et les lignes électriques. Pendant la mesure, la valeur crête à crête est également susceptible de fluctuer en raison des conditions environnementales changeantes, qui influencent la quantité de couplage inductif ou capacitif des lignes électriques aux équipements ECG. La phase de la sinusoïde, représentée par  $\Omega$  dans l'Équation 1.1, est une variable aléatoire avec une répartition uniforme dans l'intervalle  $[-\pi, \pi]$ . Ce modèle simpliste suppose que le bruit ne se produira que à 60 Hz, mais en réalité, le bruit de ligne électrique aura une bande passante finie autour de sa fréquence centrale nominale, ce qui suggère que le bruit total est composé de nombreux sinusoïdes de fréquence similaire.

#### 1.3.4.2 Contact de l'électrode et le mouvement

Le bruit de contact de l'électrode est causé par des variations de la position du coeur par rapport aux électrodes et des changements dans le milieu de propagation entre le coeur et les électrodes. Cela provoque des changements soudains dans l'amplitude du signal ECG, ainsi que des décalages basse fréquence de la ligne de base. En outre, une faible conductivité entre les électrodes et la peau diminue l'amplitude du signal ECG et augmente la probabilité de perturbations (en réduisant SNR) ; ces perturbations résultants dans la ligne de base sont causées par la variation de l'impédance de l'électrode-peau. Plus l'impédance de l'électrode-peau est grande, plus le changement d'impédance relative est important, ce qui entraînera un changement majeur dans la ligne de base du signal ECG. Si l'impédance de la peau est extraordinairement élevée, il est peut-être impossible de détecter les caractéristiques du signal de manière fiable en présence du mouvement du corps [66] (des changements soudains dans l'impédance de l'électrode-peau). Le bruit de contact est représenté par  $n_{contact}(t)$  dans la Figure 1.10.

Les artefacts de mouvement sont des changements de ligne de base transitoires causés par le mouvement de l'électrode. Les causes habituelles des artefacts de mouvement sont les vibrations, le mouvement ou la respiration du patient. L'amplitude et la durée du pic

de l'artefact sont des variables aléatoires qui dépendent aux propriétés des électrodes, les propriétés de l'électrolyte (si l'on utilise entre l'électrode et la peau) et l'impédance de la peau et le mouvement du patient [66]. La Figure 1.12 montre un segment de 70 secondes d'un signal ECG, où la dérive de la ligne de base est variée entre  $-400\text{ mV}$  à  $400\text{ mV}$ . Dans ce signal ECG, la dérive de la ligne de base se produit à une fréquence inhabituellement basse (environ  $0,014\text{ Hz}$ ) et très probablement, à partir de changements très lents dans l'impédance de l'électrode-peau. Ce bruit peut également être observé sur le spectre de puissance de Fourier dans la Figure 1.11 ; Le grand pic le plus proche de DC est le résultat de décalage basse fréquence de la ligne de base. Les artefacts du bruit introduits par le mouvement du patient sont modélisés par  $n_{mouvement}(t)$  dans la Figure 1.10.




FIGURE 1.12 – Signal ECG avec la déformation de la ligne de base.

#### 1.3.4.3 Bruit de l'électromyogramme (EMG)

Le bruit de l'EMG est causé par la contraction d'autres muscles en dehors du cœur. Lorsque d'autres muscles à proximité des électrodes contractent, ils génèrent des ondes de dépolarisation et de repolarisation qui peuvent également être récupérées par l'ECG. L'étendue de la diaphonie dépend de la quantité de contraction musculaire (mouvement du patient) et de la qualité des sondes.

Il est bien établi que l'amplitude du signal EMG est stochastique (aléatoire) et peut être raisonnablement modélisée par une fonction de distribution Gaussienne [67]. La moyenne

du bruit peut être supposée nulle ; Cependant, la variance dépend des variables environnementales et changera en fonction des conditions. Certaines études ont montré que l'écart-type du bruit est typiquement de 10% de l'amplitude crête du signal ECG [65]. Bien que le modèle statistique actuel soit inconnu, il convient de noter que l'activité électrique des muscles pendant les périodes de contraction peut générer des potentiels de surface comparables à ceux du coeur et peut complètement éliminer le signal désiré. Les effets typique du bruit EMG peuvent être observés dans le signal ECG montré dans la Figure 1.13. Ce bruit est modélisé par  $n_{EMG}(t)$  dans la Figure 1.10.




FIGURE 1.13 – Signal ECG contaminé par bruit EMG.

#### 1.3.4.4 Bruit des instruments

L'équipement électrique utilisé dans l'enregistrement du signal ECG contribue également au bruit. Les principales sources de cette forme du bruit sont les sondes d'électrodes, les câbles, le processeur, amplificateur de signaux et le convertisseur analogique-numérique, représentés respectivement par  $n_{probe}(t)$ ,  $n_{cables}(t)$ ,  $n_{amp}(t)$  et  $n_{A/D}(t)$  dans la Figure 1.10. Étant donné que cette forme du bruit est généralement définie par une distribution Gaussienne blanche. Malheureusement, le bruit d'instrumentation ne peut être éliminé car il est inhérent aux composants électroniques, mais il peut être réduit grâce à des équipements de meilleure qualité et à une conception de circuit prudente.

## 1.4 Standards AAMI

Pour pouvoir classer les battements cardiaques, il faut commencer par définir des classes. De nombreuses classifications peuvent être trouvées dans la littérature. Dans cette thèse, c'est la classification recommandée par l'AAMI (*Association for the Advancement of Medical Instrumentation*) qui a été choisie [68].

Les classes sont au nombre de cinq :

- **Classe N** : ce sont les battements normaux. Ce sont de loin les battements les plus fréquents.
- **Classe S** : ce sont les battements anormaux d'origine Supra-ventriculaire (dont ceux originaire des oreillettes).
- **Classe V** : ce sont les battements anormaux d'origine Ventriculaire (ceux originaires des ventricule).
- **Classe F** : ce sont les battements anormaux résultant de la fusion d'un battement V et d'un battement N.
- **Classe Q** : ce sont les battements inconnus.

### 1.4.1 La base de données MIT-BIH PhysioBank

Pour la validation de nos travaux de recherche nous avons choisi d'utiliser la base de données des signaux électrocardiogrammes MIB-BIH PhysioBank [58]. Cette base de données contient 48 extraits d'une demi-heure d'enregistrements ECG ambulatoires à deux canaux (DII et V5). Vingt-trois enregistrements ont été choisis au hasard parmi une série de 4000 enregistrements d'ECG ambulatoires 24 heures sur 24 recueillis auprès d'une population mixte de patients hospitalisés (environ 60%) et de patients externes (environ 40%) à l'hôpital Beth Israel de Boston ; les 25 enregistrements restants ont été sélectionnés dans le même groupe pour inclure des arythmies moins communes mais cliniquement significatives qui ne seraient pas bien représentées dans un petit échantillon aléatoire. Chaque enregistrement est échantillonné à une fréquence de 360  $Hz$  par canal avec une résolution de 11 bits sur une plage de 10  $mV$ . L'avantage majeur de cette base de données est qu'elle contient un grand nombre de pathologies cardiaques, ce qui permet de valider les algorithmes sur un grand nombre de signaux ECG. Les enregistrements sont numérotés de 100 à 124 pour le premier groupe qui comporte une variété de formes d'ondes et de 200 à 234 pour le deuxième qui comporte une variété de cas pathologiques. Chaque enregistrement a été annoté indépendamment par plusieurs cardiologues ce qui permet d'avoir des études plus fiables. L'annotation correspond à l'instant d'apparition du pic R et au type d'arythmie. Pour chaque enregistrement de la base de données, il existe trois fichiers différents avec les extensions suivantes : *.dat*, *.hea* et *.atr* (cf., Figure 1.14).

Reference annotations	Signals	Header
<a href="#">100.atr</a>	<a href="#">100.dat</a>	<a href="#">100.heg</a>
<a href="#">101.atr</a>	<a href="#">101.dat</a>	<a href="#">101.heg</a>
<a href="#">102.atr</a>	<a href="#">102.dat</a>	<a href="#">102.heg</a>
<a href="#">103.atr</a>	<a href="#">103.dat</a>	<a href="#">103.heg</a>
<a href="#">104.atr</a>	<a href="#">104.dat</a>	<a href="#">104.heg</a>
<a href="#">105.atr</a>	<a href="#">105.dat</a>	<a href="#">105.heg</a>
<a href="#">106.atr</a>	<a href="#">106.dat</a>	<a href="#">106.heg</a>
<a href="#">107.atr</a>	<a href="#">107.dat</a>	<a href="#">107.heg</a>
<a href="#">108.atr</a>	<a href="#">108.dat</a>	<a href="#">108.heg</a>
<a href="#">109.atr</a>	<a href="#">109.dat</a>	<a href="#">109.heg</a>
<a href="#">111.atr</a>	<a href="#">111.dat</a>	<a href="#">111.heg</a>
<a href="#">112.atr</a>	<a href="#">112.dat</a>	<a href="#">112.heg</a>
<a href="#">113.atr</a>	<a href="#">113.dat</a>	<a href="#">113.heg</a>
<a href="#">114.atr</a>	<a href="#">114.dat</a>	<a href="#">114.heg</a>
<a href="#">115.atr</a>	<a href="#">115.dat</a>	<a href="#">115.heg</a>
<a href="#">116.atr</a>	<a href="#">116.dat</a>	<a href="#">116.heg</a>

FIGURE 1.14 – différents fichiers de la base de données MIT-BIH PhysioBank.

#### 1.4.1.1 *Le fichier de données (.dat)*

Contient les données numérisées du signal ECG, deux différents signaux correspondant aux deux dérivations (MLII et V5) sont stockés dans le même fichier (Ex : 233.dat) (cf., [Figure 1.16](#)).

#### 1.4.1.2 *Le fichier (.heg)*

Contient les paramètres d'interprétation du fichier de données correspondant tels que : la fréquence d'échantillonnage, gain d'amplification, dérivations utilisées, nombre d'échantillons, pathologie,....etc (cf., [Figure 1.15](#)).

#### 1.4.1.3 *Le fichier (.atr)*

Comporte les positions ou les moments d'apparition des pics R du signal ECG, ces emplacements ont été marqués manuellement par plusieurs cardiologues, on donne également dans ce fichier un nombre indiquant l'ordre du pic R ainsi qu'une marque correspondant au type d'arythmie (cf., [Figure 1.16](#), [Tableau 1.1](#)).

Le [Tableau 1.1](#) représente les différents codes et leurs descriptions des annotations de la base de données MIT-BIH PhysioBank :

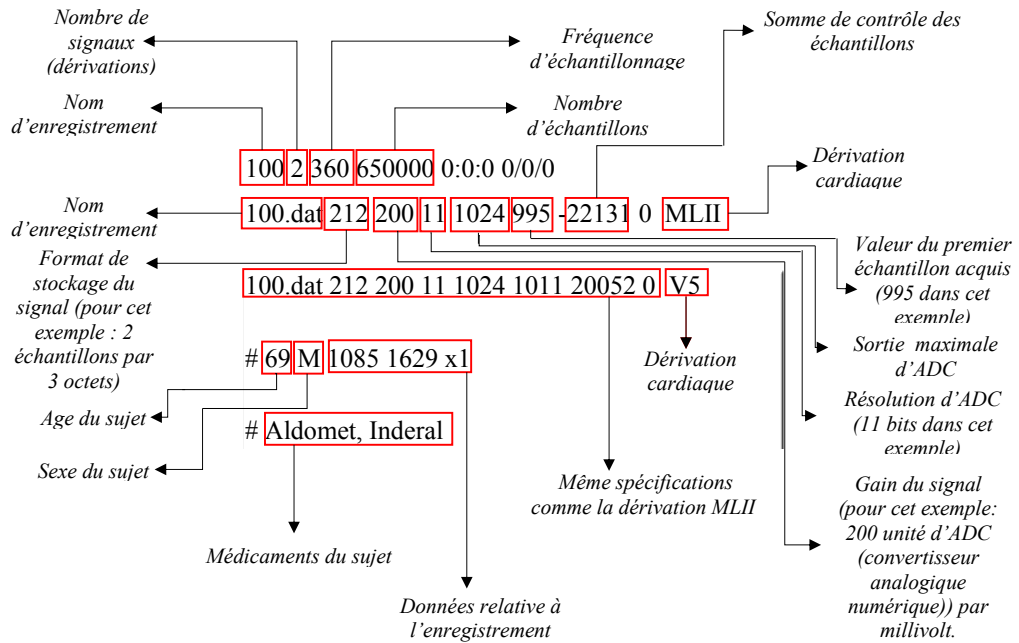


FIGURE 1.15 – Fichier .hea de l'enregistrement 100.dat de la base de données MIT-BIH PhysioBank.



FIGURE 1.16 – L'enregistrement 233.dat de la base de données MIT-BIH PhysioBank.

TABLE 1.1 – Annotations de la base de données MIT-BIH PhysioBank.

Code	Description
N	Battement Normal ( <i>Normal beat</i> )
L	Battement de bloc de branche gauche ( <i>Left bundle branch block beat</i> )
R	Battement de bloc de branche droit ( <i>Right bundle branch block beat</i> )
B	Battement de bloc de branchement (non spécifié) ( <i>Bundle branch block beat (unspecified)</i> )
A	Battement prématuré auriculaire ( <i>Atrial premature beat</i> )
a	Battement prématuré auriculaire aberré ( <i>Aberrated atrial premature beat</i> )
J	Battement prématuré nodal (jonctionnel) ( <i>Nodal (junctional) premature beat</i> )
S	Battement prématuré ou ectopique supraventriculaire (auriculaire ou nodal) ( <i>Supraventricular premature or ectopic beat (atrial or nodal)</i> )
V	Contraction ventriculaire prématurée ( <i>Premature ventricular contraction</i> )
r	R-on-T contraction ventriculaire prématurée ( <i>R-on-T premature ventricular contraction</i> )
F	Fusion du battement ventriculaire et normal ( <i>Fusion of ventricular and normal beat</i> )
e	Battement d'échappement atriale ( <i>Atrial escape beat</i> )
j	Battement d'échappement nodal (jonctionnel) ( <i>Nodal (junctional) escape beat</i> )
n	Battement d'échappement supraventriculaire (atrial ou nodal) ( <i>Supraventricular escape beat (atrial or nodal)</i> )
E	Battement d'échappement ventriculaire ( <i>Ventricular escape beat</i> )
f	Fusion du battement rythmé et normal ( <i>Fusion of paced and normal beat</i> )
Q	Battement inclassable ( <i>Unclassifiable beat</i> )

#### 1.4.2 Correspondance entre les standards de l'AAMI et la base de données MIT-BIH PhysioBank

La correspondance entre les standards de l'AAMI et le système utilisé pour notre base de données (MIT-BIH Physio Bank) [58] est repris au Tableau 1.2.

TABLE 1.2 – Standards de l'AAMI et correspondance avec le système utilisé pour notre base de données [69].

AAMI heartbeat classe	N	S	V	F	Q
Description	Any heartbeat not in the S, V, F or Q classes	Supraventricular ectopic beat	Ventricular ectopic beat	Fusion beat	Unknown beat
MIT-BIH heartbeat types	normal beat (N) left bundle branch block beat (L) right bundle branch block beat (R) atrial escape beats (e) nodal (junctional) escape beat (j)	atrial premature beat (A) aberrated atrial premature beat (a) nodal (junctional) premature beat (J) Supraventricular premature beat (S)	premature ventricular contraction (V) ventricular escape beat (E)	fusion of ventricular and normal beat (F)	paced beat (P) fusion of paced and normal beat (f) unclassified beat (Q)

## 1.5 Conclusion

Plusieurs activités électriques peuvent être détectées au niveau du corps humain (ECG, EMG, EEG). Le signal électrocardiogramme (ECG) est considéré dans notre cas. L'électrocardiogramme représente l'activité électrique du coeur. Ce signal peut être utilisé dans le domaine médical pour détecter les anomalies de fonctionnement du coeur (diagnostic). L'électrophysiologie cardiaque a été expliquée en détail dans ce chapitre où nous avons essayé d'expliquer et de vulgariser toutes les notions liées au signal électrocardiogramme. Tous les types de bruit qui peuvent contaminer l'ECG ont été présentés et bien ainsi que la base de données MIT-BIH PhysioBank d'où nous avons pris les signaux sur lesquels nous avons validé nos expérimentations.



**LOGIQUE FLOUE ET ALGORITHMES  
METAHEURISTIQUES**

---

*La logique floue et les algorithmes métaheuristique ainsi que leurs combinaisons ont été étudiés de manière approfondie dans la littérature dans le but de prouver leur efficacité. Ces deux outils seront utilisés dans notre thèse pour la modélisation, l'identification, et le filtrage du signal électrocardiogramme. Nous exposons dans ce deuxième chapitre les notions liées à la logique floue et algorithmes métaheuristiques .*

**Sommaire**

---

<b>2.1</b>	<b>Introduction</b>	<b>28</b>
<b>2.2</b>	<b>Logique floue type-1</b>	<b>29</b>
2.2.1	Ensembles flous type-1	29
2.2.2	Opérations de base sur les ensembles flous	30
2.2.3	Variables linguistiques	31
2.2.4	Système d'inférence floue	32
2.2.5	Exemple d'un système flou type-1	32
<b>2.3</b>	<b>Logique floue type-2</b>	<b>33</b>
2.3.1	Représentation d'un ensemble flou type-2	34
2.3.2	Types d'ensembles flous type-2	35
2.3.3	Opération sur les ensembles flous type-2	35
2.3.4	Structure d'un système flou type-2	38
<b>2.4</b>	<b>Algorithmes métaheuristiques</b>	<b>41</b>
2.4.1	Problème d'optimisation	41
2.4.2	Les types de problèmes d'optimisation	42
2.4.3	Les méthodes métaheuristiques classiques	43
2.4.4	L'intelligence en essaims ou Swarm Intelligence	45

---

2.4.5 Autres méthodes évolutionnaires pour l'optimisation . . . . .	49
2.5 Conclusion . . . . .	52

---

## 2.1 Introduction

**L**e terme d'ensemble flou fut paru la première fois en 1965 lorsque le professeur Lotfi A. Zadeh, de l'université de Berkeley aux USA, publie un article intitulé « Ensembles flous (*Fuzzy sets*) » [70]. Il a réalisé depuis de nombreuses avancées théoriques majeures dans le domaine et a été rapidement accompagné par de nombreux chercheurs développant des travaux théoriques. Parallèlement, certains chercheurs se sont penchés sur la résolution par logique floue des problèmes réputés difficiles. Ainsi en 1975, le professeur Mamdani à Londres développe une stratégie pour le contrôle des procédés et présente des résultats très encourageants qu'il les a obtenus sur la conduite d'un moteur à vapeur. En 1978, la société danoise F. L. Smith réalise le contrôle d'un four à ciment. C'est là, la première véritable application industrielle de la logique floue. La logique floue, dans la plupart des applications actuelles, permet de prendre en compte toutes sortes de connaissances quantitatives de concepteurs et d'opérateurs dans l'automatisation des systèmes. Dans le domaine des processus de production continue, et dans les automatismes les applications se sont également multipliées. La logique floue s'y développe car il s'agit d'une approche essentiellement pragmatique, efficace et générique. On dit parfois qu'elle permet de systématiser ce qui est du domaine de l'empirisme, et donc difficile à maîtriser. La théorie des ensembles flous fournit une méthode pertinente et facilement réalisable dans des applications temps réel ; elle permet de transcrire et rendre dynamiques les connaissances des concepteurs ou des opérateurs.

Une métaheuristique est un algorithme d'optimisation visant à résoudre des problèmes d'optimisation difficile (souvent issus des domaines de la recherche opérationnelle, de l'ingénierie ou de l'intelligence artificielle). Les calculs métaheuristicques sont généralement des algorithmes stochastiques itératifs, qui progressent vers un optimum global, c'est-à-dire l'extremum global d'une fonction. Elles se comportent comme des algorithmes de recherche tentant d'apprendre les caractéristiques d'un problème afin d'en trouver une approximation de la meilleure solution. Il existe un grand nombre de métaheuristicques différentes, allant de la simple recherche locale à des algorithmes complexes de recherche globale. Ces techniques sont souvent inspirées par des mécanismes biologiques ou biogéographiques. L'analogie entre un problème d'optimisation et ces phénomènes biologiques et biogéographiques a été formalisée par plusieurs approches, à commencer par les algorithmes génétiques.

Ce chapitre décrit les concepts de base, opérations et structure des systèmes flous type-1 et type-2, comme il décrit les notions de base liées aux problèmes d'optimisation ainsi que les principes et les algorithmes de quelques techniques métaheuristiques à savoir le GA, PSO, FA et BBO.

## 2.2 Logique floue type-1

### 2.2.1 Ensembles flous type-1

Dans la théorie des ensembles, un élément appartient ou n'appartient pas à un ensemble. La notion d'ensemble est à l'origine de nombreuses théories mathématiques. Cette notion essentielle ne permet cependant pas de rendre compte de situations pourtant simples et rencontrées fréquemment. A titre d'exemple, si on considère l'univers des fruits, il est facile de définir l'ensemble des pommes. Par contre, il sera plus difficile de définir l'ensemble des pommes mûres. on conçoit bien que la pomme mûrit progressivement..., la notion de pomme mûre est donc graduelle.

C'est pour prendre en compte de telles situations qu'a été créée la notion d'ensemble flou. La théorie des ensembles flous repose sur la notion d'appartenance partielle : chaque élément appartient partiellement ou graduellement aux ensembles flous qui ont été définis. Les contours de chaque ensemble flou (cf., [Figure 2.1](#)) ne sont pas « nets », mais « flous » ou « graduels ».




FIGURE 2.1 – Comparaison d'un ensemble classique et d'un ensemble flou.

Un ensemble flou  $B$  est défini sur un ensemble de valeur appelé l'univers du discours  $X$  par sa « fonction d'appartenance »  $\mu_B(X)$ , qui correspond à la notion de « fonction caractéristique » en logique classique. La fonction d'appartenance comprise généralement entre 0 et 1 et qui quantifie le degré avec lequel chaque élément  $x$  de  $X$  appartient de  $B$ .

Un ensemble flou  $B$  dans l'univers du discours  $X$  peut s'écrire comme suit [70, 71, 72, 73] :

$$B = \{(x, \mu_B(x)) | x \in X\}, \quad (2.1)$$

où  $\mu_B(x)$  est le degré d'appartenance de  $x$  dans  $B$ .

Selon le type de la fonction d'appartenance, différents types d'ensembles flous seront obtenus. Les fonctions d'appartenance pourraient être classées en deux groupes : celles qui sont faites de lignes droites et celles dont la forme est Gaussienne. Les fonctions d'appartenance les plus couramment utilisées sont présentées dans les Figures 2.2 :

- **Fonction d'appartenance Triangulaire** : elle est définie par une valeur inférieure  $a$ , une valeur supérieure  $b$  et une valeur modale  $m$  de sorte que  $a < m < b$  (cf., Figure 2.2(a)).
- **Fonction d'appartenance Singleton** : cette fonction d'appartenance prend la valeur 0 dans tout l'univers du discours sauf au point  $m$  où elle prend la valeur 1 (cf., Figure 2.2(b)).
- **Fonction d'appartenance Gaussienne** : elle est définie par sa moyenne  $m$  et son écart type  $\sigma$  (cf., Figure 2.2(c)).

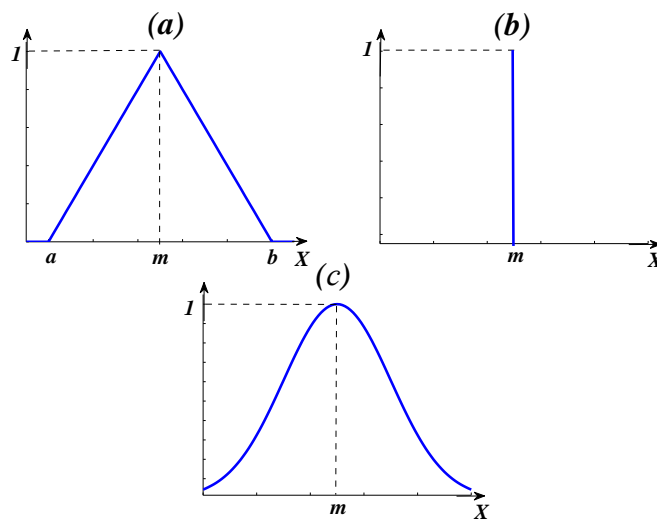


FIGURE 2.2 – Fonction d'appartenance : (a) Triangulaire, (b) Singleton, (c) Gaussienne.

### 2.2.2 Opérations de base sur les ensembles flous

Soient  $A$  et  $B$  deux ensembles flous et  $\mu_A(x)$  et  $\mu_B(x)$  sont leurs fonctions d'appartenance respectivement sur l'univers du discours  $X$ . Comme dans la théorie des ensembles classiques, on définit l'intersection, l'union des ensembles flous ainsi que le complémentaire d'un ensemble flou. Ces relations sont traduites par les opérateurs « et », « ou » et « non ». De nouvelles fonctions d'appartenance liées à ces opérateurs sont établies :

- ✓  $x$  appartient à  $A$  et  $B \Leftrightarrow x \in A \cap B \Leftrightarrow \mu_{A \cap B}(x)$ .
- ✓  $x$  appartient à  $A$  ou  $B \Leftrightarrow x \in A \cup B \Leftrightarrow \mu_{A \cup B}(x)$ .
- ✓  $x$  appartient au complément de  $A \Leftrightarrow x \in \bar{A} \Leftrightarrow \mu_{\bar{A}}(x)$ .

L'opérateur « et » se définit par une norme triangulaire ( $t$  - norme)  $T$  :

$$\begin{aligned} T : [0, 1] \times [0, 1] &\longrightarrow [0, 1] \\ (x, y) &\longmapsto z = xTy. \end{aligned} \quad (2.2)$$

De même, l'opérateur « ou » se définit par une co-norme triangulaire ( $T^*$ ) qu'on appelle aussi  $s$  - norme ( $S$ ) :

$$\begin{aligned} S : [0, 1] \times [0, 1] &\longrightarrow [0, 1] \\ (x, y) &\longmapsto z = xSy. \end{aligned} \quad (2.3)$$

Les opérateurs les plus utilisés en logique floue sont :

1) L'opérateur « et » pour la  $t$  - norme, qui correspond à l'intersection de deux ensembles  $A$  et  $B$ . Il peut être réalisé par :

- ✓ La fonction "Min" :  $\mu_{A \cap B}(x) = \min(\mu_A(x), \mu_B(x))$ .
- ✓ La fonction arithmétique "Somme" :  $\mu_{A \cup B}(x) = \mu_A(x) + \mu_B(x)$ .

2) L'opérateur « ou » pour la  $s$  - norme, qui correspond à l'union de deux ensembles  $A$  et  $B$ . Il peut être réalisé par :

- ✓ La fonction "Max" :  $\mu_{A \cup B}(x) = \max(\mu_A(x), \mu_B(x))$ .
- ✓ La fonction "Somme" :  $\mu_{A \cup B}(x) = \mu_A(x) + \mu_B(x)$ .

3) L'opérateur « non » est réalisé par :  $\mu_{\bar{A}}(x) = 1 - \mu_A(x)$ .

### 2.2.3 Variables linguistiques

En logique floue les concepts des systèmes sont normalement représentés par des variables linguistiques. Une variable linguistique est une variable dont les valeurs sont des mots ou des phrases utilisées couramment dans une langue naturelle ou un langage artificiel [74]. Une variable linguistique est définie par [75] :

$$(X, U, T(X), \mu_x), \quad (2.4)$$

où  $X$  désigne le nom de la variable,  $U$  est l'univers du discours associé à la variable  $X$  (appelé aussi référentiel [71]),  $T(x) = \{T_1, T_2, \dots, T_n\}$  est l'ensemble des valeurs linguistiques de la variables  $X$  (appelé également termes linguistiques ou étiquettes linguistiques), et finalement  $\mu_x$  sont les fonctions d'appartenance associées à l'ensemble de termes linguistiques.

### 2.2.4 Système d'inférence floue

Un système d'inférence floue (SIF) a comme but de transformer les données d'entrée en données de sortie à partir de l'évaluation d'un ensemble de règles. Les entrées sont issues du processus de fuzzification et l'ensemble de règles normalement sont définies par le savoir-faire de l'expert. Un SIF (cf., [Figure 2.3](#)) est constitué de trois étapes : a) Fuzzification, b) Inférence et c) Défuzzification.

La première étape est la fuzzification, qui consiste à caractériser les variables linguistiques utilisées dans le système. Il s'agit donc d'une transformation des entrées réelles en une partie floue définie sur un espace de représentation lié à l'entrée. Cet espace de représentation est normalement un sous-ensemble flou. Durant l'étape de la fuzzification, chaque variable d'entrée et de sortie est associée à des sous-ensembles flous.

La deuxième étape est le moteur d'inférence, qui est un mécanisme permettant de condenser l'information d'un système à travers un ensemble de règles définies pour la représentation d'un problème quelconque. Chaque règle délivre une conclusion partielle qui est ensuite agrégée aux autres règles pour fournir une conclusion (agrégation).

La troisième étape est la défuzzification, cette opération est l'inverse de la fuzzification et permet de transformer les sorties floues de l'inférence en une valeur non floue comme réponse finale du SIF.

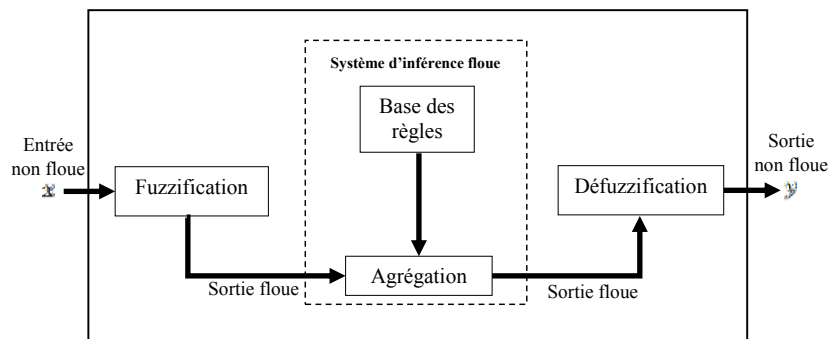


FIGURE 2.3 – Système d'inférence floue (SIF).

### 2.2.5 Exemple d'un système flou type-1

Le modèle flou « Takagi-Sugeno Kang (TSK) » est un approximateur universel de fonctions réelles continues qui sont définies dans un sous-ensemble fermé et borné de nombre réel de  $n$  – dimensions ( $R^n$ ). Cette forte propriété du modèle TSK trouve plusieurs applications dans la modélisation des systèmes dynamiques [76]. Un système flou de type TSK est décrit par un ensemble de règles *IF – THEN* qui représentent les relations entrée-

sortie d'un système. Le système flou TKS du premier ordre est le plus couramment utilisé. Il a une base de  $M$  règles, chacune ayant  $p$  antécédents, où la  $l^{ieme}$  règle est exprimée comme suite :

$$\begin{aligned} R^l : & \text{ IF } x_1 \text{ is } F_1^l \text{ and } x_2 \text{ is } F_2^l \text{ and, } \dots, \text{ and } x_p \text{ is } F_p^l, \\ & \text{ THEN } y^l = c_0^l + c_1^l x_1 + c_2^l x_2 + \dots + c_p^l x_p, \end{aligned} \quad (2.5)$$

où  $l = 1, 2, \dots, M$ ;  $c_j^l$  les paramètres de la conséquence, pour  $j = 0, 1, \dots, p$ ;  $x_j$  est l'entrée du système flou;  $y^l$  est la sortie de la  $l^{ieme}$  règle; et  $F_j^l$  est l'ensemble flou, pour  $j = 0, 1, \dots, p$ . La sortie finale du modèle TSK du premier ordre non complète est déduite comme suite [77] :

$$r = \sum_{l=1}^M f^l y^l, \quad (2.6)$$

où  $f^l$  sont les degrés d'activation des règles définies comme suit :

$$f^l = T_{j=1}^p \mu_{F_j^l}(x_j), \quad (2.7)$$

où  $T$  dénote la  $t$ -norme.

Lorsque les fonctions d'appartenance sont Gaussiennes (cf., Figure 2.2(c)) :

$$\mu_{F_j^l}(x_j) = \exp \left[ -\frac{1}{2} \left( \frac{x_j - m_j^l}{\sigma_j^l} \right)^2 \right]. \quad (2.8)$$

et la  $t$ -norme est utilisée, l'Équation 2.6 peut être exprimée comme suit :

$$r = \sum_{l=1}^M y^l \prod_{j=1}^P \exp \left[ -\frac{1}{2} \left( \frac{x_j - m_j^l}{\sigma_j^l} \right)^2 \right], \quad (2.9)$$

où  $m_j^l$  et  $\sigma_j^l$  sont les centres (moyennes) et les écarts types (déviations standards) du  $l^{iem}$  ensemble flou, respectivement.

## 2.3 Logique floue type-2

La logique floue type-2 a été introduite par le père fondateur de la logique floue Zadeh en 1975 [74], comme une extension de la logique floue type-1. Un ensemble flou type-2 est caractérisé par une fonction d'appartenance floue, dont le degré d'appartenance de chaque élément de l'ensemble est lui-même un ensemble flou dans  $[0, 1]$ . Le problème principal avec les systèmes flous type-1 est qu'ils peuvent fournir des performances inacceptables quand l'incertitude et l'imprécision se posent. L'incertitude peut être soit au niveau de la forme de la fonction d'appartenance soit dans l'un de ses paramètres. Ce problème de la logique floue type-1 était partiellement résolu par l'introduction de la logique floue type-2.

### 2.3.1 Représentation d'un ensemble flou type-2

Une fonction d'appartenance type-2 peut être vue comme une fonction à deux variables. Pour chaque  $x$  de l'univers du discours et degré d'appartenance primaire  $\mu_1$ , nous avons une appartenance secondaire, qui est un nombre ordinaire noté  $\mu_2$ . Alors, une fonction d'appartenance type-2 peut être représentée comme suit :

$$\mu_2(x, \mu_1) : X \times [0, 1] \rightarrow [0, 1], \quad (2.10)$$

où  $X$  est l'espace des entrées  $x$ .

#### 2.3.1.1 Exemple

On considère un ensemble flou type-1 caractérisé par une fonction d'appartenance Gaussienne de moyenne  $M$  et d'écart type  $\sigma_x$ . Le degré d'appartenance pour chaque élément  $x$  est donné par :

$$m(x) = \exp\left(-\frac{1}{2}\left(\frac{x-M}{\sigma_x}\right)^2\right). \quad (2.11)$$

Dans le concept des ensembles flous type-1, le degré d'appartenance d'un élément est un nombre ordinaire qui appartient à l'intervalle  $[0, 1]$ . On suppose que cette appartenance n'est pas un nombre mais un ensemble flou type-1. On note les éléments du domaine de cet ensemble par  $\mu_1$  et on l'appelle appartenance primaire de  $x$ . On note l'appartenance de ces appartenances primaires  $\mu_2(x, \mu_1)$  et on l'appelle appartenance secondaire de  $x$ .

Si les appartenances secondaires sont des Gaussiennes de moyenne  $m(x)$  et de déviation standard  $\sigma_m$  alors :

$$\mu_2(x, \mu_1) = \exp\left(-\frac{1}{2}\left(\frac{\mu_1 - m(x)}{\sigma_m}\right)^2\right), \quad (2.12)$$

avec  $\mu_1 \in [0, 1]$  et  $m(x)$  est donnée par l'Équation 2.11, d'où :

$$\mu_2(x, \mu_1) = \exp\left(-\frac{1}{2}\left(\frac{\mu_1 - \exp\left(-\frac{1}{2}\left(\frac{x-M}{\sigma_x}\right)^2\right)}{\sigma_m}\right)^2\right). \quad (2.13)$$

Le degré d'appartenance de chaque élément pour le cas d'un ensemble flou type-2 représente toutes les appartenances primaires ainsi que les appartenances secondaires correspondantes et peut être écrit sous la forme suivante :

$$\mu(x) = \int_{\mu_1 \in [0,1]} \mu_2(x, \mu_1) / \mu_1, x \in X. \quad (2.14)$$

La Figure 2.4(a) est une représentation tridimensionnelle d'un ensemble flou type-2 Gaussien, ayant une fonction d'appartenance principale Gaussienne, et la Figure 2.4(b) représente le degré d'appartenance flou type Gaussien correspondant à  $x = 1.25$ .

### 2.3.2 Types d'ensembles flous type-2

Selon la forme de l'appartenance primaire, on distingue principalement trois sortes d'ensembles flous type-2 : Intervalle, Gaussienne et Triangulaire.

#### 2.3.2.1 Ensemble type-2 Intervalle

Dans ce type d'ensembles, le degré d'appartenance de chaque point est un ensemble ordinaire dont le domaine de définition est incluse dans l'intervalle  $[0, 1]$  [78, 79, 80]. Dans ce cas, toutes les appartenances secondaires sont égales à 1. Notant que malgré que chaque degré d'un ensemble type-2 intervalle est un ensemble ordinaire, l'ensemble lui-même est de type-2, parce que les degrés d'appartenance sont des ensembles et pas de nombres ordinaires.

#### 2.3.2.2 Ensemble type-2 Gaussien

Dans ce type d'ensembles, le degré d'appartenance de chaque point est un ensemble type-1 Gaussien dont le domaine de définition est inclus dans l'intervalle  $[0, 1]$ . Notons qu'il n'est pas nécessaire que la fonction d'appartenance principale soit aussi Gaussienne.

#### 2.3.2.3 Ensemble type-2 Triangulaire

Dans ce type d'ensembles, le degré d'appartenance de chaque point est un ensemble type-1 triangulaire dont le domaine de définition est inclus dans l'intervalle  $[0, 1]$  [78].

### 2.3.3 Opération sur les ensembles flous type-2

Supposons que nous avons deux ensembles flous type-1,  $A \in X$  et  $B \in X$  caractérisés par des fonctions d'appartenance  $\theta_1$  et  $\theta_2$  :

$$A = \sum_i \theta_1(x_i)/x_i. \quad (2.15)$$

$$B = \sum_i \theta_2(x_i)/x_i. \quad (2.16)$$




FIGURE 2.4 – (a) Représentation tridimensionnelle d'un ensemble flou type-2 Gaussien. (b) Degré d'appartenance flou correspondant à  $x = 4.25$ .

En utilisant la  $T$ -conorm max et la norme  $T$ -norm, les fonctions d'appartenance de l'union, l'intersection et du complément seront données par [81, 82] :

$$\mu_{A \cup B} = \max\{\theta_1(x_i), \theta_2(x_i)\} \quad \forall i. \quad (2.17)$$

$$\mu_{A \cap B} = \min\{\theta_1(x_i), \theta_2(x_i)\} \quad \forall i. \quad (2.18)$$

$$\mu_{\bar{A}}(x_i) = 1 - \theta_1(x_i) \quad \forall i. \quad (2.19)$$

$$\mu_{\bar{B}}(x_i) = 1 - \theta_2(x_i) \quad \forall i. \quad (2.20)$$

Puisque  $A$  et  $B$  sont des ensembles flous type-1, alors leurs valeurs d'appartenance  $\theta_1(x_i)$  et  $\theta_2(x_i)$  sont des nombres ordinaires, par conséquent, pour chaque  $x_i$ , les opérations (2.15)–(2.20) peuvent être évaluées directement en une seule étape.

Maintenant, supposons que  $\tilde{A} \in X$  et  $\tilde{B} \in X$  sont des ensembles flous type-2. Dans ce cas, les degrés d'appartenance  $\theta_1(x_i)$  et  $\theta_2(x_i)$  sont des ensembles flous type-1, donc pour calculer l'union, l'intersection et le complément de  $\tilde{A}$  et  $\tilde{B}$ , nous aurons besoin d'étendre (généraliser) les opérations  $\min$ ,  $\max$  et l'opération de négation vers des ensembles flous. Pour cela, nous allons utiliser le fameux principe d'extension de zadeh [83].

Soient  $\mu_{\tilde{A}}(x)$  et  $\mu_{\tilde{B}}(x)$  deux appartenances floues (ensembles flous dans  $J \subseteq [0, 1]$ )

dans les ensembles flous type-2  $\tilde{A}$  et  $\tilde{B}$  :

$$\mu_{\tilde{A}}(x) = \sum_i f_x(u_i)/\mu_i; u_i \in J. \quad (2.21)$$

$$\mu_{\tilde{B}}(x) = \sum_i g_x(w_i)/w_i; w_i \in J. \quad (2.22)$$

Notons que dans (2.21) et (2.22),  $u_i$  et  $w_i$  sont des variables factices, utilisées juste pour différencier entre les différentes appartenances primaires de  $x$  dans  $\tilde{A}$  et  $\tilde{B}$ , respectivement. En utilisant le principe d'extension de zadeh, une opération binaire réelle  $*$  peut être étendue vers les appartenances floues  $\mu_{\tilde{A}}(x)$  et  $\mu_{\tilde{B}}(x)$  :

$$\mu_{\tilde{A}}(x) * \mu_{\tilde{B}}(x) = \sum_{i,j} (f_x(u_i) \wedge g_x(w_j)) / u_i * w_j, \quad (2.23)$$

où  $\wedge$  indique l'opération *min*, donc, en appliquant ce principe aux ensembles  $\tilde{A}$  et  $\tilde{B}$ , les fonctions d'appartenance pour l'union, l'intersection et le complément deviennent :

- **Pour l'union :**

$$\begin{aligned} \tilde{A} \cup \tilde{B} &\Leftrightarrow \mu_{\tilde{A} \cup \tilde{B}}(x) = \mu_{\tilde{A}}(x) \cup \mu_{\tilde{B}}(x); x \in X \\ &= \left( \sum_i f_x(u_i)/u_i \right) \cup \left( \sum_j g_x(w_j)/w_j \right) \\ &= \sum_{i,j} (f_x(u_i) \wedge g_x(w_j)) / u_i \vee w_j. \end{aligned} \quad (2.24)$$

- **Pour l'intersection :**

$$\begin{aligned} \tilde{A} \cap \tilde{B} &\Leftrightarrow \mu_{\tilde{A} \cap \tilde{B}}(x) = \mu_{\tilde{A}}(x) \cap \mu_{\tilde{B}}(x); x \in X \\ &= \left( \sum_i f_x(u_i)/u_i \right) \cap \left( \sum_j g_x(w_j)/w_j \right) \\ &= \sum_{i,j} (f_x(u_i) \wedge g_x(w_j)) / u_i \wedge w_j. \end{aligned} \quad (2.25)$$

- **Pour le complément :**

$$\begin{aligned} \bar{\tilde{A}} &\Leftrightarrow \mu_{\bar{\tilde{A}}}(x) = \neg \mu_{\tilde{A}}(x); x \in X \\ &= \sum_i f_x(u_i)/(1 - u_i). \end{aligned} \quad (2.26)$$

$$\begin{aligned} \bar{\tilde{B}} &\Leftrightarrow \mu_{\bar{\tilde{B}}}(x) = \neg \mu_{\tilde{B}}(x); x \in X \\ &= \sum_j g_x(w_j)/(1 - w_j). \end{aligned} \quad (2.27)$$

où  $\wedge$  et  $\vee$  représentent les opérations *max* et *min*, respectivement. Dans ce cas (type-2) et comme dans [78, 79, 80], nous allons appeler les opérations  $\cup$ ,  $\cap$  et  $\neg$  : *join*, *meet* et *negation*, respectivement. Les mêmes notations seront utilisées dans le cas continu.

### 2.3.4 Structure d'un système flou type-2

Un système flou type-2 est similaire à ce-celui du système flou type-1 (cf., sous-section 2.2.4) avec la particularité de l'utilisation d'un réducteur de type pour convertir les ensembles flous type-2 à la sortie du système d'inférence en ensembles flous type-1 avant la phase de défuzzification. La Figure 2.5 représente un système flou type-2 [84, 85, 86].

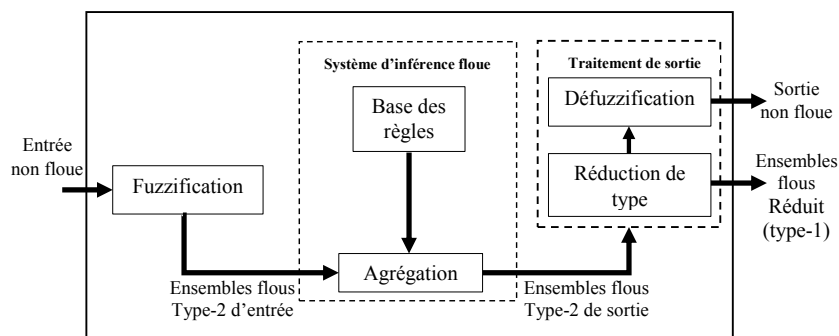


FIGURE 2.5 – Structure d'un système flou type-2.

#### 2.3.4.1 Fuzzification

Contrairement à la fonction d'appartenance type-1, la fonction d'appartenance type-2 donne plusieurs degrés d'appartenance (ou dimensions) pour chaque entrée. Par conséquent, l'incertitude sera mieux représentée. Cette représentation va nous permettre de tenir compte de ce qui a été négligé par le type-1.

#### 2.3.4.2 Base des règles

Dans le cas du type-1, nous avons généralement des règles de la forme *IF – THEN*, où la *l<sup>ième</sup>* règle possède la forme suivante :

$$\begin{aligned} R^l : & \text{ IF } x_1 \text{ is } F_1^l \text{ and } x_2 \text{ is } F_2^l \text{ and, } \dots, \text{ and } x_p \text{ is } F_p^l, \\ & \text{ THEN } y \text{ is } G^l, \end{aligned} \quad (2.28)$$

où  $x_1 \in X_1$ ,  $x_2 \in X_2, \dots, x_p \in X_p$  sont les entrées, les  $F_i^l$ s sont les ensembles flous des prémisses tel que  $i = 1, 2, \dots, p$ ,  $y \in Y$  la sortie, et les  $G^l$ s sont les ensembles flous des conséquences.

La différence entre le type-1 et le type-2 réside seulement dans la nature des fonctions d'appartenance, donc, la structure des règles dans le cas du type-2 restera exactement la même, la seule différence étant que quelques (ou toutes) les fonctions d'appartenance seront de type-2 ; alors, la  $l^{ieme}$  règle d'un système flou type-2 aura la forme [86, 87] :

$$\begin{aligned} R^l : & \text{ IF } x_1 \text{ is } \tilde{F}_1^l \text{ and } x_2 \text{ is } \tilde{F}_2^l \text{ and, } \dots, \text{ and } x_p \text{ is } \tilde{F}_p^l, \\ & \text{ THEN } y \text{ is } \tilde{G}^l. \end{aligned} \quad (2.29)$$

Il n'est pas nécessaire que toutes les fonctions d'appartenance des prémisses et des conséquences soient du type-2. Il suffit qu'une seule fonction d'appartenance dans une prémisse ou dans une conséquence soit du type-2 pour que tout le système soit du type-2.

### 2.3.4.3 Inférence

Dans cette thèse et pour des raisons de simplifications de calcul, seuls les ensembles flous type-2 intervalle sont utilisés [88].

Le système d'inférence dans un système flou type-2 utilise la base des règles floues (2.28) qui représente une relation floue type-2 entre l'espace d'entrée  $X_1 \times X_2 \times \dots \times X_p$  et l'espace de sortie  $Y$  du système flou. Notons la fonction d'appartenance de cette relation floue type-2 par  $\mu_{\tilde{F}_1^l \times \dots \times \tilde{F}_p^l \rightarrow \tilde{G}^l}(\underline{x}, y)$  où  $\tilde{F}_1^l \times \dots \times \tilde{F}_p^l$  dénote le produit cartésien de  $\tilde{F}_1^l, \tilde{F}_2^l, \dots, \tilde{F}_p^l$  et  $\underline{x} = (x_1, x_2, \dots, x_p)^T$ .

Lorsque une entrée  $\underline{x}'$  est appliquée, la composition de l'ensemble flou  $\underline{X}'$  à qui  $\underline{x}'$  appartient et la règle  $R^l$  est calculée par la composition sup-Star suivante [88, 89] :

$$\mu_{\underline{X}' \circ \tilde{F}_1^l \times \dots \times \tilde{F}_p^l \rightarrow \tilde{G}^l}(y) = \bigcup_{\underline{x} \in \underline{X}'} \left[ \mu_{\underline{X}'}(\underline{x}) \cap \mu_{\tilde{F}_1^l \times \dots \times \tilde{F}_p^l \rightarrow \tilde{G}^l}(\underline{x}, y) \right]. \quad (2.30)$$

Puisque nous utilisons une fuzzification de type singleton, l'ensemble flou  $\underline{X}'$  est tel qu'il possède un degré d'appartenance unitaire à  $\underline{x} = \underline{x}'$  est zéro ailleurs ; par conséquent (2.30) se réduit à :

$$\mu_{\underline{X}' \circ \tilde{F}_1^l \times \dots \times \tilde{F}_p^l \rightarrow \tilde{G}^l}(y) = \mu_{\tilde{F}_1^l \times \dots \times \tilde{F}_p^l \rightarrow \tilde{G}^l}(\underline{x}', y). \quad (2.31)$$

Notons l'ensemble de sortie correspondant à la  $l^{ieme}$  règle  $\underline{X}' \circ \tilde{F}_1^l \times \dots \times \tilde{F}_p^l \rightarrow \tilde{G}^l$  par  $\tilde{B}^l$ . Le second membre de (2.31) est calculé en utilisant l'implication minimum ou produit [88, 89] ( qui correspond à l'opération *meet* avec  $T - norm$  minimum ou produit dans le cas de type-2), donc (2.31) peut être écrite comme :

$$\mu_{\tilde{B}^l} = \mu_{\tilde{F}_1^l \times \dots \times \tilde{F}_p^l}(\underline{x}') \cap \mu_{\tilde{G}^l}(y). \quad (2.32)$$

qui est équivalent à :

$$\begin{aligned}\mu_{\tilde{B}^l} &= \mu_{\tilde{F}_1^l}(x_1) \cap \mu_{\tilde{F}_2^l}(x_2) \cap \dots \cap \mu_{\tilde{F}_p^l}(x_p) \cap \mu_{\tilde{G}^l}(y) \\ &= \mu_{\tilde{G}^l}(y) \cap \left[ \prod_{i=1}^p \mu_{\tilde{F}_i^l}(x_i) \right],\end{aligned}\quad (2.33)$$

où  $\cap$  dénote l'opération *meet* basée sur la  $T$  – norme choisie.

Comme seulement les ensembles flous type-2 intervalle sont utilisés et l'opération  $t$  – norme produit est mise en oeuvre, alors l'intervalle d'activation associé au  $J^{iem}$  ensemble flou de la sortie est l'ensemble flou type-1 intervalle défini par :

$$F^l(\underline{x}) = [\underline{f}^l(\underline{x}), \overline{f}^l(\underline{x})], \quad (2.34)$$

où  $\underline{f}^l(\underline{x}) = \underline{\mu}_{\tilde{F}_1^l}(x_1) * \underline{\mu}_{\tilde{F}_2^l}(x_2) * \dots * \underline{\mu}_{\tilde{F}_p^l}(x_p)$  et  $\overline{f}^l(\underline{x}) = \overline{\mu}_{\tilde{F}_1^l}(x_1) * \overline{\mu}_{\tilde{F}_2^l}(x_2) * \dots * \overline{\mu}_{\tilde{F}_p^l}(x_p)$ .

Les termes  $\underline{\mu}_{\tilde{F}_p^l}(x_p)$  et  $\overline{\mu}_{\tilde{F}_p^l}(x_p)$  sont respectivement des degrés d'appartenance inférieur et supérieur relatifs à  $\mu_{\tilde{F}_p^l}(x_p)$ .

#### 2.3.4.4 Réduction de type

Dans un système flou type-1, où les ensembles de sortie sont des ensembles flous type-1, nous effectuons la déffuzzification en but d'obtenir un nombre représentant la combinaison des ensembles de sortie.

Dans le cas du type-2, les ensembles de sortie sont du type-2; donc nous devons utiliser des versions étendues (en utilisant le principe d'extension) des méthodes de deffuzzification type-1. Puisque la deffuzzification type-1 nous donne un nombre ordinaire à la sortie du système flou, l'opération de deffuzzification étendue dans le cas du type-2 nous donne un ensemble flou du type-1 à la sortie. Puisque cette opération transforme un ensemble flou type-2 à un ensemble flou type-1, on l'appellera alors « Réduction de type », et on appelle l'ensemble flou type-1 obtenu « Ensemble de type réduit ». L'ensemble flou de type réduit doit en suite être déffuzzifié pour obtenir un nombre ordinaire.

Plusieurs méthodes ont été proposées pour calculer la sortie d'un système flou type-2 [90]. Dans cette thèse on va utiliser la méthode proposée par Karnik and Mendel (KM) [91], dont elle est célèbre par la méthode des centres d'ensembles (COS : *Center Of Sets*). L'expression de l'ensemble flou de type réduit par cette méthode est donnée par [92] :

$$Y_{cos}(Y^1, \dots, Y^M, W^1, \dots, W^M) = \int_{y^1} \dots \int_{y^M} \int_{w^1} \dots \int_{w^M} \frac{1}{\frac{\sum_{i=1}^M w^i y^i}{\sum_{i=1}^M w^i}}. \quad (2.35)$$

Étant donné que chaque ensemble dans l'Équation 2.34 est un ensemble type-1 intervalle, alors  $Y_{cos}$  est aussi un ensemble type-1 intervalle dont le domaine est situé sur l'axe

des réels :

$$Y_{cos}(Y^1, \dots, Y^M, W^1, \dots, W^M) = [y_l, y_r], \quad (2.36)$$

où  $y_l$  et  $y_r$  sont deux points de gauche et de droite caractérisant l'ensemble réduit  $Y_{cos}$ . Notons par  $f^l(\underline{x})$  le  $i^{iem}$  élément de l'intervalle d'activation (cf., [Équation 2.34](#)) et  $y^j$  un élément de l'intervalle type-2  $Y^j = [y_l^j, y_r^j]$ . Karnik et Mandel [93] ont développé un algorithme pour calculer les points extrêmes  $y_l$  et  $y_r$  comme suit :

1. Discrétiser l'espace de la sortie  $Y$  en un nombre suffisant de points en choisissant comme segment les centroïdes des ensembles flous impliqués dans l'activation des règles.
2. Trier  $y^j$  dans un ordre croissant :  $y^1 \leq y^2 \leq \dots \leq y^M$ .
3. Initialiser  $f^j$  en prenant comme point de départ :  $f^j = \frac{f^j + \bar{f}^j}{2}$ ,  $j = 1, 2, \dots, M$ .
4. Calculer :  $y_l = \frac{\sum_{j=1}^M y^j f^j}{\sum_{j=1}^M f^j}$  et poser  $y_l' = y_l$ .
5. Trouver un point de commutation  $N$  ( $1 \leq N \leq M - 1$ ) qui satisfait :  $y^N \leq y_l \leq y^{N+1}$ .
6. Poser :  $f^j = \begin{cases} \bar{f}^j, & j < N \\ f^j, & j > N \end{cases}$ .
7. Calculer :  $y_l = \frac{\sum_{j=1}^M y^j f^j}{\sum_{j=1}^M f^j}$ .
8. Poser :  $y_l'' = y_l$ .
9. Si  $y_l'' \neq y_l'$  aller à l'étape 6, Si  $y_l'' = y_l'$  arrêter et poser  $y_l = y_l''$ .
10. Poser  $y_l = y_l''$  et aller à étape 3.

L'algorithme pour calculer  $y_r$  est similaire à celui de l'algorithme  $y_l$ , sauf que toutes les instances de  $y_l, y_l', y_l'', y^N, y^{N+1}$  et  $N$  sont remplacés par  $y_r, y_r', y_r'', y^L, y^{L+1}$  et  $L$ , respectivement.

#### 2.3.4.5 Défuzzification

Pour obtenir une sortie ordinaire du système flou type-2, nous devons defuzzifier l'ensemble du type réduit. Plusieurs méthodes ont été proposées pour ce but, voir , [88, 89].

## 2.4 Algorithmes métaheuristiques

### 2.4.1 Problème d'optimisation

L'optimisation est un aspect fondamental de l'ingénierie et de la résolution de problèmes. L'objectif de l'optimisation est de chercher les valeurs d'un ensemble de paramètres pour maximiser ou minimiser les fonctions objectifs soumises à certaines contraintes.

Un choix de valeurs, pour l'ensembles des paramètres, qui satisfont toutes les contraintes, est appelé une solution faisable. Les solutions faisables avec des valeurs de la fonction objectif qui sont meilleures que les valeurs de toutes les autres solutions possibles, sont appelées les solutions optimales [94].

Un problème d'optimisation peut être formulé sous la forme d'un problème de minimisation ou d'un problème de maximisation. Parfois, nous essayons de minimiser une fonction et parfois, nous essayons de maximiser une fonction. Ces deux problèmes sont facilement convertis l'un à l'autre [95] :

$$\min_x f(x) \Leftrightarrow \max_x [-f(x)]. \quad (2.37)$$

$$\max_x f(x) \Leftrightarrow \min_x [-f(x)]. \quad (2.38)$$

La fonction  $f(x)$  est appelée la fonction objectif, et le vecteur  $x$  est appelé la variable indépendante, ou la variable de décision. Notons, qu'en fonction de contexte, les termes « variable indépendante » et « variable de décision » se réfèrent parfois à l'ensemble du vecteur  $x$ , et se réfèrent parfois à des éléments spécifiques dans le vecteur  $x$ . Les éléments de  $x$  sont aussi appelés les attributs de la solution. Le nombre des éléments de  $x$  est appelé la dimension du problème. Comme le montre les Équations (2.37) et (2.38), tout algorithme conçu pour minimiser une fonction peut facilement être utilisée pour maximiser une fonction, et tout algorithme conçu pour maximiser une fonction peut être facilement utilisé pour minimiser une fonction :

- ✓ Quand nous essayons de minimiser une fonction, nous appelons la valeur de la fonction : la fonction de coût ;
- ✓ Quand nous essayons de maximiser une fonction, nous appelons la valeur de la fonction : la fitness :
- ✘  $\min_x f(x) \Leftrightarrow f(x)$  est appelée le coût ou l'objectif.
- ✘  $\max_x f(x) \Leftrightarrow f(x)$  est appelée la fitness ou l'objectif.

### 2.4.2 Les types de problèmes d'optimisation

Il existe certains types particuliers de problèmes d'optimisation :

- **Les problèmes généraux sans contraintes** : où une fonction non linéaire est définie sur un ensemble de valeurs réelles sans contraintes.
- **Les problèmes généraux avec contraintes** : où une fonction non linéaire est définie sur un ensemble limité de valeurs réelles. Généralement, les problèmes d'optimisation sont des problèmes d'optimisation avec contraintes [95].
- **Les problèmes d'optimisation multi-objectifs** : dans lesquels un problème nécessite la résolution de plusieurs problèmes simultanément. Souvent, les solutions aux

divers problèmes interfèrent entre elles, la meilleure solution est alors une sorte de compromis [96]. L'optimisation multi-objectif cherche à optimiser les composantes de valeurs de vecteur d'une fonction de coût. Contrairement à l'optimisation avec objectif unique, la solution à ce problème n'est pas un seul point, mais une famille de points connus comme l'ensemble Pareto-optimal. Chaque point de cette surface est optimal dans le sens qu'aucune amélioration ne peut être obtenue en un composant de vecteur de coût. L'ensemble des solutions est appelé l'ensemble de Pareto [97].

- **Les problèmes d'optimisation multimodale** : ce sont ceux dans lesquels l'espace de recherche contient plusieurs optimums locaux et il est possible qu'il contient plus d'un optimum global. Ces problèmes sont intéressants, non seulement en raison du défi qu'ils représentent, en évitant les optimums locaux ou la localisation de plus d'un optimum global en même temps, mais parce qu'il existe beaucoup de problèmes du monde réel présentant ces caractéristiques [98].
- **Les problèmes combinatoire** : il existe de nombreux problèmes d'optimisation pour lesquels les variables indépendantes sont limitées à un ensemble de valeurs discrètes. Ces problèmes sont appelés problèmes d'optimisation combinatoire [95].

### 2.4.3 Les méthodes métaheuristiques classiques

Les méthodes métaheuristiques classiques, qui sont connues par les méthodes évolutionnaires sont des méthodes ayant comme principe de faire évoluer une population de base (constituée de solutions au problème à résoudre) par des opérateurs de variations (croisement et mutation). Cette population est soumise à une sélection pour le croisement puis une sélection pour la survie. L'objectif est de faire converger les solutions (appelées « individus ») vers un optimum en respectant certains critères.

Dans les années 70, les premiers travaux sur l'évolution artificielle ont concerné les algorithmes génétiques (GA), les stratégies d'évolution (SE) et la programmation évolutive (PE). Ces trois types d'algorithmes ont utilisés des principes globalement communs car ils se sont tous inspirés des mêmes principes du néo-darwinisme : utilisation d'une population d'individus, évaluation des individus par une fonction, sélection des meilleurs et génération d'une nouvelle population avec des opérateurs de croisement et de mutation. Ensuite, dans les années 90 est apparue la programmation génétique (PG) qui introduit, notamment, des représentations arborescentes [99].

### 2.4.3.1 Les algorithmes génétiques

Les algorithmes génétiques (GA : *Genetic Algorithms*) sont des stratégies d'adaptation et des techniques d'optimisation globale [100]. Ce sont les premiers, les plus connus, et les plus utilisés parmi les méthodes évolutionnaires [95]. Les algorithmes génétiques ont été développés à l'origine dans les années 60 à l'université du Michigan par John Holland et son équipe [101], qui ont mené leur recherche sur des systèmes adaptatifs et robustes. Ils ont été utilisés au début avec des représentations binaires, où les opérateurs de croisement et de mutation jouent un rôle majeur.

Les algorithmes génétiques ont trois applications majeurs nommées la recherche intelligente, l'optimisation et l'apprentissage automatique.

Un GA a généralement quatre composants : une population d'individus, où chaque individu de la population représente une solution candidate au problème d'optimisation, une fonction objectif qui est une fonction d'évaluation par laquelle nous pouvons dire si un individu est une bonne solution ou non, une fonction de sélection qui décide comment choisir les bons individus de la population actuelle pour la création de la génération suivante ; et des opérateurs génétiques tels que le croisement et la mutation, qui explorent de nouvelles régions de l'espace de recherche tout en gardant une partie de l'information actuelle.

La Figure 2.6 montre le fonctionnement itératif simplifié d'un algorithme génétique qui fonctionne grâce à un cycle simple d'étapes [102].

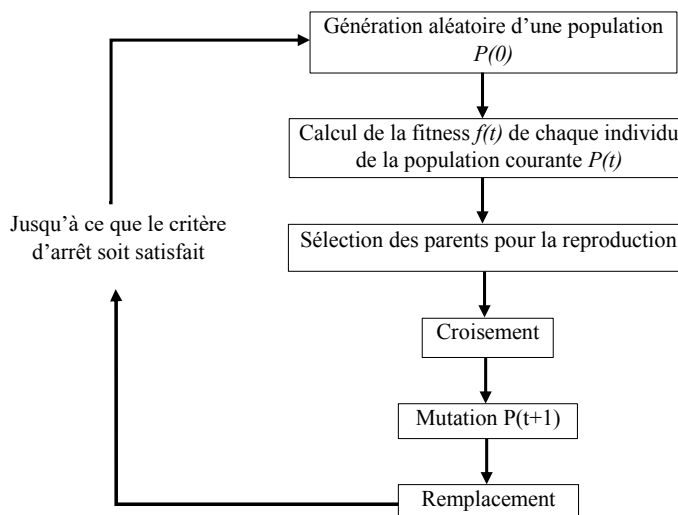


FIGURE 2.6 – Fonctionnement général d'un GA.

#### 2.4.4 L'intelligence en essaims ou Swarm Intelligence

Certains chercheurs séparent l'intelligence en essaims de l'informatique évolutionnaire. Un algorithme d'intelligence en essaims est fondé sur le comportement des essaims qui existent dans la nature (par exemple, des essaims d'insectes ou d'oiseaux). L'optimisation par colonies de fourmis et par les essaims de particules sont les premiers algorithmes de l'intelligence en essaims, et certains chercheurs insistent sur le fait qu'ils ne doivent pas être considérés comme des algorithmes évolutionnaires. Cependant, d'autres auteurs considèrent l'intelligence en essaims comme étant un sous-ensemble de l'informatique évolutionnaire. Par exemple, l'un des pionniers de l'optimisation par les essaims de particules s'y réfère comme un algorithme évolutionnaire [103]. Plusieurs algorithmes ont été développés dans le cadre de l'intelligence en essaims tels que : les algorithmes de colonies de fourmis, le système de fourmis original ou Ant System, les essaims particulaires, les algorithmes inspirés des abeilles, l'algorithme des essaims de poissons artificiels, l'algorithme des chauves-souris, l'algorithme des essaims de lucioles et l'algorithme d'optimisation de l'exploration bactérienne. Dans cette thèse, on va uniquement intéresser par les essaims particulaires et l'algorithme des essaims de lucioles.

##### 2.4.4.1 L'optimisation par essaim particulaire

L'optimisation par essaim particulaire (PSO : *Particle Swarm Optimisation*) a été introduite par Russel Elberhart et James Kennedy en 1995 [104]. Elle s'inspire des déplacements collectifs observés chez certains animaux sociaux tels que les poissons et les oiseaux migrateurs qui ont tendance à imiter les comportements réussis qu'ils observent dans leur entourage, tout en y apportant leurs variations personnelles. Elle trouve ses origines dans les travaux de Reynolds [105] et de Heppner et Granander [106] qui ont créé des modèles mathématiques permettant de simuler des vols groupés d'oiseaux et de bancs de poissons.

L'essaim particulaire correspond à une population d'agents appelés « Particules ». Chaque particule, modélisée comme une solution potentielle au problème d'optimisation, parcourt l'espace de recherche, en quête de l'optimum global. Le déplacement d'une particule est influencé par trois composantes (cf., Figure 2.7) [107] :

1. *Une composante physique* : la particule tend à suivre sa direction courante de déplacement.
2. *Une composante cognitive* : la particule tend à se diriger vers le meilleur site par lequel elle est déjà passée.
3. *Une composante sociale* : la particule tend à se fier à l'expérience de ses congénères et, ainsi, à se diriger vers le meilleur site déjà atteint par ses voisins.

Le voisinage peut être défini spatialement en prenant par exemple la distance eucli-




FIGURE 2.7 – Déplacement d'une particule.

dienne entre les positions de deux particules ou sociométriquement, en prenant la position de l'individu dans l'essaim [108]. Chaque particule  $i$  de l'essaim est caractérisée à la fois par sa position  $\vec{X}_i$  et par un vecteur de changement de position appelé « *vélocité* ou *vitesse* »  $\vec{V}_i$ . Chaque particule dispose d'une mémoire lui permettant de se souvenir de sa meilleure solution, découverte par le passé, que l'on note  $\vec{P}_i$  (*personal best*) ainsi que la meilleure position connue de son voisinage, notée  $\vec{P}_g$  (*global best*). A chaque itération, chaque particule se déplace dans l'espace de recherche en suivant un vecteur, calculé comme somme pondérée des vecteurs représentant sa vitesse courante ( $\vec{V}_i$ ), ainsi que sa  $\vec{P}_i$  et sa  $\vec{P}_g$ . Sa nouvelle vitesse  $\vec{V}_i(t+1)$  est déterminée de la façon suivante :

$$\vec{V}_i(t+1) = \omega \vec{V}_i(t) + C_1 \text{rand} \left( \vec{P}_i(t) - \vec{X}_i(t) \right) + C_2 \text{rand} \left( \vec{P}_g(t) - \vec{X}_i(t) \right), \quad (2.39)$$

où  $i = 1, 2, \dots, N$ , et  $N$  est le nombre de particules (taille de l'essaim); le coefficient d'inertie  $\omega$  [107] permet de contrôler l'influence de la vitesse obtenue au pas précédent. Un grand facteur d'inertie provoque une grande amplitude de mouvement alors qu'un petit facteur d'inertie concentre la recherche sur un petit espace, *rand* est un nombre aléatoire uniformément réparti sur  $[0,1]$ ,  $C_1$  et  $C_2$  sont deux constantes qui représentent une accélération positive. Elle correspond à la composante *cognitive* du déplacement. La position de chaque particule est également mise à jour à chaque itération comme suit :

$$\vec{X}_i(t+1) = \vec{X}_i(t) + \vec{V}_i(t+1). \quad (2.40)$$

A chaque pas du temps, la vitesse et la position de chaque particule sont régularisées en fonction de ses positions  $\vec{P}_i$  et  $\vec{P}_g$  selon (2.39) et (2.40), jusqu'à ce que la fonction de

coût soit inférieure à un seuil prédéfini  $\epsilon$  :

$$|f(\vec{p}_g(t+1)) - f(\vec{P}_g(t))| \leq \epsilon. \quad (2.41)$$

Une courte description de l'algorithme PSO est fournie dans l'algorithme 1.

**Algorithme 1** : Algorithme d'essaim particulaire (PSO).

---

\*\*\*\*\*Variables et paramètres de l'algorithme\*\*\*\*\*

$NP$  : Nombre de particules,

$\vec{X}_i$  : Position de la particule  $p_i$ ,

$\vec{V}_i$  : Vitesse de la particule  $p_i$ ,

$pbest_i$  : La meilleure « fitness » obtenue pour la particule  $p_i$ ,

$\vec{P}_i$  : Meilleure Position de la particule  $p_i$  découverte par le passé (*personal best*),

$\vec{P}_{g_i}$  : Meilleure position de la particule connue de son voisinage (*global best*) ,

$C_1$  et  $C_2$  : Constantes positives..

\*\*\*\*\*

[Initialisations]

Population initialisée au hasard

.....

**while** Le critère d'arrêt n'est pas satisfait, **do**

**for**  $i = 1$  to  $NP$  **do**

**if** ( $f(\vec{X}_i) > pbest_i$ ) **then**

$pbest_i \leftarrow F(\vec{X}_i)$ .

$\vec{P}_i \leftarrow \vec{X}_i$

**end if**

**if** ( $f(\vec{X}_i) > gbest$ ) **then**

$gbest \leftarrow F(\vec{X}_i)$ .

$\vec{P}_{g_i} \leftarrow \vec{V}_i$ .

**end if**

**end for**

**for**  $i = 1$  to  $NP$

$V_i \leftarrow \omega \times \vec{V}_i + C_1 \times rand \times (\vec{P}_i - \vec{X}_i) + C_2 \times rand \times (\vec{P}_{g_i} - \vec{V}_i)$ .

$\vec{X}_i \leftarrow \vec{X}_i + \vec{X}_i$

**end for**

**end while**

---

#### 2.4.4.2 L'algorithme des essaims de luciole

L'algorithme d'optimisation basé sur les essaims de lucioles (insectes lumineux) (FA : *Firflay Algorithm*) a été développé par Xin-She Yang à l'université de Cambridge en 2007 [109, 110, 111, 112]. FA a été inspiré du clignotement des lucioles. Chaque espèce de luciole a un motif unique de flashes. Bien que la gamme complète des fonctions flash n'a pas encore été déterminée, il est connu que le clignotant attire les compagnons. Dans certaines espèces de lucioles, les mâles sont attirés par des femelles sédentaires, dans d'autres espèces, la femelle copie le signal d'une espèce différente pour attirer les mâles de cette espèce. Le clignotement peut également être utilisé pour transmettre des informations entre les lucioles. L'algorithme FA s'inspire de l'idée de cette attraction et passage de l'information. Le degré d'attractivité d'une luciole suit une fonction de diminution monotone donnée par :

$$\beta = \beta_0 e^{-\gamma r^2}, \quad (2.42)$$

où  $\beta$  est le degré d'attractivité d'une luciole à distance  $r$ ,  $\beta_0$  est le degré d'attractivité de la luciole à  $r = 0$ ,  $r$  est la distance entre deux lucioles et  $\gamma$  est un coefficient d'absorption de lumière. La distance  $r$  entre la luciole  $i$  et  $j$  située à  $x_i$  et  $x_j$ , respectivement, est calculée comme une distance euclidien comme suit :

$$r = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_i^k - x_j^k)^2}. \quad (2.43)$$

L'algorithme FA utilise les trois règles idéalisées suivantes :

1. Tous les lucioles sont unisexes, cela signifie qu'une luciole est attirée par une autre, indépendamment de son sexe.
2. L'attractivité et la luminosité sont proportionnelles entre elles, de sorte que, pour deux lucioles clignotantes, la moins lumineuse se déplacera vers la plus lumineuse. L'attractivité et la luminosité diminuent à l'augmentation de leur distance. S'il n'y a pas une luciole plus brillante que l'autre, elles vont se placer de manière aléatoire.
3. La luminosité d'une luciole est déterminée par le point de vue de la fonction objectif.

Le mouvement de la luciole  $i$ , attirée par la luciole  $j$ , est donné par l'équation suivante :

$$x_{i+1} = x_i + \beta_0 e^{-\gamma r^2} (x_j - x_i) + \alpha (rand - \frac{1}{2}). \quad (2.44)$$

Le troisième terme en (2.44) est incluse pour le cas où il n'y a pas de luciole plus brillante que celle considérée et  $rand$  est un nombre aléatoire uniformément distribué dans l'intervalle  $[0,1]$ . Une courte description de l'algorithme FA est illustrée dans l'algorithme 2.

**Algorithme 2** : Algorithme des essaims de luciole (FA).

---

[Initialisations]

Donner des emplacements aléatoires pour  $N$  lucioles dans l'espace de dimensions  $D$ .

Évaluation initiale de tous les  $N$  lucioles.

\*\*\*\*\*

Définir le coefficient d'absorption de la lumière  $\gamma$ .

.....

**while** Le critère d'arrêt n'est pas satisfait, **do**

**for**  $i = 1$  to  $N_{lucioles}$  **do**

**for**  $j = 1$  to  $N_{lucioles}$  **do**

**if**  $I_i > I_j$  **then**

        Déplacer la luciole  $i$  vers  $j$  en utilisant 2.44.

**end if**

**end for**

  Évaluez la nouvelle solution et mettre à jour l'intensité lumineuse.

  Vérifiez si la meilleure position a été trouvée .

**end for**

**end while**

  Trouver la meilleure luciole

---

### 2.4.5 Autres méthodes évolutionnaires pour l'optimisation

Plusieurs techniques très récentes de l'informatique évolutionnaire ont été introduites ces dernières années mais n'appartiennent pas à l'intelligence en essaims tels que : l'optimisation basée sur la biogéographie, l'algorithme de recherche gravitationnelle et l'optimisation basée sur l'enseignement-apprentissage. Dans ce mémoire de thèse nous introduisons seulement la technique d'optimisation basée sur la biogéographie.

#### 2.4.5.1 L'algorithme à base de biogéographie

L'algorithme à base de biogéographie (BBO : *Biogeography-Based Optimization*), a été développé par Dan Simon en 2008 [113]. Inspiré par des études sur la répartition spatiale des espèces de plantes et d'animaux ainsi que les causes de leur répartition et de leur extinction. Elle traite de façon dont la richesse en espèces (nombres d'espèces) est maintenue dans un système d'île qui sont sujettes à l'immigration et sur lesquelles des espèces s'éteignent, quand une île ne peut pas facilement supporter la population d'une espèce,

les membres migrent vers de nouvelles îles et subissent une spéciation. L'algorithme BBO manipule une population d'individus appelés îles (ou *habitats*). Chaque île représente une solution possible au problème à résoudre. La « *fitness* » de chaque île est déterminée par son HSI (*Habitat Suitability Index*), qui considère les caractéristiques environnementales telles que les précipitations, la température et la végétation qui constituent une mesure de la qualité d'une solution candidate. Ces caractéristiques peuvent être représentées quantitativement et sont appelées variables de l'indice d'aptitude (*Suitability Index Variables* ou SIV). Une bonne solution au problème d'optimisation est une île avec un grand nombre d'espèces, ce qui correspond à une île avec un faible HSI. Dans l'algorithme BBO, chaque habitat a ses propres taux d'immigration ( $\lambda$ ) et d'émigration ( $\mu$ ) représentant les espèces qui viennent et sortent de l'île. Ces paramètres sont influencés par le nombre d'espèces ( $S$ ) sur l'île. Ils peuvent être calculés comme suit [114] :

$$\lambda_s = I \times \left(1 - \frac{S}{S_{max}}\right), \quad (2.45)$$

$$\mu_s = E \times \left(\frac{S}{S_{max}}\right), \quad (2.46)$$

où  $I$  est le taux maximal d'immigration,  $E$  est le taux maximal d'émigration et  $S_{max}$  est le nombre maximum d'espèces. Il convient de noter que (2.45) et (2.46) ne sont qu'une méthode pour calculer  $\lambda$  et  $\mu$  ; il existe d'autres options pour calculer ces valeurs en fonction de différents modèles d'espèces [113].

Les deux principaux opérateurs pour l'algorithme BBO sont la migration et la mutation. Les habitats avec un indice de survie élevé partagent leurs caractéristiques avec les habitats avec un indice de survie faible. Le processus de migration permet de partager les bonnes caractéristiques entre les îles (habitats). BBO adopte la stratégie de migration pour partager l'information entre les solutions. Les bonnes informations d'individus peuvent être conservées pendant le processus évolutionnaire afin d'assurer la convergence de la population. Un opérateur de mutation est utilisé pour générer des diverses solutions visant à promouvoir la diversité de la population [115].

Supposons que nous ayons un problème d'optimisation globale et une population d'individus candidats. L'individu est représenté par un vecteur entier « SIV » de dimension  $D$ . La population se compose de  $NP = n$  vecteurs de paramètres  $X_i, i = 1, \dots, NP$ . Une option pour la mise en oeuvre des opérateurs de migration et de mutation peut être décrite algorithmiquement comme le montre l'algorithme 3, où  $rand$  est un nombre réel aléatoire uniformément réparti dans l'intervalle  $[0, 1]$ ,  $X_i(j)$  est le  $J^{iem}$  SIV de la solution  $X_j$ , et  $m_i$  est le taux de mutation qui peut être calculé comme suit :

$$m_i = m_{max} \left(1 - \frac{P_i}{P_{max}}\right), \quad (2.47)$$

où  $m_{max}$  est un paramètre prédéfini,  $P_{max} = \operatorname{argmax} P_i, i = 1, \dots, NP$ .

La migration est un opérateur probabiliste qui vise à améliorer la solution candidate  $x_k$ . Chaque variable de décision d'une solution candidate  $x_k$  utilise le taux d'immigration de la solution candidate  $\lambda_k$  pour déterminer de manière probabiliste s'il faut immigrer ou non. Si l'immigration est sélectionnée, la solution candidate émigrante  $x_j$  est choisie de manière probabiliste en fonction de son taux d'émigration  $\mu_k$ . La migration est écrite comme suit :

$$x_k(s) \leftarrow x_j(s). \quad (2.48)$$

où  $s$  est un variable d'indice de décision.

En BBO, chaque solution candidate  $x_k$  a son propre taux d'immigration  $\lambda_k$  et taux d'émigration  $\mu_k$ . Les solutions candidates acceptables ont un taux d'émigration relativement élevée et un faible taux d'immigration, l'inverse s'applique aux mauvaises solutions candidates. Dans ce cas, le taux d'immigration  $\lambda_k$  et le taux d'émigration  $\mu_k$  sont basés sur des courbes de migration particulières telles que les courbes de migration linéaire représentées dans la Figure 2.8.

**Algorithme 3** : Algorithme BBO.

[Initialisations]

Initialiser aléatoirement la population  $P$ .

.....

Evaluer le «fitness» HSI pour chaque individu de  $P$ .

**while** Le critère d'arrêt n'est pas satisfait, **do** Trier  
la population du meilleur au pire.

For each individual, map HSI au nombre d'espèces.

Calculer le taux d'immigration  $\lambda_i$  et le taux d'émigration  $\mu_i$   
pour chaque individu  $x_i$ .

\*\*\*\*\*Opérateur de Migration\*\*\*\*\*

**for**  $i = 1$  to  $NP$  **do**

Sélectionner  $X_i$  avec probabilité  $\propto \lambda_i$ .

**if**  $\operatorname{rand}(0, 1) < \lambda_i$  **then**

**for**  $j = 1$  to  $NP$  **do**

Sélectionner  $X_j$  avec probabilité  $\propto \mu_i$ .

**if**  $\operatorname{rand}(0, 1) < \mu_i$  **then**

Choisir aléatoirement un SIV  $\sigma$  Parmi  $X_j$ .

Remplacer un aléatoire SIV dans  $X_j$  par  $\sigma$ .

**end if**

```

    end for
  end if
end for
*****
Mise à jour de la probabilité pour chaque individu
*****Opérateur de mutation*****
  for  $i = 1$  to  $NP$  do
    Calculer la probabilité  $P_i$ .
    Sélectionner un SIV  $X_i(j)$  avec probabilité  $\propto P_i$ .
    if  $rand(0,1) < m_i$  then
      Remplacer  $X_i(j)$  avec un aléatoire SIV.
    end if
  end for
*****
Évaluer la population
end while

```

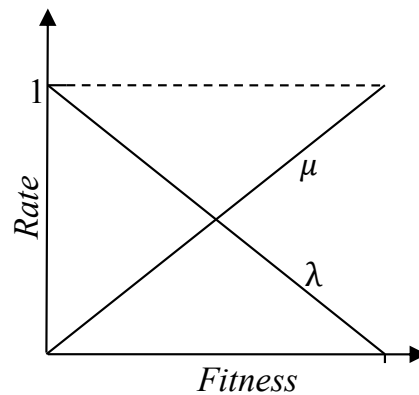


FIGURE 2.8 – Courbes de migration linéaire pour BBO où  $\lambda$  est le taux d'immigration et  $\mu$  le taux d'émigration.

## 2.5 Conclusion

Ce chapitre a été dédié à la présentation des techniques et des outils de base qui seront utilisés ultérieurement à savoir de la logique floue avec ses deux variantes type-1 et

---

type-2, et les algorithmes métaheuristiques comme le PSO, BBO, FA et GA, Le fondement théorique de ces méthodes a été explicitement présenté dans le but d'ouvrir la voie aux algorithmes qui seront proposés dans les chapitres 3, 4 et 5.



# **MODÉLISATION ET IDENTIFICATION DU SIGNAL ÉLECTROCARDIOGRAMME**

---

*La modélisation du battement cardiaque est une étape essentielle pour l'identification automatique des ondes de l'électrocardiogramme. Elle a pour objectif de trouver une représentation simple et compacte que possible, de la forme de chaque onde constitutive du battement cardiaque. Dans ce chapitre une nouvelle méthode de modélisation et d'identification des signaux électrocardiogrammes basée sur le concept de la logique floue sera présentée.*

## **Sommaire**

---

<b>3.1 Introduction</b> . . . . .	<b>56</b>
<b>3.2 Etat de l'art sur la modélisation du signal ECG</b> . . . . .	<b>57</b>
3.2.1 Méthodes temporelles . . . . .	57
3.2.2 Méthodes mathématiques . . . . .	58
3.2.3 Méthodes intelligentes . . . . .	58
<b>3.3 Contribution</b> . . . . .	<b>60</b>
<b>3.4 Méthode proposée pour la modélisation du signal ECG</b> . . . . .	<b>61</b>
3.4.1 Paramètres du système flou type-2 à ajuster . . . . .	61
3.4.2 Fonction objectif . . . . .	62
3.4.3 Identification du modèle primaire . . . . .	63
3.4.4 Identification du processus d'erreur . . . . .	63
3.4.5 Conception du modèle final . . . . .	64
3.4.6 Résultats de simulation . . . . .	65
3.4.7 Essais de validation et de généralisation . . . . .	74
3.4.8 Étude comparative . . . . .	88
<b>3.5 Conclusion</b> . . . . .	<b>90</b>

---

### 3.1 Introduction

**L**a modélisation floue utilise les concepts de la logique floue pour représenter un système ou un signal donné. L'identification et la modélisation floue sont des outils efficaces pour l'approximation des systèmes non linéaires et les séries temporelles (signaux) en raison de leur capacité d'approximation universelle. L'importance des systèmes intelligents pour résoudre des problèmes complexes du monde réel (prédiction, modélisation, contrôle, commande,...,etc) a mis en évidence l'importance de la logique floue qui a attiré l'attention de nombreux chercheurs et scientifiques. Un système d'identification flou est un modèle de calcul fondé sur les concepts de la théorie des ensembles flous, des règles *IF – THEN* floues et du raisonnement flou [116]. L'identification floue peut être catégorisée en trois catégories : une modélisation floue linguistique, une modélisation relationnelle floue et une modélisation de type Takagi-Sugeno-Kang (TSK)[117]. Le modèle linguistique introduit par Zadeh décrit le système comme des règles *IF – THEN* floues qui sont des déclarations linguistiques. Le modèle relationnel flou construit une matrice composée de données d'entrée-sortie du processus. Le modèle TSK est fondé sur la création de sous-modèles linéaires qui permettent une identification floue à l'aide d'une implication floue et de méthodes de raisonnement [118, 119].

L'identification floue comprend deux étapes clés : identification de la structure et identification des paramètres [120]. La première étape est importante et aborde la question de la construction de la structure du modèle flou en utilisant les données d'entrée-sortie. Il existe de nombreuses méthodes floues décrites dans la littérature ; on trouve celles qui utilisent une partition floue basée sur des fonctions objectifs particulières dans le but d'établir des structures des modèles appropriées [119, 120, 121, 122, 123, 124]. De nombreuses approches ont été proposées pour identifier les paramètres, y compris le filtre de Kalman, la méthode des moindres carrés non linéaires [125, 126] et d'autres [119]. Leandro *et al.* [121] ont présenté une méthode pour l'identification non linéaire d'un modèle flou de type Takagi-Sugeno (TS) qui repose sur un algorithme d'optimisation par essais particuliers chaotiques qui utilise des séquences de cartes chaotiques de Zaslavskii combinées à un algorithme efficace de clustering de Gustafson-Kessel (GK). Li *et al.* [122] ont suggéré d'utiliser un filtre Wiener flou pour identifier les systèmes chaotiques en appliquant un algorithme d'optimisation par essais particuliers pour identifier les paramètres optimaux du modèle Wiener flou. Rahib *et al.* [123] ont décrit un nouveau système neurone-flou de type-2 qui utilise des algorithmes de clustering et de gradient pour identifier les systèmes dynamiques et pour l'égalisation des canaux de transmission. Une autre nouvelle méthode d'identification floue proposée par Huaguang *et al.* dans [124] où ils ont introduit la conception critique adaptative (AD) dans le modèle hyperbolique flou généralisé

pour les systèmes discrets non linéaires inconnus dans le but de déterminer les paramètres optimaux. Chafaa *et al.* [120] ont proposé une méthode efficace pour construire automatiquement un modèle flou de type Takagi-Sugeno (TS) ; Les paramètres des fonctions d'appartenance sont sélectionnés à l'aide de l'algorithme de filtre de Kalman.

## 3.2 Etat de l'art sur la modélisation du signal ECG

Plusieurs méthodes ont été proposées dans la littérature pour la modélisation des signaux ECG, ces méthodes peuvent être regroupées en trois catégories : dans la première catégorie on trouve, les méthodes directes qui considèrent le signal électrocardiogramme comme une succession de segments ou de courbes. La recherche des pentes, des débuts et des fins de ces segments, a été effectuée par des estimateurs, d'extrapolation et d'interpolation. Ces méthodes sont connues sous le nom de méthodes temporelles. La deuxième catégorie comprend Les méthodes qui se basent sur la théorie des équations différentielles (méthodes mathématiques). Finalement, on trouve la troisième catégorie qui comprend les méthodes de modélisation qui se basent sur l'intelligence artificielle (Réseaux de neurones artificielles, logique floue,..., etc.) dont on peut l'appeler méthodes intelligentes.

### 3.2.1 Méthodes temporelles

L'un des premiers algorithmes de modélisation et compression du signal ECG par approximations linéaires fût présenté par Cox *et al.* [4] et baptisé (AZTEC : *Amplitude Zone Time Epoch Coding*). AZTEC cherche des segments horizontaux dont la longueur est supérieure à deux échantillons et représente les points contenus entre deux plateaux par des pentes. L'algorithme CORTES (*Coordinate Reduction Time Encoding System*) est une combinaison de la technique AZTEC avec la méthode (TP : *Turning Point*). AZTEC est appliquée aux régions du signal correspondant à la ligne isoélectrique et TP est utilisée sur les complexes QRS et les ondes environnantes. L'algorithme TP enregistre un échantillon sur deux où son principe est décrit dans [5]. L'algorithme SAPA (*Scan Along Polygonal Approximation*) consiste en la représentation du signal ECG par une succession des segments polygonaux. L'écart entre les segments (signal approché) et le signal original doit toujours être inférieur à un seuil Prédéfini [6].

D'autres méthodes ont utilisé les fonctions Spline qui sont des traçons de polynôme définis sur des sous intervalles et raccordés par des conditions de continuités, la variante la plus populaire est la Spline cubique qui a été adoptée dans les calculs scientifiques [127, 128]. Imai *et al* ont proposé un algorithme de compression de l'ECG avec des fonctions Spline, où l'idée est de réaliser la modélisation et la compression du signal ECG avec

des fonctions Spline cubiques en construisant l'ensemble de noeuds  $t = t_0, \dots, t_n$  ayant un petit nombre d'éléments. Les positions  $t_i$  et l'ensemble de valeurs du signal à ces positions  $y = y_0, \dots, y_n$  seront enregistrées et exploitées. [7]. Nygaard *et al* ont eu l'idée de proposer un algorithme de modélisation et de compression du signal électrocardiogramme dans laquelle les fonctions d'interpolation sont des polynômes de second degré [8]. Daniel *et al.* [9] ont présenté une méthode de compression et de modélisation du signal ECG en utilisant une modélisation polynomiale. Une étude exhaustive et comparative des méthodes directes de compression et de modélisation de l'ECG a été effectuée par Daniel dans [10].

### 3.2.2 Méthodes mathématiques

MacSharry *et al.* dans [11] ont introduit un modèle de synthèse du signal ECG qui unifie la morphologie et la répartition des ondes du signal ECG dans un seul modèle dynamique non-linéaire. Ce modèle repose sur l'approche de l'espace d'état et basé sur la théorie des équations différentielles. Ce modèle produit une trajectoire dans un espace d'état tridimensionnel avec les coordonnées  $(x, y, z)$ . La quasi périodicité de l'ECG a été modélisée par le mouvement de la trajectoire autour d'un cycle limite de rayon unité dans le plan  $(x, y)$ . L'amplitude du signal ECG a été considérée comme la variation suivant l'axe  $z$  de la trajectoire circulaire. Dans le plan  $(x, y)$  on trouve l'évolution d'une trajectoire circulaire, et à des moments bien déterminés (les instants de réalisation des pics ou sommets P, Q, R, S et T) des Gaussiennes dans la direction de l'axe  $z$  ont été introduites dans le but d'obtenir les amplitudes du signal ECG.

### 3.2.3 Méthodes intelligentes

Plusieurs chercheurs et scientifiques proposent des méthodes intelligentes pour la modélisation des séries temporelles et les systèmes dynamiques en se basant sur la théorie de l'auto-organisation, qui est une théorie de la complexité qui permet d'étudier les changements brutaux du comportement d'un système. Wang *et al.* Dans [12] ont proposé un système d'auto-organisation pour les réseaux de neuro-flou parcimonieux (FAOS-PFNN : *Self-Organizing Scheme for Parsimonious Fuzzy Neural Networks*). La parcimonie exprime le fait que le réseau a besoin d'un petit nombre de paramètres ajustables pour réaliser correctement sa tâche. Le FAOS-PFNN commence sans des couches cachées et génère de manière parcimonieuse de nouvelles unités cachées (croissance) en utilisant un algorithme d'apprentissage incorporant une stratégie d'élagage où plusieurs critères de croissance ont été adoptés (erreur, capacité de généralisation, ..., etc.). L'ajustement de paramètres des unités cachées a été réalisé en utilisant le filtre de Kalman étendu. Une autre approche d'auto-organisation baptisée (GP : *Growing-and-Pruning*) a été proposée par Hanguai *et al.*

[13] pour optimiser une structure à base de réseau de neuro-flou (FNN : *Fuzzy Neural Network*). Cette méthode (GP-FNN) est basée sur les réseaux de neurones à fonctions de base radiales où un ensemble de règles floues peuvent être insérées ou réduites au cours du processus d'apprentissage. L'ajustement de paramètres de cette structure (GP-FNN) a été réalisé en utilisant la méthode de descente du gradient supervisée.

Dans le même contexte qui est les systèmes d'auto-organisation, Honggui *et al.* [14] ont proposé un autre système d'auto-organisation neuro-flou incorpore un algorithme de calcul adaptatif baptisé (SOFNN-ACA : *Self-Organizing Fuzzy-Neural-Network with Adaptive Computation Algorithm*). Dans la phase d'apprentissage un ensemble de règles floues peuvent être ajoutées ou réduites en utilisant la méthodologie suivante : si les règles floues possèdent des intensités de pointage élevées (SI : *Spiking Intensities*), ces règles seront considérées comme un nouvel ensemble de règles, dans le cas opposé, si les règles floues ont une petite valeur d'information mutuelle relative (RMI : *Relative Mutual Information*), ces règles seront taillées afin de simplifier la structure de réseau de neuro-flou adoptée, où un algorithme d'ajustement de paramètres de réseau de neuro-flou incorpore une stratégie à base de taux d'apprentissage a été utilisé pour accélérer la vitesse de convergence. En changeant les techniques de simplification des réseaux de neuro-flou et les algorithmes d'ajustement de leurs paramètres, Hanggui *et al.* dans [15] ont proposé un autre système d'auto-organisation neuro-flou baptisé (SOFNN-AGA : *Self-Organisation Fuzzy Neural Network with Adaptive Gradient Algorithm*). Les auteurs ont développé une approche d'apprentissage de la structure neurones-floue adoptée basée sur une méthode baptisée (PFR : *Potentiality of Fuzzy Rules*) et le taux de réduction d'erreur (ERR : *Error Reduction Ratio*). Un algorithme d'ajustement de paramètres basé sur la méthode de gradient à base de taux d'apprentissage adaptatif a été utilisé.

Un système d'auto-organisation neuro-flou basé sur les techniques d'analyses de sensibilités a été proposé par Chen *et al.* dans [16]. L'analyse de sensibilité est l'étude de la façon dont l'incertitude de la sortie d'un système peut être attribuée à l'incertitude dans ses entrées. Il s'agit d'estimer les indices de sensibilité qui quantifient l'influence d'une entrée ou d'un groupe d'entrée sur la sortie. Les auteurs de [16] ont trouvé que les réseaux de neuro-flou ont les caractéristiques des modèles additifs dans lesquels l'indice d'effet du premier ordre de l'influence peut fournir la même information que l'indice d'effet total, donc il suffit d'analyser les effets du premier ordre des entrées sur leurs couches de sortie. Sur la base de cette hypothèse les auteurs de [16] ont utilisé une méthode d'analyse de sensibilité globale du premier ordre baptisée (RBD : *Random Balance Designs*) pour développer une structure d'auto-organisation neuro-flou, de plus, ils ont également introduit le concept de fluctuation systématique des réseaux de neuro-flou pour déterminer si un ajustement de la structure est nécessaire ou non, et pour accélérer la vitesse de convergence

dans la phase d'apprentissage.

Un autre système d'auto-organisation d'une structure à base de la logique floue et la méthode des Moindres Carrées Modifiée baptisé (SOFMLS : *Self-Organisation Fuzzy Modified Least-Square*) a été proposé par José *et al.* [17]. Le système a la capacité de réorganiser la structure adoptée et de s'adapter à l'existence de nouvelles informations.

En dehors des systèmes d'auto organisation, Juang *et al.* [18] ont proposé une méthode de modélisation récurrente à base de réseau de neuro-flou baptisé (LRFNN-SVR : *Locally Recurrent Fuzzy Neural Network with Support Vector Regression*). Cette méthode a une structure à cinq couches et traite les problèmes en utilisant les propriétés temporelles. La couche résultante est de type Takagi-Sugeno-Kang (TSK), qui est une fonction linéaire des états actuelles. Un algorithme linéaire et itératif baptisé (SVR : *Support Vector Regression*) a été utilisé pour ajuster les paramètres des règles floues. Une autre approche de modélisation des séries temporelles basée sur les systèmes d'inférences neurones flous (ANFIS : *Adaptive Neuro-Fuzzy Inference Systems*) a été développée par Hosein *et al.* dans [19]. L'ANFIS intègre la capacité d'apprentissage des réseaux de neurones artificielles avec le système d'inférence flou de type Takagi-Sugeno pour modéliser les fonctions non linéaires. Les paramètres du système proposé ont été ajustés en utilisant une méthode qui fusionne l'algorithme d'optimisation des abeilles (BA : *Bees Algorithm*) et l'estimateur des moindres carrés (LSE : *Least Square Estimation*).

### 3.3 Contribution

Vu l'importance de la modélisation des signaux ECGs, nous avons proposé un nouveau modèle flou pour les signaux électrocardiogrammes, basé sur les intervalles des systèmes flous et comprend une interconnexion parallèle de deux sous-modèles flous [130]. Le premier sous-modèle flou est le modèle primaire, qui représente un modèle ordinaire à faible résolution. Pour surmonter le problème de la résolution et obtenir un modèle avec une résolution plus élevée, nous avons introduit un deuxième sous-modèle flou appelé le modèle d'erreur, qui représente la modélisation d'erreur entre la sortie du modèle primaire et le signal électrocardiogramme réel. Le modèle d'erreur représente l'incertitude dans le modèle principal, cette incertitude est minimisée par une simple soustraction de la sortie du modèle d'erreur de la sortie du modèle primaire, ce qui entraîne une interconnexion parallèle entre les deux modèles. Cette interconnexion nous emmène à un seul modèle final unique et complet possédant une résolution plus élevée. La représentation et l'identification des modèles sont mises en oeuvre à l'aide des modèles flous type-2 autorégressifs et moyenne mobile (ARMA : *Autoregressive Moving Average Model*) et des modèles flous type-2 autorégressifs (AR : *Auto regressive*). Les paramètres du modèle flou proposé ont

été ajustés en utilisant des calculs métaheuristiques à savoir : GA, PSO, BBO et FA.

### 3.4 Méthode proposée pour la modélisation du signal ECG

Notre objectif est d'offrir un modèle flou-type2 fiable et efficace pour représenter tous types des signaux électrocardiogrammes quelque soit la dérivation utilisée (cf., [chapitre 1](#)). Un modèle primaire est initialement conçu à l'aide de données ECG. Ensuite, l'erreur entre le signal ECG réel et la sortie du modèle primaire est modélisée pour créer le modèle d'erreur. Ce dernier modèle représente les incertitudes dans le modèle primaire qui peuvent être facilement supprimés par une simple soustraction de la sortie du modèle d'erreur de la sortie du modèle Primaire. Les détails de cette méthode seront présentés dans les sections suivantes.

Un modèle flou peut représenter ou modéliser n'importe quel système ou fonction inconnu,  $y = f(x)$ , en utilisant les données d'entrée/sortie  $x_k = [x_{1k}, x_{2k}, \dots, x_{nk}]^T$  et  $y_k$ . L'indice  $k$  désigne le nombre de l'échantillon et  $n$  la dimension du vecteur (nombre de régresseurs). Le modèle flou utilisé dans cette thèse est le système flou type-2 discuté dans la section [2.3](#), dont l'idée est de trouver une relation entre l'entrée et la sortie du système flou en ajustant au fur et à mesure ses paramètres (cf., [sous-section 3.4.1](#)) en utilisant des mécanismes d'ajustement (algorithme d'optimisation) (cf., [section 2.4](#)) de telle façon une fonction objectif atteint son optimum. Pour avoir l'objectif voulu notre méthode sera composée de trois étapes :

- **Étape 1** : identification du modèle primaire,
- **Étape 2** : identification du processus d'erreur,
- **Étape 3** : conception du modèle final.

#### 3.4.1 Paramètres du système flou type-2 à ajuster

La conception du système flou type-2 pour la modélisation comprend la détermination des paramètres inconnus qui sont les paramètres de l'antécédent et les parties consécutives des règles floues *IF – THEN* ([Équation 2.28](#)). Dans les parties antécédentes, l'espace d'entrée est divisé en un ensemble de régions floues, puis dans les parties consécutives, le comportement du système dans ces régions conçu d'une manière automatique. Dans les ensembles flous types-2 Gaussiens, l'incertitude peut être associée à la moyenne (centre) et à la déviation standard (STD). Dans cette thèse, les fonctions d'appartenance Gaussiennes ont été choisies en raison de leur capacité d'approximation universelle et de leur aptitude à estimer uniformément des fonctions continues [[131](#)]. Les figures [3.1 \(a\)](#) et [\(b\)](#) représentent des ensembles flous type-2 Gaussiens avec des incertitudes dans la déviation

standard (STD) et la moyenne (centre), respectivement.




FIGURE 3.1 – Ensemble flou type-2 Gaussien avec : (a) déviation standard incertaine, (b) moyenne incertaine (centre).

L'expression mathématique de la fonction d'appartenance Gaussienne est exprimée comme suit :

$$\mu(x) = \exp\left(-\frac{1}{2} \frac{(x - c)^2}{\sigma^2}\right), \quad (3.1)$$

avec  $c$  et  $\sigma$  sont le centre (moyenne) et la largeur (STD) de la fonction d'appartenance et  $x$  est le vecteur d'entrée, respectivement. Dans notre travail nous allons considérer l'incertitude sur la moyenne  $c = [c_1, c_2]$ , avec une déviation standard  $\sigma$  fixe, où  $c_1$  et  $c_2$  sont les limites inférieures et supérieures de l'intervalle d'incertitude. Notons que nous avons utilisé une déviation standard  $\sigma = 0.75$ , une fonction d'appartenance inférieure avec une amplitude constante égale à 0.8 et une fonction d'appartenance supérieure avec une amplitude constante égale à 1.

### 3.4.2 Fonction objectif

Le terme fonction objectif ou la fonction de coût est utilisé en optimisation mathématique pour désigner une fonction qui sert de critère pour déterminer la meilleure solution à un problème d'optimisation. La fonction objectif utilisée est le critère d'erreur quadratique moyenne (MSE : *Mean Square Error*) qui combine les valeurs réelles et estimées comme suit :

$$MSE = \frac{\sum_{k=1}^N (y_k - \hat{y}_k)^2}{N} = \frac{\sum_{k=1}^N e_k^2}{N}, \quad (3.2)$$

avec  $y_k$  et  $\hat{y}_k$  sont la mesure réelle et son estimation, respectivement, et  $N$  est la taille des données.

### 3.4.3 Identification du modèle primaire

Pour cette étape (*Stage 1*), l'ensemble de données  $(x_n, y_n)$  est utilisé pour déterminer le modèle flou type-2 primaire (T2FPM : *Type-2 Fuzzy Primary Model*)  $\hat{f}_p$  pour le processus, qui est dans notre cas le signal électrocardiogramme comme indiqué sur la Figure 3.2 (*stage 1*) où :

$f$  : fonction inconnue représentant le signal électrocardiogramme que nous souhaitons identifier, ayant  $y_{n+1}$  comme sortie.

$(x_n, y_n)$  : données d'apprentissage.

$\hat{y}_p$  : la sortie du modèle primaire.

$e_1$  : erreur de modélisation primaire, utilisée dans la fonction du coût 3.2 des algorithmes d'optimisation (pour exciter le mécanisme d'ajustement).

Le principe de l'identificateur flou (T2FPM) consiste en une adaptation en temps réel de  $\hat{f}_p$ . Le bloc algorithme d'optimisation (mécanisme d'ajustement) représenté dans la Figure 3.2 (*Stage 1*), peut être l'un des algorithmes discutés dans la section 2.4 (GA, PSO, FA ou BBO) qui va ajuster les paramètres du modèle flou  $\hat{f}_p$  de telle sorte que l'erreur  $e_1$  entre la sortie du processus  $y$  et la sortie du modèle primaire  $\hat{y}_p$  atteigne sa valeur minimale.

Pour identifier  $\hat{f}_p$ , on va utiliser un modèle autorégressif (AR) flou, qui est une technique de modélisation stochastique des séries temporelles. Le modèle AR (Équation 3.3) fait partie d'un groupe de formules de prédiction qui tentent de prédire la sortie d'un système en se basant sur les résultats précédents (ancienne sortie devient nouvelle entrée) :

$$\hat{y}(k+1) = \hat{f}_p[y(k), y(k-1), \dots, y(k-n+1)]. \quad (3.3)$$

En supposant qu'il existe  $M_1$  règles floues pour le modèle flou AR, les règles floues de T2FPM ( $\hat{f}_p$ ) peuvent être décrites comme suit :

$$\begin{aligned} R^l : & \text{ IF } y(k) \text{ is } \tilde{Y}^l(y_k) \text{ and, } \dots, \text{ and } y(k-n+1) \text{ is } \tilde{Y}^l(y_{k-n+1}), \\ & \text{ THEN } \hat{y}_p = \tilde{Y}^l; \quad l = 1, 2, \dots, M_1, \end{aligned} \quad (3.4)$$

avec  $\tilde{Y}^l(y_{k-i})$  est la fonction d'appartenance type-2 de la prémisse relative au régresseur  $y(k-j)$  et  $\tilde{Y}^l$  est la fonction d'appartenance intervalle de la sortie (conséquence) de la  $l^{ieme}$  règle. Les paramètres du modèle primaire  $\hat{f}_p$  à ajuster par l'algorithme d'optimisation sont les centres (moyennes) des fonctions d'appartenance floues type-2 Gaussiennes de la prémisse  $\tilde{Y}^l(y_k), \tilde{Y}^l(y_{k-1}), \dots, \tilde{Y}^l(y_{k-n+1})$ , et les intervalles de conséquence  $\tilde{Y}^1, \tilde{Y}^2, \dots, \tilde{Y}^{M_1}$ .

### 3.4.4 Identification du processus d'erreur

Le processus d'erreur ( $E_p$ ) est défini comme une interconnexion parallèle entre le processus (signal électrocardiogramme considéré) et le modèle primaire (T2FPM) comme

le montre la Figure 3.2. La sortie  $e_1$  du processus d'erreur ( $E_p$ ) est défini comme suit :

$$e_1 = \hat{y}_p - y. \quad (3.5)$$

Une fois que la sortie du processus d'erreur ( $E_p$ ) est obtenue (Équation 3.5), un deuxième système flou type-2 peut être conçu pour la modélisation de l'erreur  $e_1$ . Ce modèle sera étiqueté par le modèle flou type-2 d'erreur (T2FEM : *Type-2 Fuzzy Error Model*). L'erreur  $e_1$  peut être considérée comme une série temporelle, donc il convient de concevoir son modèle en utilisant un modèle flou autorégressif (AR), qui tente de prédire la nouvelle sortie en fonction des résultats précédents. Le modèle flou AR utilisé pour identifier  $e_1$  peut être décrit comme suit :

$$\hat{e}_1(k+1) = \hat{E}_p[e_1(k), e_1(k-1), \dots, e_1(k-n+1)]. \quad (3.6)$$

La structure de l'étape 2 (*stage 2*) est illustrée dans la Figure 3.2 (*stage 2*), où  $\hat{e}_1$  est la sortie du T2FEM et  $e_2$  est l'erreur de modélisation entre le signal d'erreur  $e_1$  et  $\hat{e}_1$ . Supposant qu'il existe  $M_2$  règles floues pour le modèle flou AR (3.6), les règles floues de T2FEM peuvent être alors décrites comme suit :

$$\begin{aligned} R^l : & \text{ IF } e_1(k) \text{ is } \tilde{E}^l(e_{1,k}) \text{ and, } \dots, \text{ and } e_1(k-n+1) \text{ is } \tilde{E}^l(e_{1,k-n+1}), \\ & \text{ THEN } \hat{e}_1 = \tilde{E}^l ; l = 1, 2, \dots, M_2, \end{aligned} \quad (3.7)$$

avec  $\tilde{E}^l(e_{1,k})$  est la fonction d'appartenance type-2 de la prémisse relative au régresseur  $e_1(k)$  et  $\tilde{E}^l$  est la fonction d'appartenance intervalle de la sortie (conséquence) de la  $l^{ieme}$  règle.

La tâche maintenant est d'ajuster les paramètres du T2FEM jusqu'à ce que l'erreur  $e_2$  atteigne son minimum. Les paramètres du T2FEM à ajuster en utilisant le bloc d'optimisation (cf., Figure 3.2 (*stage 2*)) sont les centres (moyennes) des fonctions d'appartenance floues type-2 Gaussiennes de la prémisse  $\tilde{E}^l(e_{1,k}), \tilde{E}^l(e_{1,k-1}), \dots, \tilde{E}^l(e_{1,k-n+1})$ , et les intervalles de conséquence  $\tilde{E}^1, \tilde{E}^2, \dots, \tilde{E}^{M_2}$ .

### 3.4.5 Conception du modèle final

Dans cette dernière étape (*stage 3*), le modèle primaire  $\hat{f}_p$  et le modèle d'erreur  $\hat{E}_p$  sont interconnectés en une structure parallèle (cf., Figure 3.2 (*stage 3*)) afin d'obtenir le modèle final  $\hat{f}_F$ . Cette configuration nous permettra de compenser l'erreur résiduelle (erreur de modélisation) obtenu dans la première étape (modèle primaire), ce qui a comme conséquence la minimisation de l'erreur de modélisation globale. La sortie  $\hat{y}$  du modèle final peut être décrite comme suit :

$$\hat{y} = \hat{y}_p - \hat{e}_1, \quad (3.8)$$

où  $\hat{y}_p$  et  $\hat{e}_1$  sont les sorties du modèle primaire (T2FPM) et la sortie du modèle d'erreur (T2FEM), respectivement.

La méthode d'identification discutée dans cette section est récapitulée dans la Figure 3.2. Le passage d'un stage à un autre est garanti par des cycles *ON* – *OFF* des commutateurs  $k_1, k_2, \dots, k_7$  comme illustré dans la Figure 3.3.

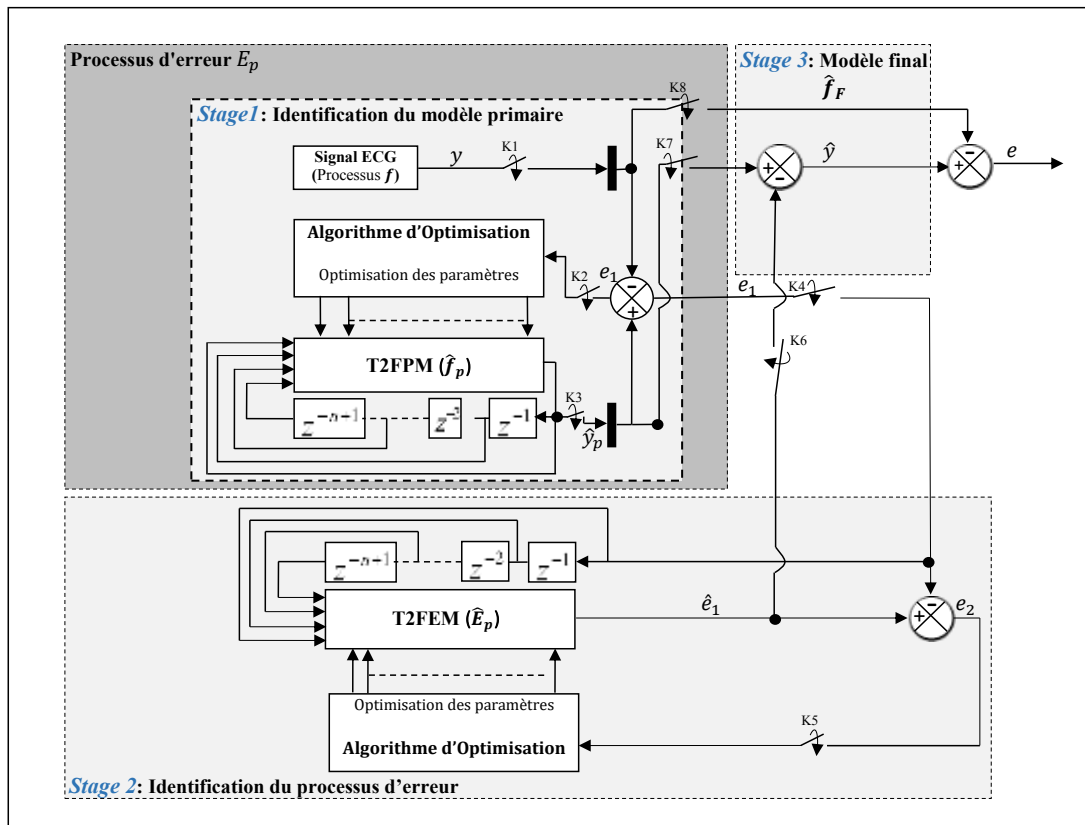


FIGURE 3.2 – Structure de la méthode proposée pour l'identification du signal ECG.

### 3.4.6 Résultats de simulation

Dans cette section nous allons présenter et discuter les résultats de simulation de notre méthode appliquée pour la modélisation de signaux électrocardiogrammes. deux types de signaux électrocardiogrammes ont été considérés :

- ✓ Signal électrocardiogramme synthétique [11] (générer par un modèle mathématique) (cf., chapitre 4).
- ✓ Signal électrocardiogramme réel [132].

Notre méthode a été simulée avec un nombre de règles  $M_1 = M_2 = 40$ . Par conséquent,

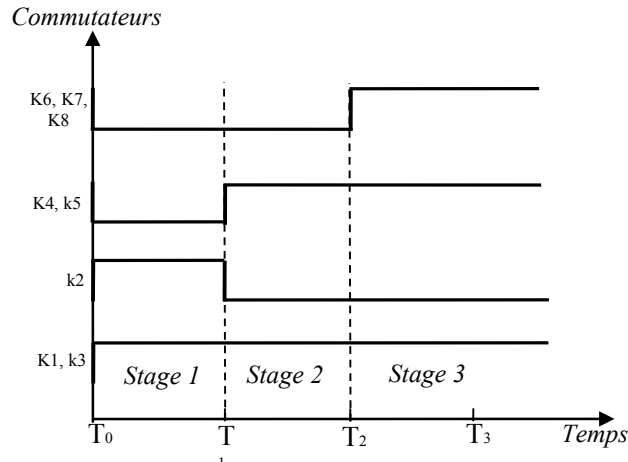


FIGURE 3.3 – Chronogrammes relatifs aux cycles *ON* – *OFF* des commutateurs de la Figure 3.2.

l'identificateur était structuré selon un ensemble de 80 règles (40 pour T2FPM et 40 pour T2FEM), ce qui nous donne  $80 \times 3 = 240$  paramètres ajustables. Au cours de la phase 1 (identification du modèle primaire), il y a un seul intervalle de sortie et deux régresseurs pour chaque règle. Cela signifie qu'il y a  $2 \times 40$  paramètres de prémisse et  $1 \times 40$  paramètres de conséquence. Donc pour l'étape 1 il y'a 120 paramètres ajustables et le même nombre pour l'étape 2 (identification du processus d'erreur), l'ensemble total sera alors de 240 paramètres ajustables.

#### 3.4.6.1 Paramètres des algorithmes métaheuristiques

La taille de la population utilisée dans les algorithmes métaheuristiques est un facteur important dans la détermination de la solution optimale. Lorsque la taille de la population augmente, la solution dans l'espace d'exploration est améliorée ; cependant cela augmente le temps de calcul. Dans ce travail une étude comparative de l'efficacité des différents algorithmes d'optimisations sera présentée et pour fournir une bonne comparaison, la taille de population correspondante pour chaque algorithme a été fixé à 200. Les différents paramètres des différents algorithmes d'optimisations (cf., section 2.4) sont choisis comme suit :

- ✓ GA : la probabilité de croisement et la probabilité de mutation ont été fixées à 0.80 et 0.05, respectivement.
- ✓ PSO : les constantes d'accélération  $C_1 = C_2 = 2$  et le coefficient d'inertie  $\omega = 0.75$ .
- ✓ FA : le coefficient d'absorption de lumière  $\gamma = 1$ , le degré d'attractivité d'une luciole à distance  $r = 0$  est  $\beta_0 = 2$ , et le taux d'amortissement du coefficient de mutation

$\alpha = 0.98$ .

- ✓ BBO : le taux de mutation  $m = 0.01$  et le taux d'immigration  $\lambda_k$  et le taux d'émigration  $\mu_k$  sont similaires aux courbes de migration linéaire (cf., [Figure 2.8](#)).

### 3.4.6.2 Modélisation du signal électrocardiogramme synthétique

Dans cette sous section on va utiliser un modèle mathématique (dynamique) permettant de générer un signal électrocardiogramme [11]. Ce modèle produit une trajectoire dans un espace d'état tridimensionnel avec les coordonnées  $(x, y, z)$ . La quasi périodicité du signal ECG est modélisée par le mouvement de la trajectoire autour d'un cycle limite de rayon unité dans le plan  $(x, y)$ . L'amplitude du signal ECG va être considérée comme la variation suivant l'axe  $z$  de la trajectoire quasi circulaire. Ce modèle génère l'évolution d'une trajectoire circulaire, et à des moments bien déterminés (les instants de réalisation des sommets P, Q, R, S et T) on fait introduire des Gaussiennes dans la direction de l'axe  $z$  dans le but d'obtenir les amplitudes du signal ECG (cf., [chapitre 4](#)).

La méthode de modélisation présentée dans les sections précédentes sera appliquée pour modéliser les données du signal électrocardiogramme synthétique. Quatre cas ont été pris en considération, dans chaque cas, les techniques d'optimisation : PSO, BBO, FA et GA ont été utilisées. Les résultats de simulation relatifs aux PSO, BBO, FA et GA sont illustrés dans les Figures [3.4](#), [3.5](#), [3.6](#), et [3.7](#), respectivement, telle que :

- ✓ sous-figure (a) : représente une superposition du signal ECG synthétique et la sortie du modèle primaire obtenu.
- ✓ sous-figure (b) : représente une superposition du signal ECG synthétique et la sortie du modèle final de ce signal.
- ✓ sous-figure (c) : représente une superposition de l'erreur de modélisation, le modèle de l'erreur de modélisation et l'erreur de modélisation finale.

Comme présenté dans les Figures [3.4](#), [3.5](#), [3.6](#), et [3.7](#), le modèle final est beaucoup mieux que le modèle primaire, où nous constatons que l'erreur de modélisation finale a été réduite dans tous les cas, ce qui permet d'améliorer efficacement le modèle final.

Le meilleur résultat a été obtenu en utilisant la technique d'optimisation BBO ; ce fait est confirmé par une simple inspection visuelle de la Figure [3.8](#), ce qui représente une comparaison entre les erreurs de modélisation finale en utilisant les quatre techniques d'optimisation (PSO, BBO, FA et GA). En se basant sur la Figure [3.8](#), la qualité et l'efficacité d'optimisation des différents algorithmes métaheuristiques utilisés pour ce type d'application (modélisation) peut être classée comme suit : BBO en première position, PSO en deuxième position, FA en troisième position et finalement GA en dernière position.

### 3.4.6.3 Modélisation du signal électrocardiogramme réel

Dans ce qui suit nous allons considérer l'application de notre méthode pour la modélisation d'un signal électrocardiogramme réel. Pour cette fin le signal électrocardiogramme *18177.dat* pris de la base de données MIT-BIH PhysioBank [132] va être considéré comme une fonction inconnue que nous souhaitons de modéliser.

Les résultats expérimentaux sont présentés dans les Figures 3.9, 3.10, 3.11, et 3.12 pour les quatre cas relatifs aux algorithmes d'optimisations déjà mentionnés (PSO, BBO, FA et GA) (cf., section 2.4) où :

- ✓ sous-figure (a) : représente une superposition du signal ECG réel et la sortie du modèle primaire obtenu.
- ✓ sous-figure (b) : représente une superposition du ECG réel et la sortie du modèle final.
- ✓ sous-figure (c) : représente une superposition de l'erreur de modélisation, le modèle de l'erreur de modélisation et l'erreur de modélisation finale.

Semblable au cas de modélisation du signal électrocardiogramme synthétique, l'erreur de modélisation finale a été réduite dans toutes les expériences, par conséquent, un modèle final plus net a été obtenu.

Pour la deuxième fois, la technique d'optimisation BBO a produit les résultats les plus précieux, ce fait est démontré par la Figure 3.13, qui fournit une comparaison entre les éventuelles erreurs de modélisation des quatre méthodes d'optimisation (PSO, BBO, FA et GA).

Dans ce qui suit, on va comparer quantitativement les performances de la méthode proposée en utilisant les quatre algorithmes d'optimisation PSO, BBO, FA et GA. Nous avons exécuté notre algorithme 20 fois comme essais indépendants pour chaque algorithme d'optimisation. Des mesures de performance statistiques telles que la mauvaise et la meilleure valeur, la moyenne, déviation standard (STD) et le taux de convergence (TC) de la fonction objectif (Équation 3.2) étaient estimées et présentée dans le Tableau 3.1, ceci nous confirme que l'algorithme BBO est clairement supérieur et possède les meilleures performances tout au long des tests indépendants. Noter également que les deux algorithmes d'optimisations FA et GA utilisés dans notre méthode de modélisation ont eu la deuxième et la troisième : meilleure valeur, moyenne et la déviation standard de la fonction objectif 3.2, respectivement. L'algorithme d'optimisation PSO a échoué en termes de moyenne et déviation standard de la fonction objectif 3.2. En terme de taux de convergence, nous avons constaté que les deux algorithmes d'optimisations FA et GA avaient un taux de convergence mieux que PSO et BBO ; l'algorithme d'optimisation BBO a eu le plus rapide vitesse de convergence par rapport à l'algorithme PSO.

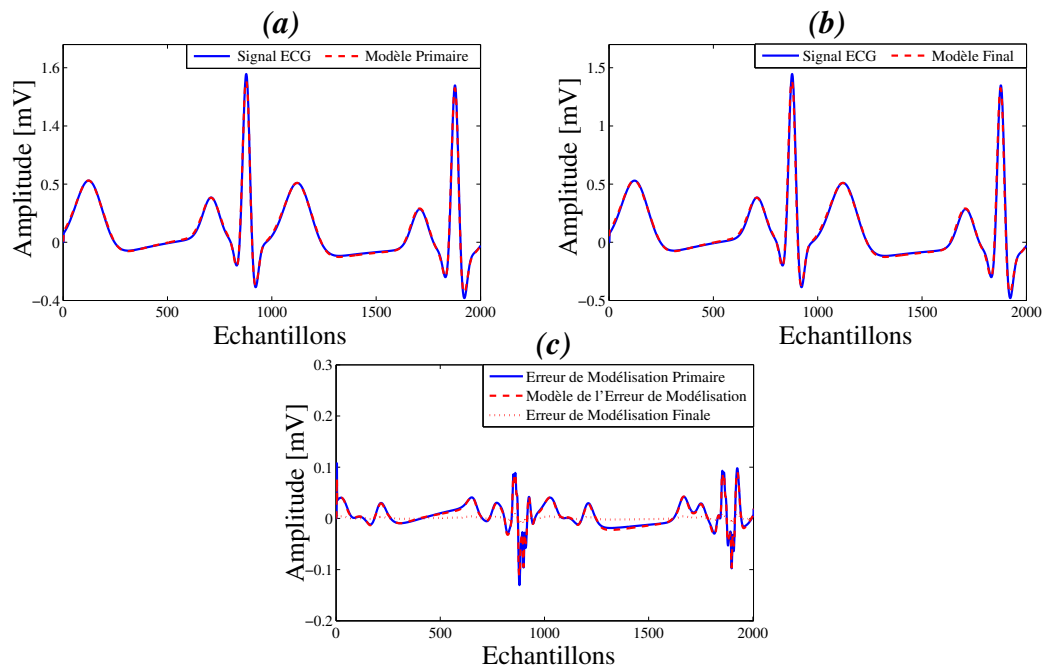


FIGURE 3.4 – Résultats de modélisation du signal ECG synthétique basé sur PSO, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale.

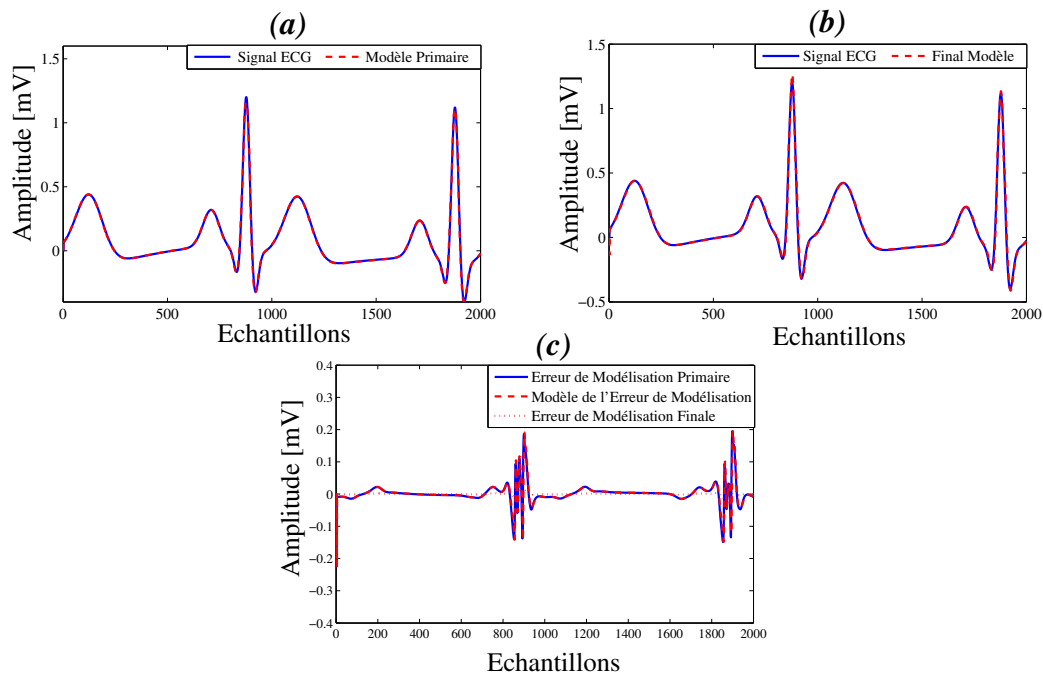


FIGURE 3.5 – Résultats de modélisation du signal ECG synthétique basé sur BBO, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale.

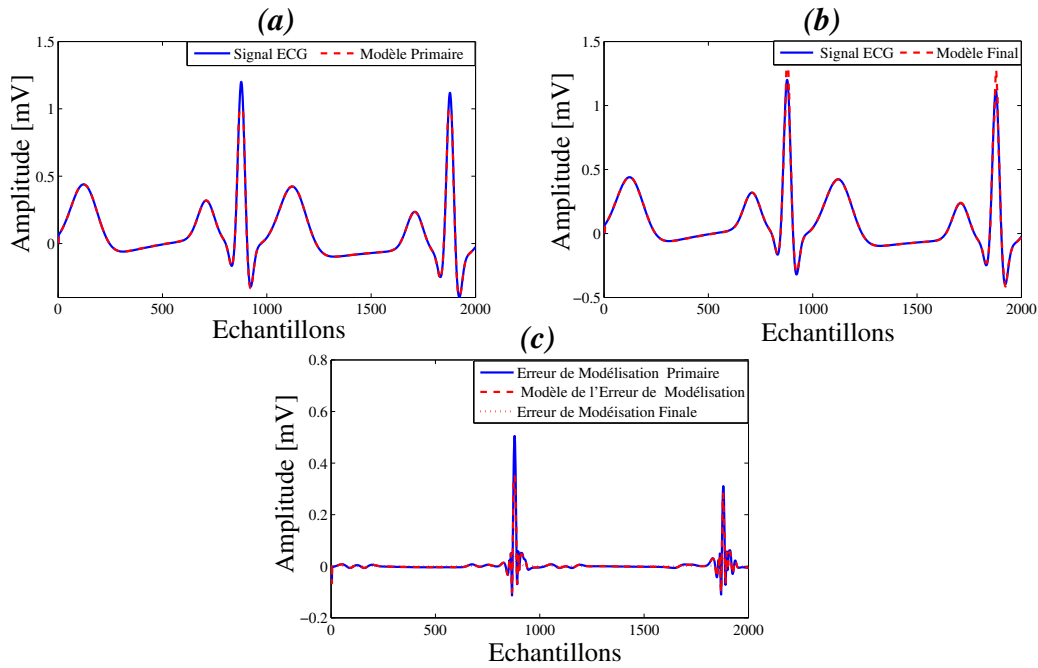


FIGURE 3.6 – Résultats de modélisation du signal ECG synthétique basé sur FA, (a) Modélé primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale.

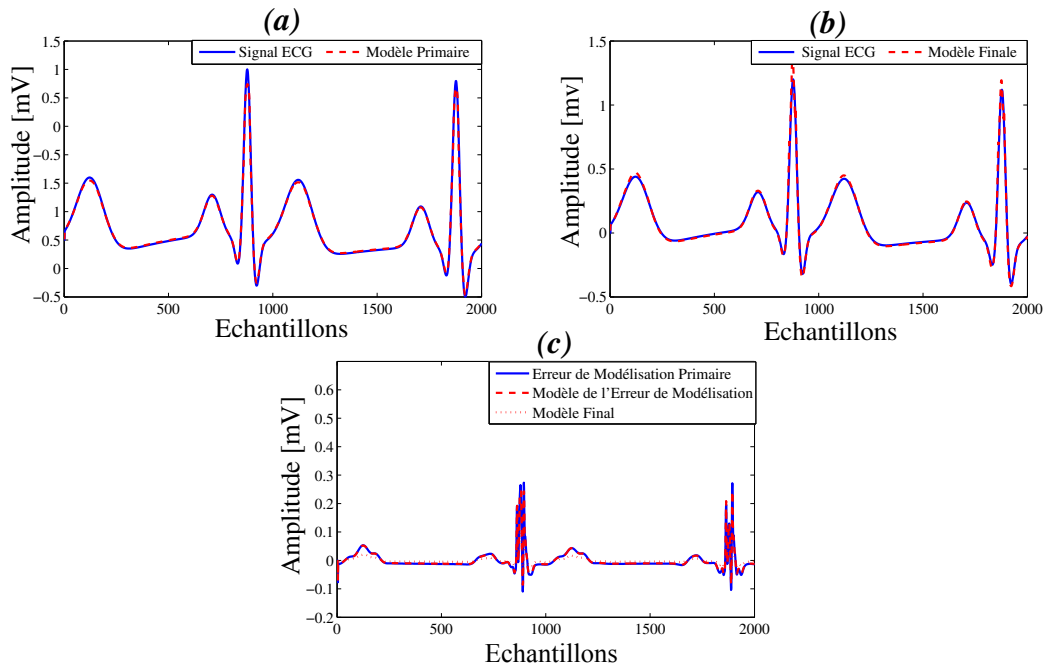


FIGURE 3.7 – Résultats de modélisation du signal ECG synthétique basé sur GA, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale.




FIGURE 3.8 – Comparaison entre les erreurs de modélisation du signal ECG synthétique en utilisant PSO, BBO, FA et GA.

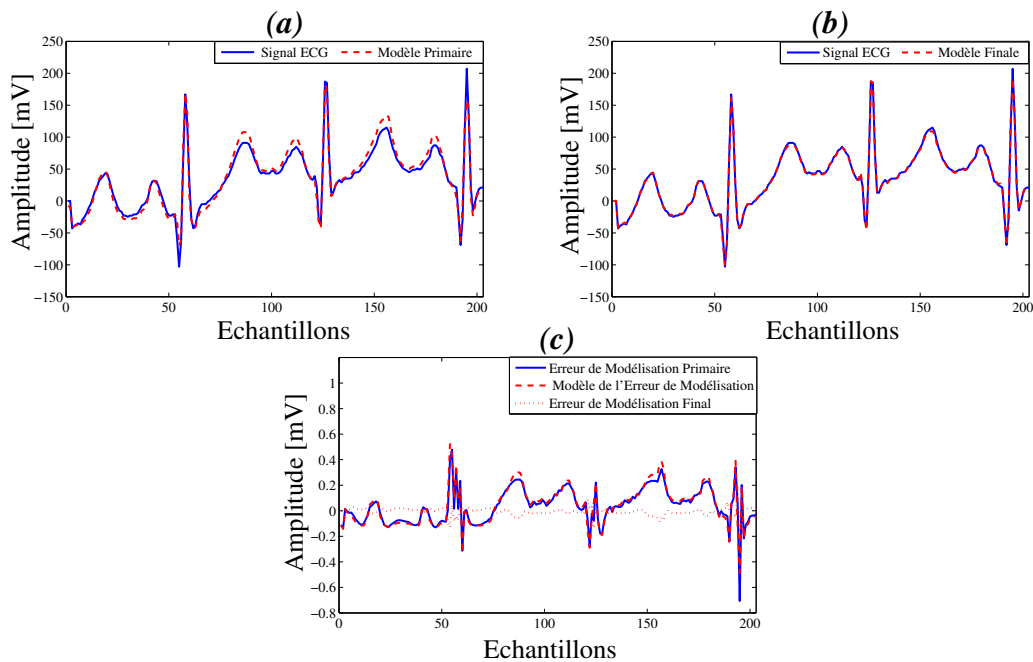


FIGURE 3.9 – Résultats de modélisation du signal ECG réel (18177.dat) basé sur PSO, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale.

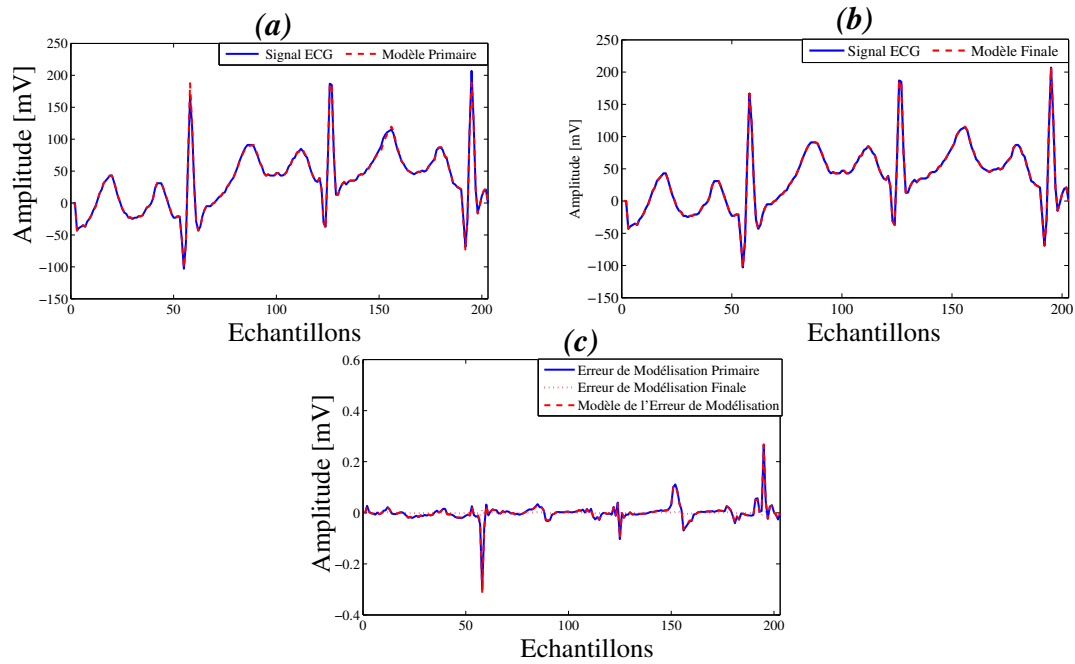


FIGURE 3.10 – Résultats de modélisation du signal ECG réel (18177.dat) basé sur BBO, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale.

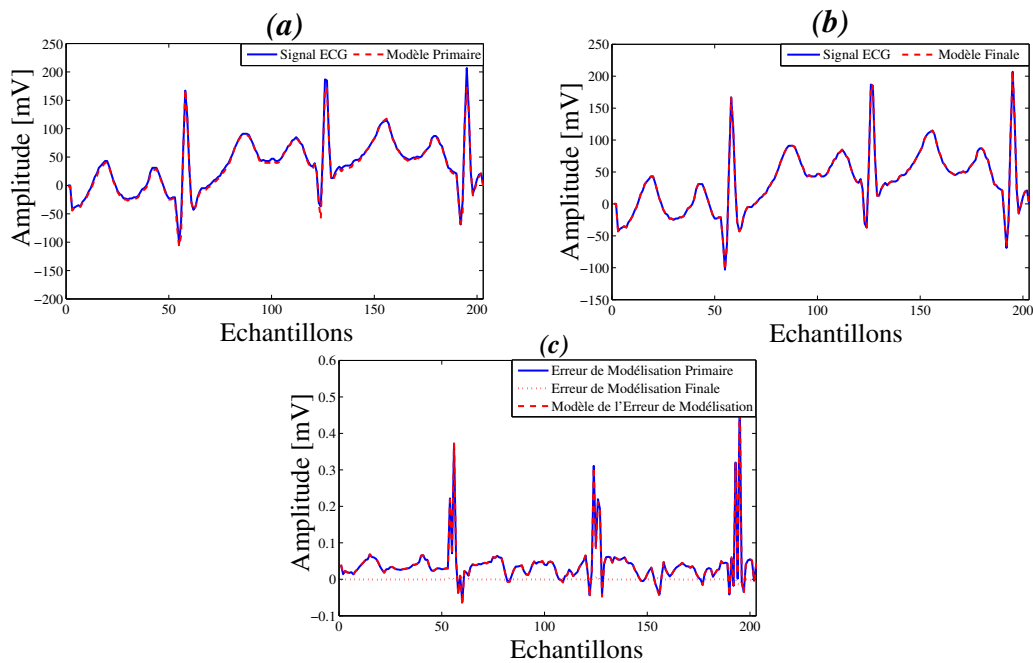


FIGURE 3.11 – Résultats de modélisation du signal ECG réel (18177.dat) basé sur FA, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale.

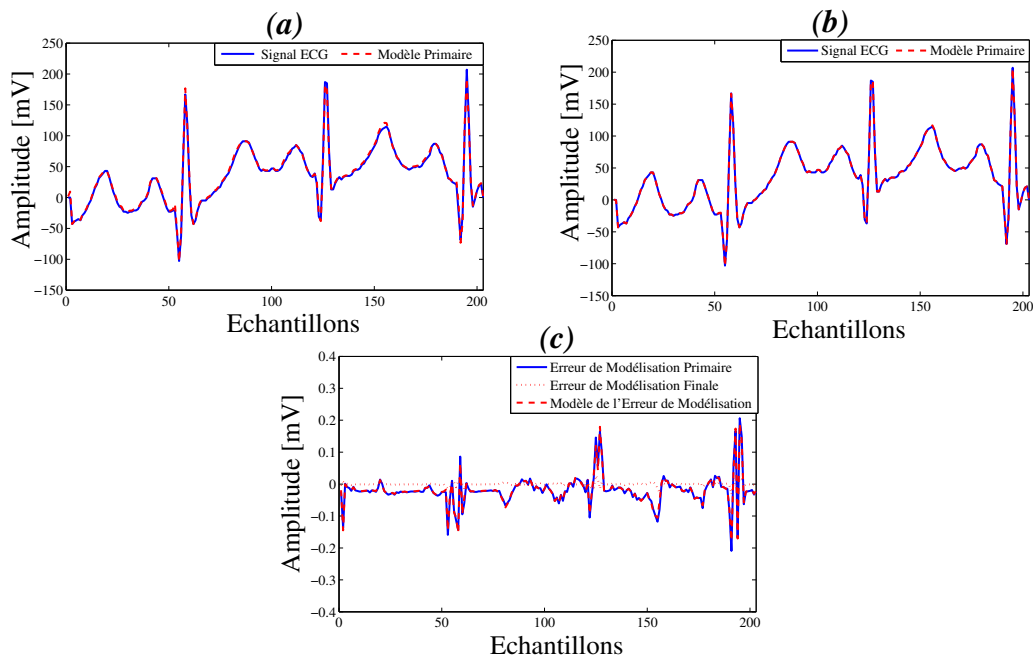


FIGURE 3.12 – Résultats de modélisation du signal ECG réel (18177.dat) basé sur GA, (a) Modèle primaire, (b) Modèle final, (c) Erreur de modélisation primaire Vs Erreur de modélisation finale.




FIGURE 3.13 – Comparaison entre les erreurs de modélisation du signal ECG réel (18177.dat) en utilisant PSO, BBO, FA et GA.

TABLE 3.1 – Performances statistiques de 20 essais indépendants avec 200 itérations.

<i>Algorithme</i>	<b>Mauvaise</b>	<b>Moyenne</b>	<b>Meilleure</b>	<b>STD</b>	<b>TC</b>
<i>PSO</i>	0.0083	0.0046	0.0011	0.0022	1
<i>BBO</i>	<b>1.4101e-005</b>	<b>4.5348e-006</b>	<b>4.0313e-006</b>	<b>2.1946e-006</b>	0.921
<i>FA</i>	7.9309e-005	2.4644e-005	4.3402e-006	2.2606e-005	<b>0.657</b>
<i>GA</i>	0.0019	4.9229e-004	3.4177e-005	0.0022	0.894

Pour une analyse statistique supplémentaire et une interprétation complète, nous avons considéré les barres d'erreur des différents algorithmes d'optimisation. Cette technique est une représentation graphique de la variabilité des paramètres estimés (Paramètres du modèle flou proposé), pour avoir une idée générale sur l'incertitude d'estimation et la précision des valeurs des paramètres trouvés. Les barres d'erreur des paramètres d'optimisation du modèle primaire et du modèle d'erreur sont présentées dans les Figures 3.14 et 3.15, respectivement, où nous pouvons clairement voir que les largeurs des barres d'erreur de la méthode BBO sont les plus étroites par rapport aux méthodes PSO, BBO et GA. Ce fait est confirmé quantitativement dans le tableau 3.2 où nous fournissons des mesures statistiques telles que les moyennes et les intervalles de confiance (CI : *Confidence Interval*) du 83<sup>ième</sup> paramètre (utilisé à titre d'exemple parmi les 120 paramètres) sur les 20 essais indépendants.

TABLE 3.2 – Valeurs moyennes et les intervalles de confiance du 83<sup>ième</sup> paramètre de 20 essais indépendants.

<i>Algorithme</i>	<b>Moyenne</b>		<b>CT(95%)</b>	
	<i>Stage 1</i>	<i>Stage 2</i>	<i>Stage 1</i>	<i>Stage 2</i>
<i>PSO</i>	-0.5722	-1.4601	[-2.5257 : 1.3813]	[-3.7226 : 0.8024]
<i>BBO</i>	-2.9277	0.2884	[-3.6413 : -2.2141]	[0.2713 : 0.3055]
<i>FA</i>	0.8611	-0.0427	[-1.7125 : 3.4347]	[-2.4884 : 2.4030]
<i>GA</i>	0.3173	0.4350	[-2.8446 : 3.4792]	[-3.4374 : 4.3047]

### 3.4.7 Essais de validation et de généralisation

Dans cette sous-section, nous allons montrer la nature universelle de la méthode proposée à partir de deux points de vue :

- ✓ Application de la méthode proposée pour modéliser des données bruitées.

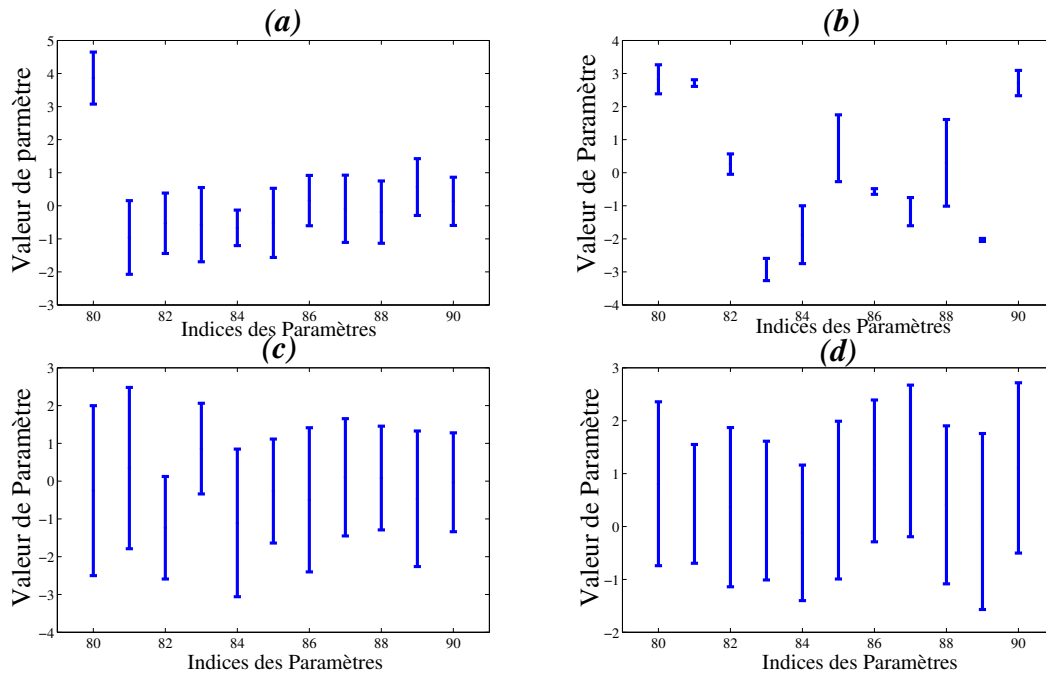


FIGURE 3.14 – Barres d’erreur des paramètres du modèle primaire, (a) PSO, (b) BBO, (c) FA, (d) GA.

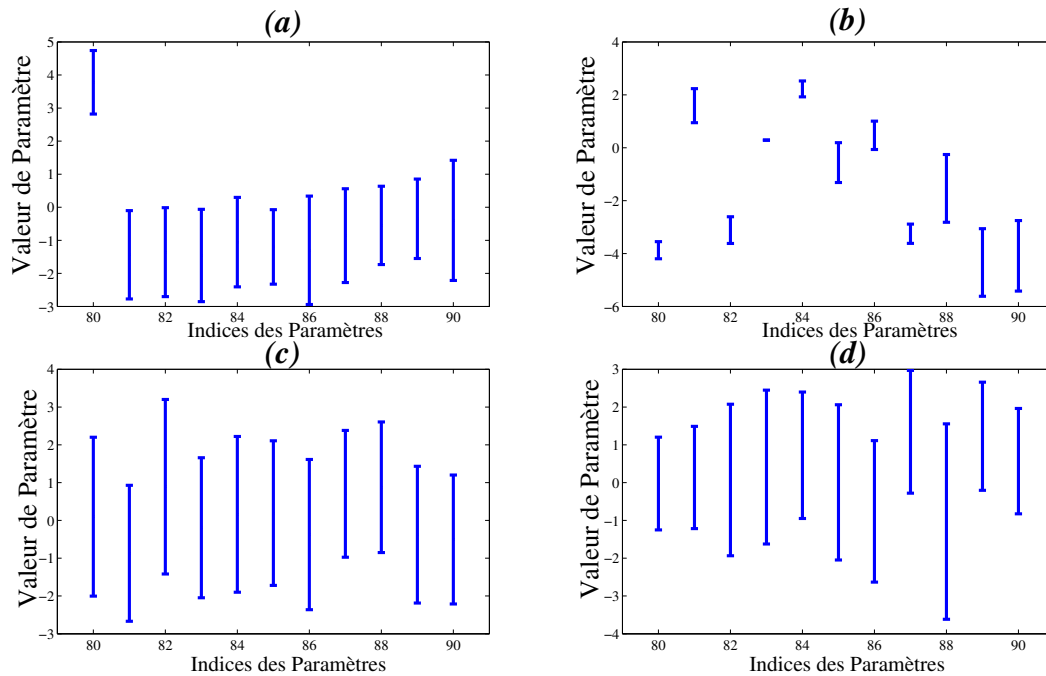


FIGURE 3.15 – Barres d’erreur des paramètres du modèle d’erreur, (a) PSO, (b) BBO, (c) FA, (d) GA.

- ✓ Application de la méthode proposée pour la modélisation des systèmes dynamiques non-linéaires.

### 3.4.7.1 Modélisation des données bruitées

Dans ce qui suit, nous validons la robustesse et l'efficacité de notre approche en l'appliquant à un signal électrocardiogramme bruité. La Figure 3.16 représente le résultat de simulation correspondant dans lequel nous voyons clairement que le modèle du signal ECG bruité (18177.dat [132] + bruit blanc Gaussien) suit bien la morphologie du signal ECG réel bruité ( $MSE = 1.215e - 006$ ).




FIGURE 3.16 – Modélisation du signal ECG réel bruité, (a) signal ECG réel bruité, (b) Modèle du signal ECG réel bruité ( $MSE = 1.215e - 006$ ).

### 3.4.7.2 Modélisation des systèmes dynamiques non linéaires

Dans cette sous-section, les trois systèmes dynamiques non linéaires [133] décrits ci-dessous vont être considérer pour modélisation :

- **Modèle I :**

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1)] + \sum_{i=0}^{m-1} \beta_i u(k-1). \quad (3.9)$$

- **Modèle II :**

$$y_p(k+1) = \sum_{i=0}^{n-1} \alpha_i y_p(k-1) + g[u(k), u(k-1), \dots, u(k-m+1)]. \quad (3.10)$$

- **Modèle III :**

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1)] + g[u(k), u(k-1), \dots, u(k-m+1)]. \quad (3.11)$$

La seule modification qu'on doit apporter, afin d'appliquer notre méthode pour la modélisation des systèmes dynamiques non linéaires est d'utiliser les modèles autorégressifs et moyenne mobile flou type-2 (T2FARMA : *Type-2 Fuzzy Auto Regressive Moving Average*) au lieu des modèles autorégressifs flou type-2 (T2FAR : *Type-2 Fuzzy Auto Regressive*) pour identifier le modèle primaire (*Stage 1*) dans ce qui suit nous résumons les différentes étapes de notre méthode pour modéliser les systèmes dynamiques :

- **Etape 1** : dans cette étape (*Stage 1*), l'ensemble de données  $(u_1, y_1)$  est utilisé pour déterminer le modèle flou type-2 primaire (T2FPM : *Type-2 Fuzzy Primary Model*)  $\hat{f}_p$  du procédé (le système dynamique non linéaire en considération) (cf., [Figure 3.17](#) (*Stage 1*)) où :

$f$  : fonction inconnue qui représente le système dynamique que nous souhaitons identifier.

$(u_1, y_1)$  : données d'apprentissage (entrée-sortie du procédé).

$\hat{y}_{p1}$  : sortie du modèle primaire.

$e_1$  : erreur de modélisation primaire que nous allons utiliser pour exciter les algorithmes d'optimisation.

La structure de cette première étape est la même que celle discutée dans la sous-section 3.4.3 et qui consiste en une adaptation en ligne des paramètres du modèle primaire  $\hat{f}_p$  en utilisant l'un des algorithmes d'optimisation : PSO, BBO, FA ou GA (cf., [section 2.4](#)), jusqu'à ce que l'erreur  $e_1$  atteigne son minimum.

Supposons qu'il y a  $M_1$  règles floues type-2, et on va utiliser un modèle flou type-2 autorégressif et moyenne mobile pour identifier le modèle primaire (T2FPM)  $\hat{f}_p$ . Alors, les règles du modèle primaire peuvent être décrites comme suit :

$$R^l : \mathbf{IF} \ u_1(k) \mathbf{is} \ \tilde{U}^l(u_1) \ \mathbf{and} \ y(k) \mathbf{is} \ \tilde{Y}^l(y_k) \ \mathbf{and}, \dots, \ \mathbf{and} \ y(k-n+1) \mathbf{is} \ \tilde{Y}^l(y_{k-n+1}), \\ \mathbf{THEN} \ \hat{y}_p = \tilde{Y}^l ; \ l = 1, 2, \dots, M_1, \quad (3.12)$$

où  $\tilde{U}^l(u_1)$  et  $\tilde{Y}^l(y_{k-j})$  sont les fonctions d'appartenance floues type-2 de la prémisse relatives aux régresseurs  $u_1(k)$  et  $y(k-j)$ , respectivement, et  $\tilde{Y}^l$  est la fonction d'appartenance intervalle de la sortie (conséquence) de la  $l^{ieme}$  règle. Les paramètres du modèle primaire  $\hat{f}_p$  à ajuster sont les centres (moyennes) des fonctions d'appartenance floues type-2 Gaussiennes de la prémisse et les intervalles de conséquence.

- **Etape 2** : dans cette deuxième étape (*Stage 2*), et pour des raisons de généralisation, le modèle primaire est validé avec de nouvelles données d'entrée  $u_2$  afin d'obtenir un nouveau signal d'erreur  $e_2$  (erreur générale) qui sera ensuite considéré comme la sortie du processus d'erreur (cf., [Figure 3.17](#)). Le processus d'erreur est défini par l'interconnexion parallèle entre le procédé et le modèle primaire

comme le montre la Figure 3.17, où l'entrée est le nouveau signal  $u_2$  et la sortie est le signal d'erreur  $e_2$  décrit comme suit :

$$e_2 = \hat{y}_{p2} - y_2, \quad (3.13)$$

avec  $y_2$  et  $\hat{y}_{p2}$  sont la nouvelle sortie du procédé et du modèle primaire, respectivement, correspondantes à la nouvelle entrée  $u_2$ . Une fois la sortie du processus d'erreur  $e_2$  obtenue (Équation 3.13), un deuxième système flou type-2 peut être conçu pour modéliser  $e_2$ . Ce modèle sera étiqueté par « modèle flou type-2 de l'erreur générale  $\hat{E}_p$  » (T2FGEM : *Type-2 Fuzzy General Error Model*) (cf., Figure 3.17 (Stage 2)). La tâche maintenant est d'ajuster les paramètres du modèle  $\hat{E}_p$  (T2FGEM) jusqu'à ce que l'erreur  $e_3$  (cf., Figure 3.17 (Stage 2)) atteigne son minimum. L'erreur  $e_2$  est une série temporelle, donc il convient de concevoir son modèle en utilisant un modèle flou type-2 autorégressif. Supposons qu'il y a  $M_2$  règles floues type-2. Les règles de ce modèle peuvent être décrites de la manière suivante :

$$\begin{aligned} R^l : & \text{ IF } e_2(k) \text{ is } \tilde{E}^l(e_{2,k}) \text{ and, } \dots, \text{ and } e_2(k-n+1) \text{ is } \tilde{E}^l(e_{2,k-n+1}), \\ & \text{ THEN } \hat{e}_2 = \tilde{E}^l ; l = 1, 2, \dots, M_2, \end{aligned} \quad (3.14)$$

avec  $\tilde{E}^l(e_{2,k-j})$  est la fonction d'appartenance floue type-2 de la prémisse relative au régresseur  $e_2(k-j)$ , et  $\tilde{E}^l$  est la fonction d'appartenance intervalle de la sortie (conséquence) de la  $l^{i\text{eme}}$  règle. Les paramètres du modèle primaire  $\hat{E}_p$  à ajuster sont les centres (moyennes) des fonctions d'appartenances floues type-2 Gaussiennes de la prémisse et les intervalles de conséquence.

- **Étape 3** : dans cette dernière étape (Stage 3), le modèle primaire  $\hat{f}_p$  et le modèle d'erreur  $\hat{E}_p$  sont interconnectés en une structure parallèle (cf., Figure 3.17 (Stage 3)) afin d'obtenir un modèle final plus net  $\hat{f}_F$ , ce modèle est décrit comme suit :

$$\hat{y}_2 = \hat{y}_{p2} - \hat{e}_2. \quad (3.15)$$

La structure complète de ce système de modélisation flou type-2 pour les systèmes dynamiques non linéaire est illustrée dans la Figure 3.17, où le passage d'une étape à une autre est assuré par les cycles  $On - OFF$  des commutateurs  $k_1, k_2, \dots, k_{10}$  de la Figure 3.18.

### A. Modélisation du système I

Dans cette sous-section nous allons examiner l'efficacité de notre méthode sur un système plus compliqué (cf., Équation 3.9), en considérant le cas particulier régi par l'équa-

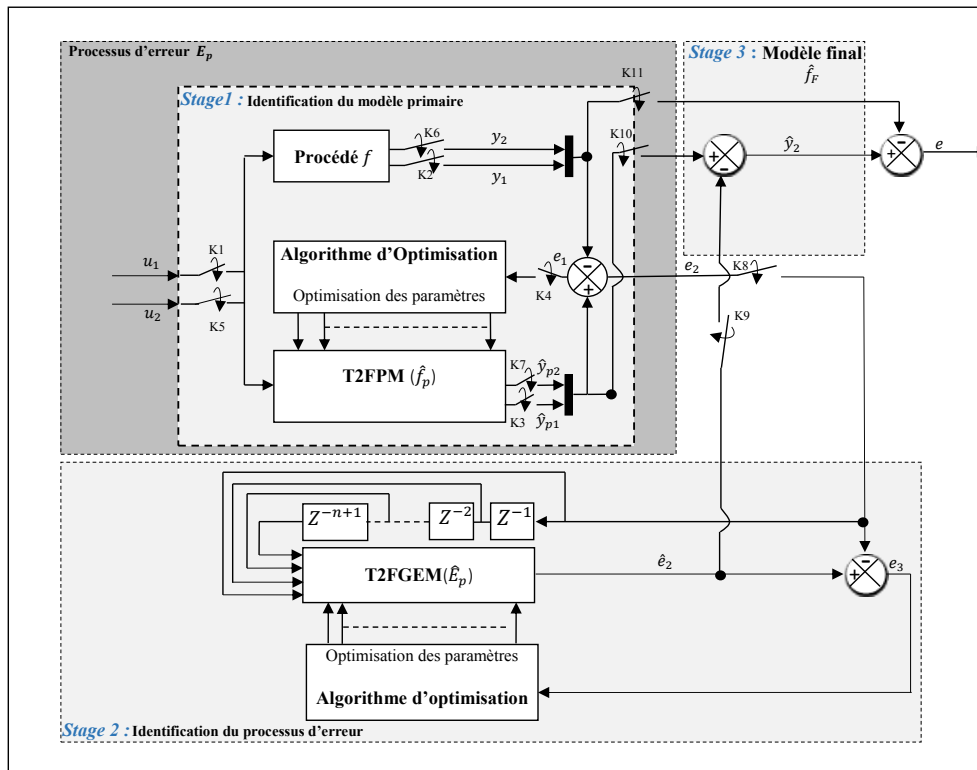


FIGURE 3.17 – Structure de la méthode proposée pour l’identification des systèmes dynamiques non linéaires.

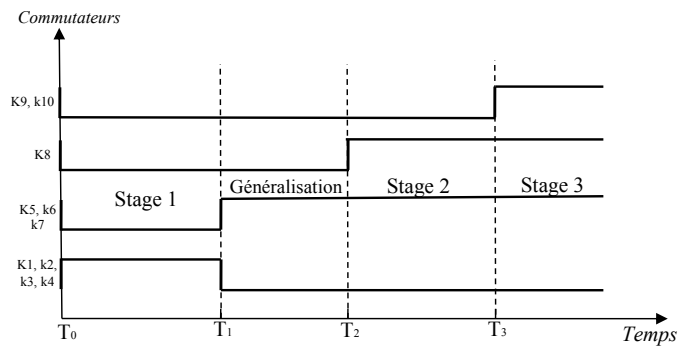


FIGURE 3.18 – Chronogrammes relatifs aux cycles ON – OFF des commutateurs de la Figure 3.17.

tion aux différences suivante :

$$y_p(k + 1) = f[y_p(k), y_p(k - 1)] + u(k), \tag{3.16}$$

avec :

$$f[y_p(k), y_p(k-1)] = \frac{y_p(k)y_p(k-1)[y_p(k) + 2.5]}{1 + y_p^2(k) + y_p^2(k-1)}, \quad (3.17)$$

$f$  est la partie de l'Équation 3.16 à identifier en utilisant le modèle primaire  $\hat{f}_p$  selon le modèle flou type-2 auto régressif du deuxième ordre suivant :

$$\begin{aligned} R^l : & \text{ IF } y(k) \text{ is } \tilde{Y}^l(y_k) \text{ and } y(k-1) \text{ is } \tilde{Y}^l(y_{k-1}), \\ & \text{ THEN } \hat{f}_p^l = \tilde{f}^l ; l = 1, 2, \dots, M_1, \end{aligned} \quad (3.18)$$

où  $\tilde{Y}^l(y_k)$  et  $\tilde{Y}^l(y_{k-1})$  sont les fonctions d'appartenance floues type-2 de la prémisse relatives aux régresseurs  $y(k)$  et  $y(k-1)$ , respectivement, et  $\tilde{f}^l$  sont les intervalles ajustables de la conséquence.

Au cours de la deuxième étape, le processus d'erreur  $\hat{E}_p$  est identifié en utilisant le modèle flou type-2 autorégressif du deuxième ordre comme suit :

$$\begin{aligned} R^l : & \text{ IF } e_2(k) \text{ is } \tilde{E}^l(e_{2,k}) \text{ and } e_2(k-1) \text{ is } \tilde{E}^l(e_{2,k-1}), \\ & \text{ THEN } \hat{E}_p^l = \tilde{E}^l ; l = 1, 2, \dots, M_2, \end{aligned} \quad (3.19)$$

où  $\tilde{E}^l(e_{2,k})$  et  $\tilde{E}^l(e_{2,k-1})$  sont les fonctions d'appartenance floues type-2 de la prémisse relatives aux régresseurs  $e_2(k)$  et  $e_2(k-1)$ , respectivement, et  $\tilde{E}^l$  sont les intervalles ajustables de la conséquence.

La méthode a été simulée en utilisant un nombre de règles similaires à ce utiliser en sous-section 3.4.6 (même nombre de paramètres ajustable). Les différents paramètres des algorithmes d'optimisation utilisés sont aussi similaires à ceux présentés dans la section 3.4.6.1. Les Figures 3.19, 3.20, 3.21 et 3.22 représentent les résultats de simulation en utilisant les différents algorithmes d'optimisation où :

- ✓ sous-figure (a) : représente une superposition de la sortie du procédé et la sortie du modèle primaire en utilisant la première entrée  $u_1$  avec :

$$u_1(k) = \sin\left(\frac{2\pi k}{25}\right). \quad (3.20)$$

- ✓ sous-figure (b) : représente une superposition de la sortie du procédé et la sortie du modèle primaire en utilisant la deuxième entrée (généralisation)  $u_2$  avec :

$$u_2(k) = \sin\left(\frac{2\pi k}{25}\right) \text{ for } 1 \leq k \leq 50 \text{ \& } 150 \leq k \leq 200. \quad (3.21)$$

$$u_2(k) = 0.5 \sin\left(\frac{2\pi k}{10}\right) + 0.5 \sin\left(\frac{2\pi k}{5}\right) \text{ } 50 \leq k \leq 150. \quad (3.22)$$

- ✓ sous-figure (c) : représente une superposition de l'erreur de modélisation et le modèle de l'erreur de modélisation.

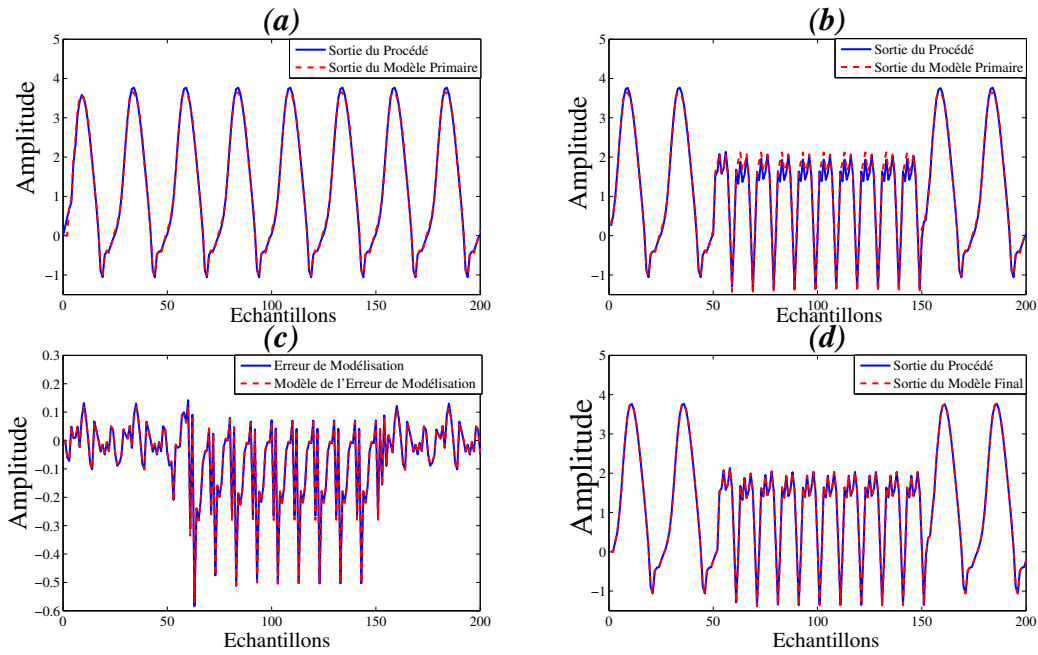


FIGURE 3.19 – Résultats de modélisation du système dynamique non linéaire (Équation 3.16) basé sur PSO, (a) Modèle primaire, (b) Validation, (c) Modèle de l'erreur de modélisation, (d) Modèle final.

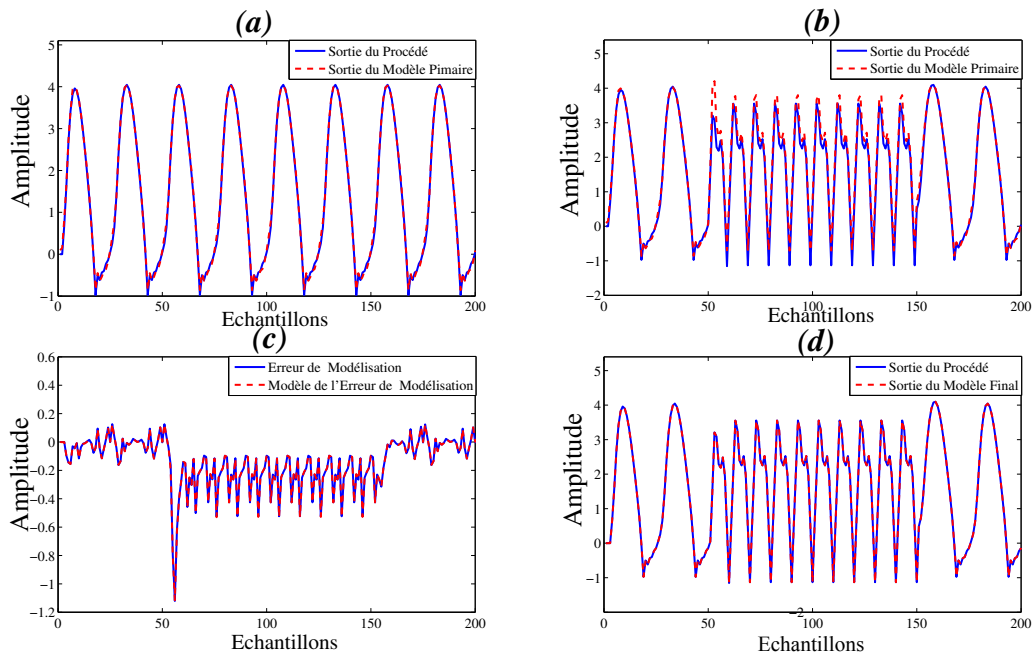


FIGURE 3.20 – Résultats de modélisation du système dynamique non linéaire (Équation 3.16) basé sur BBO, (a) Modèle primaire, (b) Validation, (c) Modèle de l'erreur de modélisation, (d) Modèle final.

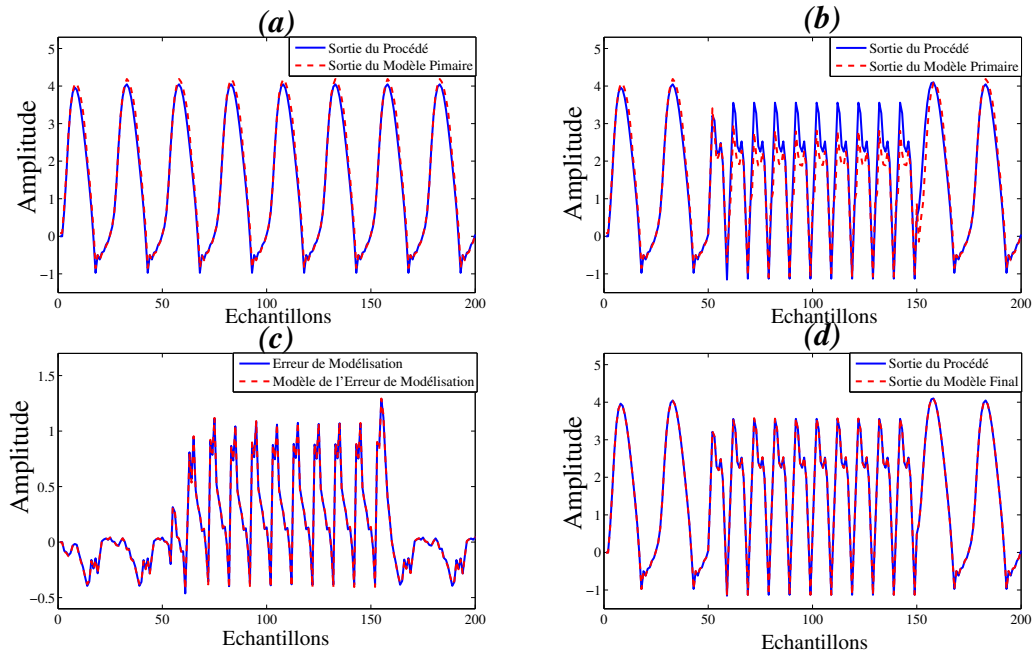


FIGURE 3.21 – Résultats de modélisation du système dynamique non linéaire (Équation 3.16) basé sur FA, (a) Modèle primaire, (b) Validation, (c) Modèle de l'erreur de modélisation, (d) Modèle final.

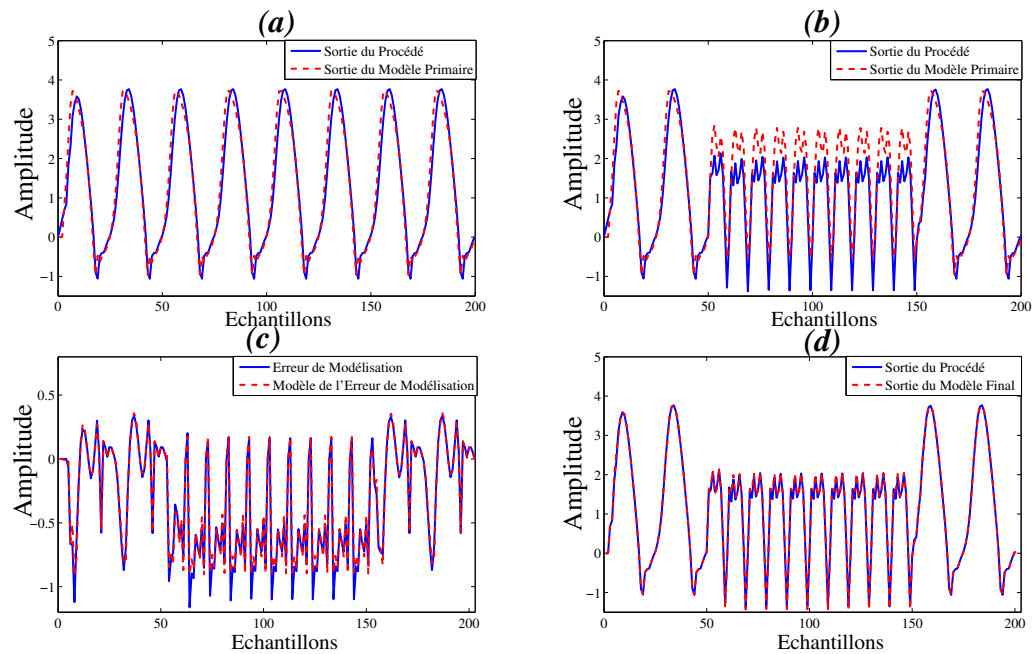


FIGURE 3.22 – Résultats de modélisation du système dynamique non linéaire (Équation 3.16) basé sur GA, (a) Modèle primaire, (b) Validation, (c) Modèle de l'erreur de modélisation, (d) Modèle final.

✓ sous-figure (d) : représente une superposition de la sortie du procédé et la sortie du modèle final.

Par une inspection visuelle des Figures 3.19, 3.20, 3.21, et 3.22, nous constatons clairement que la sortie du modèle final est bien meilleur que celle du modèle primaire avec toutes les techniques d'optimisation discutées (PSO, BBO, FA et GA). Nous confirmons ce fait par la comparaison visuelle donnée sur la Figure 3.23 où nous présentons une superposition des courbes d'erreurs. La figure 3.23 montre également que le résultat obtenu avec l'algorithme BBO est le meilleur comparativement aux autres techniques (PSO, FA et GA).

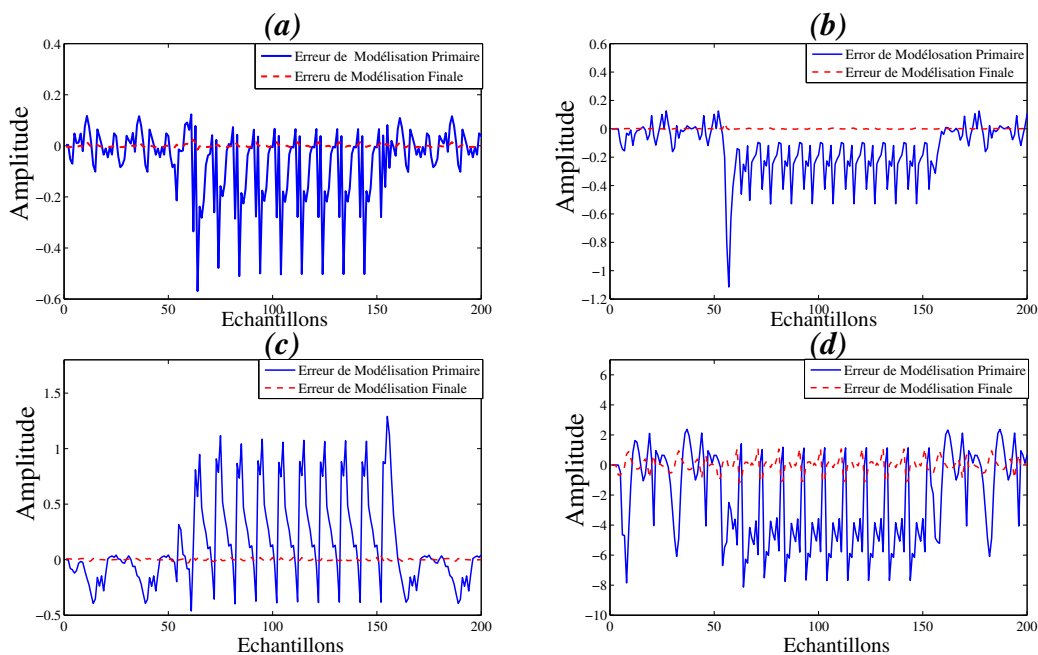


FIGURE 3.23 – Comparaison entre le modèle primaire et final en termes d'erreur avec (a) PSO, (b) BBO, (c) FA, (d) GA.

Dans ce qui suit, nous allons comparer quantitativement les performances de la méthode proposée pour la modélisation des systèmes dynamiques non linéaire, en utilisant les quatre algorithmes d'optimisation PSO, BBO, FA et GA. Nous avons exécuté notre algorithme 20 fois comme essais indépendants pour chaque algorithme d'optimisation. Des mesures de performance statistiques telles que la mauvaise et la meilleure valeur, la moyenne, la déviation standard (STD) et le taux de convergence (TC) de la fonction objectif (Équation 3.2) étaient estimées et présentées dans le Tableau 3.3, où l'algorithme BBO préserve une autre fois sa supériorité pour ce type de problèmes qui est la modélisation des systèmes dynamiques non linéaire par rapport aux autres techniques d'optimisations (PSO, FA, et GA).

TABLE 3.3 – Performances statistiques de 20 essais indépendants avec 200 itérations.

Algorithme	Mauvaise	Moyenne	Meilleure	STD	TC
PSO	7.8820e-004	1.6196e-004	3.1008e-005	1.6196e-004	1
BBO	<b>7.7998e-006</b>	<b>2.2326e-006</b>	<b>1.2501e-006</b>	<b>6.9036e-006</b>	0.9782
FA	0.5896	0.0331	5.8205e-005	0.1319	<b>0.7861</b>
GA	0.1036	0.0289	0.0017	0.387	0.95

Considérant Maintenant la représentation des barres d'erreur. Les Figures 3.24 et 3.25 représentent les barres d'erreur des paramètres du modèle primaire et du modèle d'erreur, respectivement, où nous pouvons clairement voir que les largeurs des barres d'erreur de la technique d'optimisation BBO sont les plus étroites par rapport aux autres techniques (PSO, FA et GA), ce résultat est confirmé quantitativement dans le Tableau 3.4 où nous présentons des mesures statistiques telles que les moyennes et les intervalles de confiance (CI : *Confidence Interval*) du 83<sup>iem</sup> paramètre.

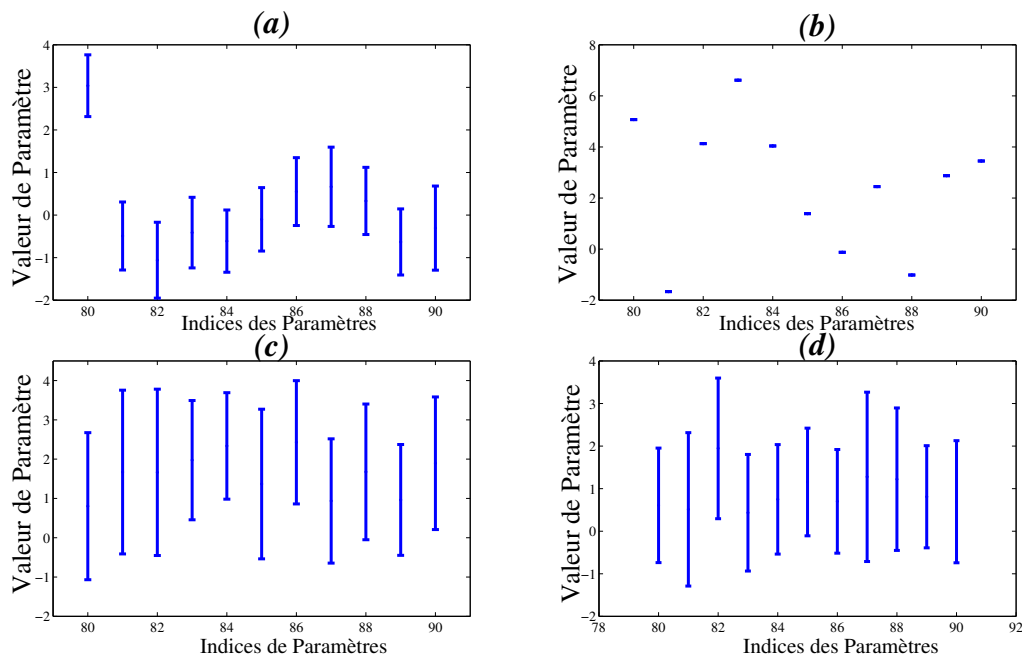


FIGURE 3.24 – Barres d'erreur des paramètres du modèle primaire (a) PSO, (b) BBO, (c) FA, (d) GA.

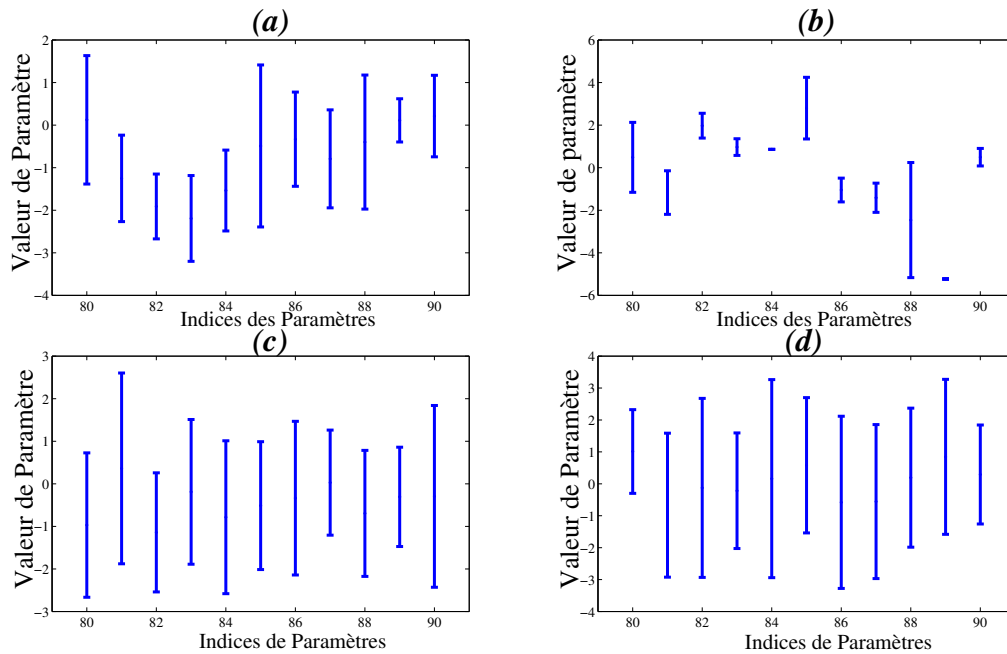


FIGURE 3.25 – Barres d’erreur des paramètres du modèle d’erreur (a) PSO, (b) BBO, (c) FA, (d) GA.

TABLE 3.4 – Valeurs moyennes et les intervalles de confiance du 83<sup>ième</sup> paramètre de 20 essais indépendants.

<i>Algorithme</i>	<b>Moyenne</b>		<b>CT(95%)</b>	
	<i>Stage 1</i>	<i>Stage 2</i>	<i>Stage 1</i>	<i>Stage 2</i>
<b>PSO</b>	-0.4124	-2.0840	[-1.6427 : 0.8179]	[-3.2614 : -0.9062]
<b>BBO</b>	6.6136	0.9665	[tend vers zéro]	[0.4568 : 1.4762]
<b>FA</b>	0.8611	-0.1887	[-1.7125 : 3.4347]	[-2.8145 : 2.4371]
<b>GA</b>	0.4773	-0.2173	[-1.7996 : 2.7542]	[-3.4451 : 3.0105]

## B. Modélisation du système II

Dans ce qui suit nous examinons l’efficacité de notre méthode sur un deuxième système plus compliqué (Équation 3.10), en prenant en considération l’équation aux différences suivante :

$$y_p(k+1) = 0.3y_p(k) + 0.6y_p(k-1) + f[u(k)], \quad (3.23)$$

où la fonction inconnue  $f$  à identifier possède la forme suivante :

$$f(u) = 0.6 \sin(\pi u) + 0.3 \sin(3\pi u) + 0.1 \sin(5\pi u). \quad (3.24)$$

Le signal d'entrée  $u$  du procédé et du modèle est choisi sinusoïdal comme suit :

$$u(k) = \sin\left(\frac{2\pi k}{250}\right). \quad (3.25)$$

Dans la première étape, le modèle primaire  $\hat{f}_p$  est identifié en utilisant un modèle flou type-2 autorégressif du deuxième ordre où les règles floues peuvent être décrites comme suit :

$$\begin{aligned} R^l : & \text{ IF } u(k) \text{ is } \tilde{U}^l(u_k) \text{ and } u(k-1) \text{ is } \tilde{U}^l(u_{k-1}), \\ & \text{ THEN } \hat{f}_p^l = \tilde{f}^l; \quad l = 1, 2, \dots, M_1, \end{aligned} \quad (3.26)$$

avec  $\tilde{U}^l(u_k)$  et  $\tilde{U}^l(u_{k-1})$  sont les fonctions d'appartenance floues type-2 de la prémisse relatives aux régresseurs  $u(k)$  et  $u(k-1)$ , respectivement, et  $\tilde{f}^l$  sont les intervalles ajustables de la conséquence.

Pour la deuxième étape, le processus d'erreur  $\hat{E}_p$  est identifié en utilisant un modèle flou type-2 autorégressif du deuxième ordre comme suit :

$$\begin{aligned} R^l : & \text{ IF } e_2(k) \text{ is } \tilde{E}^l(e_{2,k}) \text{ and } e_2(k-1) \text{ is } \tilde{E}^l(e_{2,k-1}), \\ & \text{ THEN } \hat{E}_p^l = \tilde{E}^l; \quad l = 1, 2, \dots, M_2, \end{aligned} \quad (3.27)$$

avec  $\tilde{E}^l(e_{2,k})$  et  $\tilde{E}^l(e_{2,k-1})$  sont les fonctions d'appartenance floues type-2 de la prémisse relatives aux régresseurs  $e_2(k)$  et  $e_2(k-1)$ , respectivement, et  $\tilde{E}^l$  sont les intervalles ajustables de la conséquence.

La Figure 3.26, représente les résultats finaux de l'identificateur flou type-2 en utilisant le PSO, BBO, FA et GA, respectivement, avec les mêmes paramètres des algorithmes d'optimisation et le même nombre de règles que ceux utilisés dans la section 3.4.6. En inspectant les zooms, nous confirmons l'efficacité de notre méthode pour ce type de problèmes et la supériorité de l'algorithme BBO par rapport aux autres techniques d'optimisation (PSO, FA, GA).

### B. Modélisation du système III

Le modèle III (Équation 3.11), pour lequel l'entrée et la sortie du système sont tous les deux compris dans la non linéarité, va être utilisé pour confirmer l'efficacité de notre méthode pour ce type de problèmes, en considérant le cas particulier décrit par l'équation aux différences suivante :

$$y_p(k+1) = f(y_p(k), u(k)) = \frac{y_p(k)}{1 + y_p(k)^2} + u^3(k). \quad (3.28)$$

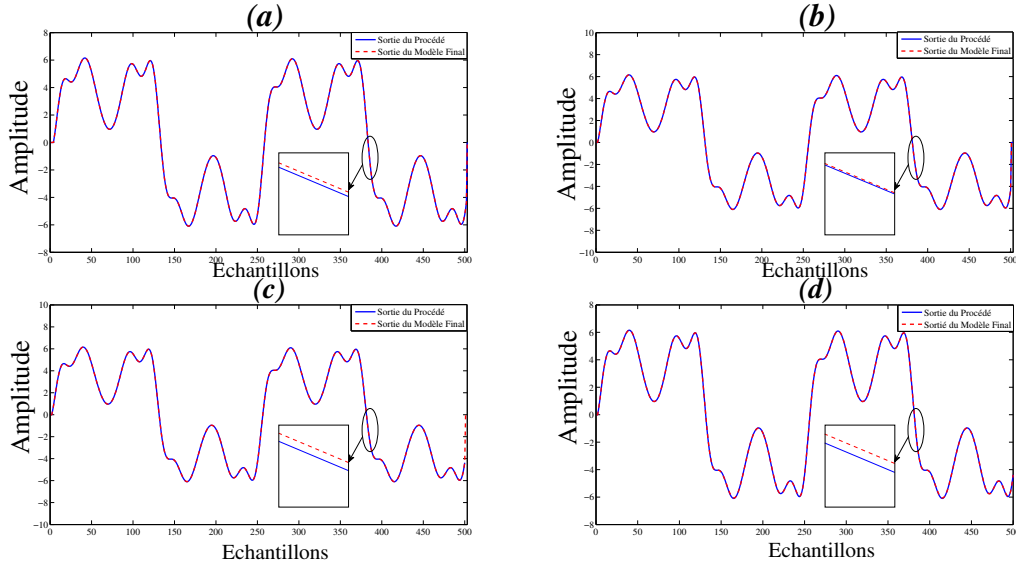


FIGURE 3.26 – Résultats de modélisation du système dynamique non linéaire (Équation 3.23) : (a) PSO, (b) BBO, (c) FA, (d) GA.

où la fonction inconnue  $f$  à identifier a une forme plus générale du fait que ses variables indépendantes sont les signaux d'entrée et de sortie.

Le signal d'entrée  $u$  est choisi comme suit :

$$u(k) = \sin\left(\frac{2\pi k}{25}\right) + \sin\left(\frac{2\pi k}{10}\right). \quad (3.29)$$

$f$  est identifiée dans la première étape par le modèle primaire  $\hat{f}_p$  selon les règles floues type-2 ARMA du deuxième ordre suivantes :

$$\begin{aligned} R^l : & \text{ IF } u(k) \text{ is } \tilde{U}^l(u_k) \text{ and } y(k) \text{ is } \tilde{Y}^l(y_k), \\ \text{ THEN } & \hat{f}_p^l = \tilde{f}^l; \quad l = 1, 2, \dots, M_1, \end{aligned} \quad (3.30)$$

avec  $\tilde{U}^l(u_k)$  et  $\tilde{Y}^l(y_k)$  sont les fonctions d'appartenance floues type-2 de la prémisse relatives aux régresseurs  $u(k)$  et  $y(k)$ , respectivement,  $\tilde{f}^l$  sont les intervalles ajustables de la conséquence et  $M_1$  est le nombre de règles.

Dans la deuxième étape, le processus d'erreur  $\hat{E}_p$  est identifié en utilisant le modèle flou type-2 AR du deuxième ordre suivant :

$$\begin{aligned} R^l : & \text{ IF } e_2(k) \text{ is } \tilde{E}^l(e_{2,k}) \text{ and } e_2(k-1) \text{ is } \tilde{E}^l(e_{2,k-1}), \\ \text{ THEN } & \hat{E}_p^l = \tilde{E}^l; \quad l = 1, 2, \dots, M_2, \end{aligned} \quad (3.31)$$

avec  $\tilde{E}^l(e_{2,k})$  et  $\tilde{E}^l(e_{2,k-1})$  sont les fonctions d'appartenance floues type-2 de la prémisse relatives aux régresseurs  $e_2(k)$  et  $e_2(k-1)$ , respectivement,  $\tilde{E}^l$  sont les intervalles ajustables de la conséquence et  $M_2$  est le nombre de règles.

Nous avons simulé ce cas avec le même nombre de règles et paramètres des algorithmes d'optimisations qu'avec le système I et système II. La figure 3.27 représente une superposition de la sortie du procédé et la sortie finale de l'identificateur flou type2 en utilisant le PSO, BBO, FA et GA, respectivement. Toujours, l'efficacité de notre système et la supériorité de l'algorithme BBO est confirmée (voir les zooms dans la Figure 3.27).

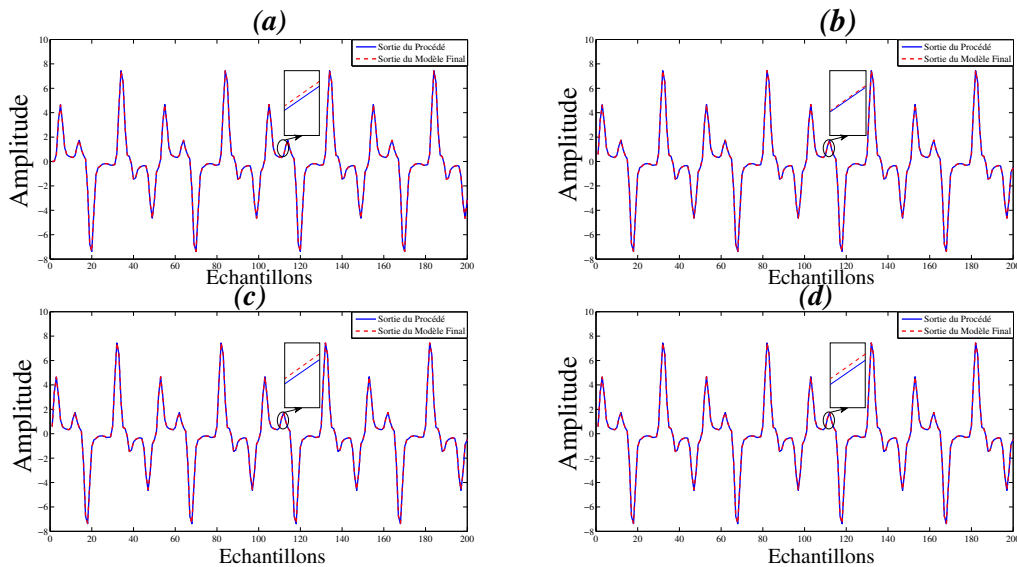


FIGURE 3.27 – Résultats de modélisation du système dynamique non linéaire (Équation 3.28) : (a) PSO, (b) BBO, (c) FA, (d) GA.

### 3.4.8 Étude comparative

Pour évaluer la performance de la structure de l'identificateur flou type-2 présenté dans ce chapitre en termes de temps de calcul (TC), la méthode sera de nouveau appliquée à des signaux électrocardiogrammes réels de la base de données MIT-BIH PhysioBank [129] et des systèmes dynamiques non linéaires (cf., sous-sous-section 3.4.7.2). Généralement, dans les systèmes flous, le temps de calcul peut être réduit en réduisant le nombre de règles. Dans notre cas, cela doit être fait sous la contrainte de préserver la qualité d'ajustement. Pour cette raison, l'erreur quadratique moyenne ( $MSE$ ) (Équation 3.2) doit être considérée.

Le Tableau 3.5 présente une étude comparative prenant en compte un nombre différent de règles du système flou (10, 8, 6, 4 et 2 règles) et un nombre différent d'itération des algorithmes d'optimisation utilisés (200, 100 et 50 itérations). Ce tableau (Tableau 3.5) montre que notre approche peut préserver un petit  $MSE$  sous la contrainte d'un faible nombre de règles, cela montre également que le temps de calcul est considérablement

diminué.

TABLE 3.5 – Performance avec différents nombre de règles et d'itérations en termes d'*MSE* et TC.

Itération	Type des données		$M_1=M_2=10$ Règles		$M_1=M_2=8$ Règles		$M_1=M_2=6$ Règles		$M_1=M_2=4$ Règles		$M_1=M_2=2$ Règles	
			<i>MSE</i>	TC	<i>MSE</i>	TC	<i>MSE</i>	TC	<i>MSE</i>	TC	<i>MSE</i>	TC
200	Signal ECG Réel	100.dat	1.25e-005	28.51	2.14e-005	27.35	5.12e-005	25.71	1.87e-004	25.10	2.15e-004	23.11
		105.dat	9.84e-006		1.13e-005		3.54e-005		1.22e-004		1.75e-004	
		210.dat	6.21e-005		6.98e-005		7.25e-005		4.21e-004		6.54e-004	
	Système dynamique non Linéaire	Modèle I	2.15e-005		2.47e-005		3.25e-005		1.45e-004		3.21e-004	
		Modèle II	1.84e-005		2.75e-005		2.91e-005		1.26e-004		2.76e-004	
		Modèle III	6.51e-005		6.99e-005		7.42e-005		8.88e-004		9.41e-004	
100	Signal ECG Réel	100.dat	7.33e-005	14.55	7.96e-005	14.55	8.01e-005	12.24	4.15e-004	11.93	5.15e-004	11.93
		105.dat	5.12e-005		5.77e-005		6.55e-005		2.14e-004		3.33e-004	
		210.dat	5.74e-005		7.45e-005		7.59e-005		3.28e-004		4.32e-004	
	Système dynamique non Linéaire	Modèle I	1.41e-005		2.71e-005		9.76e-005		3.64e-004		3.89e-004	
		Modèle II	1.01e-005		1.54e-005		9.71e-005		3.44e-004		3.81e-004	
		Modèle III	4.42e-004		5.01e-004		5.99e-004		1.23e-003		1.98e-004	
50	Signal ECG Réel	100.dat	2.15e-004	7.86	3.24e-004	6.93	7.42e-004	6.93	1.14e-003	6.15	2.98e-003	5.90
		105.dat	1.26e-004		2.22e-004		4.25e-004		1.01e-003		1.80e-003	
		210.dat	2.15e-004		3.67e-004		3.95e-004		8.01e-003		9.20e-003	
	Système dynamique non Linéaire	Modèle I	1.32e-004		1.42e-004		3.75e-004		7.12e-003		9.37e-003	
		Modèle II	8.57e-05		1.42e-004		3.90e-004		9.71e-004		1.25e-003	
		Modèle III	1.32e-003		3.59e-003		5.79e-003		8.66e-003		8.99e-003	

Pour évaluer la performance de la méthode proposée par rapport à d'autres méthodes de référence pour la modélisation des séries temporelles et les systèmes dynamiques non linéaires, les résultats de notre étude ont été comparés à des travaux récemment publiés, où ces méthodes de référence ont été comparées à d'autres méthodes dans le documents original, afin de produire une comparaison valide, la méthode proposée a été simulée avec les mêmes paramètres, les mêmes séries temporelles et dans les mêmes conditions en utilisant les mêmes critères d'évaluation que ceux utilisés dans les études de comparaison avec les méthodes de référence. La comparaison de notre méthode avec la méthode SOFNN-AGA [15] est donnée dans le Tableau 3.6. Les auteurs de cette méthode (SOFNN-AGA) ont comparé leur travail avec d'autres méthodes telles que : FAOS [12], GPFNN [13], SOFNN-ACA [14], NFN-FOESA [16], SOFMLS [17], LRFNN-SVR [18], et SOFNNGA [134], Dans lesquels ils ont appliqué leur méthode pour prédire la série temporelle Mackey-Glass défini comme suit :

$$x(t+1) = (1-a)x(t) + \frac{bx(t-\tau)}{1+x^{10}(t-\tau)}, \quad (3.32)$$

avec  $a = 0.1$ ,  $b = 0.2$ ,  $\tau = 17$  et l'état initiale  $x(0) = 1.2$ . Le modèle de prédiction est

donné par :

$$x(t + p) = f[x(t), x(t + \Delta t), x(t - 2\Delta t), x(t - 3\Delta t)]. \quad (3.33)$$

Dans cet exemple 500 échantillons entre  $t = 0$  et 500 sont choisis comme des échantillons d'apprentissage et 500 autres échantillons entre  $t = 501$  et 1000 sont choisis pour le test. le Tableau 3.6 montre l'étude comparative en utilisant les deux critères suivants :

1. Pourcentage de l'erreur moyenne (APE : *Average Percentage Error*) :

$$APE(t) = \frac{1}{N} \sum_{t=1}^N \left| \frac{y_d(t) - y(t)}{y_d(t)} \right| \times 100\%. \quad (3.34)$$

2. Racine de l'erreur quadratique moyenne (RMSE : *Root-Mean-Squared Error*) :

$$RMSE(t) = \sqrt{\frac{1}{N} \sum_{t=1}^N [y_d(t) - y(t)]^2}. \quad (3.35)$$

avec  $N$  le nombre d'échantillons,  $y(t)$  et  $y_d(t)$  sont la sortie et la sortie désirée, respectivement.

Du Tableau 3.6, on peut voir que notre approche possède presque le plus petit nombre de règles et les plus faibles valeurs des critères :  $RMSE$ ,  $APE$ , et TC par rapport aux autres méthodes, ce qui confirme la supériorité de notre méthode.

TABLE 3.6 – Comparaison de la méthode proposée avec plusieurs méthodes de références

Méthode	Règle	RMSE d'apprentissage		RMSE de Test		APE de Test		TC(s)
		Moyenne	STD	Moyenne	STD	Moyenne	STD	
Méthode Proposée ( $M1=M2$ )	2	0.0067	2.03e-005	0.0074	1.74e-005	1.51e-007	3.62e-007	15.22
SOFNN-AGA (taux d'apprentissage adaptatif)	6	0.0166	2.10e-04	0.0119	9.50e-04	0.0076	8.25e-04	21.2
SOFNN-AGA (taux d'apprentissage fixe=0,01)	8	0.019	0.0023	0.0165	0.0029	0.0095	0.003	36.7
SOFNN-AGA (taux d'apprentissage fixe=0,05)	6	0.0201	0.0015	0.0198	0.0033	0.0125	0.0036	36.38
SOFNN-AGA (taux d'apprentissage fixe=0,1)	9	0.0185	0.0101	0.0179	0.0085	0.0102	0.0039	35.41
GPNN	7	0.0117	0.0021	0.0107	0.0026	0.0076	0.0035	27.33
FAOS-PFNN	11	0.0073	0.0013	0.0127	0.0021	0.009	0.0011	18.18
NFN-FOESA	9	0.0178	0.0021	0.0127	0.001	0.0079	0.0019	48.42
SOFMLS	7	0.0356	0.007	0.0471	0.0019	0.0019	0.0017	52.35
SOFNNGA	7	0.019	0.002	0.0132	0.0015	0.0094	0.0021	168.35
SOFNN-ACA	7	0.0187	0.0045	0.201	0.0019	0.0076	0.001	27.33
LRFNN-SVR	3	0.0407	0.005	0.055	0.0031	0.0391	0.0026	72.1

## 3.5 Conclusion

Dans ce chapitre, nous avons présenté une nouvelle technique pour résoudre deux problèmes classiques qui sont : la modélisation des séries temporelles (le signal électrocardiogramme dans notre cas) et le temps de calcul des systèmes flous type-2. La technique proposée est basée sur la logique floue type-2 et les algorithmes metaheuristiques.

Cette méthode peut être appliquée à plusieurs domaines, notamment la télé-médecine (compression), la biométrie (classification (cf., [chapitre 5](#)), le traitement du signal et le débruitage (cf., [chapitre 4](#)) et d'autres comme la prédiction et l'égalisation des canaux de transmission. L'approche permet de généraliser la notion d'identification en ajoutant un nouveau module d'identification, appelé modèle d'erreur. Le modèle d'erreur flou type-2 introduit a été utilisé comme un complément du modèle primaire pour améliorer la qualité du modèle, ce qui a fourni une bonne précision. L'optimisation des paramètres de l'identificateur flou type-2 proposé a été assurée en utilisant différents algorithmes d'optimisation (PSO, BBO, FA et GA). Plusieurs résultats de simulations ont été introduits y compris la modélisation des systèmes dynamiques non linéaires pour vérifier l'efficacité de notre méthode pour ce type de problèmes. Les résultats de simulation ont montré qu'avec cette méthode, nous pouvons réduire le nombre de règles floues type-2 à seulement deux règles sans perdre la qualité d'ajustement. Des résultats expérimentaux et des études comparatives ont confirmé que les meilleurs résultats d'optimisation ont été obtenus avec l'algorithme BBO, et que notre identificateur flou type-2 est meilleur que d'autres méthodes de références.



## **PRÉ-TRAITEMENT DU SIGNAL ÉLECTROCARDIOGRAMME**

---

*La fonction du filtrage consiste à estimer une information (signal) utile noyée dans un bruit. Le filtrage (ou débruitage) du signal électrocardiogramme est une technique de suppression du « bruit » autour du « signal » produit par un électrocardiographe. Comme il a été annoncé au chapitre 1, plusieurs types de bruits peuvent affecter l'ECG, il y a le bruit de haute fréquence, provoqué par l'activité musculaire extra-cardiaque et les interférences dues aux appareils électriques, et le bruit de basse fréquence provoqué par le mouvement du corps lié à la respiration, les changements physicochimiques induits par les électrodes posées sur la peau et les micro variations du flux sanguin. Dans ce chapitre, nous présentons plusieurs techniques de filtrages du signal électrocardiogramme basées sur différentes approches y compris, la logique floue, le filtre de kalman étendu, et la décomposition en valeurs singulières.*

### **Sommaire**

---

<b>4.1 Introduction</b> . . . . .	<b>94</b>
<b>4.2 État de l'art sur le filtrage du signal électrocardiogramme</b> . . . . .	<b>95</b>
4.2.1 Travaux qui s'intéressent au bruit haute fréquence . . . . .	95
4.2.2 Travaux qui s'intéressent au bruit basse fréquence . . . . .	99
4.2.3 Travaux qui s'intéressent à la séparation des signaux électrocardiogrammes mère-foetus . . . . .	100
<b>4.3 Contributions</b> . . . . .	<b>102</b>
<b>4.4 Filtrage du signal ECG par le filtre flou adaptatif</b> . . . . .	<b>103</b>
4.4.1 Filtre flou adaptatif . . . . .	103
4.4.2 Conception du filtre flou adaptatif basé sur l'algorithme BBO . . .	104
4.4.3 Résultats de simulation . . . . .	106
<b>4.5 Filtrage du signal ECG par le filtre de Kalman étendu adaptatif</b> . . .	<b>115</b>

---

4.5.1	Filtre de kalman étendu . . . . .	115
4.5.2	Modèle dynamique du signal ECG . . . . .	117
4.5.3	Conception du filtre de Kalman étendu adaptatif basé sur l'algorithme BBO . . . . .	120
4.5.4	Résultats de simulation . . . . .	124
<b>4.6</b>	<b>Filtrage du signal ECG par la décomposition en valeurs singulières</b>	<b>125</b>
4.6.1	La décomposition en valeurs singulières . . . . .	125
4.6.2	Pseudo inverse . . . . .	127
4.6.3	Hypothèse de filtrage par SVD . . . . .	128
4.6.4	Méthode de filtrage du signal ECG par SVD et résultats de simulation . . . . .	132
<b>4.7</b>	<b>Séparation des signaux ECG Mère-Foetus par SVD</b>	<b>134</b>
<b>4.8</b>	<b>Suppression de la déformation de la ligne de base</b>	<b>137</b>
4.8.1	Résultats de simulation . . . . .	140
4.8.2	Étude comparative . . . . .	142
<b>4.9</b>	<b>Conclusion</b>	<b>144</b>

---

## 4.1 Introduction

**L**'une des étapes principales de l'opération d'acquisition de données est le filtrage. Le filtrage est une opération relative, c'est-à-dire pour l'appliquer nous devons déterminer ce qu'on veut filtrer (déterminer les signaux utiles et les signaux parasites ou perturbateurs). Par exemple, si notre système est un RADAR poursuivant un avion, le signal utile sera la position de cet avion, et tous les autres signaux seront considérés comme perturbation. Dans notre cas, le signal utile est le signal électrocardiogramme, et les signaux parasites seront tous les autres signaux que ce soient extérieurs (bruit des instruments, bruit de contact et de mouvement) ou intérieurs (interférence entre les signaux circulant dans le corps humain). Donc, nous pouvons dire que la fonction principale d'un filtre est de minimiser l'effet des perturbations et de délivrer un signal utile plus lisse. Le filtrage du signal électrocardiogramme (ECG) est une étape très importante dans le processus de diagnostic des maladies cardiovasculaires. Cette dernière opération se compose de deux parties, l'extraction des caractéristiques du signal électrocardiogramme et la classification selon le type de pathologies. L'opération de classification nécessite de bonnes caractéristiques ce qui implique un bon signal utile.

Plusieurs sources de bruit qui contaminent le signal électrocardiogramme ont été discutées en détail en [chapitre 1](#), ces genres de bruit peuvent être classés en trois catégories :

1. **Bruit haute fréquence** : comme le bruit des instruments qui constituent l'électrocardiographie, l'interférence entre les signaux circulant dans le corps humain (EMG, EEG, et autres), l'interférence de ligne électrique et les artefacts de contact des électrodes .
2. **Bruit basse fréquence** : comme les artefacts de mouvement et la respiration du patient (qui se résume dans la déformation de la ligne de base du signal électrocardiogramme).
3. **Interférence entre les signaux électrocardiogrammes Mère-foetus** : on n'a pas classé ce bruit avec les deux classes précédentes, parce que ce type de bruit est lié uniquement aux femmes et juste aux femmes enceintes. Il est dû à l'interférence entre le signal électrocardiogramme de la mère et le signal électrocardiogramme du fœtus ce qui provoque un signal composite.

## 4.2 État de l'art sur le filtrage du signal électrocardiogramme

Le filtrage du signal électrocardiogramme a attiré l'attention de plusieurs chercheurs et scientifiques depuis plusieurs années. Ces derniers ont développé plusieurs techniques pour résoudre ce problème. Ces techniques peuvent être regroupées en trois catégories : celles qui s'intéressent au bruit haute fréquence, celles qui s'intéressent au bruit basse fréquence et celles de séparation des signaux électrocardiogrammes maternel et foetal. Dans cette section nous allons présenter chronologiquement des travaux développés dans ce contexte.

### 4.2.1 Travaux qui s'intéressent au bruit haute fréquence

Ces travaux peuvent également être classés en deux groupes :

#### 4.2.1.1 Méthodes non basées sur des modèles mathématiques

En 1991 Thakor *et al.* [36] ont proposé une structure de plusieurs filtres adaptatifs pour le filtrage du signal électrocardiogramme. Cette structure minimise essentiellement l'erreur quadratique moyenne entre une entrée primaire, qui est le signal électrocardiogramme bruité, et une entrée de référence qui est soit un bruit corrélé d'une façon avec le bruit de l'entrée primaire, soit un signal qui n'est corrélé qu'avec le signal électrocardiogramme de l'entrée primaire. Pablo *et al.* [37] ont proposé un filtre baptisé (AICF : *Adaptive Impulse Correlated Filter*). Ce filtre estime la composante déterministe du signal et supprime le bruit non corrélé au stimulus. L'AICF a besoin de deux entrées : le signal

électrocardiogramme (entrée primaire) et une impulsion corrélée avec la composante déterministe (entrée de référence), où la méthode des moindres carrées a été utilisée pour ajuster les poids dans le processus adaptatif. Le concept de filtrage a posteriori de Wiener baptisé (APWF : *A Posteriori Wiener Filtering*), réalisé dans le plan temps-fréquence a été introduit par Paul *et al.* [38]. Kestler *et al.* dans [39] ont combiné la transformée en ondelettes discrète et le filtre de Wiener dans le but de réduire le bruit qui contamine le signal électrocardiogramme.

Popescu *et al.* dans [135] ont introduit une technique de filtrage du signal électrocardiogramme en utilisant la méthode de *Wavelet shrinkage* (rétrécissement en ondelettes). La méthode de *Wavelet shrinkage* a été introduite par Donoho, Johnstone et leurs collaborateurs au début des années 90. Elle consiste à calculer les coefficients du signal bruité sur une base orthonormée. La méthode proposée dans [135] comprend trois étapes de base : calcul de la transformée en ondelettes dyadique (*dyadic wavelet*) qui sont des échantillonnages en échelle des transformées en ondelettes, rétrécissement des coefficients d'ondelettes à l'aide de règles bayésiennes adaptatives et finalement la reconstruction du signal dé-bruité par la transformée en ondelettes inverse. L'analyse en composantes indépendantes a été introduite par Barros *et al.* dans [136] pour éliminer les artefacts du signal électrocardiogramme. Cette technique consiste à séparer aveuglement les signaux mixtes statistiquement indépendants. Un nouveau schéma de filtrage adaptatif du signal électrocardiogramme a été proposé par Almenar *et al.* dans [137]. Ce schéma repose sur deux algorithmes l'un baptisé (AICF : *Adaptive Impulse Correlated Filter*) et l'autre (TSAF : *Time-Sequenced Adaptive Filter*), la technique proposée réalise une moyenne entre battements, dès que les sorties des deux filtres AICF et TSAF ne sont pas adéquates.

Une méthode de filtrage à base de paquets d'ondelettes a été proposée par Tikkanen *et al.* dans [138]. Les paquets d'ondelettes sont une généralisation des ondelettes orthogonales. Ils permettent une analyse plus fine en décomposant les espaces de détail qui ne sont jamais décomposés dans le cas des ondelettes. Cette méthode de filtrage non linéaire a été étudiée en appliquant plusieurs méthodes de seuillage, dans lesquelles les seuils ont été choisis en utilisant quatre méthodes différentes. Iravanian *et al.* [139] ont proposé une méthode appelée la méthode du résidu filtré baptisé (FR : *Filtered Residue*). Le résidu est la différence entre le signal d'entrée et la moyenne du signal correspondant en chaque point. Pour trouver la moyenne du signal périodique ou quasi-périodique, il y a eu besoin à des informations temporelles dans le but d'aligner les battements. Ces informations temporelles sont l'une des entrées requises de l'algorithme FR. Le résidu passe à travers un filtre FIR passe-bas, et le résultat (le résidu filtré) est ajouté à la moyenne du signal pour reconstruire la sortie finale. Une technique efficace pour le dé-bruitage du signal électrocardiogramme contaminé par des bruits non-stationnaires a été proposée par Ercelebi.

dans [140]. Cette technique est basée sur la transformée en ondelettes et un estimateur de seuil dépendant du niveau. Les coefficients d'ondelettes du signal électrocardiogramme ont été obtenus en utilisant des filtres à base de *lifting* en ondelettes (*Lifting-based wavelet filters*). Un *lifting* en ondelettes est un schéma d'implantation d'une transformation en ondelettes un peu différent de celui plus habituel réalisé par les bancs de filtres. Le *lifting* en ondelettes est l'expression retenue pour désigner le procédé d'amélioration des propriétés des ondelettes par utilisation réciproque des bandes passe-bas et passe-haut.

Une technique de filtrage du signal électrocardiogramme à base de l'estimateur de Stein baptisé (SURE : *Stein's Unbiased Risk Estimation*), et une nouvelle classe de fonction de rétrécissement (*Shrinkage function*) à dérivée continue, a été proposée par Poornachandra *et al.* dans [141]. Une structure de filtrage du signal électrocardiogramme à base d'une nouvelle transformée en ondelettes adaptative baptisé (BWT : *Bionic Wavelet Transform*) a été développée par Sayadi *et al.* dans [142]. Une autre structure de débruitage du signal électrocardiogramme à base de la décomposition en modes empiriques (EMD : *Empirical Mode Decomposition*) a été introduite par Blanco-Velasco *et al.* dans [143]. Dans [144] les auteurs ont proposé une technique de débruitage du signal électrocardiogramme contaminé par un bruit blanc Gaussien, à base de la transformée en ondelettes, où une nouvelle procédure de seuillage a été adoptée. La procédure de seuillage proposée appelée : sous-bande adaptative (*Subband adaptive*), dont ses paramètres ont été choisis par la méthode de différence en moyenne (*difference in mean method*). Les auteurs de [145] ont présenté un système de réduction du bruit dans le signal électrocardiogramme baptisé (UNANR : *Unbiased and Normalized Adaptive Noise Reduction*). Le principe de L'UNANR est d'estimer et soustraire le bruit qui contamine le signal électrocardiogramme. L'UNANR ne contient pas d'unité de biais, et ses coefficients sont ajuster de manière adaptative en utilisant l'algorithme de la plus forte pente (*steepest-descent algorithm*). Une combinaison entre le réseau de neurones artificiel et le filtre de kalman a été proposée par Moein dans [40] dans le but d'éliminer et de supprimer le bruit dans le signal électrocardiogramme. Chang *et al.* dans [41] ont proposé une nouvelle version de l'algorithme de décomposition en modes empiriques (EMD), baptisé (EEMD : *Ensemble Empirical Mode Decomposition*) pour le filtrage du signal électrocardiogramme.

Une méthode de détection du bruit qui contamine le signal ECG en temps réel a été proposée dans [42]. Cette méthode basée sur l'EMD. La première étape consiste à utiliser la fonction du mode intrinsèque du premier ordre de l'EMD pour isoler le bruit car il est largement concentré dans les fréquences les plus élevées. Par la suite, trois mesures statistiques de la fonction du mode intrinsèque en jeu ont été calculées pour chercher les caractéristiques aléatoires du bruit telles que : l'entropie de Shannon, la moyenne et la variance. Kabir *et al.* [43] ont proposé une nouvelle approche du filtrage du signal électro-

cardiogramme basée sur l'EMD et la transformée en ondelettes discrète. Autre technique adaptative de filtrage du signal ECG basée sur la transformée en ondelettes discrète et le réseau de neurones artificiels a été proposée par Pongpongsri *et al.* dans [44]. Cette technique combine la propriété de résolution de la décomposition en ondelettes et la capacité d'apprentissage adaptatif des réseaux de neurones artificiels. Awal *et al.* [45] ont proposé une nouvelle méthode de seuillage d'ondelettes dépendant du niveau adaptatif pour le débruitage du signal ECG. Cette méthode baptisée seuil S-médian modifié (*Modified S-median thresholding*).

En 2014 Wang *et al.* dans [46] ont proposé une méthode de filtrage du signal électrocardiogramme à base des techniques de filtrage à phase zéro (*Zero phase filtering techniques*) et l'intégrale de Riemann-Liouville (*Riemann-Liouville integral*). Au cours de l'année suivante 2015 une autre méthode de filtrage parallèle à base des techniques de filtrage à phase zéro (*parallel-type fractional zero-phase filtering technique*) et le désintégrateur central de Grünwald-Letnikov (*the center Grünwald-Letnikov differintegrator*), a été proposée par Wang *et al.* dans [47]. En 2016 une autre méthode basée sur un filtre adaptatif à double seuil baptisé (ADTF : *Adaptive Dual Threshold Filtre*) et la transformée en ondelettes discrète (DWT) a été proposée par Jenkal *et al.* dans [48]. Le but de cette méthode est de rassembler les avantages de ces techniques pour filtrer le signal électrocardiogramme. Après, une méthodologie de débruitage adaptatif du signal électrocardiogramme à base de la décomposition en modes empiriques d'ensemble (EEMD) et une technique de seuillage basée sur l'algorithme génétiques (GA) a été proposée par Nguyen *et al.* dans [49]. Finalement, Wang *et al.* dans [50] ont proposé une méthode de filtrage du signal ECG basée sur la décomposition de Fourier adaptative baptisée (AFD : *Adaptive Fourier Decomposition*). L'AFD décompose un signal en fonction de sa distribution d'énergie. Cette méthode est apte à séparer le signal ECG et le bruit avec des gammes de fréquences qui se chevauchent mais des distributions d'énergies différentes.

#### 4.2.1.2 Méthodes basées sur des modèles mathématiques

McSharry *et al.* [11] ont développé un modèle dynamique dans l'espace d'état qui permet de générer des signaux électrocardiogrammes synthétiques. En effet plusieurs travaux de filtrages du signal ECG ont été développés en utilisant ce modèle. Sameni *et al.* dans [33] ont développé une structure de filtrage bayésien pour débruiter le signal ECG, où le modèle mathématique suggéré précédemment [11] a été modifié pour la génération des signaux ECGs synthétiques très réalistes. Cette version modifiée du modèle mathématiques a été à nouveau utilisée avec une nouvelle version du filtre de kalman étendu, cette technique de filtrage a été discutée en détail dans [34]. En 2017 Danandeh *et al.*

[35] ont utilisé la version modifiée du modèle mathématique [33] pour développer un nouveau filtre bayésien pour le filtrage du signal ECG baptisé (MP-EKF : *Marginalized Participle-Extended Kalman Filter*).

#### 4.2.2 Travaux qui s'intéressent au bruit basse fréquence

Dans cette section nous allons présenter les travaux de recherches qui s'intéressent au bruit basse fréquence qui sont souvent considérés comme le bruit ou bien la déformation de la ligne de base du signal électrocardiogramme. En 1977 Meyer *et al.* [146] ont proposé l'une des premières techniques pour supprimer ce genre de bruit. Les auteurs ont décrit un processus d'estimation et de suppression de la dérive de la ligne de base du signal ECG, en utilisant les Spline cubiques générées à partir du segment PR du signal ECG. Sa *et al.* dans [147] ont proposé d'utiliser les filtres FIR (*Finite Impulse Response*) pour la suppression de ce genre de bruit. Les auteurs de [148] ont discuté une technique de filtrage à phase linéaire (*Linear phase filtering*) pour éliminer la dérive de la ligne de base, où le spectre de filtrage souhaité a été défini périodiquement. Une autre approche de filtrage à phase linéaire a été proposée par van *et al.* dans [149]. Sornmo [150] a proposé une technique de filtrage variant dans le temps (*time-varying filtering*) pour la correction de la déformation de la ligne de base tout en laissant la fréquence de coupure du filtre linéaire être contrôlée par les propriétés basse fréquence du signal ECG. Boucheham *et al.* [151] ont discuté une méthode pour la suppression du bruit de la ligne de base du signal ECG en utilisant des outils de reconnaissance de forme, à savoir, les points dominants (DPs : *Dominant Points*). Les DPs sont calculés par l'algorithme de simplification de courbe de Douglas-Peucker.

Une méthode de correction de la déformation de la ligne de base du signal ECG en utilisant des filtres non linéaires a été proposée par Jacek *et al.* dans [152], dont le but est d'éliminer l'inconvénient des filtres linéaires qui est leur réponse impulsionnelle longue. Tinati *et al.* dans [153] ont présenté un algorithme pour la suppression du bruit de la ligne de base du signal ECG à base de la transformée en ondelettes, où ils ont utilisé l'énergie du signal à différentes échelles pour isoler le bruit de la ligne de base du signal ECG. Ji *et al.* [154] ont proposé une autre technique de correction de la dérive de la ligne de base du signal ECG à base de la décomposition en modes empiriques (EMD) et la morphologie mathématique (MM : *Mathematical Morphology*). L'EMD est un outil puissant pour l'analyse temps-fréquence et la MM est une technique non linéaire axée sur l'analyse de structure et de l'information sur la forme d'un signal et qui est liée avec l'algèbre et les probabilités, dont elle peut être également utilisée comme un filtre. La décomposition en modes empiriques (EMD) était présente une autre fois pour la correction de la ligne de base dans [143]. Les auteurs de [155] ont choisi d'utiliser l'analyse en

composantes indépendantes (ICA) pour supprimer ce genre de bruit. Le filtre à moyenne mobile statistiquement pondérée (*statistical weighted moving average filter*) a été introduit par Hu *et al.* [156] pour supprimer le bruit de la ligne de base. Les auteurs de [51] ont visé d'éliminer la dérive de la ligne de base du signal ECG en appliquant une technique de transformation temps-fréquence (TFT : *Time-Frequency Transformation*) qui se base sur la transformée en ondelettes.

La dérive de la ligne de base du signal ECG et le signal ECG propre ont été modélisées comme des processus de mouvement brownien fractionnaire (fBm : *fractional Brownian motion*) du premier et de seconde ordre, respectivement. Le mouvement Brownien fractionnaire a été introduit par Kolmogorov en 1940 comme moyen d'engendrer des spirales Gaussiennes dans des espaces de Hilbert. Cette modélisation fractal a été utilisée pour trouver un opérateur de projection pour éliminer le bruit de la ligne de base [52]. Miroslav *et al.* dans [53] ont modélisé la déformation de la ligne de base du signal ECG par un ensemble de sinusoides harmoniquement liées. Ces sinusoides ont été modélisées par des polynômes temporels à faible ordre, où les polynômes ayant des écarts de fréquences et d'amplitudes par rapport à leurs valeurs nominales vont caractériser la déformation de la ligne de base du signal ECG. La variation quadratique est une mesure de variabilité pour les vecteurs ou les fonctions échantillonnées. La réduction de cette mesure (*quadratic variation reduction*) a été utilisée pour la suppression du bruit de la ligne de base du signal ECG dans [54]. Une nouvelle extension de la méthode de décomposition en modes empiriques baptisé (MEMD : *Multivariate Empirical Mode Decomposition*) a été proposée par Gupta *et al* et décrit dans [55] pour la suppression de la déformation de la ligne de base du signal ECG.

Une technique baptisé (HVD : *Hilbert Vibration Decomposition*) a été introduite par Sharma *et al.* dans [56] pour la suppression du bruit de la ligne base du signal ECG, où ils ont trouvé que la première composante (composante d'énergie la plus élevée) du signal ECG obtenu en utilisant l'HVD, correspond à la dérive de la ligne de base. En 2017 Zou *et al.* [57] ont proposé une technique baptisé (QRSMR : *QRS detection based Motion Artifact Removal Algorithm*). Cette méthode détecte le complexe QRS entier et supprime le bruit entre deux complexes QRS, tout en récupérant les ondes P et T du signal électrocardiogramme.

#### 4.2.3 Travaux qui s'intéressent à la séparation des signaux électrocardiogrammes mère-foetus

Dans cette section nous allons présenter les travaux qui ont été développés dans l'espoir de séparer les signaux ECGs mère foetus, en commençant par les travaux de recherche

de Zarzoso *et al.* présentés dans [157]. Ces auteurs ont considéré le problème de séparation des signaux électrocardiogrammes mère-foetus comme un problème de séparation aveugle de source (BSS : *Blind Source Separation*) où plusieurs méthodes ont été appliquées pour cette séparation aveugle à savoir : l'analyse en composantes principales (PCA : *Principal Component Analysis*), la décomposition en valeurs singulières d'ordre supérieur (HOSVD : *Higher-Order Singular-Value Decomposition*) et la décomposition en valeurs propres d'ordre supérieur (HOEVD : *High-Order Eigenvalue Decomposition*). Lieven *et al.* dans [158] ont utilisé l'analyse en composantes principales (PCA) pour résoudre ce genre de problèmes.

Une autre méthode basée sur la transformation en ondelettes a été décrite dans [159], pour extraire le signal ECG foetal du signal abdominal composite. Cette méthode est basée sur la détection de singularités obtenues à partir du signal abdominal composite, en utilisant les maxima du module dans le domaine des ondelettes. Les emplacements du module du muscle abdominal ont été utilisés pour distinguer les signaux ECG maternels et foetaux. Une autre technique a été proposée dans le même contexte en utilisant la transformée en ondelettes, a été décrite par Mochimaru *et al.* dans [160]. Aussi Vigneron *et al.* dans [161] ont montré que ce type des problèmes peut être résolu en utilisant des outils statistiques d'ordre supérieur et la transformée en ondelettes.

Assaleh *et al.* dans [162] ont proposé une structure polynomiale (*polynomial networks*) pour l'extraction du signal électrocardiogramme foetal. Assaleh a proposé une autre technique dans [163] pour extraire le signal ECG foetal d'un enregistrement ECG composite. L'auteur a utilisé un système d'inférence neuro-flou adaptatif (ANFIS : *Adaptive Neuro-Fuzzy Inference System*) qui fonctionne sur deux signaux ECGs enregistrés dans la zone thoraciques et abdominales de la peau de la mère. L'ECG thoracique est supposé purement maternel. Cependant L'ECG Abdominal contiendra à la fois une composante maternelle et une composante foetal. Une technique de séparation aveugle de source en utilisant un signal de référence baptisé (BSSR : *Blind Source Separation with the Reference signal*) a été proposée dans [164] pour extraire le signal ECG foetal du signal ECG composite.

Une technique d'extraction du signal électrocardiogramme foetal basée sur le filtre de kalman étendu a été proposée par Niknazar *et al.* dans [165]. Han *et al.* dans [166] ont proposé une technique pour traiter ce type de problèmes baptisé (*v-SVR : v-Support Vector Regression*). Finalement en 2017, Ahmadieh *et al.* [167] ont proposé une méthode pour séparer le signal ECG foetal (FECG) de l'ECG maternel (MECG) en utilisant un système d'inférence neurone-flou adaptatif de type-2

### 4.3 Contributions

Le pré-traitement du signal électrocardiogramme est une étape essentielle dans le processus de diagnostic des maladies cardiaques. Cela a été prouvé par le nombre important des travaux développés dans ce contexte. De notre part et au fur et à mesure de la réalisation de notre thèse on a développé plusieurs outils de filtrage. Pour le bruit haute fréquence notre contribution principale a été le développement d'un algorithme de débruitage efficace basé sur la logique floue type-1. Deux autres contributions secondaires ont été développées dans ce contexte en utilisant le filtre de kalman étendu [168], et la décomposition en valeurs singulières[169]. Pour le bruit basse fréquence (le bruit de la ligne de base du signal ECG), nous avons proposé une nouvelle technique basée sur la détection des pics R du signal ECG et l'interpolation par splines cubiques [170].

Notre contribution principale, pour la suppression du bruit haute fréquence, vient de l'idée, et que n'importe quelles données bruitées constituant un signal, ils doivent varier autour de leurs valeurs moyennes à chaque instant, et la variance de ces données nous fournit une idée sur leur dispersion autour des valeurs moyennes. Par conséquent, si on oblige ces données à se disperser de manière légère (on fixe la variance à une petite valeur) et on ajuste la valeur moyenne à chaque instant en minimisant certaine fonction objectif, on arrive à filtrer ces données bruitées. Cette idée a été réalisée en utilisant un filtre flou adaptatif (FAF : *Fuzzy Adaptatif Filtre*). Le FAF se base sur une procédure récursive pour obtenir une extraction acceptable de l'information, dans le cas où les caractéristiques statistiques du signal d'entrée-sortie ne sont pas connues. Ce filtre se compose de deux parties, la première partie étant le modèle autorégressif du filtre flou, la deuxième partie étant responsable de l'ajustement des paramètres des fonctions d'appartenance qui caractérisent les concepts flous dans les règles *IF – THEN*. La deuxième partie ajuste les paramètres du filtre flou adaptatif, ce qui permettra d'atteindre la reconstruction du signal requise en minimisant une fonction objectif, cette partie est assurée en utilisant l'algorithme d'optimisation à base de biogéographie (BBO : *Biogeography-Based Optimization*) (cf., chapitre 2).

Dans la deuxième contribution, le filtre de Kalman étendu (EKF) a été utilisé. Le filtre de Kalman est un outil important dans la théorie de l'estimation linéaire. Le filtre de Kalman est un estimateur d'état optimal pour les systèmes linéaires et stochastiques lorsque les mesures sont noyées dans des bruits aléatoires. Le filtre de kalman peut être utilisé dans les situations où nous voulons lisser, estimer ou prédire les états d'un certain système dynamique et linéaire. En effet le filtre de kalman est constitué d'un ensemble d'équations discrètes qui permettent d'estimer les états d'un système par rapport aux données mesurées, ces équations comprennent plusieurs paramètres ajustables, y compris les variances

des bruits d'état et de mesure. Dans cette contribution le filtre de kalman étendu a été utilisé pour le filtrage du signal électrocardiogramme synthétique. Les paramètres de l'EKF à savoir les deux variances des bruits d'état et de mesure ont été ajustées en utilisant l'algorithme d'optimisation à base de biogéographie (BBO : *Biogeography-Based Optimization*) (cf., chapitre 2).

La troisième contribution a été réalisée en utilisant la décomposition en valeurs singulières (SVD : *Singular Value Decomposition*). Cet outil a été utilisé pour le filtrage du signal électrocardiogramme et la séparation des sources (Signaux ECG Mère-foetus) [171]. La SVD, est un outil d'estimation du spectre à haute résolution, elle est utilisée pour décomposer une matrice de données en sous-espaces orthogonaux, ces deux espaces correspondent aux composantes du signal propre et du bruit contenus dans les données. La projection des données sur le sous-espace désiré élimine le bruit et les composantes du signal indésirables.

La quatrième contribution consiste en la suppression du bruit de la ligne de base du signal électrocardiogramme. L'idée de cette méthode est de considérer la variation du signal ECG comme étant une modulation avec le signal de la ligne de base, c-à-d, la forme du signal ECG suit la variation de la ligne de base. Par conséquent, tous les pics du signal électrocardiogramme (P, Q, R, S et T) (cf., chapitre 1) suivront aussi la forme de cette ligne de base. La forme obtenue en utilisant l'interpolation de l'un des types des pics du signal ECG (enveloppe de pics) est une approximation efficace de la déviation de la ligne de base du signal électrocardiogramme.

## 4.4 Filtrage du signal ECG par le filtre flou adaptatif

### 4.4.1 Filtre flou adaptatif

Les filtres flous adaptatifs sont des filtres basés sur les concepts de la logique floue (cf., chapitre 2). Les filtres flous adaptatifs sont des processeurs d'information qui utilisent à la fois des informations linguistiques (sous forme des règles *IF – THEN* floues) et numériques (sous forme de paires de données d'entrée-sortie). Les principaux avantages de l'utilisation d'un filtre flou adaptatif et que ce filtre est non linéaire et les informations linguistiques provenant d'experts humains peuvent être directement incorporées dans ce filtre. Si aucune information linguistique n'est disponible, les filtres flous adaptatifs deviennent des filtres adaptatifs non linéaires bien définis. Les algorithmes adaptatifs ajustent les paramètres des fonctions d'appartenance, qui caractérisent les fonctions floues dans les règles *IF – THEN*, en minimisant une certaine fonction objectif. Il est possible de former le filtre flou adaptatif pour déterminer la relation entrée-sortie requise en utilisant

certain algorithmes d'apprentissage (l'algorithme BBO dans notre cas).

Dans cette thèse nous avons choisi le modèle flou type Takagi-Sugeno (TS) [172] pour modéliser notre filtre flou, dans lequel les sorties de règles sont des nombres ordinaires c-à-d, les conséquences de règles  $IF - TEHN$  sont des fonctions linéaires des variables d'entrée [120]. Ce type de modèle sera utilisé et sera composé d'une partition floue Gaussienne pour l'entrée et d'une partition de singletons pour la sortie. Dans ce modèle flou, les règles ont la forme suivante :

$$R^l : \mathbf{IF } x \mathbf{ is } F^l(x), \mathbf{ THEN } y^l = \bar{y}^l, \quad l = 1, 2, \dots, M, \quad (4.1)$$

où  $x$  est le vecteur d'entrée de dimension  $n \times 1$ ,  $y^l \in R$  est la variable de la sortie,  $\bar{y}^l$  est la valeur de la sortie relative à la  $l^{ieme}$  règle et  $M$  est le nombre de règles dans la base de règles.  $F^l$  est la fonction d'appartenance multivariable de la prémisse de la  $l^{ieme}$  règle.

La prémisse «  $x$  is  $F^l(x)$  » peut être exprimée comme une combinaison logique dont la forme conjonctive est la suivante [120] :

$$\begin{aligned} R^l : \mathbf{IF } x_1 \mathbf{ is } F_1^l(x_1) \mathbf{ and, } \dots, \mathbf{ and } x_n \mathbf{ is } F_n^l(x_n), \\ \mathbf{ THEN } \hat{y}^l = \bar{y}^l \quad l = 1, 2, \dots, M. \end{aligned} \quad (4.2)$$

Le degré d'activation d'une règle est calculé par le produit des appartenances des règles individuelles comme suit :

$$\beta^l(x) = \prod_{i=1}^n \mu_{F_i^l}(x), \quad (4.3)$$

où  $\mu_{F_i^l}(x)$  est la fonction d'appartenance de l'ensemble flou multidimensionnel  $F_i^l$ .

L'inférence et tout le système flou sont réduits à la formule fuzzy-mean defuzzification suivante [173] :

$$\hat{y} = \frac{\sum_{l=1}^M \bar{y}^l \beta^l(x)}{\sum_{l=1}^M \beta^l(x)}. \quad (4.4)$$

#### 4.4.2 Conception du filtre flou adaptatif basé sur l'algorithme BBO

La Figure 4.1 représente la structure du filtre flou basé sur l'algorithme BBO.

Trois étapes sont à suivre pour construire le filtre flou adaptatif proposé :

- **Étape 1** : définir  $M$  ensembles flous  $F_i^l$  pour chacun des intervalles d'espace d'entrée  $[C_i-, C_i+]$  avec des fonctions d'appartenance Gaussiennes :

$$\mu_{F_i^l} = \exp \left[ -\frac{1}{2} \left( \frac{x_i - \tilde{x}_i^l}{\sigma_i^l} \right)^2 \right], \quad (4.5)$$

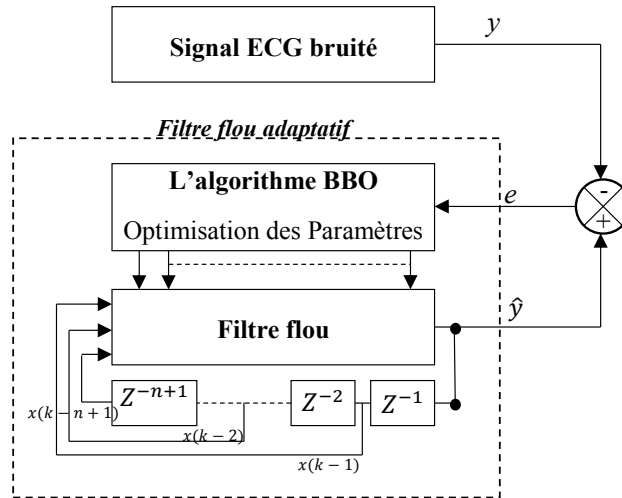


FIGURE 4.1 – Structure du filtre flou adaptatif.

où  $l = 1, 2, \dots, M$  et  $i = 1, 2, \dots, n$ ,  $M$  et  $n$  sont le nombre de règles et le nombre de régresseurs, respectivement.  $x_i$  est l'entrée du filtre,  $\tilde{x}_i^l$  est le centre de la fonction d'appartenance de la  $l^{i\text{eme}}$  règle et  $\sigma_i^l$  est la déviation standard de la fonction d'appartenance de la  $l^{i\text{eme}}$  règle. Dans cette thèse les déviations standards sont fixées à des faibles valeurs pour forcer la dispersion légère des données par rapport aux valeurs moyennes, et les  $\tilde{x}_i^l$  sont optimisés en utilisant l'algorithme BBO.

- **Étape 2** : Construire un ensemble de règles *IF – THEN* floues ajustables en utilisant des informations numériques ou linguistiques dérivées des paires de données d'entrée-sortie d'apprentissage :

$$\begin{aligned}
 R^l : & \text{ IF } x_1 \text{ is } F_1^l(x_1) \text{ and, } \dots, \text{ and } x_n \text{ is } F_n^l(x_n), \\
 & \text{ THEN } \hat{y}^l = \bar{y}^l; \quad l = 1, 2, \dots, M.
 \end{aligned}
 \tag{4.6}$$

où la sortie désirée est désignée par  $\hat{y}$ ,  $F_n^l$  est défini dans l'étape 1,  $\bar{y}^l$  est l'ensemble flou de la sortie de la  $l^{i\text{eme}}$  règle ayant une fonction d'appartenance de type singleton. Notons qu'il y aura un changement des paramètres des fonctions d'appartenance de la prémisse et la conséquence pendant le processus d'adaptation.

- **Étape 3** : En utilisant l'Équation 4.4, le filtre flou est construit autour de l'ensemble des règles  $M$ .

La Figure 4.1 représente la structure du filtre flou adaptatif, qui consiste en une adaptation en temps réel de ses paramètres. L'algorithme d'optimisation BBO est capable d'ajuster les paramètres du filtre de sorte que la valeur de la fonction objectif atteigne sa valeur minimale. La fonction objectif utilisée est l'erreur quadratique moyenne (MSE) (cf., Équa-

tion 3.2) définie entre la sortie du filtre flou  $\hat{y}$  et le signal électrocardiogramme bruité  $y$ . Les paramètres du filtre flou à ajuster sont les centres des Gaussiennes des prémisses et les singletons des conséquences.

#### 4.4.3 Résultats de simulation

Nous présenterons dans cette section les résultats de filtrage du signal électrocardiogramme en utilisant le filtre FAF. Cette méthode a été simulée avec un nombre de règles  $M = 40$ , ce qui nous donne  $40 \times 3 = 120$  paramètres ajustables, puisque chacune des règles est constituée d'un seul singleton de sortie et deux régresseurs en entrée. Cela signifie qu'il y a  $2 \times 40$  paramètres de prémisse et  $1 \times 40$  paramètres de conséquence. Donc en total il y a un ensemble 120 paramètres ajustables. Le vecteur d'entrée initial  $x$  du filtre est défini comme  $x = [x_1, x_2]^T = [0, 0]^T$ . Les différents paramètres de l'algorithme d'optimisation BBO sont fixés comme suit : le taux de mutation  $m = 0.01$ , le taux d'immigration  $\lambda_k$  et le taux d'émigration  $\mu_k$  sont similaires aux courbes de migration linéaire (cf., Figure 2.8) avec un nombre d'itération égale à 200. L'efficacité de notre approche a été entièrement étudiée en évaluant sa performance en utilisant différents types de bruit, y compris les bruits typiques associés aux enregistrements ECG ambulatoires comme les artefacts de mouvement d'électrodes (EM : *Electrode Motion Artifact*) et les artefacts des muscles (MA : *Muscle Artifact*), qui ont été sélectionnés à partir de la base de données MIT-BIH PhysioBank (MIT-BIH stress) [174]. De plus, la méthode proposée a été testée avec un bruit blanc Gaussien artificiel (WGN : *White Gaussian Noise*), qui a été ajouté au signal électrocardiogramme propre avec différents niveaux du rapport signal sur bruit (SNR : *Signal to Noise Ratio*). En général, l'évaluation des méthodes de débruitage implique généralement une mesure de similarité entre le signal débruité et le signal original. Afin d'évaluer la qualité de filtrage du FAF proposé, plusieurs critères ont été appliqués à savoir :

- **Rapport signal sur bruit** : en abrégé (SNR : *Signal to Noise Ratio*), c'est un critère qui nous permet de mesurer le rapport du signal considéré sur le bruit qui le contamine. Alors, si l'effet du bruit est minime sur le signal, cela veut dire que le rapport signal sur bruit sera grand. Le rapport signal sur bruit peut être calculé pour le signal d'entrée et de sortie comme suit :

$$SNR_{input} = 10 \times \log \left( \frac{\sum_{k=1}^N (y_{c,k})^2}{\sum_{k=1}^N (b_k)^2} \right). \quad (4.7)$$

$$SNR_{output} = 10 \times \log \left( \frac{\sum_{k=1}^N (y_{c,k})^2}{\sum_{k=1}^N (y_{c,k} - \hat{y})^2} \right). \quad (4.8)$$

- **Facteur d'amélioration** : une fois le rapport signal sur bruit est calculé pour le signal d'entrée et le signal de sortie, une autre mesure donnant un facteur d'amélioration peut aussi être utilisée. Cette mesure s'appelle « facteur d'amélioration » (imp : *improvement*) dont l'expression mathématique est :

$$SNR_{imp} = SNR_{output} - SNR_{input}. \quad (4.9)$$

- **Erreur quadratique moyenne** : En abrégé (MSE : *Mean Square Error*), c'est un autre critère qui nous donne une mesure du module de l'erreur. Si l'erreur est grande l'MSE sera alors grand. Alors, plus l'MSE est petit, plus l'approximation est bonne. l'MSE est donné par l'expression suivante :

$$MSE = \frac{1}{N} \sum_{k=1}^N (y_{c,k} - \hat{y})^2. \quad (4.10)$$

- **Racine d'Erreur moyenne quadratique** : en abrégé (RMSE : *Root Mean Square Error*), c'est un critère qu'on peut utiliser comme complément de l'MSE dans le cas où l'MSE est très petit, dont on peut l'exprimer comme suit :

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_{c,k} - \hat{y})^2}. \quad (4.11)$$

Dans tous ces critères  $N$  est le nombre des échantillons,  $y_c$  le signal électrocardiogramme propre (sans bruit),  $\hat{y}$  le signal électrocardiogramme estimé et  $b$  le bruit contaminant.

- **Mesure de distorsion basée sur l'entropie multi-échelles pondérée** : (MSEW-PRD : *Multi-Scale Entropy based Weighted Distortion Measure*), cette mesure donne une idée sur l'impact de la méthode de filtrage proposée sur la distorsion des caractéristiques de diagnostics du signal électrocardiogramme [175]. Le détail de cette mesure sera donné en Annexe G.

#### 4.4.3.1 Filtrage du signal ECG réel

Afin d'étudier les résultats de la méthode proposée, trois types de bruit ont été utilisés. Les résultats de débruitage pour les différents types de bruit sont montrés dans les Figures 4.2, 4.3, 4.4 et 4.5. Ceux-ci incluent les résultats de débruitage des bruits réels et du bruit blanc Gaussien qui ont été ajoutés aux données du signal électrocardiogramme réel *18177.dat* de la base de données MIT-BIH PhysioBank [132]. Les résultats montrent que pour le cas du bruit blanc Gaussien additif avec un  $SNR_{input}$  de 3 dB, le signal électrocardiogramme estimé suit bien la morphologie du signal électrocardiogramme propre (sans

bruit) (cf., Figure 4.2). Pour le cas d'un bruit réel MA (*Muscle Artifact*) avec un  $SNR_{input}$  de 3 dB, la Figure 4.3 représente le résultat de débruitage de ce genre du bruit, dont on peut clairement remarquer que le signal électrocardiogramme estimé ne possède aucun artefact de l'électromyogramme (EMG). Parmi les bruits les plus difficiles à supprimer on trouve les artefacts de mouvement des électrodes (EM : *Electrod Motion*), en raison de leur capacité à imiter les battements ectopiques qui sont des battements du coeur irréguliers qui entraînent des variations dans le pouls normalement régulier. Ce type de bruit à été supprimé parfaitement du signal électrocardiogramme, et la Figure 4.4 montre ce résultat. Afin d'évaluer l'efficacité de notre méthode à éliminer des bruits plus compliqués, les trois types de bruit (EM, MA et WGN) ont été ajoutés simultanément au même signal électrocardiogramme (18177.dat). Par une inspection visuelle de la Figure 4.5 on peut voir que le signal électrocardiogramme estimé est plus lisse que le signal électrocardiogramme bruité, et suit parfaitement la morphologie du signal ECG propre.




FIGURE 4.2 – Filtrage typique du FAF pour le signal ECG 18177.dat avec un bruit blanc Gaussien additif (WGN) ( $SNR_{input} = 3dB$ ).

Dans ce qui suit, les différents types de bruits (WGN, MA et EM), vont être ajoutés au signal électrocardiogramme 18177.dat, avec différentes valeur d'SNR d'entrée sur l'intervalle 0 à 10 dB. Pour évaluer la sortie du FAF pour chaque cas du bruit, les formules : 4.8, 4.9, 4.10 et 4.11 ont été utilisées. Les différents critères tels que  $SNR_{output}$ ,  $SNR_{imp}$ ,  $MSE$  et  $RMSE$  ont été calculés pour la sortie du FAF, et ont été représentés dans les Figures 4.6, 4.7 et 4.8. Ces résultats montrent que la méthode proposée donne des résultats positifs sous les environnements du bruit avec les différents niveau d'SNR d'entée. Ceci peut être constaté lorsque la pente des différents critères, en particulier le  $SNR_{out}$ , n'est pas plate et qu'il y a une augmentation évidente du  $SNR_{out}$  avec chaque diminution




FIGURE 4.3 – Filtrage typique du FAF pour le signal ECG 18177.dat avec l'artefact de l'électromyogramme (MA) ( $SNR_{input} = 3dB$ ).




FIGURE 4.4 – Filtrage typique du FAF pour le signal ECG 18177.dat avec l'artefact de mouvement des électrodes ( $SNR_{input} = 3dB$ )

correspondante au  $SNR_{input}$ . Par conséquent, il apparaît que la structure du FAF est capable de filtrer de manière optimale le signal électrocardiogramme en présence d'artefacts tels que le bruit blanc Gaussien, l'artefact de mouvement des électrodes et le l'interférence avec les différents signaux du corps.

#### 4.4.3.2 Étude Comparative

Afin d'évaluer la performance de notre filtre par rapport à d'autres méthodes de références de débruitage des signaux électrocardiogrammes, Les résultats de notre étude ont été comparés aux résultats obtenus par des travaux récemment publiés. Pour effectuer une comparaison valide, notre méthode de filtrage a été simulée avec les mêmes




FIGURE 4.5 – Filtrage typique du FAF pour le signal ECG 18177.dat avec les trois types du bruit (WGN+MA+EM) électrodes

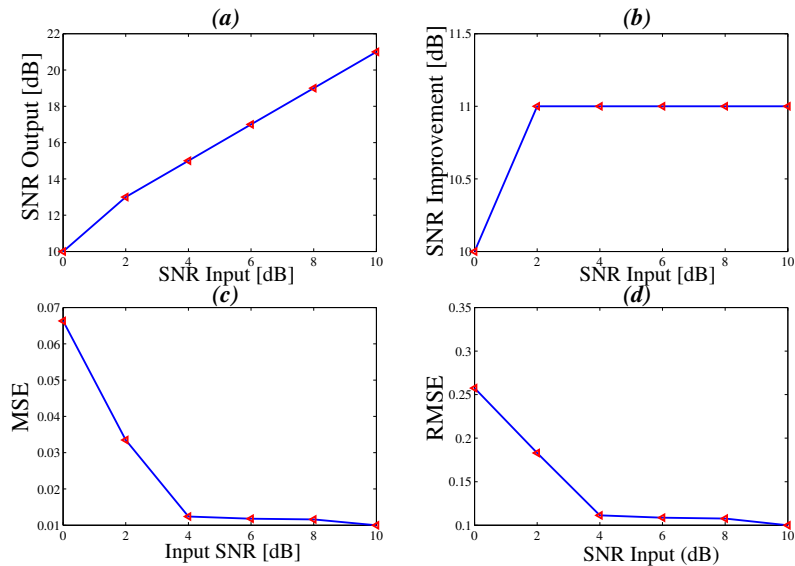


FIGURE 4.6 – Mesures des performances du FAF par rapport aux différents SNR d'entrée pour le cas d'un bruit blanc Gaussien, (a) SNR de sortie, (b) facteur d'amélioration, (c) Erreur quadratique moyenne, (d) Racine de l'erreur quadratique moyenne.

paramètres, signaux d'essai et bruits, et dans les mêmes conditions en utilisant les mêmes critères d'évaluation que ceux utilisés avec les méthodes de références. Les détails des résultats de l'étude comparative de notre approche avec la méthode baptisée (ADTF-DWT) (cf., [sous-section 4.2.1](#)) [48] sont présentés dans les Tableaux 4.1, 4.2, 4.3 et 4.4. Les auteurs de la méthode (ADTF-DWT) ont comparé leur approche avec plusieurs autres méthodes telles que : (RL) [46] et la méthode (FZP) et (AZP) présentée dans [47] (cf., [sous-section 4.2.1](#)). Les résultats de la comparaison des artefacts de l'électromyogramme




FIGURE 4.7 – Mesures des performances du FAF par rapport aux différents SNR d’entrée pour le cas d’un bruit MA, (a) SNR de sortie, (b) facteur d’amélioration, (c) Erreur quadratique moyenne, (d) Racine de l’erreur quadratique moyenne.




FIGURE 4.8 – Mesures des performances du FAF par rapport aux différents SNR d’entrée pour le cas d’un EM, (a) SNR de sortie, (b) facteur d’amélioration, (c) Erreur quadratique moyenne, (d) Racine de l’erreur quadratique moyenne.

(EMG) (cf., chapitre 1) sont présentés dans le Tableau 4.1. La comparaison des résultats de débruitage du signal ECG pour le cas d’un bruit blanc Gaussien avec 5 dB d’SNR en utilisant plusieurs données réelles de la base de données PhysioBank [129] est montrée

dans le Tableau 4.2. Les Tableaux 4.3 et 4.4 montrent les résultats de comparaison de débruitage du signal ECG pour le cas d'un bruit blanc Gaussien avec un SNR de 5dB et plusieurs signaux de tests[129] de notre méthode et les méthode suivantes : (ADWT) et (MABWT) [45] (cf., sous-section 4.2.1 ).

TABLE 4.1 – Comparaison des résultats de débruitage de l'artefact EMG dans le signal 115.dat de la base de données MIT-BIH PhysioBank [129].

<i>Critère</i>	<b>RL</b>	<b>AZP</b>	<b>FZP</b>	<b>ADTF-DWT</b>	<b>FAF</b>
<i>SNRoutput</i>	6.83	11.82	13.68	15.59	30.65
<i>MSE</i>	0.0705	0.0223	0.0146	0.0146	0.0051

TABLE 4.2 – Comparaison des résultats de débruitage dans le cas d'un WGN de 5dB pour plusieurs signaux réels de la base de données MIT-BIH PhysioBank [129].

<i>MIT-BIH Record N°</i>	<i>Critère</i>	<b>ADTF-DWT</b>	<b>FAF</b>
<b>100.dat</b>	<i>MSE</i>	0.0044	0.0026
	<i>RMSE</i>	0.066	0.0511
	<i>SNRimp</i>	9.70	20.59
<b>101.dat</b>	<i>MSE</i>	0.0042	0.0019
	<i>RMSE</i>	0.04	0.0440
	<i>SNRimp</i>	10.23	20.72
<b>103.dat</b>	<i>MSE</i>	0.0058	0.0023
	<i>RMSE</i>	0.076	0.0480
	<i>SNRimp</i>	9.10	20.68
<b>113.dat</b>	<i>MSE</i>	0.0088	0.0015
	<i>RMSE</i>	0.093	0.0388
	<i>SNRimp</i>	9.33	22.18
<b>115.dat</b>	<i>MSE</i>	0.0122	0.0056
	<i>RMSE</i>	0.110	0.0751
	<i>SNRimp</i>	9.45	16.81
<b>117.dat</b>	<i>MSE</i>	0.0283	0.0081
	<i>RMSE</i>	0.168	0.0899
	<i>SNRimp</i>	9.34	14.08
<b>119.dat</b>	<i>MSE</i>	0.0459	0.0084
	<i>RMSE</i>	0.214	0.0914
	<i>SNRimp</i>	8.13	14.49
<b>122.dat</b>	<i>MSE</i>	0.0411	0.005
	<i>RMSE</i>	0.202	0.0707
	<i>SNRimp</i>	8.07	17.34

TABLE 4.3 – Comparaison des résultats de débruitage dans le cas d'un WGN de 5dB pour plusieurs signaux réels de la base de données MIT-BIH PhysioBank [129].

<i>Critère</i>	<b>ADWT</b>	<b>ADTF-DWT</b>	<b>FAF</b>
<i>MSE</i>	0.005	0.0042	0.0019
<i>RMSE</i>	0.072	0.064	0.0440
<i>SNRimp</i>	9.098	10.23	20.72

TABLE 4.4 – Comparaison en terme de  $SNR_{imp}$  des résultats de débruitage dans le cas d'un WGN de 5dB pour plusieurs signaux réels de la base des données Physio Bank [129].

MIT-BIH Record N°	ADWT	MABWT	ADTF-DWT	FAF
100	9.90	7.80	9.70	20.59
101	9.09	6.90	10.23	20.72
103	7.13	7.70	9.10	20.68
113	7.82	7.90	9.33	22.18
115	7.19	7.80	9.45	16.81
117	8.62	7.90	9.34	14.08
119	7.27	7.60	8.13	14.49
122	7.86	6.90	8.07	17.34

Les résultats des comparaisons montrent que les résultats trouvés par notre méthode (FAF) sont meilleurs que ceux trouvés par les autres méthodes de références, à savoir l'ADTF-DWT, RL, AZP, FZP, ADWT et MABWT. En effet, ces résultats montrent que la méthode proposée possède les meilleures valeurs sous tous les critères ( $MSE$ ,  $RMSE$ , et  $SNR_{imp}$ ). Pour valider plus ces résultats, nous avons également comparé la performance de notre méthode (FAF) avec une autre méthode récemment proposée [50], qui est basée sur la décomposition de fourier adaptative (AFD), dont les auteurs ont comparé leur méthode à d'autres approches basée sur l'EMD et l'EEMD [41] (cf., sous-section 4.2.1). Les résultats de cette comparaison sont présentés dans le Tableau 4.5. Les résultats montrent encore que notre filtre est plus performant en terme d' $MSE$  (les résultats présentés dans le Tableau 4.5 sont calculés avec une amplitude du signal qui a été augmenté de 200 fois de sa valeur d'origine).

TABLE 4.5 – Résultats de comparaison entre le FAF, AFD, EEMD et EMD pour le dé-bruitage du signaux ECGs bruités (10 dB) [129] en terme de  $MSE$ 

MIT-BIH Record N°	101	102	103	104	105	106	107	108	109	201	202	203	205	207	208	209
EMD	126.9	83.3	189.4	151.6	180.6	245.6	771.6	103.2	237.2	67.1	131	279.7	72.5	129.7	361.2	140.3
EEMD	97.4	60.0	147.0	109.5	128.1	192.5	574.9	76.9	179.7	38.6	76.3	206.5	55.0	99.9	232.0	103.3
AFD	36.0	32.6	76.0	55.7	73.6	98.9	572.6	24.0	112.1	38.3	28.4	321.3	29.5	93.9	199.2	60.8
FAF	23.42	18.46	42.9	27.28	47.5	56.8	88.00	13.3	96.2	24.80	20.06	43.49	17.00	51.49	66.8	44.2

Dans ce que suit nous allons présenter les résultats de comparaisons de notre approche par rapport à une méthode basée sur un modèle mathématique [35], baptisé (MP-EKF : *Marginalized Particle Extended Kalman Filter*). Le FAF a été comparé à cette méthode en terme de mesure de distorsion des caractéristiques de diagnostic du signal ECG (MSEW-

PRD : *Multi-Scale Entropy based Weighted Distortion Measure*) [175]. Les résultats de comparaison du FAF par rapport à MP-EKF [35] et d'autres méthodes présentées dans [35] à savoir le EKF (*Extended Kalman Filter*) et le EKS (*Extended Kalman Smoothing*) en utilisant le *MSEWPRD* avec différents niveau du SNR d'entrée sont présenté dans le Tableau 4.6. Les résultats de ce tableau ont été générés en déterminant les *MSEWPRD* de 200 segments des signaux ECG filtrés qui ont été sélectionnés de la base de données MIT-BIH PhysioBank [132].

TABLE 4.6 – Résultats de comparaison en termes de *MSEPWRD* du FAF, MP-EKF, EKF et EKF en présence du bruit blanc Gaussien et les artefacts musculaire

Type du bruit	Méthode	MSEPWRD (moyenne $\pm$ SD)(mv)			
		0 dB	-1dB	-3 dB	-5 dB
Bruit blanc Gaussien	MP-EKF	1.284 $\pm$ 0.225	1.329 $\pm$ 0.224	1.434 $\pm$ 0.231	1.552 $\pm$ 0.242
	EKS	1.358 $\pm$ 0.180	1.458 $\pm$ 0.196	1.678 $\pm$ 0.237	1.9239 $\pm$ 0.288
	EKF	1.677 $\pm$ 0.183	1.824 $\pm$ 0.200	2.158 $\pm$ 0.242	2.552 $\pm$ 0.297
	<b>FAF</b>	<b>0.306<math>\pm</math>0.047</b>	<b>0.4184<math>\pm</math>0.078</b>	<b>0.4866<math>\pm</math>0.0597</b>	<b>0.5247<math>\pm</math>0.321</b>
Artefacts de l'électromyogramme (EMG)	MP-EKF	1.468 $\pm$ 0.199	1.552 $\pm$ 0.200	1.747 $\pm$ 0.223	1.987 $\pm$ 0.255
	EKS	2.933 $\pm$ 0.455	3.247 $\pm$ 0.514	3.992 $\pm$ 0.656	4.918 $\pm$ 0.836
	EKF	3.057 $\pm$ 0.473	3.393 $\pm$ 0.534	4.188 $\pm$ 0.681	5.179 $\pm$ 0.866
	<b>FAF</b>	<b>0.3880<math>\pm</math>0.0599</b>	<b>0.4320<math>\pm</math>0.0499</b>	<b>0.5437<math>\pm</math>0.0546</b>	<b>0.6649<math>\pm</math>0.0385</b>

En utilisant un ensemble de règles *IF – THEN* floues, nous avons construit un filtre fou adaptatif, qui était capable de s'ajuster de façon adaptative afin de réduire une fonction objectif, lors de la disponibilité des nouvelles informations. Les résultats de simulation montrent que notre filtre est très efficace pour débruiter le signal électrocardiogramme. L'efficacité de ce filtre a été comparée aux résultats d'autres méthodes basées et non basées sur des modèles mathématiques en utilisant différents critères à savoir le *SNR*, *MSE*, *RMSE* et d'autres. Si le *SNR* est grand ça indique que l'effet du bruit sur le signal est réduit. Inversement, le *MSE* est une mesure de précision du suivi du signal filtré par rapport au signal propre. Par conséquent, la performance du filtre est dite bonne lorsque le *MSE* est plus petit. D'après les Tableaux 4.1, 4.2, 4.3, 4.4 et 4.5, notre méthode possède les meilleures performances, ce qui montre sa supériorité par rapport aux méthodes qui ne se basent pas sur des modèles mathématiques. Le tableaux 4.6 présente les résultats de comparaison de notre méthode avec d'autres méthodes basées sur des modèles mathématiques en termes de *MSEPWRD*. Ce tableau révèle que notre méthode possède la plus petite valeur de *MSEPWRD*, ce qui montre que le filtre proposé est le plus efficace par rapport aux autres méthodes de références (MP-EKF, EKF et EKS) du point de vue préservation caractéristiques de diagnostic et la morphologie du signal électrocardiogramme.

## 4.5 Filtrage du signal ECG par le filtre de Kalman étendu adaptatif

### 4.5.1 Filtre de kalman étendu

Le filtre de Kalman (KF : *Kalman Filter*) est l'un des développements mathématiques les plus intéressants dans la théorie de l'estimation linéaire [176, 177, 178]. Ce filtre est un re-constructeur d'état dans un environnement stochastique à condition que les variances des bruits sont connues. Il est considéré comme un estimateur linéaire minimisant la variance de l'erreur d'estimation [179]. En effet il est constitué d'un ensemble d'équations discrètes qui permettent d'estimer les états d'un système par rapport aux données mesurées. Le filtre de Kalman permet de donner un estimé de l'état du système à partir d'une information a priori sur l'évolution de cet état (modèle) et des mesures réelles.

Le filtre de Kalman est limité qu'aux systèmes linéaires. Cependant, la plupart des systèmes physiques sont non linéaires. La non linéarité peut être associée au modèle du processus, au modèle d'observation ou bien à tous les deux. Le filtre de kalman étendu (EKF : *Extended Kalman Fitre*) est une extension non linéaire du filtre de Kalman conventionnel qui a été développé spécifiquement pour les systèmes qui ont des modèles dynamiques non linéaires[178, 180].

Considérons un système dynamique, non linéaire et discret dans le temps possédant un vecteur d'état  $x_k$  et un vecteur de mesure (observation)  $z_k$ . Un modèle dynamique non linéaire de ce système peut être décrit comme suit :

$$x_{k+1} = f(x_k, w_k), \quad (4.12)$$

où  $x_k$  est l'état du système à l'instant discret  $k$ ,  $f(\cdot)$  la dynamique du système et  $w_k$  est le bruit d'état (bruit blanc Gaussien additif), tous avec une dimension de  $n \times 1$ . On suppose aussi que nous avons des mesures bruitées  $z_k$ , décrites en fonction de  $x_k$  comme suit :

$$z_k = g(x_k, v_k), \quad (4.13)$$

où  $g(\cdot)$  désigne la relation entre le vecteur d'état et l'observation, et  $v_k$  est le bruit de mesure (bruit blanc Gaussien additif). Notons que  $g(\cdot)$  et  $v_k$  sont de dimensions unitaires (scalaires) dans notre cas. Les deux vecteurs du bruit  $w_k$  et  $v_k$  sont supposés être Gaussiens et non corrélés l'un avec l'autre avec des valeurs moyennes nulles et matrices de covariances  $Q = E[w_k, w_k^T]$  et  $R = [v_k, v_k^T]$ , respectivement [181].

L'état du système est supposé être inconnu, et c'est pour cette raison, le filtre de Kalman étendu va être utilisé afin de trouver la meilleur estimation ( $\hat{x}_k$ ) de l'état  $x_k$ . Pour obtenir les équations de l'algorithme du filtre de kalman étendu, les Équations 4.12 et 4.13, seront développées en séries de Taylor (cf., [Annexe. C](#)) comme suit[182] :

- ✓ Au voisinage du vecteur d'état estimé  $\hat{x}_k$  et au voisinage de l'estimé du vecteur du bruit d'état  $\hat{w}_k$  pour l'Équation 4.12.
- ✓ Au voisinage du vecteur d'état estimé  $\hat{x}_k$  et au voisinage de l'estimé du vecteur du bruit de mesure  $\hat{v}_k$  pour l'Équation 4.13.

ce qui nous donne :

$$f(x_k, w_k) = f(\hat{x}_k, \hat{w}_k) + A_k(x_k - \hat{x}_k) + W_k(w_k - \hat{w}_k), \quad (4.14)$$

$$g(x_k, v_k) = g(\hat{x}_k, \hat{v}_k) + C_k(x_k - \hat{x}_k) + V_k(v_k - \hat{v}_k), \quad (4.15)$$

avec :

$A_k = \left. \frac{\partial f}{\partial x_k} \right|_{x_k=\hat{x}_k}$ ,  $W_k = \left. \frac{\partial f}{\partial w_k} \right|_{w_k=\hat{w}_k}$  sont les matrices Jacobiennes du vecteur non linéaire  $f$  aux points  $\hat{x}_k$  et  $\hat{w}_k$ , respectivement.

$C_k = \left. \frac{\partial g}{\partial x_k} \right|_{x_k=\hat{x}_k}$ ,  $V_k = \left. \frac{\partial g}{\partial v_k} \right|_{v_k=\hat{v}_k}$  sont les matrices Jacobiennes du vecteur non linéaire  $g$  aux points  $\hat{x}_k$  et  $\hat{v}_k$ , respectivement.

Supposons maintenant que les termes d'ordres supérieurs dans les Équations 4.14 et 4.15 sont de très faibles valeurs, ce qui nous permet de les négliger, ce qui nous donne les modèles approximatifs linéaires suivants [183] :

$$x_{k+1} = f(\hat{x}_k, 0) + A_k(x_k - \hat{x}_k) + W_k w_k. \quad (4.16)$$

$$z_k = g(\hat{x}_k, 0) + C_k(x_k - \hat{x}_k) + V_k v_k. \quad (4.17)$$

Notons que les estimés des bruits d'état et de mesure  $\hat{w}_k$  et  $\hat{v}_k$ , respectivement, sont remplacés par des zéros dans les Équations 4.16 et 4.17, à cause de leurs natures centrées. Par conséquent, au voisinage de l'estimé  $\hat{x}_k$ , la dynamique linéaire correspondante sera donnée par les matrices Jacobiennes.

L'ensemble des équations du filtre de kalman étendu est décrit comme suit :

- **Équations de prédiction :**

$$\hat{x}_{k/k-1} = f(\hat{x}_{k-1/k-1}, 0), \quad (4.18)$$

$$P_{k/k-1} = A_k P_{k-1/k-1} A_k^T + W_k Q W_k^T, \quad (4.19)$$

- **Équations de correction :**

$$K_k = P_{k/k-1} C_k^T (C P_{k/k-1} C^T + V_k R V_k^T)^{-1}, \quad (4.20)$$

$$\hat{x}_{k/k} = \hat{x}_{k/k-1} + K_k (y_k - g(\hat{x}_{k/k-1}, 0)), \quad (4.21)$$

$$P_{k/k} = P_{k/k-1} - K_k C_k^T P_{k/k-1}, \quad (4.22)$$

avec :

$P_{k/k-1} = E[(x_k - \hat{x}_{k/k-1})(x_k - \hat{x}_{k/k-1})^T]$  est l'estimation de la matrice de covariance de

l'erreur a priori.

$P_{k/k} = E[(x_k - \hat{x}_{k/k})(x_k - \hat{x}_{k/k})^T]$  est l'estimation de la matrice de covariance de l'erreur a posteriori, et  $K_k$  est le gain de kalman.

### 4.5.2 Modèle dynamique du signal ECG

Pour appliquer le filtre de Kalman au signal électrocardiogramme un modèle dynamique pour ce dernier est nécessaire.

Ce modèle produit une trajectoire dans un espace d'état tridimensionnel avec les coordonnées  $(x, y, z)$ . La quasi périodicité de l'ECG sera modélisée par le mouvement de la trajectoire autour d'un cycle limite de rayon unité dans le plan  $(x, y)$  [11].

Un cycle limite est une trajectoire circulaire qui peut être obtenu par la solution d'une équation différentielle du deuxième ordre. L'équation différentielle du deuxième ordre considérée dans [11] décrite en fonction des variables d'état  $x_1$  et  $x_2$  est donnée par :

$$\begin{cases} \dot{x}_1 = \alpha x_1 - \omega x_2 \\ \dot{x}_2 = \alpha x_2 + \omega x_1 \end{cases} \quad (4.23)$$

avec  $\alpha = 1 - \sqrt{x_1^2 + x_2^2}$ , et  $\omega$  c'est la vitesse angulaire. Notons bien que l'Équation 4.23 possède la solution analytique suivante :

$$\begin{cases} x_1 = \sin(\omega t) \\ x_2 = \cos(\omega t) \end{cases} \quad (4.24)$$

La Figure 4.9(a) représente la trajectoire circulaire produit par la solution de l'équation 4.23. Chaque révolution de la trajectoire circulaire (Équation 4.23, Figure 4.9) va correspondre à un intervalle RR (un battement du coeur) du signal ECG (cf., Figure 4.9)(b)).




FIGURE 4.9 – (a) Trajectoire circulaire, (b) Intervalle RR.

L'amplitude du signal électrocardiogramme va être considéré comme la variation suivant l'axe  $z$  de la trajectoire circulaire (Figure 4.9). Dans le plan  $x - y$  nous avons l'évolution d'une trajectoire circulaire, et à des moments bien déterminés (les instants de réalisation des pics ou sommets P, Q, R, S et T) on introduit des Gaussiennes dans la direction de l'axe  $z$  dont le but est d'obtenir les amplitudes du signal électrocardiogramme et ceci en utilisant l'équation différentielle suivante :

$$\dot{x}_3 = - \sum_{i \in \{P, Q, R, S, T\}} a_i \Delta \theta_i \exp \left( -\frac{\Delta \theta_i^2}{2b_i^2} \right) - (x_3 - z_0), \quad (4.25)$$

avec :  $\Delta \theta_i = (\theta - \theta_i)$ ,  $\theta = \arctan 2(x_2, x_1)$ ,  $a_i$  sont les paramètres représentant les amplitudes des Gaussiennes, Les  $b_i$  représentent les largeurs des Gaussiennes et  $z_0$  représente la ligne de base du signal ECG.

Les points P, Q, R, S et T de l'ECG sont décrits par des événements correspondant à des attracteurs négatifs ou positifs dans la direction  $z$ . Ces événements sont placés à des angles fixes le long du cercle unitaire (Figure 4.9) et sont donnés par  $\theta_p, \theta_Q, \theta_R, \theta_S$  et  $\theta_T$  (Figure 4.10). Quand la trajectoire s'approche de l'un de ces événements, elle sera poussée soit vers le haut soit vers le bas loin du cycle limite, et ensuite après un certain moment elle revient (retirée) vers le cycle limite.

La Figure (4.10) représente une trajectoire typique produite par le modèle dynamique (cf., Équation 4.23 et Équation 4.25 (ces équations ont été intégrées en utilisant la méthode de Runge Kutta d'ordre quatre (cf., Annexe. A))) dans l'espace 3-D donné par  $(x_1, x_2, x_3)$ , la ligne rouge reflète le cycle limite de rayon unitaire, et la ligne bleu montre les positions des événements P, Q, R, S et T.




FIGURE 4.10 – Trajectoire typique produite par le modèle dynamique dans l'espace 3-D.

D'après tous ce que nous avons présenté, le modèle dynamique du signal électrocardiogramme peut être décrit par l'ensemble des trois équations différentielles suivantes :

$$\begin{cases} \dot{x}_1 = \alpha x_1 - \omega x_2 \\ \dot{x}_2 = \alpha x_2 + \omega x_1 \\ \dot{x}_3 = - \sum_{i \in \{P, Q, R, S, T\}} a_i \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - (x_3 - z_0) \end{cases} \quad (4.26)$$

La déviation de la ligne de base a été introduite en injectant la valeur de la ligne de base (de fréquence égale à la fréquence respiratoire  $f_r$ ) notée  $z_0$  dans la troisième équation du modèle (cf., Équation 4.26) comme suit :

$$z_0(t) = A \sin(2\pi f_r t), \quad (4.27)$$

avec :  $A = 0.15mv$  et  $f_r = 0.25Hz$ .

Le Tableau 4.7 représente les paramètres d'un modèle général du signal électrocardiogramme (cf., Équation 4.26). La Figure 4.11 représente un signal électrocardiogramme obtenue par le modèle (Équation 4.26) en utilisant les paramètres de tableau 4.7.

TABLE 4.7 – Paramètres du modèle d'ECG.

Indice ( $i$ )	P	Q	R	S	T
Temps (secs)	-0.2	-0.05	0	0.05	0.3
$\theta_i$ (radians)	$-\pi/3$	$-\pi/12$	0	$\pi/12$	$\pi/2$
$a_i$	1.2	-0.5	30.0	-7.5	0.75
$b_i$	0.25	0.1	0.1	0.1	0.4




FIGURE 4.11 – Signal électrocardiogramme synthétique.

### 4.5.3 Conception du filtre de Kalman étendu adaptatif basé sur l'algorithme BBO

La structure du filtrage du signal électrocardiogramme synthétique par le filtre de Kalman étendu adaptatif est représentée sur la Figure 4.9. Quatre étapes sont à suivre pour

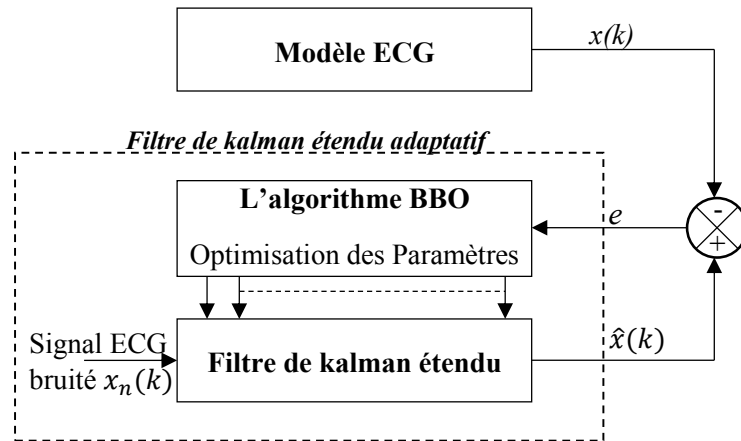


FIGURE 4.12 – Structure du filtre de kalman étendu adaptatif.

construire le filtre de kalman étendu adaptatif :

- **Étape 1** : cette étape consiste à la discrétisation du modèle dynamique non linéaire du signal ECG (Équation 4.26). Le modèle 4.26 est un modèle continu dans le temps, et vu la nature discrète du FK, alors, une discrétisation de ce modèle (cf., Équation 4.26) sera nécessaire. Généralement la discrétisation se fait en utilisant la méthode d'Euler (cf., Annexe. B), décrite de façon générale comme suit :

$$\frac{dx}{dt} = \dot{x} \approx \frac{x(t_{n+1}) - x(t_n)}{h}. \quad (4.28)$$

Pour appliquer la méthode d'Euler d'ordre 1 au modèle 4.26, calculant les approximations suivantes :

$$\dot{x}_1 = \frac{x_1(k+1) - x_1(k)}{h}. \quad (4.29)$$

$$\dot{x}_2 = \frac{x_2(k+1) - x_1(k)}{h}. \quad (4.30)$$

$$\dot{x}_3 = \frac{x_3(k+1) - x_1(k)}{h}. \quad (4.31)$$

Après le remplacement des Équations 4.29, 4.30, et 4.31 dans les différentes équations du modèle 4.26, ce modèle dans sa forme discrète sera donné par (cf., Annexe.

D pour le détail des calculs) :

$$\begin{cases} x_1(k+1) = (1 + \alpha h)x_1(k) - \omega h x_2(k) \\ x_2(k+1) = (1 + \alpha h)x_2(k) + \omega h x_1(k) \\ x_3(k+1) = - \sum_{i \in \{P, Q, R, S, T\}} a_i h \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - ((h-1)x_3 - h z_0), \end{cases} \quad (4.32)$$

- **Étape 2** : cette étape consiste à l'établissement d'un modèle quasi réel de l'ECG. Le modèle discret non linéaire (Équation 4.32) peut être réécrit sous sa forme compacte suivante :

$$x_{k+1} = f(x_k), \quad (4.33)$$

où  $x_k$  est le vecteur d'état donné par  $x_k = [x_1(k), x_2(k), x_3(k)]^T$ , donc :

$$\begin{pmatrix} x_1(k+1) \\ x_2(k+1) \\ x_3(k+1) \end{pmatrix} = \begin{pmatrix} (1 + \alpha h)x_1(k) - \omega h x_2(k) \\ (1 + \alpha h)x_2(k) + \omega h x_1(k) \\ - \sum_{i \in \{P, Q, R, S, T\}} a_i h \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - ((h-1)x_3 - h z_0) \end{pmatrix} \quad (4.34)$$

L'équation vectorielle 4.34 représente l'équation d'état non bruitée du modèle discret du signal ECG. Pour représenter un signal ECG plus réel, nous devons introduire des bruits aléatoires au modèle 4.33 comme suit :

$$x_{k+1} = f(x_k, w_k), \quad (4.35)$$

où  $w_k = [w_1(k), w_2(k), w_3(k)]^T$  est un vecteur aléatoire du bruit d'état supposé additif, normal est Gaussien, possédant une matrice de covariance  $Q_k = E[w_k w_k^T]$ , alors l'Équation 4.34 devient comme suit :

$$\begin{pmatrix} x_1(k+1) \\ x_2(k+1) \\ x_3(k+1) \end{pmatrix} = \begin{pmatrix} (1 + \alpha h)x_1(k) - \omega h x_2(k) + w_1(k) \\ (1 + \alpha h)x_2(k) + \omega h x_1(k) + w_2(k) \\ - \sum_{i \in \{P, Q, R, S, T\}} a_i h \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - ((h-1)x_3 - h z_0) + w_3(k) \end{pmatrix} \quad (4.36)$$

L'équation de mesure correspondante à la représentation d'état (Équation 4.36) peut être reliée au vecteur d'état  $x_k = [x_1(k) \ x_2(k) \ x_3(k)]^T$  par la relation suivante :

$$S_k = [0 \ 0 \ 1]x_k + v_k, \quad (4.37)$$

où  $S_k$  est la mesure considérée et  $v_k$  est un bruit de mesure additif, normal et Gaussien de covariance  $R_k = E[v_k v_k^T]$ . La Figure 4.13 représente la solution suivant l'axe  $z$  des systèmes 4.36 et 4.37 en utilisant la méthode de Runge Kutta d'ordre quatre (cf., Annexe. A) . Cette solution représente un modèle plus proche au signal ECG réel.




FIGURE 4.13 – Signal électrocardiogramme quasi-réel.

- **Étape 3** : le modèle du signal ECG 4.36 et 4.37 est un modèle non linéaire et pour l'utiliser avec le filtre de kalman étendu, il faut le linéariser ; comme méthode de linéarisation, nous avons choisis la méthode du développement limité en série de Taylor (cf., [Annexe. C](#)).

Le modèle 4.36 peut être séparé en trois équations comme suit :

$$\begin{cases} x_1(k+1) = F(x_1(k), x_2(k), x_3(k)) \\ x_2(k+1) = G(x_1(k), x_2(k), x_3(k)) \\ x_3(k+1) = H(x_1(k), x_2(k), x_3(k)) \end{cases} \quad (4.38)$$

où  $F$ ,  $G$  et  $H$  sont les trois composantes du vecteur non linéaire  $f$ .

Appliquant maintenant la linéarisation du modèle du signal ECG en utilisant l'approximation linéaire de Taylor au voisinage d'un point  $x_0$  comme suit :

$$x_{k+1} = f(x_k, w_k) \approx f(x_0, w_0) + \frac{\partial f}{\partial x_k} \Big|_{x_k=x_0} (x_k - x_0) + \frac{\partial f}{\partial w_k} \Big|_{w_k=w_0} (w_k - w_0) \quad (4.39)$$

où  $\partial f / \partial x_k$  est la dérivée d'un vecteur par rapport à un autre vecteur. Cette dérivée comme on a vu précédemment appelée le Jacobien de  $f$  par rapport à  $x_k$  et  $\partial f / \partial w_k$  est le Jacobien de  $f$  par rapport à  $w_k$ . Les matrices  $\partial f / \partial x_k$  et  $\partial f / \partial w_k$  seront notées respectivement par  $A_k$  et  $W_k$  comme suit :

$$A_k = \begin{pmatrix} \frac{\partial F}{\partial x_1(k)} & \frac{\partial F}{\partial x_2(k)} & \frac{\partial F}{\partial x_3(k)} \\ \frac{\partial G}{\partial x_1(k)} & \frac{\partial G}{\partial x_2(k)} & \frac{\partial G}{\partial x_3(k)} \\ \frac{\partial H}{\partial x_1(k)} & \frac{\partial H}{\partial x_2(k)} & \frac{\partial H}{\partial x_3(k)} \end{pmatrix} \quad (4.40)$$

$$W_k = \begin{pmatrix} \frac{\partial F}{\partial w_1(k)} & \frac{\partial F}{\partial w_2(k)} & \frac{\partial F}{\partial w_3(k)} \\ \frac{\partial G}{\partial w_1(k)} & \frac{\partial G}{\partial w_2(k)} & \frac{\partial G}{\partial w_3(k)} \\ \frac{\partial H}{\partial w_1(k)} & \frac{\partial H}{\partial w_2(k)} & \frac{\partial H}{\partial w_3(k)} \end{pmatrix} \quad (4.41)$$

Notons bien que la matrice  $\partial f/\partial x_k$  va remplacer la non linéarité  $f$ , ce qui va nous donner un modèle linéaire au voisinage de  $x_0$ , et c'est cette matrice qui représente maintenant la dynamique de notre modèle non linéaire. Donc, l'approximation linéaire du modèle ECG au voisinage de  $x_0$  sera :

$$x_{k+1} \approx f(x_0, w_0) + A_k(x_k - x_0) + W_k(w_k - w_0). \quad (4.42)$$

Pour la linéarisation de l'Équation 4.27, changeant d'abord sa forme vers la forme suivante :

$$S_k = g(x_k, v_k). \quad (4.43)$$

avec  $g(x_k) = x_3(k+1)$  une fonction non linéaire.

Alors, par l'application de l'approximation linéaire de Taylor, on a :

$$S_k \approx g(x_0, v_0) + \frac{\partial g}{\partial x_k} \Big|_{x_k=x_0} (x_k - x_0) + \frac{\partial g}{\partial v_k} \Big|_{v_k=v_0} (v_k - v_0), \quad (4.44)$$

où  $\partial g/\partial x_k$  est la dérivée d'un scalaire par rapport à un vecteur (qui nous donne un vecteur), et  $\partial g/\partial v_k$  est un scalaire. Les matrices  $\partial g/\partial x_k$  et  $\partial g/\partial v_k$  seront notées respectivement par  $C_k$  et  $V_k$  comme suit :

$$C_k = \begin{bmatrix} \frac{\partial g}{\partial x_1} & \frac{\partial g}{\partial x_2} & \frac{\partial g}{\partial x_3} \end{bmatrix}. \quad (4.45)$$

$$V_k = 1. \quad (4.46)$$

Finalement après les calculs des différents éléments des matrices dynamiques (4.40), (4.41) et (4.45) (cf., [Annexe. E](#) pour voir le détail des calculs), ces matrices seront décrites comme suit :

$$A_k = \begin{pmatrix} 1 + h - \left( \frac{2hx_1(k)^2 + hx_2(k)^2}{\sqrt{x_1(k)^2 + x_2(k)^2}} \right) & -\frac{hx_1(k)x_2(k)}{\sqrt{x_1(k)^2 + x_2(k)^2}} - \omega h & 0 \\ -\frac{hx_1(k)x_2(k)}{\sqrt{x_1(k)^2 + x_2(k)^2}} + \omega h & 1 + h - \left( \frac{hx_1(k)^2 + 2hx_2(k)^2}{\sqrt{x_1(k)^2 + x_2(k)^2}} \right) & 0 \\ \sum_i \frac{a_i hx_2(k)}{x_1(k)^2 + x_2(k)^2} \exp\left(-\frac{\Delta\theta_i^2}{2b_i^2}\right) \left[1 - \frac{\Delta\theta_i^2}{b_i^2}\right] & \sum_i \frac{-a_i hx_1(k)}{x_1(k)^2 + x_2(k)^2} \exp\left(-\frac{\Delta\theta_i^2}{2b_i^2}\right) \left[1 - \frac{\Delta\theta_i^2}{b_i^2}\right] & 1 - h \end{pmatrix} \quad (4.47)$$

$$W_k = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (4.48)$$

$$C_k = \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} \quad (4.49)$$

- **Étape 4** : cette étape consiste à établir l'algorithme du filtre de kalman en utilisant les Équations (4.18–4.22), afin de construire la structure du filtre de kalman étendu adaptatif (Figure 4.12), qui consiste en une adaptation en temps réel des paramètres de ce filtre. L'algorithme d'optimisation BBO est capable d'ajuster les paramètres du filtre de kalman étendu (les covariances des bruits d'état et de mesure  $Q$  et  $R$ , respectivement) de sorte que la valeur de la fonction objectif utiliser pour exciter l'algorithme BBO atteint sa valeur minimale. La fonction objectif utilisée est l'erreur quadratique moyenne (Équation 3.2) définie entre la sortie du filtre de Kalman adaptatif  $\hat{y}$  et la sortie du modèle du signal ECG  $y$ .

#### 4.5.4 Résultats de simulation

Nous fournissons dans cette section les résultats de filtrage du signal électrocardiogramme synthétique obtenu en utilisant le filtre de kalman étendu adaptatif. Commencant par donner les différents paramètres de l'algorithme d'optimisation BBO : le taux de mutation  $m = 0.01$ , le taux d'immigration et d'émigration  $\lambda_k$  et  $\mu_k$ , respectivement, sont similaires aux courbes de migration linéaire (cf., Figure 2.8). Nous avons exécuté notre algorithme plusieurs fois en utilisant différents nombres d'itérations, différentes tailles de population et différentes valeurs de variance du bruit d'état et de mesure. La Figure 4.14 représente le résultat de filtrage du signal ECG synthétique avec la variance du bruit d'état  $var(w_k) = 1 \times 10^{-9}$ , variance du bruit de mesure  $var(v_k) = 0.0028$ , nombre d'itération de l'algorithme BBO et la taille de population 50 et 10, respectivement. La Figure 4.15 représente le résultat de filtrage du signal ECG synthétique avec une variance du bruit d'état  $var(w_k) = 1 \times 10^{-9}$ , variance du bruit de mesure  $var(v_k) = 0.0014$ , nombre d'itération de l'algorithme BBO et la taille de population 50 et 10, respectivement. La Figure 4.16 représente le résultat de filtrage du signal ECG synthétique avec une variance du bruit d'état  $var(w_k) = 1 \times 10^{-9}$ , variance du bruit de mesure  $var(v_k) = 0.0014$ , nombre d'itération de l'algorithme BBO et la taille de population 200 et 100, respectivement. D'après les trois Figures 4.14, 4.15 et 4.16 et par une inspection visuelle des zooms on peut clairement remarquer que l'effet du bruit sur le signal ECG a été diminué dans les trois cas,

mais avec un nombre d'itération et taille de population élevé (cf., Figure 4.16), on remarque que le signal électrocardiogramme dé-bruité est plus lisse que les deux autres cas (cf., Figure 4.14 et Figure 4.15). Les résultats obtenus nous confirment l'efficacité du filtre de Kalman étendu adaptatif pour résoudre le problème de filtrage du signal électrocardiogramme synthétique, et cette efficacité reste subordonnée au nombre d'itération et la taille de population de l'algorithme d'optimisation. Pour utiliser ce filtre avec des signaux électrocardiogrammes réels nous proposons comme perspective, d'ajouter un mécanisme pour ajuster les paramètres du modèle dynamique (cf., Équation 4.26) à savoir les amplitudes des Gaussiennes ( $a_i$ ), les largeurs ( $b_i$ ) des Gaussiennes, les instants pour introduire ces Gaussiennes et la déviation de la ligne de base ( $z_0$ ) par rapport à un signal ECG réel.




FIGURE 4.14 – Résultat de filtrage du signal électrocardiogramme synthétique.

## 4.6 Filtrage du signal ECG par la décomposition en valeurs singulières

### 4.6.1 La décomposition en valeurs singulières

La décomposition en valeurs singulières (SVD : *Singular Value Decomposition*) est une méthode de l'algèbre linéaire, utilisée pour la factorisation des matrices rectangulaires réelles ou complexes. Ses applications s'étendent du traitement du signal aux statistiques. Dans notre travail cette méthode sera utilisée pour le calcul des pseudo-inverses [184].

Étant donnée la matrice  $X$  de taille  $n \times m$ , il existe deux matrices orthogonales  $V$  (de




FIGURE 4.15 – Résultat de filtrage du signal électrocardiogramme synthétique.




FIGURE 4.16 – Résultat de filtrage du signal électrocardiogramme synthétique.

taille  $m \times m$ ) et  $U$  (de taille  $n \times n$ ) telle que :

$$U^T X V = \begin{bmatrix} W & 0_{r \times m-r} \\ 0_{n-r \times r} & 0_{n-r \times m-r} \end{bmatrix}, \quad (4.50)$$

où :

$W = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r)$ , est une matrice diagonale  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r \geq 0$ ,  $\sigma_i$  sont les valeurs singulières de la matrice  $X$ , et  $r$  est le rang de la matrice  $X$ .

$V$  : est une matrice orthogonale dont les colonnes sont les vecteurs de base ( $v_i$ ) de l'espace d'entrée ( $V : n \times n$ ).

$U$  : est une matrice orthogonale dont les colonnes sont les vecteurs de base ( $u_i$ ) de l'espace de sortie ( $U : m \times m$ ).

#### 4.6.2 Pseudo inverse

Soit à résoudre le système suivant :

$$AX = b, \quad (X : n \times m). \quad (4.51)$$

La solution de ce système est calculée comme suit :

$$\begin{aligned} A &= \frac{b}{X} \\ &= X^{-1}b, \end{aligned} \quad (4.52)$$

où  $X^{-1}$  est l'inverse de la matrice  $X$  dont on distingue plusieurs cas à savoir :

1. Le rang de la matrice  $X$ ,  $r = n = m$  (rang complet), alors, l'inverse de  $X$  existe est vérifiée :

$$XX^{-1} = I = X^{-1}X. \quad (4.53)$$

On dit que cet inverse est bilatéral (inverse ordinaire), car  $X^{-1}$  peut être multipliée soit par la gauche ou par la droite de  $X$  pour donner la matrice  $I$ .

2. Le rang de la matrice  $X$ ,  $r = n$  et  $m > n$  (système sous-déterminé (plus d'inconnues que d'équations)). Dans ce cas la matrice  $X$  ne peut pas être inversée directement sauf si nous introduisons une astuce. Puisque  $r = n$ ; alors  $X^T X$  peut être inversé, donc :

$$(X^T X)^{-1}(X^T X) = I_n \quad (4.54)$$

$$\underbrace{(X^T X)^{-1} X^T X}_{X_{gauche}^{-1}} = I_n \quad (4.55)$$

$$X_{gauche}^{-1} X = I. \quad (4.56)$$

L'expression  $(X^T X)^{-1} X^T$  est appelée inverse gauche.

3. Le rang de la matrice  $X$ ,  $r = m$  et  $n > m$  (un système sur-déterminé (plus d'équations que d'inconnues)). L'inverse de  $X$  est obtenu par l'inverse  $XX^T$  puisque ce dernier est de rang complet. Donc :

$$(XX^T)(XX^T)^{-1} = I_m \quad (4.57)$$

$$XX_{droite}^{-1} = I. \quad (4.58)$$

L'expression  $X^T(XX^T)^{-1}$  est appelée inverse droite de A.

4. Nous discutons maintenant le cas où la matrice  $X$  est d'ordre générale, c'est-à-dire Le rang de la matrice  $X$ ,  $r < m$  et  $r < n$ . Dans ce cas l'inverse de  $X$  s'appelle inverse généralisé ou la pseudo inverse qu'on va noter par  $X^+$ . L'intérêt de la SVD est de formuler une définition générale de la pseudo-inverse. On définit la pseudo-inverse de la matrice  $X$  comme :

$$X^+ = V \begin{bmatrix} W^{-1} & 0_{r \times m-r} \\ 0_{n-r \times r} & 0_{n-r \times m-r} \end{bmatrix} U^T. \quad (4.59)$$

où :

$$W^{-1} = \text{diag}(\sigma_1^{-1}, \sigma_2^{-1}, \dots, \sigma_r^{-1}). \quad (4.60)$$

et  $r$  est le rang de  $X$ . Cette définition s'applique quelle soit la matrice  $X$ , qu'elle soit sur ou sous déterminée et quel que soit son rang. Cette pseudo-inverse peut encore s'écrire :

$$X^+ = \sum_{i=1}^r \frac{1}{\sigma_i} v_i u_i^T. \quad (4.61)$$

#### 4.6.3 Hypothèse de filtrage par SVD

Les matrices  $U$  et  $V$  (cf., [Équation 4.50](#)) peuvent être réarrangées suivant le rang  $r$  (le nombre des valeurs singulières différents de zéro) comme suit :

$$X = U W V^T = \begin{bmatrix} U_r & U_r^\perp \end{bmatrix} \begin{bmatrix} W_r & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} V_r^T \\ (V_r^\perp)^T \end{bmatrix}, \quad (4.62)$$

avec :

$$U_r = \begin{bmatrix} u_1 & u_2 & \dots & u_r \end{bmatrix} \quad \text{et} \quad U_r^\perp = \begin{bmatrix} u_{r+1} & u_{r+2} & \dots & u_m \end{bmatrix}. \quad (4.63)$$

$$V_r = \begin{bmatrix} v_1 & v_2 & \dots & v_r \end{bmatrix} \quad \text{et} \quad V_r^\perp = \begin{bmatrix} v_{r+1} & v_{r+2} & \dots & v_n \end{bmatrix}. \quad (4.64)$$

$$W_r = \text{diag}(\sigma_1, \dots, \sigma_r). \quad (4.65)$$

Les vecteurs singuliers  $u_i$  et  $v_i$  dans  $U_r$  et  $V_r$  correspondants aux plus grandes valeurs singulières sont connus sous le nom de vecteurs dominants (signaux dominants), de la même façon, les vecteurs singuliers associés avec les petites valeurs singulières sont connus sous le nom de vecteurs singuliers sous dominants (introduisent des bruits). Un peu du bruit dans les données change les valeurs singulières égale zéro en petits nombres

positifs différents de zéro. Par conséquent, la SVD est utilisée pour décomposer une matrice de données en deux sous espaces orthogonaux. Ces deux sous espaces correspondent au signal et aux composantes du bruit qu'il le contamine. La projection des données sur le sous-espace désiré élimine le bruit et les composantes du signal indésirables, donc la tâche sera de trouver le bon opérateur de projection.

#### 4.6.3.1 Calcul de l'opérateur de projection

Soit le système linéaire suivant :

$$y(i) = \sum_{l=0}^{L-1} h_{s,l}x(i-l) + v(i), \quad (4.66)$$

avec :

$y(i)$  : le signal mesuré à l'instant  $i$  ;

$x(i)$  : le signal d'entrée ;

$h_l$  : sont les paramètres inconnus du modèle ;

$v(i)$  : est un bruit blanc Gaussien.

La tâche maintenant est d'estimer les paramètres  $h_{s,l}$ , pour cela, on va définir l'erreur entre le signal mesuré  $y(i)$  et la sortie d'un filtre RIF  $\hat{y}(i)$  comme suit :

$$\begin{aligned} e(i) &= y(i) - \hat{y}(i) \\ &= y(i) - \sum_{l=0}^{L-1} h_l x(i-l), \end{aligned} \quad (4.67)$$

avec :  $h_l$  sont les coefficients du filtre.

Dans ce qui suit on va choisir les paramètres  $h_l$  qui minimisent la fonction objectif suivante :

$$J = \sum_{i=i_1}^{i=i_2} e^2(i), \quad (4.68)$$

où :  $i_1$  et  $i_2$  sont la borne inférieure et la borne supérieure de l'intervalle, là où la minimisation se fait. Les coefficients du filtre  $h_l$  sont constants pendant l'intervalle  $[i_1 \ i_2]$ . En utilisant cette fonction objectif (cf., [Équation 4.68](#)), on peut dire que le filtre obtenu est un filtre linéaire au sens des moindres carrés.

Maintenant on utilise  $i_1 = L$  et  $i_2 = N$ , où le signal d'entrée peut être réarrangé sous

la forme matricielle suivante :

$$\begin{bmatrix} x(L) & x(L+1) & \dots & x(N) \\ x(L-1) & x(L) & \dots & x(N-1) \\ \vdots & \vdots & \ddots & \vdots \\ x(1) & x(2) & \dots & x(N-L+1) \end{bmatrix}. \quad (4.69)$$

Pour obtenir les coefficients optimaux du filtre qui minimisent la fonction objectif  $J$  (cf., [Équation 4.68](#)), le gradient de (4.68) sera utilisé et doit être égale à zéro comme suit :

$$\begin{aligned} \frac{\partial L}{\partial h_l} &= 2 \sum_{i=L}^N \frac{\partial e(i)}{\partial h_l} e(i) \\ &= -2 \sum_{i=L}^N x(i-l)e(i) \\ &= 0. \end{aligned} \quad (4.70)$$

On suppose que l'erreur pour laquelle la fonction objectif (cf., [Équation 4.68](#)) est minimisée soit noté par  $e_{min}(i)$ , on a donc :

$$\sum_{i=L}^N x(i-l)e_{min}(i) = 0, \quad l = 0, 1, \dots, L-1. \quad (4.71)$$

Cette expression représente une description mathématique de la version temporelle du principe d'orthogonalité, ça veut dire que la suite temporelle  $e_{min}(i)$  est orthogonale à la suite temporelle  $x(i-l)$  quand le filtre opère dans les conditions des moindres carrés.

Pour obtenir l'opérateur de projection orthogonal, on suit la procédure suivante :

$$\begin{aligned} \sum_{i=L}^N x(i-l)e_{min}(i) &= 0, \quad l = 0, 1, \dots, L-1, \\ \sum_{i=L}^N x(i-l) \left[ y(i) - \sum_{k=0}^{L-1} h_{opt,k} x(i-k) \right] &= 0, \\ \sum_{k=0}^{L-1} h_{opt,k} \sum_{i=L}^N x(i-l)x(i-k) &= \sum_{i=L}^N x(i-l)y(i), \\ \sum_{k=0}^{L-1} h_{opt,k} r(k,l) &= p(-l), \quad l = 0, 1, \dots, L-1, \end{aligned} \quad (4.72)$$

avec :

$$r(k, l) = \sum_{i=L}^K x(i-l)x(i-k), \quad l, k = 0, 1, \dots, L-1, \quad (4.73)$$

$$p(-l) = \sum_{i=L}^N x(i-l)y(i), \quad l = 0, 1, \dots, L-1, \quad (4.74)$$

L'Équation 4.73 est la fonction d'autocorrélation du signal d'entrée  $x(i)$ , et l'équation 4.74 est la fonction d'intercorrélacion entre la sortie  $y(i)$  et l'entrée  $x(i)$ . On peut remarquer que l'Équation 4.72 peut s'écrire sous forme matricielle suivante :

$$Rh_{opt} = P, \quad (4.75)$$

où la matrice d'autocorrélation du signal  $x(i)$  peut être décrite comme suit :

$$R = \begin{bmatrix} r(0,0) & r(1,0) & \dots & r(L-1,0) \\ r(0,1) & r(1,1) & \dots & r(L-1,1) \\ \vdots & \vdots & \ddots & \vdots \\ r(0,L-1) & r(1,L-1) & \dots & r(L-1,L-1) \end{bmatrix}. \quad (4.76)$$

Le vecteur d'intercorrélacion entre la sortie  $y(i)$  et l'entrée  $x(i)$  peut être décrit comme suit :

$$P = [p(0) \quad p(-1) \quad \dots \quad p(-L+1)]^T. \quad (4.77)$$

En supposant que  $R$  est inversible, on a donc :

$$h_{opt} = R^{-1}P. \quad (4.78)$$

En utilisant le vecteur d'entrée suivant :

$$\times(i) = [x(i) \quad x(i-1) \quad \dots \quad x(i-L+1)]^T, \quad (4.79)$$

La matrice  $R$  (cf., Équation 4.76) peut se réécrire comme suit :

$$R = \sum_{i=L}^N \times(i) \times^T(i). \quad (4.80)$$

En effet, nous introduisons la matrice rectangulaire de Toeplitz de taille  $L \times (N-L+1)$  suivante :

$$\begin{aligned} X &= [\times(L) \quad \times(L+1) \quad \dots \quad \times(N)]^T \\ &= \begin{bmatrix} x(L) & x(L+1) & \dots & x(N) \\ x(L-1) & x(L) & \dots & x(N-1) \\ \vdots & \vdots & \ddots & \vdots \\ x(1) & x(2) & \dots & x(N-L+1) \end{bmatrix}^T. \end{aligned} \quad (4.81)$$

On peut clairement voir que :

$$R = X^T X. \quad (4.82)$$

L'Équation 4.78 peut encore s'écrire en fonction de la matrice des données d'entrées de Toeplitz  $X$ , d'une part :  $R = X^T X$  et d'autre part l'Équation 4.74 peut se réécrire sous forme matricielle suivante :

$$P = X^T Y, \quad (4.83)$$

d'où la nouvelle forme de l'Équation 4.78 :

$$h_{opt} = (X^T X)^{-1} X^T Y. \quad (4.84)$$

Finalement l'estimation de  $Y$  au sens des moindres carrés est donnée par :

$$\begin{aligned} \hat{Y} &= X h_{opt} \\ &= X (X^T X)^{-1} X^T Y. \end{aligned} \quad (4.85)$$

La matrice :

$$\mathbf{P} = X (X^T X)^{-1} X^T, \quad (4.86)$$

est un opérateur de projection pour le sous espace  $X$ . Définissons la matrice suivante :

$$X^+ = (X^T X)^{-1} X^T, \quad (4.87)$$

Alors l'opérateur de projection  $\mathbf{P}$  peut se réécrire comme suit :

$$\mathbf{P} = X X^+, \quad (4.88)$$

où la matrice  $X^+$  est la pseudo-inverse ou l'inverse généralisée de la matrice  $X$ , qu'on peut calculer en utilisant la méthode SVD (cf., Équation 4.61)

#### 4.6.4 Méthode de filtrage du signal ECG par SVD et résultats de simulation

Soit le signal électrocardiogramme bruité sous forme d'un vecteur  $x$  :

$$x(i) = [x(i) \quad x(i-1) \quad \dots \quad x(i-L+1)]^T. \quad (4.89)$$

La première étape consiste à former la matrice de Toeplitz de taille  $L \times (N-L+1)$  en utilisant le vecteur du signal ECG comme suit :

$$X = \begin{bmatrix} x(L) & x(L+1) & \dots & x(N) \\ x(L-1) & x(L) & \dots & x(N-1) \\ \vdots & \vdots & \ddots & \vdots \\ x(1) & x(2) & \dots & x(N-L+1) \end{bmatrix}^T. \quad (4.90)$$

Le rang  $r$  de la matrice 4.90 qui est le nombre des valeurs singulières différentes de zéro n'est pas le même que le rang de la matrice du signal ECG propre, parce que une petite quantité du bruit dans les données change les valeurs singulières égale à zéro en petit nombre positif non nul (sous-section 4.6.3) ; cependant, la perturbation des sous-espaces dominants reste relativement insignifiante. Donc, la tâche maintenant est de trouver la meilleure matrice  $X$  de rang  $r = k$  qui représente la matrice de Toeplitz du signal ECG dé-bruité.

Soit la norme Frobenius des matrices, qui est donnée pour la matrice  $X$  comme suit :

$$\begin{aligned}\|X\|_F &= \sqrt{\sum_{i=1}^L \sum_{j=1}^N |a_{ij}|^2} = \|U^T X V\|_F \\ &= \|W\|_F = \sqrt{(\sigma_1^2 + \dots + \sigma_n^2)}.\end{aligned}\quad (4.91)$$

La norme de Frobenius est invariante par rapport à la transformation orthogonale, et montre que l'énergie des données est conservée dans son spectre des valeurs singulières  $\sigma(X)$ , de plus, la meilleure (au sens des moindres carrées) approximation de rang  $k$ ,  $X_k$  ( $k < \text{rang}(X)$ ), de la matrice  $X$  :

$$\begin{aligned}\min_{\forall A:r(A)=k} \|X - A\|_F &= \|M - X_k\|_F \\ &= \sqrt{\sigma_{k+1}^2 + \dots + \sigma_{\min(L,N)}^2}.\end{aligned}\quad (4.92)$$

est obtenu en mettant zéro les  $k$  plus grandes valeurs singulières, c'est-à-dire en utilisant un opérateur de projection de rang  $k$ , par conséquent, la matrice de Toeplitz du signal ECG dé-bruité peut être donnée par :

$$X_k = \sum_{i=1}^k \sigma_i u_i v_i^T = \mathbf{P}_k X, \quad (4.93)$$

L'opérateur de projection  $\mathbf{P}_k$  de rang  $k$  peut être calculé comme suit (cf., sous-sous-section 4.6.3.1) :

$$\mathbf{P}_k = X_k X_k^+, \quad (4.94)$$

En effet, l'estimé  $\hat{x}$  du signal électrocardiogramme bruité  $x$  (cf., Équation 4.89) peut être décrit comme suit :

$$\hat{x} = \mathbf{P}_k x. \quad (4.95)$$

Dans ce qui suit, nous présentons les résultats de filtrage du signal ECG synthétique en utilisant la méthode discutée précédemment dans cette section. La Figure 4.17 représente un signal ECG synthétique propre, et le même signal contaminé par un bruit blanc

Gaussien additif avec une variance de  $0.05 \text{ mV}$ . La Figure 4.18 représente les résultats de filtrage du signal ECG bruité (cf., Figure 3.7(b)) avec différents opérateur de projection ( $\mathbf{P}_6$  (rang=6),  $\mathbf{P}_4$  (rang=4) et  $\mathbf{P}_2$  (rang=2)), dont on peut remarquer que l'effet du bruit a été diminué pour les trois cas, ce qui confirme l'efficacité de cette méthode, mais cette efficacité reste subordonnée au bon choix de l'opérateur de projection, parce qu'un mauvais choix de cet opérateur peut affecter la morphologie du signal ECG.




FIGURE 4.17 – (a) Signal ECG synthétique propre, (b) Signal ECG synthétique bruité ( $\text{variance} = 0.05 \text{ mV}$ ).

## 4.7 Séparation des signaux ECG Mère-Foetus par SVD

Dans cette section nous allons appliquer la méthode discutée dans la section précédente pour séparer les signaux ECG mère-foetus. La Figure 4.19 représente le modèle de suivi des signaux ECG Mère-foetus [185].

On note par  $x_p$  le signal provenant du capteur sur la poitrine et  $x_v$  le signal provenant du capteur sur l'abdomen. Théoriquement, le signal observé par le capteur thoracique représente le signal électrocardiogramme de la mère bruité par le signal foetal provenant du coeur du foetus. Cependant, comme ce capteur est situé loin du coeur du foetus, nous supposons que le signal  $x_p$  représente le signal ECG de la mère filtré en parcourant le tissu thoracique. Soit le signal cardiaque de la mère noté par  $C_M$ . Lorsque ce dernier traverse le




FIGURE 4.18 – Résultats de filtrage, (a) Avec un opérateur de projection  $\mathbf{P}_6$ , (b) Avec un opérateur de projection  $\mathbf{P}_4$ , (c) Avec un opérateur de projection  $\mathbf{P}_2$ .




FIGURE 4.19 – Modèle de suivi des signaux ECGs mère-foetus

tissu qui agit comme un filtre linéaire de type "réponse impulsionnelle finie" de longueur  $K_p$ , alors nous avons :

$$x_p(n) = g_1 C_M(n - n_p) + \dots + g_{k_p} C_M(n - n_p - K_p + 1), \quad (4.96)$$

où  $n_p$  représente le délai de propagation global à travers la poitrine. Il faut noter que dans la pratique, cette valeur s'avère faible.

Le signal  $x_v$  est la somme du signal cardiaque du fœtus, filtré en passant à travers le tissu de l'abdomen et le signal provenant du coeur de la mère, cependant, ce dernier signal n'est pas en fait le signal  $x_p$  observé par le capteur posé sur la poitrine, parce que le signal produit par le coeur de la mère atteint le capteur abdominal après avoir traversé l'abdomen, par conséquent, il subi quelques transformations. En supposant une autre fois que le transfert abdominal se comporte comme un filtre linéaire (filtre à réponse impulsionnelle finie) de longueur  $K_a$ , le signal provenant du coeur de la mère peut s'écrire comme suit :

$$v_M(n) = f_1 C_M(n - n_a) + \dots + f_{K_a} C_M(n - n_a - K_a + 1), \quad (4.97)$$

où  $n_a$  représente le retard de propagation global à travers l'abdomen. En remplaçant l'expression 4.97 dans l'expression 4.96, nous obtenons une relation entre le signal perturbateur du capteur abdominal et le signal du capteur thoracique, qui peut s'écrire comme suit :

$$v_M(n) = h_{-M} x_p(n + M) + \dots + h_{-1} x_p(n + 1) + h_0 x_p(n) + \dots + h_{L-1} x_p(n - (L - 1)). \quad (4.98)$$

Dans cette expression, le signal  $x_p(n)$  n'est pas exactement celui qui est produit par le coeur de la mère, car celui-ci est soumis selon (Équation 4.96) à un retard  $n_p$  dû à la propagation dans le tissu thoracique, en plus les temps de propagation sont inconnus,  $n_p$  peut être supérieur à  $n_a$ , c'est pourquoi nous avons prévu une partie « anticausal » présentée par les termes  $h(-M) \dots h(-1)$ . Cependant, si  $n_p < n_a$ , ce qui est certainement le cas dans cette expérience, le signal  $v_M(n)$  sera retardé par rapport à  $x_p(n)$  et les coefficients  $h(-M), \dots, h(-1)$  sont également presque nulles.

Finalement, les deux signaux  $x_p$  et  $x_v$ , observés sur la poitrine et l'abdomen de la mère peuvent être représentés comme suit :

$$x_v(n) = h_{-M} x_p(n + M) + \dots + h_{-1} x_p(n + 1) + h_0 x_p(n) + \dots + h_{L-1} x_p(n - L + 1) + c_F(n). \quad (4.99)$$

qui peut s'écrire sous forme matricielle suivante :

$$X_v = \underbrace{H X_p}_{ECG_{mere}} + \underbrace{C_F}_{ECG_{foetus}}. \quad (4.100)$$

Le signal électrocardiogramme du fœtus est plus faible que le signal électrocardiogramme maternel. Par conséquent, les deux sous espaces des vecteurs dominants et sous dominants obtenus par la décomposition en valeurs singulières vont correspondre respectivement au signal ECG de la mère et au signal ECG du fœtus. En utilisant la méthode de filtrage par

SVD discutée dans la section 4.6, les deux signaux électrocardiogrammes de la mère et du fœtus peuvent être donnés comme suit :

$$\widehat{HX}_p = \mathbf{P}_r X_v \quad (4.101)$$

$$\widehat{C}_F = \underbrace{(I - \mathbf{P}_r)}_{\mathbf{P}_r^\perp} X_v. \quad (4.102)$$

avec :  $\mathbf{P}_r$  est l'opérateur de projection,  $\mathbf{P}_r^\perp$  l'opérateur de projection orthogonale et  $I$  la matrice identité.

Cette méthode sera appliquée dans ce qui suit pour la séparation des signaux maternel et foetal composants le signal ECG dans la Figure 4.20. La Figure 4.21 représente le résultat de séparation en utilisant un opérateur de projection  $\mathbf{P}_{10}$  (rang=10).




FIGURE 4.20 – Signal ECG composé (ECG mère+ECG foetus)

## 4.8 Suppression de la déformation de la ligne de base

On appelle ligne de base, la ligne isoélectrique du coeur ; elle correspond au tracé qui serait observé sur un ECG si le coeur n'avait aucune activité électrique. Dans le cas idéal et lorsque l'ECG est effectué (pendant les périodes d'enregistrements), cette ligne est le plus souvent horizontale, mais en pratique, le mouvement et la respiration du patient modifient les positions relatives des électrodes, de sorte que cette ligne présente un tracé ondulé. Pour analyser un signal électrocardiogramme, cette ligne sera prise comme référence pour étudier la forme et la hauteur des différentes ondes cardiaques (P, Q, R, S et T), donc il est impératif de la repérer précisément pour fixer le « Zero ». Dans cette section on va présenter une méthode pour rendre cette ligne bien horizontale, en se basant sur l'hypothèse suivante : le signal ECG varie normalement autour de sa ligne de base, et les

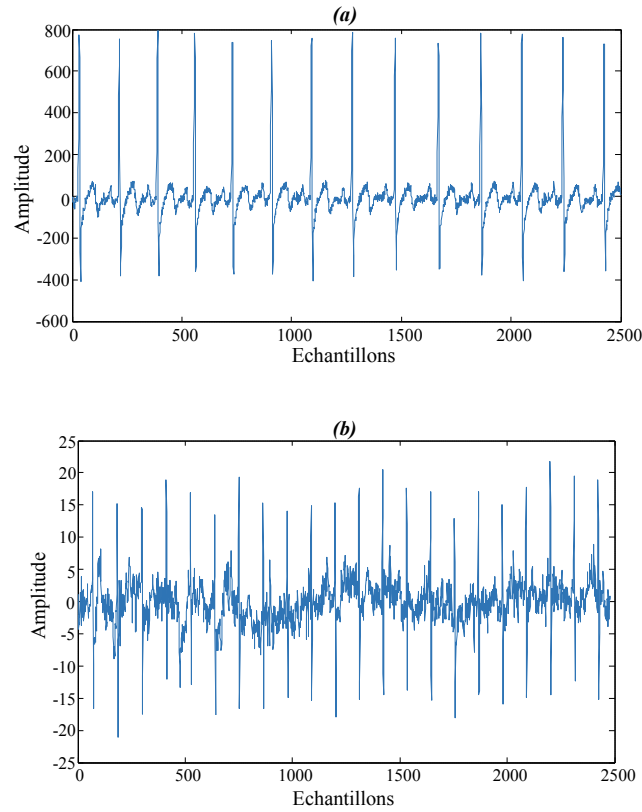


FIGURE 4.21 – Résultats de séparation (a) signal ECG de la mère, (b) signal ECG du fœtus

pics P, Q, R, S et T du signal ECG suivent la variation de la dérive de la ligne de base, ça implique qu'une approximation fiable de la dérive de la ligne de base peut être obtenue à partir de la forme dérivée en utilisant l'interpolation de l'une des formes de pics (P, Q, R, S ou T) du signal ECG (enveloppe de pic).

La Figure 4.22 représente les différentes étapes de notre méthode pour la suppression de la déformation de la ligne de base :




FIGURE 4.22 – Structure de la méthode proposée pour retirer la déformation de la ligne de base.

Cette méthode comporte cinq étapes :

- **Étape 1** : Le processus commence en déterminant tous les extrema du signal ECG d'entrée  $x(t)$ . Les extrema d'une fonction  $f = x(t)$  sont les valeurs minimales et maximales sur un graphe. La dérivée d'une fonction  $f$  notée par  $dx/dt$  représente le taux de changement. Mathématiquement, ceci représente la pente de la tangente de la courbe  $x = f(t)$  à un point  $t$  donné. On peut en déduire beaucoup de choses sur la courbe en déterminant la valeur de la dérivée à chaque instant. Noter que lorsque  $dx/dt = 0$ , la pente de la tangente de la courbe est horizontale, donc on dit que la courbe possède un point stationnaire. Trois types de points stationnaires peuvent être rencontrés : minimum locale, maximum locale et point d'inflexion horizontale. dans notre méthode on va utiliser que les maxima et les minima locaux qui peuvent être localisés comme suit :

✓Maxima locale à  $t = t_n$  si :

$$\begin{cases} \frac{dx}{dt} > 0 & \text{si } t < t_n \\ \frac{dx}{dt} = 0 & \text{si } t = t_n \cdot \\ \frac{dx}{dt} < 0 & \text{si } t > t_n \end{cases} \quad (4.103)$$

✓Minima locale à  $t = t_m$  si :

$$\begin{cases} \frac{dx}{dt} < 0 & \text{si } t < t_m \\ \frac{dx}{dt} = 0 & \text{si } t = t_m \cdot \\ \frac{dx}{dt} > 0 & \text{si } t > t_m \end{cases} \quad (4.104)$$

- **Étape 2** : Comme la variation du signal ECG suit la déviation de la ligne de base, les pics P, Q, R, S, et T suivront systématiquement la même forme que la déviation de la ligne de base. Parmi tous les pics du signal ECG (P, Q, R, S et T), considérons les pics R en raison de leurs amplitudes élevées et de leurs variations rapides, tout en étant assez résistantes au bruit. La forme obtenue de l'interpolation des pics d'ondes R (enveloppe des pics) est une estimation appropriée de la déformation de la ligne de base. Par conséquent, un algorithme de détection des pics R sera nécessaire. Un tel algorithme est constitué de deux étapes :
  1. identification des maxima et minima du signal ECG en utilisant l'approche du point stationnaire décrit dans étape 1.
  2. trouver un seuil pour isoler les pics R des autres Pics. Dans notre thèse ce seuil a été trouvé par déterminé par tâtonnement (essai et erreur). Noter que nous pouvons utiliser des méthodes de détection automatique des pics R telle que la méthode Pan et Tompkins [186].

- **Étape 3** : Après avoir déterminé les pics R, la technique d'interpolation par splines cubiques (cf., [Annexe. F](#)) sera utilisée pour interpoler les pics R afin d'obtenir l'enveloppe supérieure  $e_{up}(t)$  supposée avoir la forme de la déviation de la ligne de base.
- **Étape 4** : L'enveloppe supérieure  $e_{up}(t)$  représente une forme décalée de la déviation de la ligne de base  $\hat{b}(t)$  à estimer. En soustrayant la différence entre les moyennes de l'enveloppe supérieure  $e_{up}(t)$  et du signal ECG  $x(t)$  de l'enveloppe supérieure  $e_{up}(t)$ , une estimation de la déformation de la ligne de base peut être obtenue par :

$$\hat{b}(t) = e_{up}(t) - \left( \overline{e_{up}(t)} - \overline{x(t)} \right), \quad (4.105)$$

avec :  $\overline{e_{up}(t)}$  et  $\overline{x(t)}$  les moyennes de  $e_{up}(t)$  et  $x(t)$ , respectivement.

- **Étape 5** : La déformation de la ligne de base dans le signal ECG est modélisée comme un bruit additif à basse fréquence [[187](#), [188](#)] ; par conséquent, une estimation du signal ECG propre  $\hat{x}(t)$  peut être déduite de la soustraction directe de la déformation de la ligne de base  $\hat{b}(t)$  du signal ECG  $x(t)$  comme suit :

$$\hat{x}(t) = x(t) - \hat{b}(t). \quad (4.106)$$

#### 4.8.1 Résultats de simulation

Dans cette section, des tests de simulation et expérimentaux sur des signaux ECG synthétique et réels sont effectués pour évaluer la performance de la méthode proposée. Pour le signal ECG synthétique nous considérons le signal ECG généré par le Modèle [4.26](#), dont les paramètres sont données dans le Tableau [4.7](#). La déviation de la ligne de base a été introduite en utilisant l'Équation [4.27](#) avec une amplitude  $A = 0.15 \text{ mV}$  et une fréquence respiratoire  $f_r = 0.25 \text{ Hz}$ . La Figure [4.23](#) représente les résultats de simulation de notre méthode pour la suppression de cette déviation de la ligne de base. La Figure [4.24](#) représente les résultats de suppression de cette déviation d'un signal ECG réel (109.dat) pris de la base de données MIT-BIH PhysioBank [[129](#)].

Le signal ECG réel (105.dat) de la base de données MIT-BIH PhysioBank [[129](#)] a été utilisé pour évaluer les performances de la technique étudiée dans le cas d'une distorsion sévère de la ligne de base. Une déviation de la ligne de base artificielle très sévère avec une amplitude de 100 (valeur numérique) a été ajoutée. La Figure [4.25](#) nous montre l'efficacité de la méthode et son succès à éliminer la distorsion de la ligne de base à haute amplitude du signal ECG réel.

Dans La Figure [4.26](#) nous fournissons plusieurs résultats expérimentaux de notre méthode appliquée sur plusieurs signaux ECG réels présent de la base de données MIT-BIH

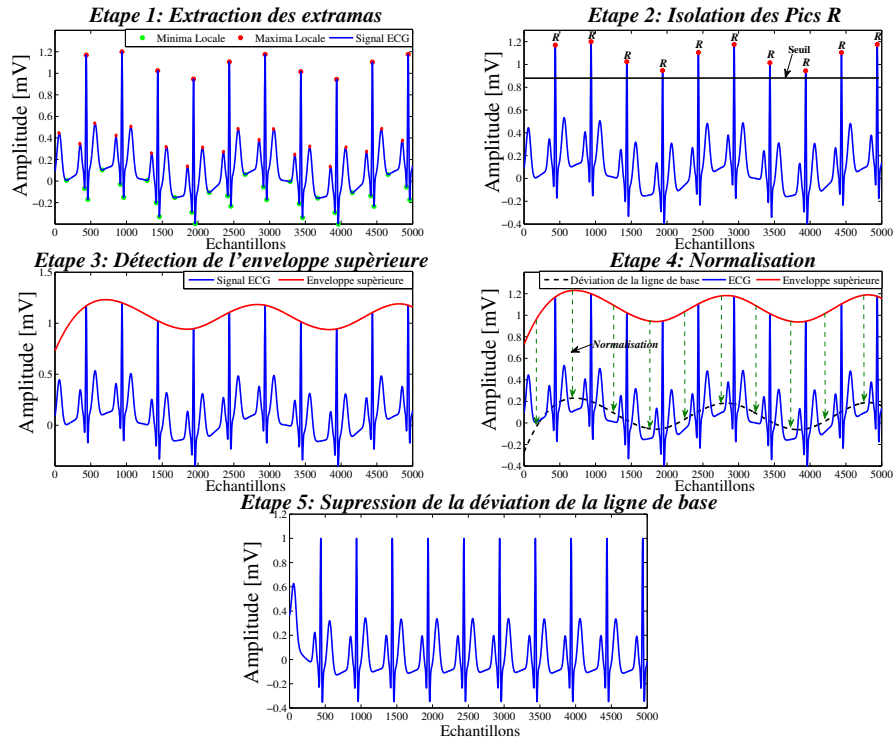


FIGURE 4.23 – Suppression de la déviation de la ligne de base d'un signal ECG synthétique.

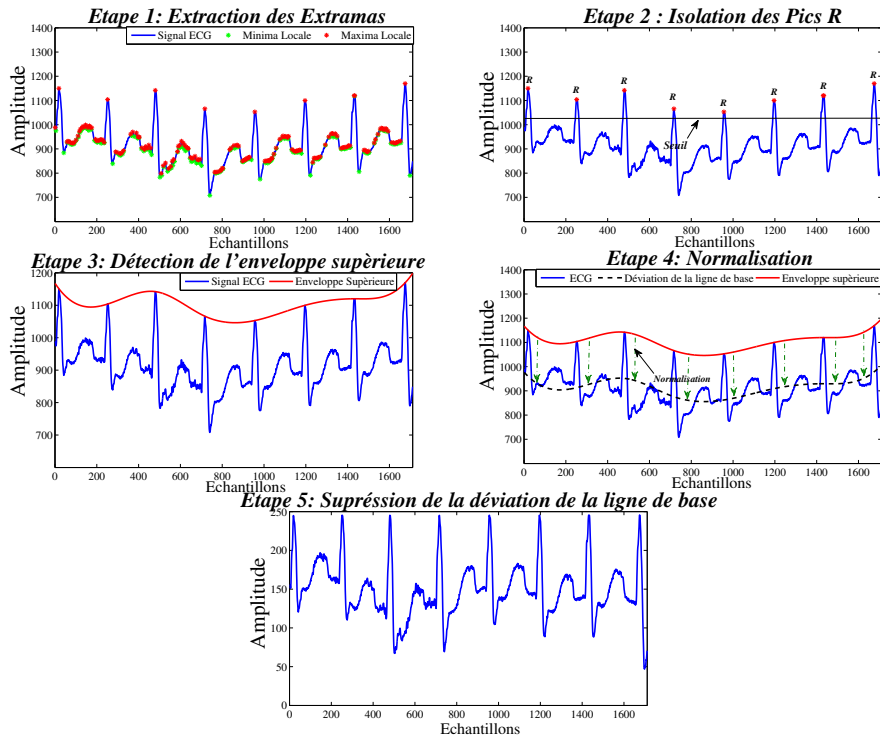


FIGURE 4.24 – Suppression de la déviation de la ligne de base d'un signal ECG réel.




FIGURE 4.25 – (a) Signal ECG réel 105.dat sans ligne de base artificielle (b) Signal ECG réel 105.dat avec ligne de base artificielle d’amplitude 100 (c) Signal ECG réel 105.dat corrigé.

PhysioBank [129].

Il faut noter que la déviation de la ligne de base et le signal ECG ont des bandes fréquentielles qui se chevauchent dans la région basse fréquence de leurs spectres [189]. Notons que, la distorsion dans cette bande affecte négativement la forme du segment ST, qui est la partie reliant le complexe QRS avec l’onde T. Le segment ST a une forte pertinence clinique, puisque les déviations de son niveau physiologique reflètent un syndrome coronarien aigu, qui est l’une des formes les plus sévères de maladies cardiaques et la principale cause de mortalité dans le monde [190]. Les Figures 4.27 et 4.28 représentent le contenu spectrale du signal ECG avec la déviation de la ligne de base (Figure 4.23 (étape 1)) et le signal ECG corrigé (Figure 4.23 (étape 5)), où on peut voir que notre méthode n’a pas déformé le spectre du signal ECG original; par conséquent, la méthode préserve les informations cliniques très importantes.

#### 4.8.2 Étude comparative

Dans cette section, nous fournissons les résultats d’une étude comparative de notre méthode avec d’autres méthodes de références telles que la méthode baptisé HVD [56] et une autre méthode baptisé EMD-MM [154] décrites précédemment (cf., sous-section 4.2.2). Afin de produire une comparaison valide, notre méthode a été simulée avec les mêmes paramètres, signaux de test (présent de la base de données MIT-BIH PhysioBank [129]), et les mêmes conditions en utilisant les mêmes critères d’évaluation ( $SNR_{output}$  (Équa-

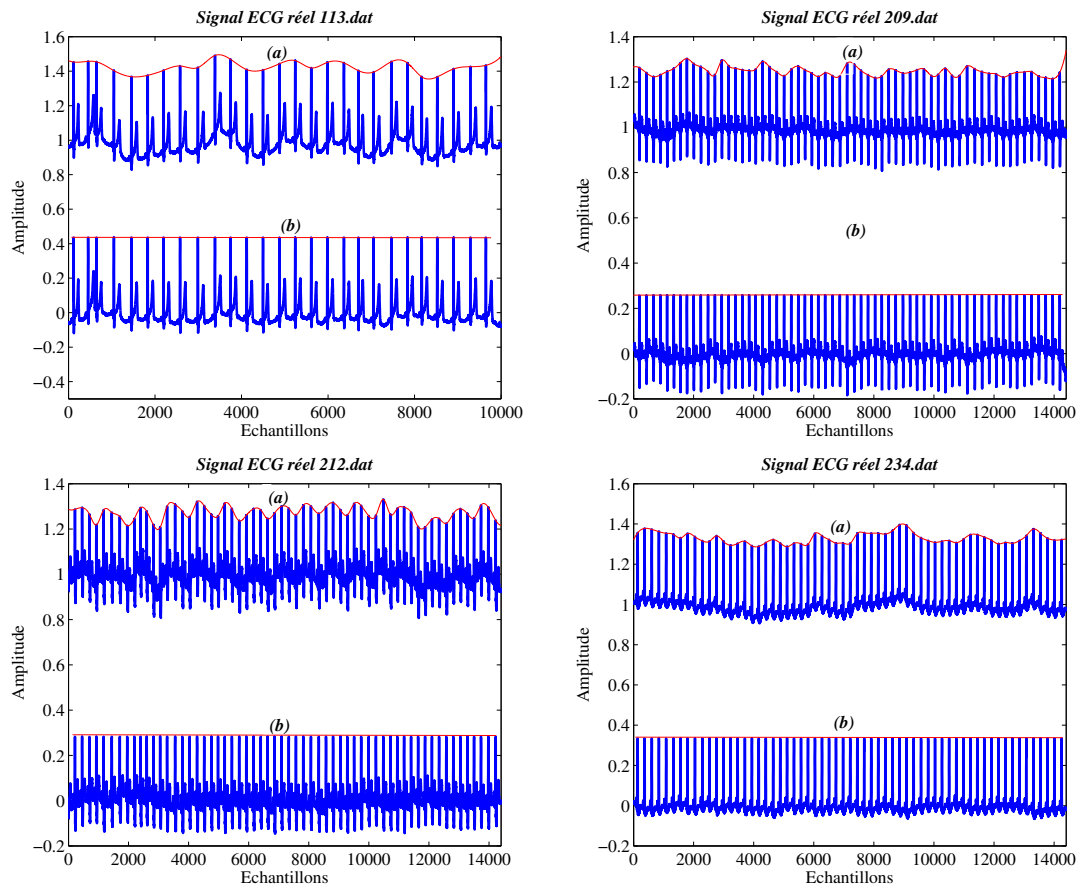


FIGURE 4.26 – (a) Signal ECG réel avec la déviation de la ligne de base (b) Signal ECG réel corrigé.




FIGURE 4.27 – Contenu spectrale du signal ECG original avec une déviation de la ligne de base de fréquence  $f_r = 0.25 Hz$ .




FIGURE 4.28 – Contenu spectrale du signal ECG corrigé (sans déviation de la ligne de base).

tion 4.8)). Les résultats de la comparaison sont présentés dans le Tableau 4.8, dont on peut remarquer que notre méthode possède le meilleur  $SNR_{output}$  par rapport aux autres méthodes de références, ce qui confirme l'efficacité de notre méthode.

TABLE 4.8 – Résultats de comparaison de la méthode proposée avec d'autres méthode de références.

Signal ECG réel	Amplitude de la ligne de base	$SNR_{output}$ [dB]		
		Méthode proposée	HVD	EMD-MM
<i>100.dat</i>	100	41.82	21.03	20.73
<i>105.dat</i>	100	53.04	30.22	26.27
<i>119.dat</i>	100	55.01	34.20	30.08

## 4.9 Conclusion

Dans ce chapitre on a abordé un sujet très intéressant, qui est le pré-traitement du signal électrocardiogramme, qui joue un rôle important dans l'exactitude des résultats du processus de diagnostic. Plusieurs points ont été discutés à savoir le filtrage du signal électrocardiogrammes des différents types de bruit et artefacts haute fréquence, séparation des signaux électrocardiogrammes maternel et foetal et suppression de la déformation de la ligne de base du signal électrocardiogramme. Pour le filtrage du signal électrocardiogramme du bruit haute fréquence, plusieurs techniques ont été développées pour enrichir ce sujet. La première technique développée est un filtre flou adaptatif qui se base sur les concepts de la logique floue. Un algorithme d'optimisation (BBO) a été utilisé pour ajus-

ter les paramètres des fonctions d'appartenance. Une étude comparative a été également menée pour confirmer l'efficacité de l'approche proposé.

La deuxième technique développée a été basée sur le filtre de Kalman étendu. La nouveauté dans notre approche est que les paramètres du filtre de Kalman étendu à savoir la variance du bruit d'état et de mesure ont été ajustés en utilisant un algorithme métaheuristique (BBO). Les résultats de simulation ont été présentés, une très bonne performance surtout avec un nombre élevé d'itérations et de la taille de la population.

La troisième technique a été le filtrage de l'ECG en utilisant la décomposition en valeurs singulières. La méthode a été exprimée en détail, où on a utilisé cette méthode pour le filtrage du signal électrocardiogramme et la séparation des signaux électrocardiogrammes mère-foetus. De très bon résultats ont été obtenus, où nous avons conclu que l'efficacité de cette méthode reste subordonnée au bon choix de l'opérateur de projection.

Parmi les bruits basse fréquence difficile à supprimer sans causé de déformation dans les caractéristiques morphologiques du signal ECG, nous mentionnons la déformation de la ligne de base. Une méthode efficace basée sur la détection des pics R du signal électrocardiogramme et l'interpolation par spline cubique, a été développée pour supprimer ce genre du bruit. Les résultats de simulation ont montré que cette méthode supprime efficacement ce bruit en préservant les caractéristiques morphologiques du signal électrocardiogramme.



## **EXTRACTION DES CARACTÉRISTIQUES ET CLASSIFICATION DES BATTEMENTS CARDIAQUES**

---

*Le diagnostic des maladies du coeur est la dernière étape de toute une chaîne d'acquisition qui commence par les capteurs, amplification, conversion analogique numérique, filtrage et en fin le diagnostic par un système expert contenant une base de données. Cette opération se compose de deux étapes clés qui sont l'extraction des caractéristiques et la classification. Dans ce chapitre plusieurs outils seront utilisés pour réaliser ces deux étapes clés à savoir : la logique floue type-2, la transformée en ondelettes discrète et la machine d'apprentissage extrême (ELM : Extreme learning machine).*

### **Sommaire**

---

<b>5.1 Introduction</b> . . . . .	<b>148</b>
<b>5.2 État de l'art sur l'extraction des caractéristiques et la classification des battements cardiaques</b> . . . . .	<b>148</b>
<b>5.3 Contribution</b> . . . . .	<b>151</b>
<b>5.4 Préparation des bases de données</b> . . . . .	<b>151</b>
<b>5.5 Extraction des caractéristiques</b> . . . . .	<b>152</b>
5.5.1 Extraction des caractéristiques par la logique floue type-2 . . . . .	153
5.5.2 Extraction des caractéristiques par la transformée en ondelettes discrète DWT . . . . .	154
<b>5.6 Sélection des caractéristiques par la méthode mRMR</b> . . . . .	<b>157</b>
<b>5.7 Normalisation des paramètres</b> . . . . .	<b>157</b>
<b>5.8 Classification</b> . . . . .	<b>158</b>
<b>5.9 Résultat et discussion</b> . . . . .	<b>159</b>
<b>5.10 Conclusion</b> . . . . .	<b>160</b>

---

## 5.1 Introduction

**T**out ce qui affecte le coeur et l'empêcher de fonctionner normalement fait partie des maladies du coeur. On groupe souvent ces maladies selon qu'elles sont congénitales (c-à-d présentes à la naissance) ou acquises (c-à-d attribuable à une autre condition). Parmi les maladies du coeur, on compte :

- ✓ la cardiomyopathie : une maladie du muscle cardiaque,
- ✓ l'insuffisance cardiaque congestive : fonctionnement insuffisant de la pompe cardiaque qui entraîne l'accumulation de liquide dans les poumons et ailleurs dans le corps ;
- ✓ les troubles des valves cardiaques : d'origine congénitale (p.ex. maladie d'Ebstein) ou acquis (Ex : péricardite infectieuse) ;
- ✓ la maladie du péricarde : une infection du péricarde, la membrane qui enveloppe le coeur tel un sac.

L'électrocardiographie est un procédé rapide, simple et indolore, qui consiste à amplifier et enregistrer soit sur un papier soit sous forme de données les impulsions électriques traversant le coeur (électrocardiogramme). Cet enregistrement, l'électrocardiogramme (ECG), donne des informations concernant la partie du coeur qui initie chaque battement cardiaque (le stimulateur cardiaque, appelé noeud sino-auriculaire ou sinusal), les voies de conduction nerveuse, ainsi que la vitesse et rythme cardiaque. Ces informations peuvent être extraites soit par un expert en utilisant l'enregistrement sur un papier, soit automatiquement en utilisant un système expert contenant une base de données. Dans notre thèse on a adopté la deuxième méthode. Généralement, ces systèmes se composent de deux parties, la première partie consiste à l'extraction des caractéristiques des différents battements constituant le signal électrocardiogramme, la deuxième étape sera le classement de ces battements selon le type de pathologie atteinte. Dans ce chapitre une nouvelle classe des caractéristiques appelée caractéristique floue sera exprimée en détails et fusionnée avec d'autres caractéristiques extraites en utilisant la transformée en ondelettes discrète . Une méthode de classification baptisée (ELM : *Extreme Learning Machine*) sera utilisée pour l'étape de classement.

## 5.2 État de l'art sur l'extraction des caractéristiques et la classification des battements cardiaques

Dans cette section on va présenter chronologiquement les travaux développés dans le contexte d'extraction des caractéristiques et classification des battements cardiaques.

Maglaveras *et al.* [191] ont utilisé l'analyse en composantes principales (PCA : *Principal Component Analysis*) et les réseaux de neurones pour la reconnaissance de formes et la classification du signal électrocardiogramme. Dokur *et al.* [192] ont proposé une structure hybride de réseau de neurones pour la classification des battements cardiaques, où les caractéristiques des battements ont été extraites en utilisant deux méthodes : la transformée de Fourier et d'ondelettes. Engin [193] a présenté une méthode basée sur la logique floue et le réseau de neurones hybride pour la classification des battements cardiaques, où les variances de cumulants d'ordre supérieur et de la transformée en ondelettes ont été utilisées dans la phase d'extraction des caractéristiques. ozbay *et al.* [194] ont discuté une autre structure basée sur la logique floue et le réseau de neurones pour le diagnostic précoce.

Meau *et al.* [195] ont développé un système hybride se basant sur le filtre de Kalman étendu, le perceptron multicouche et la logique floue pour la reconnaissance des signaux électrocardiogrammes. Ce système peut distinguer différents types de signaux ECG anormaux. Un schéma commutable a été proposé pour discriminer différents types de battements du signal électrocardiogramme basé sur l'analyse en composantes indépendantes (ICA : *Independent Component Analysis*) [196]. Ubeyli *et al.* [197] ont présenté une approche basée sur l'implémentation des machines à support de vecteurs multi-classe avec une méthode des codes correcteurs d'erreurs baptisé (ECOC : *Error Correcting Output Codes*) pour la classification des battements cardiaques, où les caractéristiques des battements cardiaques ont été extraites en utilisant la transformée en ondelettes. Yu *et al.* [198] ont utilisé le réseau de neurones et l'analyse en composantes indépendantes (ICA) pour classifier les battements cardiaques, où le réseau de neurones a été utilisé comme classificateur et l'ICA pour extraire les caractéristiques des battements cardiaques. Yu *et al.* [199] ont proposé une stratégie d'arrangement des composantes indépendantes pour coopérer avec la méthode d'analyse en composantes indépendantes (ICA) pour la classification des battements du signal électrocardiogramme.

Une méthode de classification des signaux électrocardiogrammes basée sur un système d'inférence neuro-flou adaptatif comme classificateur et l'exposant de Liapounov pour l'étape d'extraction des caractéristiques a été discutée dans [200]. Un autre classificateur automatique pour la détection d'anomalies cardiaques basé sur le signal électrocardiogramme en utilisant un modèle de mélange Gaussien (GMM : *Gaussian Mixture Model*) a été présenté dans [201]. Ceylan *et al.* [202] ont présenté un classificateur des arythmies d'électrocardiogramme basé sur un algorithme de clustering neuro-flou, où une méthode de clustering floue type-2 a été utilisée pour améliorer la structure du réseau de neurones. Mishra *et al.* [203] ont discuté un classificateur basé sur la dimension fractale locale pour la classification des arythmies d'électrocardiogramme.

Un classificateur basé sur le réseau de neurones avec une fonction d'activation adaptative a été implémenté pour la classification des arythmies électrocardiogrammes [204]. Korurek *et al.* [205] ont présenté une méthode pour la classification des battements du signal électrocardiogramme basée sur l'optimisation par essais particuliers (PSO : *Particle Swarm Optimization*) et le réseau de neurones. Gayathri *et al.* [206] ont développé un système pour la classification des signaux électrocardiogrammes en utilisant la machine à pertinence de vecteur (RVM : *Relevance Vector Machine*). Wang *et al.* [207] ont présenté un classificateur des arythmies du signal électrocardiogramme, où l'analyse en composantes principales (PCA : *Principal Component Analysis*) et l'analyse discriminante linéaire (LDA : *Linear Discriminant analysis*) ont été utilisées pour l'extraction et la réduction des caractéristiques, et le réseau de neurones a été utilisé pour la classification de ces caractéristiques. Zidelmal *et al.* [208] ont utilisé un classificateur à base de machine à support de vecteurs, où des informations fréquentielles, l'intervalle RR et la morphologie du complexe QRS ont été utilisés comme caractéristiques. Martis *et al.* [209] ont développé une approche pour l'extraction des caractéristiques et la classification des battements cardiaques, où plusieurs méthodes ont été utilisées pour l'extraction et la réduction des caractéristiques dans le domaine d'ondelettes à savoir : l'analyse en composantes principales (PCA : *Principal Component Analysis*), l'analyse discriminante linéaire (LDA : *Linear Discriminant analysis*), l'analyse en composantes indépendantes (ICA : *Independent Component Analysis*).

Une méthode de classification des arythmies cardiaques en utilisant plusieurs classificateurs à savoir : la machine à support de vecteurs à noyau (KSVM : *Kernel Support Vector Machine*) et le k-plus proche voisin (KNN : *K-Nearest Neighbor*), où les caractéristiques ont été extraites en utilisant la méthode de Burg, a été discutée dans [210]. La machine à support de vecteurs, l'analyse en composantes principales et la transformée en ondelettes discrète ont été combinées pour construire un classificateur des battements cardiaques [211]. Faziludeen *et al.* [212] ont adopté le classificateur baptisé (KNN : *K-Nearest Neighbor*) pour la classification des arythmies cardiaques, où les intervalles RR du signal électrocardiogramme ont été pris comme caractéristiques de pathologie. L'optimisation par essais particuliers et le réseau de neurones ont été combinées pour traiter le problème de la classification des signaux électrocardiogrammes, et ont été discutées par Shadmand *et al.* [213]. Une approche pour la classification des arythmies cardiaques basée sur la décomposition en modale empirique (EEMD : *Ensemble Empirical Mode Decomposition*) et machine à support de vecteurs (SVM : *Support vector machine*) a été discutée dans [10], où l'EEMD a été utilisée pour l'extraction des caractéristiques et le SVM a été utilisée pour la classification.

## 5.3 Contribution

Dans ce chapitre, nous allons présenter notre méthode proposée pour la classification des arythmies cardiaques. Dans cette étude, cinq types de battements d'arythmie recommandés par AAMI (*Association for the Advancement of Medical Instrumentation*) seront considérés : battement normal (N), battement anormal d'origine supra-ventriculaire (S), battement anormal d'origine ventriculaire (V), battement résultant de la fusion d'un battement V et d'un battement N (F), et battement inconnu (Q) (cf., [chapitre 1](#)). Pour la première étape qu'est l'extraction des caractéristiques, deux méthodes ont été utilisées afin de fusionner les caractéristiques extraites. La première méthode est la technique de modélisation et d'identification floue type-2 du signal électrocardiogramme discutée dans le [chapitre 3](#), où les paramètres de ce modèle à savoir : les valeurs moyennes (centres) des fonctions d'appartenance floues type-2 Gaussiennes de la prémisse, et les intervalles de conséquences, ont été prises comme étant les caractéristiques des différents battement du signal électrocardiogramme. Dans la deuxième méthode on a utilisé la transformée en ondelettes, où après la décomposition du signal en plusieurs niveaux, des mesures (caractéristiques) ont été calculées pour chaque niveau à savoir : la variance, l'entropie, l'énergie. Comme méthode d'apprentissage automatique nous avons choisi d'utiliser la technique ELM (*Extreme Learning Machine*) comme classificateur, cette technique fait référence à un type de réseau de neurones. La Figure 5.1 représente l'organigramme de la procédure adoptée.

## 5.4 Préparation des bases de données

La base de données MIT-BIH PhysioBank [[129](#)] nous a permis de créer deux sous bases de données : une pour l'apprentissage et l'autre pour les tests qui serviront l'entraînement et l'évaluation des performances du classificateur. Les battements sélectionnés sont regroupés selon les cinq classes recommandées par AAMI (cf., [chapitre 1](#)) données dans le Tableau 5.1 .

TABLE 5.1 – Enregistrements ECG et nombres de battements utilisés dans cette étude.

Classe	ECG record (Sous classe)	Base d'apprentissage	Base de test
N	100, 103, 105, 113, 115, 119, 121	07	03
S	100, 103, 113, 121, 202, 205, 209, 210	07	03
V	100, 105, 119, 121, 123, 202	07	03
F	202, 205, 210	07	03
Q	105, 203, 208	07	03
<b>Total</b>		35	15

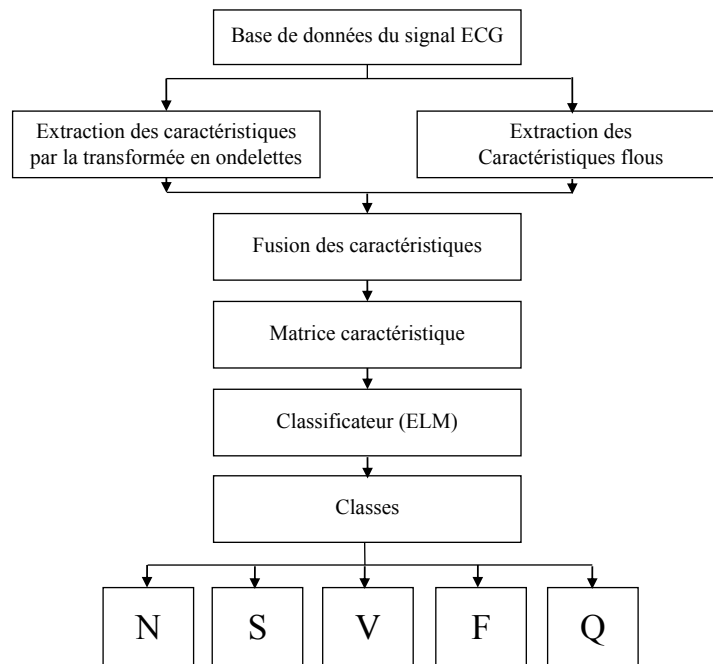


FIGURE 5.1 – Organigramme de la procédure adoptée.

L'application **LighthWAVE** (cf., [Figure 5.2](#)) de la base de données MIT-BIH physiobank nous a permis d'extraire les différentes sous classes de notre base de données. Cette application permet de visualiser les différents enregistrements du signal électrocardiogramme (100.dat, 202.dat....etc) (cf., [Figure 5.2](#)) et permet aussi de donner les différentes annotations que contient un signal ainsi que leurs instants d'apparition ([Figure 5.3](#)).

Pour l'extraction d'une sous classe quelconque on prend l'instant d'apparition de l'annotation correspondante (N, V, S, Q...etc) et l'instant de l'annotation qui la précède et on extrait le battement correspondant. La [Figure 5.4](#) représente un exemple d'extraction de la sous classe 1 (annotation A) qui appartient à la classe S.

## 5.5 Extraction des caractéristiques

L'extraction et l'identification des caractéristiques du signal électrocardiogramme sont la base de l'analyse et du diagnostic de l'ECG. Après la création des bases de données (cf., [Tableau 5.1](#)) l'étape suivante sera l'extraction des caractéristiques des sous classes (différents battements) constituant les différentes classes. Ci-après les deux méthodes qui vont être utilisées pour l'extraction des caractéristiques des différents battements cardiaques.



FIGURE 5.2 – LightWaVE.



FIGURE 5.3 – Table récapitulatif du signal 100. dat en utilisant l'application LightWaVE.

### 5.5.1 Extraction des caractéristiques par la logique floue type-2

La méthode d'identification et de modélisation du signal électrocardiogramme (cf., chapitre 3) a été adoptée pour l'extraction des caractéristiques des différentes sous classes du tableau 5.1, et qui consiste à modéliser et identifier les différentes sous classes l'un après l'autre, afin de constituer les vecteurs caractéristiques de chaque sous classes des différentes classes. Ces caractéristiques correspondent aux vecteurs des paramètres des modèles flous des différentes sous classes, qui sont les valeurs moyennes (centres) des




FIGURE 5.4 – Exemple d'extraction d'une sous classe.

fonctions d'appartenance floues type-2 Gaussiennes de la prémisse, et les intervalles de conséquence qui caractérisent les concepts flous dans les règles  $IF - THEN$ . Finalement on compose la sous matrice caractéristique constituée de différents vecteurs caractéristiques des différentes sous classes constituant les classes (cf., [Tableau 5.1](#)). La Figure 5.5 représente les différentes phases de l'étape d'extraction des caractéristiques, où les  $c_i$  sont les paramètres des modèles flou type-2 des différentes sous classes,  $N$ ,  $S$ ,  $V$ ,  $F$ , et  $Q$  sont les différentes classes,  $L$  est le nombre des sous classes dans chaque classe,  $n$  est le nombre des intervalles de sortie et les régresseurs pour chaque règle et  $M$  est le nombre de règles qui constituent le système de modélisation et identification flou type-2 (cf., [chapitre 3](#)).

### 5.5.2 Extraction des caractéristiques par la transformée en ondelettes discrète DWT

Dans la littérature des ondelettes, on parle souvent d'approximation et de détails [[214](#), [215](#)]. L'approximation représente les composantes basses fréquences du signal tandis que les détails représentent les composantes de haute fréquence. Selon cette transformée, un signal  $x(t)$  peut être décomposé en plusieurs composantes de faibles et de hautes résolutions [[216](#), [217](#), [218](#)] (composantes d'approximations et composantes de détails). Les Figures 5.6 et 5.7 représentent la décomposition en ondelettes à trois niveaux où  $f_e$

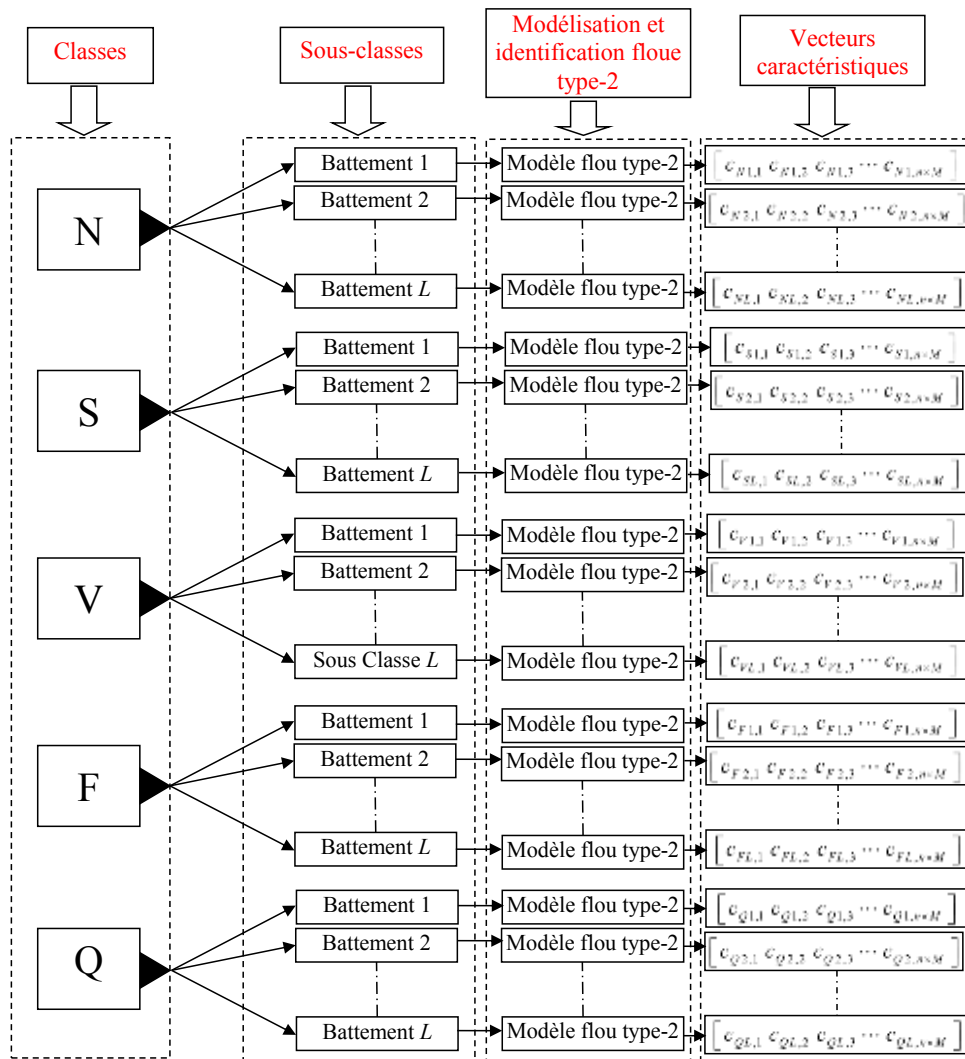


FIGURE 5.5 – Organigramme de l'étape d'extraction des caractéristiques en utilisant la logique floue type-2.

représente la fréquence d'échantillonnage,  $cA$  les coefficients d'approximation et  $cD$  les coefficients de détails.

Le nombre de décompositions est appelé nombre de niveaux, son choix dépend de la nature du signal considéré et du problème à résoudre.

Après la décomposition du signal électrocardiogramme par la transformée en ondelettes en plusieurs niveaux  $L$ , une fenêtre glissante de taille  $N$  va être utilisée pour chaque niveau et pour chaque composante (composantes d'approximations et composantes de détails), où des mesures statistiques vont être calculées pour chaque fenêtre à savoir : l'énergie, la variance, Entropie de Shannon. Ces grandeurs vont être considérées comme

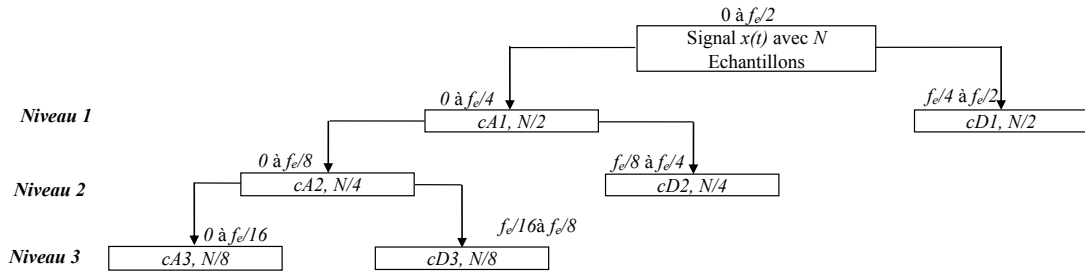


FIGURE 5.6 – Décomposition : Transformée en ondelette discrète.

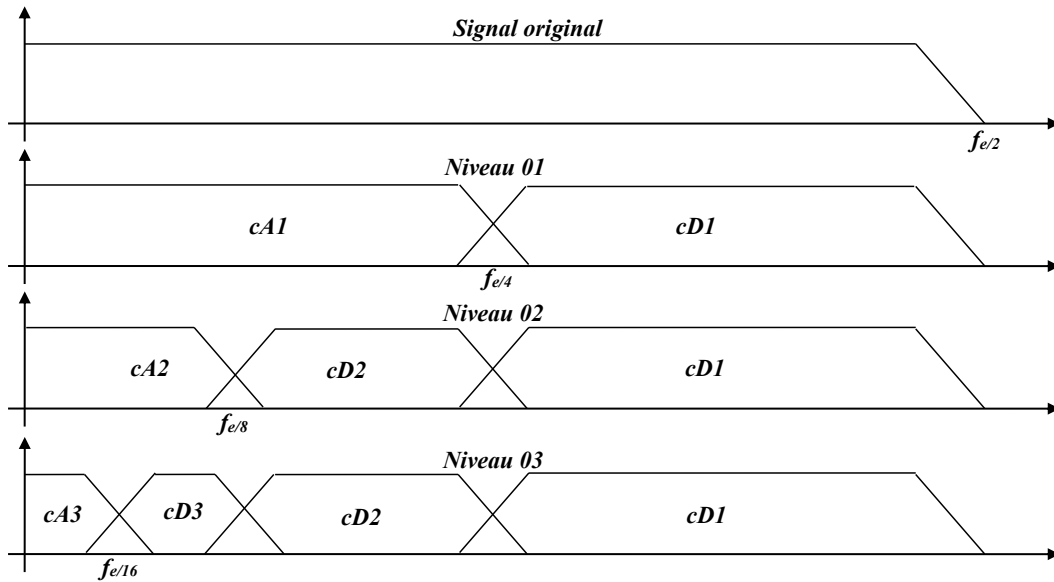


FIGURE 5.7 – Vue dans le domaine fréquentiel de la décomposition en ondelette discrète

des caractéristiques du signal électrocardiogramme.

Finalement les vecteurs caractéristiques extraits par la logique floue type-2 et la transformée en ondelettes seront réarrangés sous forme de deux matrices **M** et **K**, où la matrice caractéristique finale peut s'écrire comme suit :

$$\mathbf{X} = [\mathbf{M} \ \mathbf{Y}]. \tag{5.1}$$

## 5.6 Sélection des caractéristiques par la méthode mRMR

Dans les problèmes de classification, et sur tous si la taille de la matrice caractéristique (Équation 5.1) est énorme, nous cherchons toujours à trouver le meilleur sous ensemble de caractéristiques pour choisir le modèle approprié et minimiser les erreurs de classification et aussi le temps de calcul. Plusieurs techniques ont été développées pour résoudre ce problème de sélection à savoir : l'analyse en composantes principales (PCA), l'analyse en composantes indépendantes (ICA), la décomposition en valeurs singulières (SVD), ReliefF, Fisher et autres. Dans notre thèse une méthode baptisée mRMR (*minimum-redundancy maximum relevancy*) est adoptée. L'mRMR est une méthode de filtrage pour la sélection des caractéristiques proposée par Peng *et al.* [219]. Cette méthode est basée sur des mesures statistiques classiques comme l'information mutuelle, la corrélation...etc. L'idée de base est de profiter de ces mesures pour essayer de minimiser la redondance (mR) entre les variables et de maximiser la pertinence (MR). Peng *et al.* [219] ont utilisé l'information mutuelle pour calculer les deux facteurs mR et MR. Le calcul de la redondance et de la pertinence d'une variable est donnée par l'équation suivante :

$$Redondance(i) = \frac{1}{|F|^2} \sum_{i,j \in F} I(i,j) \quad (5.2)$$

$$Pertinence(i) = \frac{1}{|F|^2} \sum_{i,j \in F} I(i,Y) \quad (5.3)$$

avec :

$|F|$  : représente la taille de l'ensemble de variables.

$I(i,j)$  : est l'information mutuelle entre la  $i^{ieme}$  et la  $j^{ieme}$  variable.

$I(i,Y)$  : est l'information mutuelle entre la  $i^{ieme}$  variable et l'ensemble des étiquettes de la classe Y.

Le score d'une variable est la combinaison de ces deux facteurs tel que :

$$Score(i) = Pertinence(i) - Redondance(i) \quad (5.4)$$

## 5.7 Normalisation des paramètres

Puisque les quantités des paramètres peuvent être différentes, un procédé de normalisation est nécessaire pour normaliser tous les paramètres au même niveau. Nous avons appliqué l'Équation 5.5, cette équation a été appliquée pour représenter chaque paramètre de matrice caractéristique dans l'intervalle [0,1].

$$matrice\ caractéristique\ normalisée = \frac{X - \min(X)}{\max(X) - \min(X)}. \quad (5.5)$$

où  $X$  est la matrice caractéristique donnée par l'Équation 5.1.

## 5.8 Classification

Le but est de classifier automatiquement les battements cardiaques selon le type d'arythmie. Le choix du classificateur est très important, parce qu'il constitue l'élément de décision dans le système de reconnaissance de formes. L'efficacité du classificateur reste aussi subordonnée à plusieurs autres facteurs à savoir : le choix et la taille de la base d'apprentissage et la méthode d'extraction des caractéristiques. La machine à apprentissage extrême (ELM : *Extreme Learning Machine*) est un classificateur multi-classe introduit récemment pour la reconnaissance des formes. Le système d'action de reconnaissance incorpore ce classificateur, est une version de réseaux de neurones [220]. Comparativement à d'autres classificateurs, l'ELM fournit des performances significatives, telles que le temps d'apprentissage rapide et la précision de reconnaissance. L'ELM est une technique d'apprentissage automatique qui fait référence à un type de réseau de neurones, sa spécificité est de n'avoir qu'une seule couche des noeuds cachés. Les noeuds cachés dans l'ELM sont initialisés de manière aléatoire et ne doivent pas être réglés de manière itérative (les poids des entrées de connexion de noeuds cachés sont répartis au hasard et jamais misent à jour). En fait, ces noeuds restent fixes après l'initialisation. De cette manière, seuls les paramètres des poids d'entrée doivent être appris.

Lorsque l'échantillon d'apprentissage  $A$  est donnée par  $(x_j, y_j)$ ,  $j = [1, \dots, q]$  dans lequel  $x_j \in R^N$  et  $y_j \in R^M$ , la fonction de sortie du modèle ELM avec  $L$  neurones cachés peut être exprimée comme suit :

$$f_l(x) = \sum_{i=1}^L g_i \omega_i(x) = \Omega(\mathbf{x})G, \quad (5.6)$$

où  $G = [g_1, \dots, g_L]$  est le vecteur des poids de sortie reliant les noeuds cachés  $L$  aux noeuds de sortie  $m > 1$ , et  $\Omega(\mathbf{x}) = [\omega_1(x), \dots, \omega_L(c)]$  est une fonction d'activation non linéaire [220]. Le système  $\Omega(\mathbf{x})$  peut être écrit sous une forme explicite comme suit :

$$\Omega_i(x) = \beta(\tau_i \cdot x + \epsilon_i), \quad \tau_i \in R^d, \epsilon_i \in R, \quad (5.7)$$

avec  $B$  une fonction d'activation avec des paramètres de couche caché  $(\tau, \epsilon)$ . La deuxième étape du processus d'apprentissage dans l'ELM, est la minimisation des erreurs entre les données d'entraînement et les poids de sortie obtenus en utilisant la norme des moindres carrées décrite ci-dessous :

$$\min \|\Omega G - H\|^2, \quad G \in R^{N \times M}, \quad (5.8)$$

où  $\Omega$  définit le système de la couche de neurones cachés donnée par :

$$\Omega = \begin{bmatrix} \beta(\tau_1 \cdot x_1 + \epsilon_1) & \dots & \beta(\tau_L \cdot x_1 + \epsilon_L) \\ \vdots & \dots & \vdots \\ \beta(\tau_1 \cdot x_N + \epsilon_1) & \dots & \beta(\tau_L \cdot x_N + \epsilon_L) \end{bmatrix}, \quad (5.9)$$

et  $H$  est la matrice des données d'entraînement décrite comme suit :

$$H = \begin{bmatrix} h_1^T \\ \vdots \\ h_N^T \end{bmatrix}. \quad (5.10)$$

La solution optimale pour minimiser l'erreur d'apprentissage dans 5.8 suppose pratiquement que le nombre de neurones cachés  $L$  est inférieur à celui de l'ensemble d'apprentissage (c'est-à-dire  $L < Q$ ). Par conséquent, en utilisant l'inverse généralisé de la matrice de Moore-Penrose [220], la solution optimale de l'Équation 5.8 sera décrit comme suit :

$$G^* = \Omega^* H, \quad (5.11)$$

où  $\Omega^*$  est l'inverse de  $\Omega$ .

## 5.9 Résultat et discussion

Dans cette section nous fournissons les résultats de la méthode proposée pour l'extraction des caractéristique et la classification des signaux électrocardiogrammes. Les ensembles de données des différents arythmies cardiaques sont des données réelles et elles sont présentées dans le Tableau 5.1. Pour la première méthode d'extraction des caractéristiques (modélisation et identification floue type-2), la méthode a été simulée avec un nombre de règles  $M_1 = M_2 = 5$ . L'identificateur est structuré selon un ensemble de 10 règles, ce qui nous donne  $10 \times 3 = 30$  paramètres ajustables (30 caractéristiques pour chaque sous classe (Tableau 5.1)), ce qui nous donne une première sous-matrice caractéristique de taille  $40 \times 30$ . L'algorithme d'ajustement de ces paramètres (l'algorithme BBO) a été paramétré comme suit : le taux de mutation  $m = 0.01$ , le taux d'immigration  $\lambda_k$  et le taux d'émigration  $\mu_k$  sont similaires aux courbes de migration linéaire (cf., Figure 2.8). Pour la transformée en ondelettes discrète, chaque sous classe a été décomposé en ondelettes à un seul niveau et une fenêtre glissante de taille  $f_e/16$  a été utilisée. Par conséquent, en utilisant cette fenêtre avec un seul niveau de décomposition (Figure 5.7) chaque composante (composante d'approximation et composante de détail) sera divisée en quatre fenêtres et on calcule quatre mesures (énergie , variance, entropie de shannon

) pour chaque fenêtre, ce qui nous donne une deuxième sous-matrice caractéristique de taille  $40 \times 36$ . L'entrée du classificateur est l'ensemble des caractéristiques extraits des signaux ECG représentant les différents types d'arythmies cardiaques en utilisant les deux méthodes discutées précédemment. Par conséquent, une matrice caractéristique de taille  $40 \times 64$  a été utilisée comme entrée de classificateur. Les battements sélectionnés à partir de l'ensemble des caractéristiques ont été assignés au hasard dans le sous-ensemble d'apprentissage et de test. La méthode proposée a classé efficacement les différents battements et fournit de résultat substantiel en termes de précision (99%).

## 5.10 Conclusion

Dans ce chapitre nous avons présenté une méthode pour classifier le signal électrocardiogramme en cinq classes selon la recommandation d'AAMI. Cette méthode se compose de deux blocs principaux à savoir : le bloc d'extraction des caractéristiques et le bloc de classification. Pour le premier bloc deux techniques ont été utilisées pour l'extraction de différents caractéristiques à fin de fusionner ces caractéristiques pour trouver une seule matrice caractéristique. La première méthode d'extraction des caractéristiques a été basée sur la modélisation et l'identification floue type-2 et la deuxième a été basée sur la transformée en ondelettes discrète. La matrice caractéristique trouvée a été utilisée comme l'entrée d'un classificateur qui représente le deuxième bloc. Ce classificateur est une version de réseaux de neurones qui s'appelle ELM (*Extreme Learning Machine*). Un résultat excellent en termes de précision (99%) a été trouvé ce qui confirme l'efficacité de la méthode proposée.

---

---

## CONCLUSION GÉNÉRALE

---

**L**es travaux de recherche présentés dans cette thèse, avaient pour but principal de trouver :

- ✦ Une nouvelle structure pour la modélisation et l'identification intelligente des signaux électrocardiogrammes.
- ✦ Développer des outils pour le traitement des signaux électrocardiogrammes et le diagnostic des maladies cardiovasculaires.

Plusieurs contributions ont été développées durant la préparation de ce travail, où nous avons essayé d'utiliser plusieurs techniques existantes auparavant avec de nouvelles structures, dont le but est la modélisation et l'identification des signaux électrocardiogrammes, le traitement des signaux électrocardiogrammes (débruitage), et le diagnostic des maladies cardiovasculaires. Plusieurs études comparatives des techniques développées avec d'autres techniques de références ont été effectuées pour montrer l'efficacité et la supériorité de nos méthodes proposées.

Dans le chapitre un nous avons décrit le signal électrocardiogramme avec son origine, ses caractéristiques morphologiques, ses variabilités et les différentes classes utilisées dans le processus de diagnostic, où nous avons vu que le signal électrocardiogramme est de nature électrophysiologique qui procure une information essentielle dans le diagnostic des pathologies cardiaques.

Les aspects théoriques et fondamentaux des différentes techniques utilisées ont été présentés en détails dans le deuxième chapitre tels que les notions de base de la logique floue type-1 et type-2, comme nous avons présenté en détails plusieurs algorithmes métaheuristiques à savoir le GA, PSO, FA et BBO.

La modélisation et l'identification des signaux électrocardiogrammes est une étape essentielle pour l'identification automatique des ondes du signal électrocardiogramme. Une nouvelle structure de modélisation et d'identification des signaux électrocardiogrammes en utilisant la logique floue type-2 et les algorithmes métaheuristiques a été présentée

dans le chapitre trois, où nous avons introduit la notion de modélisation en utilisant le module d'erreur. La structure proposée a pu traiter les problèmes d'ajustement de courbe (technique d'analyse d'une courbe expérimentale, consistant à construire une courbe à partir de fonctions mathématiques et d'ajuster les paramètres de ces fonctions pour se rapprocher de la courbe mesurée) et de temps de calcul des systèmes flous type-2. Cette méthode a réduit significativement le nombre de règles floues type-2 et a préservé simultanément la qualité d'ajustement. La structure proposée a contenu une interconnexion parallèle de deux sous modèles flous type-2. Le premier était le modèle primaire, qui représente un modèle ordinaire avec une basse résolution du signal électrocardiogramme en considération. Le deuxième sous modèle flou est celui de l'erreur et qui représente l'incertitude dans le modèle primaire. L'étape d'identification (ajustement des paramètres de la structure floue type-2 proposée) a été réalisée en utilisant des algorithmes d'optimisations métaheuristiques. Notons que La méthode proposée peut identifier soit les signaux soit les systèmes. Les résultats de simulation et les études comparatives ont montés l'efficacité et la supériorité de la méthode proposée pour l'identification des signaux électrocardiogrammes.

Le diagnostic des maladies cardiovasculaires est la dernière étape de toute une chaîne d'acquisition qui commence par la détection des battements cardiaques, le pré-traitement et finalement le diagnostic en utilisant un système expert contenant une base de données. Plusieurs outils et approches du traitement du signal ont été utilisés et développés dans les chapitres quatre et cinq. Pour la première étape qui est la détection des battements cardiaques, la base de données PhysioBank [58] a été utilisée . Cette base de données contient plusieurs extraits de signaux électrocardiogrammes réels qui sont une description électrique de l'activité électrique du cœur ainsi que plusieurs extraits de bruits qui peuvent contaminer ce signal à savoir : le bruit de l'électromyogramme et le bruit de mouvement des électrodes....etc.

Durant l'étape d'enregistrement du signal électrocardiogramme, il est souvent contaminé par plusieurs types de bruit. Alors l'extraction des informations utiles à partir de ces mesures bruitées est l'un des axes les plus importants du traitement des signaux biomédicaux. Plusieurs techniques (approches) ont été développées pour le filtrage du signal électrocardiogramme (chapitre 4). La première contribution pour le filtrage du signal électrocardiogramme a été la proposition d'un filtre adaptatif à base de logique flou type-1 et de d'algorithme d'optimisation à base biogéographie (BBO). Plusieurs environnements de bruit ont été utilisés pour tester la performance du filtre flou proposé à savoir des bruits artificiels et des bruits réels. Les résultats de simulation ont montré la capacité de ce filtre à supprimer tous ces types de bruits. Une étude comparative approfondie de ce filtre par rapport à d'autres méthodes de référence a été aussi menée.

La deuxième contribution dans ce contexte (filtrage du signal ECG) a été la proposition d'un autre algorithme de filtrage adaptatif basé sur le filtre de kalman étendu (EKF) et l'algorithme d'optimisation à base biogéographie (BBO). Le filtre de kalman étendu a été utilisé pour estimer les états cachés de la dynamique non linéaire du signal électrocardiogramme présenté dans l'ensemble de données de l'électrocardiogramme.

Une autre alternative pour le débruitage du signal électrocardiogramme et la séparation des signaux électrocardiogrammes maternel et fetal basé sur : la décomposition en valeurs singulières a été développée. La méthode de décomposition en valeurs singulières a été utilisée pour la décomposition de la matrice de données en deux sous-espace orthogonaux, l'un pour le signal utile et l'autre pour le signal parasite. La projection de ces données sur le sous espace désiré élimine efficacement le bruit. Les résultats de simulation ont montré l'efficacité de ce filtre surtout avec un bon choix de l'opérateur de projection. Comme perspective de ce filtre nous proposons d'introduire un mécanisme d'ajustement automatique pour cet opérateur de projection.

L'un des bruits les plus difficile à supprimer sans modifier les caractéristiques morphologiques du signal électrocardiogramme est la déformation de la ligne de base du signal électrocardiogramme, parce que ce genre de bruit et le signal électrocardiogramme ont des bandes fréquentielles qui se chevauchent dans la région basse fréquence de leurs spectres. A la fin du chapitre quatre une méthode de suppression de l'artefact de la ligne de base a été proposée, cette méthode a été basée sur l'idée que l'enveloppe supérieure du signal électrocardiogramme est une bonne approximation de la dérive de la ligne de base. Des études spectrale et expérimentale des résultats de cette méthode ont montré que ce bruit a été supprimé avec succès en préservant les caractéristiques morphologiques du signal électrocardiogramme.

Finalement au chapitre cinq, nous avons traité l'étape de diagnostic des maladies cardiovasculaires. Dans cette étape nous avons présenté l'extraction des caractéristiques et la classification des battements cardiaques selon la pathologie atteinte. Pour l'extraction des caractéristiques deux méthodes ont été utilisées : la méthode de modélisation et d'identification des signaux électrocardiogrammes développée au chapitre trois, dont les paramètres du modèle flou type-2 proposé ont été utilisés pour composer la première sous matrice caractéristique des différents battements cardiaques du signal électrocardiogramme en considération. La transformée en ondelettes discrète a été aussi utilisée pour cet objectif, dont une deuxième sous matrice caractéristique a été extraite. Ces deux sous matrices caractéristiques ont été fusionnées pour avoir une seule matrice caractéristique. Cette matrice a été utilisée comme l'entrée du classificateur qui représente la deuxième phase de la dernière étape (diagnostic). Le classificateur utilisé dans cette thèse est une version de réseaux de neurones artificiels connu sous le nom de machine d'apprentissage extrême

(ELM :*Extreme Learning Machine*). Le résultat obtenu a un taux de reconnaissance de classificateur (99%) ce qui montre l'efficacité de la méthode proposée pour classifier les différents battements cardiaques selon le type de pathologie.

Enfin et comme perspectives nous proposons de :

- ✓ utiliser des versions étendues des réducteurs de types pour améliorer plus les performances et la vitesse de la structure de modélisation et d'identification des signaux ECGs proposée.
- ✓ utiliser le modèle flou proposé pour la compression des signaux ECGs.
- ✓ Appliquer les techniques proposées pour d'autres signaux physiologiques (EEG, EMG...etc).

---

---

## ANNEXE

---

### Annexe. A : La méthode de Runge Kutta d'ordre quatre

1. Étant donné un pas de temps  $h$ , une condition initiale  $(t_0, y_0$  et un nombre maximal d'itérations  $N$ .
2. Pour  $0 \leq n \leq N$  :
  - ✓  $k_1 = hf(y_n)$ ;
  - ✓  $k_2 = hf(y_n + \frac{k_1}{2})$ ;
  - ✓  $k_3 = hf(y_n + \frac{k_2}{2})$ ;
  - ✓  $k_4 = hf(y_n + k_3)$ ;
  - ✓  $y_{n+1} = y_n + \frac{1}{6}(k_1 + 2k_2 + 3k_3 + k_4)$ ;
  - ✓  $t_{n+1} = t_n + h$ ;
  - ✓ *Ecrire*  $t_{n+1}$  et  $y_{n+1}$ ;
3. Arrêt.

## Annexe. B : La méthode d'Euler

La méthode d'Euler est de loin la méthode la plus simple de résolution numérique d'équations différentielles ordinaires. Elle possède une belle interprétation géométrique et son emploi est facile.

Soit l'équation différentielle suivante :

$$\begin{cases} \dot{x}(t) = f(t, x(t)) \\ x(t_0) = x_0 \end{cases} . \quad (1)$$

Considérons plus attentivement la condition initiale  $x(t_0) = x_0$  le but maintenant d'obtenir une approximation de la solution en  $t = t_1 = t_0 + h$ . Avant d'effectuer la première itération, il faut déterminer dans quelle direction on doit avancer à partir du point  $(t_0, y_0)$  pour obtenir le point  $(t_1, y_1)$ , qui est une approximation du point  $(t_1, y(t_1))$ . Nous avons pas l'équation de la courbe  $x(t)$ , mais nous en connaissons la pente  $\dot{x}(t)$  en  $t = t_0$ . En effet, l'équation différentielle assure que :

$$\dot{x}(t_0) = f(t_0, x(t_0)) = f(t_0, x_0). \quad (2)$$

on peut donc suivre la droite passant par  $(t_0, x_0)$  et de pente  $f(t_0, x_0)$ . L'équation de cette droite, notée  $d_0(t)$ , est :

$$d_0(t) = x_0 + f(t_0, x_0)(t - t_0). \quad (3)$$

et il est illustrée à la Figure qu'en  $t = t_1$ , on a :

$$d_0(t_1) = x_0 + f(t_0, x_0)(t_1 - t_0) = x_0 + hf(t_0, x_0) = x_1. \quad (4)$$

en d'autres termes,  $d_0(t)$  est proche de la solution analytique  $x(t_1)$ , c'est-à-dire :

$$x(t_1) \approx x_1 = d_0(t_1) = x_0 + hf(t_0, x_0). \quad (5)$$

Il est important de noter que, le plus souvent,  $x_1 \neq x(t_1)$ . Cette inégalité n'a rien pour étonner, mais elle a des conséquences sur la suite du raisonnement. En effet, si l'on souhaite faire une deuxième itération et obtenir une approximation de  $x(t_2)$ , on peut refaire l'analyse précédente à partir du point  $(t_1, x_1)$ . On remarque cependant que la pente de la solution analytique en  $t = t_1$  est :

$$\dot{x}(t_1) = f(t_1, x(t_1)). \quad (6)$$

On ne connaît pas exactement  $x(t_1)$ , mais on possède l'approximation  $x_1$  de  $x(t_1)$ . On doit alors utiliser l'expression :

$$\dot{x}(t_1) = f(t_1, x(t_1)) \approx f(t_1, x_1). \quad (7)$$

et construire la droite (Figure) :

$$d_1(t) = x_1 + f(t_1, x_1)(t - t_1). \quad (8)$$

qui permettra d'estimer  $x(t_2)$ . On constate que l'erreur commise à la première itération est réintroduite dans les calculs de la deuxième itération, on a alors :

$$x(t_2) \approx x_2 = d_1(t_2) = x_1 + hf(t_1, x_2). \quad (9)$$

de (4) et (8) on a :

$$f(t_0, x_0) = \dot{x}(t_0) = \frac{x_1 - x_0}{h} \quad (10)$$

$$f(t_1, x_1) = \dot{x}(t_1) = \frac{x_2 - x_1}{h} \quad (11)$$

donc de (10) et (11) et d'une façon générale on a :

$$\frac{dx}{dt} = \dot{x} \approx \frac{x(t_{n+1}) - x(t_n)}{h} \quad (12)$$




FIGURE A.1 – Méthode d'Euler

## Annexe. C : Développement limité en série Taylor

Ce développement concerne à approximer les fonctions non linéaires au voisinage de certains points de fonctionnement. Soit  $f(x)$  une fonction non linéaire et soit  $x_0$  un point dans le domaine de définition de la fonction. Alors, selon Taylor, cette fonction peut être décrite par la somme infinie :

$$f(x) = f(x_0) + \frac{df}{dx}|_{x_0}(x - x_0) + \frac{1}{2} \frac{d^2f}{dx^2}|_{x_0}(x - x_0)^2 + \dots \quad (13)$$

Si nous voulons approximer linéairement une fonction  $f(x)$  au voisinage d'un certain point  $x$ , alors (13) devient approximativement :

$$f(x) \approx f(x_0) + \frac{df}{dx}|_{x_0}(x - x_0). \quad (14)$$

Qui représente une équation d'une droite de pente  $f'(x_0)$  comme le montre l'expression simplifiée de (14) :

$$f(x) \approx \underbrace{f'(x_0)}_a x + \underbrace{f(x_0) - f'(x_0)x_0}_b = ax + b. \quad (15)$$




FIGURE A.2 – Approximation linéaire d'une fonction non linéaire

On peut même effectuer une approximation d'ordre supérieur avec le développement limité en série de Taylor, en considérant les termes de puissance supérieur ou égale à deux. Une approximation d'ordre deux sera par exemple donnée par :

$$f(x) = f(x_0) + \frac{df}{dx}|_{x_0}(x - x_0) + \frac{1}{2} \frac{d^2f}{dx^2}|_{x_0}(x - x_0)^2. \quad (16)$$

Qui représente bien sur une parabole. Donc, au voisinage de  $x_0$ , la fonction  $f(x)$  va être approximée par une parabole comme le montre la Figure A.3.




FIGURE A.3 – Approximation non linéaire d'une fonction non linéaire

## Annexe. D : Discrétisation des différents équations du modèle du signal électrocardiogramme

$$\begin{aligned}
 \dot{x}_1 &= \frac{x_1(k+1) - x_1(k)}{h} = \alpha x_1(k) - \omega x_2(k) \\
 x_1(k+1) - x_1(k) &= h\alpha x_1(k) - h\omega x_2(k) \\
 x_1(k+1) &= h\alpha x_1(k) - h\omega x_2(k) + x_1(k) \\
 x_1(k+1) &= (1 + \alpha h)x_1(k) - \omega h x_2(k) \tag{17}
 \end{aligned}$$

$$\begin{aligned}
 \dot{x}_2 &= \frac{x_2(k+1) - x_2(k)}{h} = \alpha x_2(k) + \omega x_1(k) \\
 x_2(k+1) - x_2(k) &= h\alpha x_2(k) + h\omega x_1(k) \\
 x_2(k+1) &= h\alpha x_2(k) + h\omega x_1(k) + x_2(k) \\
 x_2(k+1) &= (1 + \alpha h)x_2(k) + \omega h x_1(k) \tag{18}
 \end{aligned}$$

$$\begin{aligned}
 \dot{x}_3 &= \frac{x_3(k+1) - x_3(k)}{h} = - \sum_{i \in \{P, Q, R, S, T\}} a_i \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - x_3(k) + z_0 \\
 x_3(k+1) - x_3(k) &= - \sum_{i \in \{P, Q, R, S, T\}} h a_i \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - h x_3(k) + h z_0 \\
 x_3(k+1) &= - \sum_{i \in \{P, Q, R, S, T\}} h a_i \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - h x_3(k) + h z_0 + x_3(k) \\
 x_3(k+1) &= - \sum_{i \in \{P, Q, R, S, T\}} a_i h \Delta \theta_i \exp\left(-\frac{\Delta \theta_i^2}{2b_i^2}\right) - ((h-1)x_3(k) - h z_0) \tag{19}
 \end{aligned}$$

## Annexe. E : Calcul des différents éléments des matrice Jacobiennes $A_k$ , $W_k$ et $C_k$ du Modèle linéaire du signal ECG

### 1. La matrice $A_k$ :

$$\begin{aligned}
\frac{\partial F}{\partial x_1} &= \frac{\partial}{\partial x_1}((1 + \alpha h)x_1(k) - \omega h x_2(k)) \\
&= \frac{\partial}{\partial x_1}((1 + \alpha h)x_1(k)) - \frac{\partial}{\partial x_1}(\omega h x_2(k)) \\
&= (1 + h(1 - (\sqrt{x_1(k)^2 + x_2(k)^2} + \frac{2x_1(k)^2}{2\sqrt{x_1(k)^2 + x_2(k)^2})))) \\
&= \left(1 + h \left(1 - \left(\frac{2x_1(k)^2 + 2x_2(k)^2 + 2x_1(k)^2}{2\sqrt{x_1(k)^2 + x_2(k)^2}}\right)\right)\right) \\
&= 1 + h - \left(\frac{2hx_1(k)^2 + hx_2(k)^2}{\sqrt{x_1(k)^2 + x_2(k)^2}}\right) \tag{20}
\end{aligned}$$

$$\begin{aligned}
\frac{\partial F}{\partial x_2} &= \frac{\partial}{\partial x_2}((1 + \alpha h)x_1(k) - \omega h x_2(k)) \\
&= \frac{\partial}{\partial x_2}((1 - \sqrt{x_1(k)^2 + x_2(k)^2})hx_1(k) - \omega h x_2(k)) \\
&= \frac{\partial}{\partial x_2}(hx_1(k) - hx_1(k)\sqrt{x_1(k)^2 + x_2(k)^2} - \omega h x_2(k)) \\
&= \frac{\partial}{\partial x_2}(-h(x_1(k)\sqrt{x_1(k)^2 + x_2(k)^2} + \omega x_2(k))) \\
&= -h \left(\frac{2x_1(k)x_2(k)}{2\sqrt{x_1(k)^2 + x_2(k)^2}} + \omega\right) \\
&= -\frac{hx_1(k)x_2(k)}{\sqrt{x_1(k)^2 + x_2(k)^2}} - \omega h \tag{21}
\end{aligned}$$

$$\begin{aligned}
\frac{\partial F}{\partial x_3} &= \frac{\partial}{\partial x_3}((1 + \alpha h)x_1(k) - \omega h x_2(k)) \\
&= 0 \tag{22}
\end{aligned}$$

$$\begin{aligned}
\frac{\partial G}{\partial x_1} &= \frac{\partial}{\partial x_1}((1 + \alpha h)x_2(k) + \omega h x_1(k)) \\
&= \frac{\partial}{\partial x_1}((1 - \sqrt{x_1(k)^2 + x_2(k)^2})hx_2(k) + \omega h x_1(k)) \\
&= \frac{\partial}{\partial x_1}(hx_2(k) - hx_2(k)\sqrt{x_1(k)^2 + x_2(k)^2} + \omega h x_1(k)) \\
&= -\frac{hx_1(k)x_2(k)}{\sqrt{x_1(k)^2 + x_2(k)^2}} + \omega h \tag{23}
\end{aligned}$$

$$\begin{aligned}
\frac{\partial G}{\partial x_2} &= \frac{\partial}{\partial x_2} ((1 + \alpha h)x_2(k) + \omega h x_1(k)) \\
&= \frac{\partial}{\partial x_2} (x_2(k) + \alpha h x_2(k)) \\
&= \frac{\partial}{\partial x_2} (x_2(k) + (1 - \sqrt{x_1(k)^2 + x_2(k)^2})h x_2(k)) \\
&= \frac{\partial}{\partial x_2} (x_2(k) + h x_2(k) - h x_2(k) \sqrt{x_1(k)^2 + x_2(k)^2}) \\
&= (1 + h - h(\sqrt{x_1(k)^2 + x_2(k)^2}) + \frac{2x_2(k)^2}{2\sqrt{x_1(k)^2 + x_2(k)^2}}) \\
&= (1 + h - h \left( \frac{2x_1(k)^2 + 4x_2(k)^2}{2\sqrt{x_1(k)^2 + x_2(k)^2}} \right)) \\
&= 1 + h - \left( \frac{hx_1(k)^2 + 2hx_2(k)^2}{\sqrt{x_1(k)^2 + x_2(k)^2}} \right) \tag{24}
\end{aligned}$$

$$\begin{aligned}
\frac{\partial G}{\partial x_3} &= \frac{\partial}{\partial x_3} ((1 + \alpha h)x_2(k) + \omega h x_1(k)) \\
&= 0 \tag{25}
\end{aligned}$$

$$\begin{aligned}
\frac{\partial H}{\partial x_1} &= \frac{\partial}{\partial x_1} \left( - \sum a_i h \Delta \theta_i \exp \left( - \frac{\Delta \theta_i^2}{2b_i^2} \right) - ((h-1)x_3(k) - h z_0) \right) \\
&= \frac{\partial}{\partial x_1} \left( - \sum \underbrace{a_i h (\theta - \theta_i)}_{\phi} \underbrace{\exp \left( - \frac{(\theta - \theta_i)^2}{2b_i^2} \right)}_h - ((h-1)x_3(k) - h z_0) \right) \\
&= \frac{\partial}{\partial x_1} \left( - \sum \phi h - ((h-1)x_3(k) - h z_0) \right) \\
&= - \sum \left( \frac{\partial}{\partial x_1} \phi h \right) \\
&= - \sum \left( \frac{\partial \phi}{\partial x_1} h + \phi \frac{\partial h}{\partial x_1} \right)
\end{aligned}$$

Nous avons :

$$\begin{aligned}
\frac{\partial \phi}{\partial x_1} &= \frac{\partial}{\partial x_1} (a_i h (\theta - \theta_i)) \\
&= \frac{\partial}{\partial x_1} \left( a_i h \left( \arctan \left( \frac{x_2(k)}{x_1(k)} \right) - \theta_i \right) \right) \\
&= \frac{\partial}{\partial x_1} a_i h \arctan \left( \frac{x_2(k)}{x_1(k)} \right) - \frac{\partial}{\partial x_1} a_i h \theta_i \\
&= \frac{\partial}{\partial x_1} a_i h \arctan \left( \frac{x_2(k)}{x_1(k)} \right) \tag{26}
\end{aligned}$$

et :

$$\frac{\partial}{\partial x} (\arctan(g(x))) = \frac{1}{1 + (g(x))^2} \frac{\partial}{\partial x} g(x) \tag{27}$$

donc :

$$\begin{aligned}\frac{\partial \phi}{\partial x_1} &= a_i h \left( \frac{-\frac{x_2(k)}{x_1(k)^2}}{1 + \frac{x_2(k)^2}{x_1(k)^2}} \right) \\ &= \frac{-a_i h \frac{x_2(k)}{x_1(k)^2}}{\frac{x_1(k)^2 + x_2(k)^2}{x_1(k)^2}} \\ &= \frac{-a_i h x_2(k)}{x_1(k)^2 + x_2(k)^2}\end{aligned}\quad (28)$$

$$\begin{aligned}\frac{\partial \hbar}{\partial x_1} &= \frac{\partial}{\partial x_1} \exp\left(-\frac{(\theta - \theta_i)^2}{2b_i^2}\right) \\ &= -\frac{2}{2b_i^2} \frac{\partial(\theta - \theta_i)}{\partial x_1} (\theta - \theta_i) \exp\left(-\frac{\Delta\theta_i^2}{2b_i^2}\right) \\ &= -\frac{1}{b_i^2} \frac{\partial\left(\arctan\left(\frac{x_2(k)}{x_1(k)}\right) - \theta_i\right)}{\partial x_1} \Delta\theta_i \exp\left(-\frac{\Delta\theta_i^2}{2b_i^2}\right) \\ &= \frac{1}{b_i^2} \left(\frac{x_2(k)}{x_1(k)^2 + x_2(k)^2}\right) \Delta\theta_i \exp\left(-\frac{\Delta\theta_i^2}{2b_i^2}\right)\end{aligned}\quad (29)$$

Alors, en utilisant (28) et (29),  $\frac{\partial H}{\partial x_1}$  devient :

$$\begin{aligned}\frac{\partial H}{\partial x_1} &= \sum \frac{a_i h x_2(k)}{x_1(k)^2 + x_2(k)^2} \exp\left(-\frac{\Delta\theta_i^2}{2b_i^2}\right) - \frac{a_i h x_2(k) \Delta\theta_i^2}{b_i^2 (x_1(k)^2 + x_2(k)^2)} \exp\left(-\frac{\Delta\theta_i^2}{2b_i^2}\right) \\ &= \sum \frac{a_i h x_2(k)}{x_1(k)^2 + x_2(k)^2} \exp\left(-\frac{\Delta\theta_i^2}{2b_i^2}\right) \left[1 - \frac{\Delta\theta_i^2}{b_i^2}\right]\end{aligned}\quad (30)$$

en suivant le même raisonnement, on trouve que :

$$\frac{\partial H}{\partial x_2} = \sum \frac{-a_i h x_1(k)}{x_1(k)^2 + x_2(k)^2} \exp\left(-\frac{\Delta\theta_i^2}{2b_i^2}\right) \left[1 - \frac{\Delta\theta_i^2}{b_i^2}\right]\quad (31)$$

$$\frac{\partial H}{\partial x_3} = 1 - h\quad (32)$$

**2. La matrice  $W_k$  :**

$$\frac{\partial F}{\partial \omega_1} = \frac{\partial G}{\partial \omega_2} = \frac{\partial H}{\partial \omega_3} = 1\quad (33)$$

$$\frac{\partial F}{\partial \omega_2} = \frac{\partial F}{\partial \omega_3} = \frac{\partial G}{\partial \omega_1} = \frac{\partial G}{\partial \omega_3} = \frac{\partial H}{\partial \omega_1} = \frac{\partial H}{\partial \omega_2} = 0\quad (34)$$

3. La matrice  $C_k$  :

$$\frac{\partial g}{\partial x_3} = 1 \quad (35)$$

$$\frac{\partial g}{\partial x_1} = \frac{\partial g}{\partial x_2} = 0 \quad (36)$$

## Annexe. F : Interpolation par splines cubiques

Supposons que l'on veuille interpoler par morceaux une fonction  $y(x)$  sur un intervalle  $[x_0, x_n]$  que l'on partitionné en sous-intervalles  $[x_{i-1}, x_i]$ ,  $i = 1, 2, \dots, n$ .

L'interpolation par splines cubiques consiste à remplacer, sur chaque sous-intervalle, la fonction  $y$  par un polynôme du troisième degré, de sorte que la fonction interpolante soit continue ainsi que ses dérivées première et seconde sur tout l'intervalle  $[x_0, x_n]$ .

Les courbes splines cubiques simulent l'attitude prise par une fine latte de bois dont la forme est imposée à l'aide de piquets. La déformation de la latte entre deux piquets successifs est représentée par une fonction dont la dérivée quatrième s'annule, c'est-à-dire par un polynôme du troisième degré ou cubique (spline est en anglais, le nom d'une latte flexible utilisée en dessin industriel).

Les cubiques d'interpolation s'écrivent :

$$f_i(x) = a_i x^3 + b_i x^2 + c_i x + d_i, \quad x_{i-1} \leq x \leq x_i, \quad i = 1, 2, \dots, n. \quad (37)$$

Posons  $f_i''(x_i) = f_i''$ ,  $i = 1, 2, \dots, n$ .

La continuité de la dérivée seconde s'écrit :

$$f_i''(x_i) = f_i'' \quad \text{et} \quad f_i''(x_{i-1}) = f_{i-1}'', \quad i = 1, 2, \dots, n \quad (38)$$

ou, comme la dérivée seconde est linéaire :

$$f_i''(x) = f_{i-1}'' \frac{x - x_i}{x_{i-1} - x_i} + f_i'' \frac{x - x_{i-1}}{x_i - x_{i-1}}. \quad (39)$$

soit, en posant  $h_i = x_i - x_{i-1}$  :

$$f_i''(x) = f_{i-1}'' \frac{x_i - x}{h_i} + f_i'' \frac{x - x_{i-1}}{h_i}. \quad (40)$$

En intégrant deux fois il vient :

$$f_i(x) = f_{i-1}'' \frac{(x_i - x)^3}{6h_i} + f_i'' \frac{(x - x_{i-1})^3}{6h_i} + r_i x + s_i. \quad (41)$$

On détermine les constantes d'intégration  $r_i$  et  $s_i$  à l'aide des valeurs connues de  $f_i(x)$  en  $x_i$  et  $x_{i-1}$  ( $f_i(x_{i-1}) = y_{i-1}$ ,  $f_i(x_i) = y_i$ ).

Après quelques manipulations algébriques, il vient :

$$f_i(x) = f_{i-1}'' \frac{(x_i - x)^3}{6h_i} + f_i'' \frac{(x - x_{i-1})^3}{6h_i} + \left[ \frac{y_{i-1}}{h_i} - f_{i-1}'' \frac{h_i}{6} \right] (x_i - x) + \left[ \frac{y_i}{h_i} - f_i'' \frac{h_i}{6} \right] (x - x_{i-1}). \quad (42)$$

Les fonctions  $f_i(x)$  seront entièrement connues quand nous aurons calculé les valeurs de  $f_i''$ . Pour obtenir ces valeurs, nous utilisons les conditions de continuité des dérivées

premières aux points intérieurs.

Après dérivation de  $f_i(x)$  nous imposons :

$$f'_i(x_i) = f'_{i+1}(x_i), \quad i = 1, 2, \dots, n - 1. \quad (43)$$

Pour obtenir :

$$h_i f''_{i-1} + 2(h_i + h_{i+1}) f''_i + h_{i+1} f''_{i+1} = \frac{6}{h_{i+1}} (y_{i+1} - y_i) + \frac{6}{h_i} (y_{i-1} - y_i); \quad i = 1, 2, \dots, n - 1. \quad (44)$$

soit un système de  $n - 1$  équations à  $n + 1$  inconnues , les  $f''_i$ .

Il nous reste donc la possibilité d'imposer deux conditions supplémentaires , obtenues par exemple, par les conditions aux limites de l'intervalles  $[x_0, x_n]$ .

Si nous imposons les deux conditions suivantes :

$$f''_i(x_0) = 0 \quad \text{et} \quad f''_n(x_n) = 0. \quad (45)$$

nous obtenons les splines cubiques naturelles.

## Annexe. G : Mesure de distorsion basée sur l'entropie multi-échelles pondérée : MSEWPRD

L'erreur entre les échantillons joue un rôle important dans l'évaluation clinique des distorsions dans les caractéristiques morphologiques du signal électrocardiogramme à savoir l'amplitudes, durées et les formes des ondes P, Q, R, S, et T du signal ECG [175]. Le critère de distorsion d'erreur quadratique est le plus approprié pour l'optimisation du taux de distorsion. La mesure de PRD (*Percentage Root mean-square Difference*) basé sur l'entropie multi-échelles pondérée (*Multi-Scale Entropy Based Weighted*) (MSEWPRD) est définie comme suit :

$$MSEWPRD = w_{A_L} \times \left( \sqrt{\frac{\sum_{k=1}^{N_{A_L}} [A_L(k) - \tilde{A}_L(k)]^2}{\sum_{k=1}^{N_{A_L}} [A_L(k)]^2}} \times 100 \right) + \sum_{j=1}^L w_{D_j} \times \left( \sqrt{\frac{\sum_{k=1}^{N_{D_j}} [D_j(k) - \tilde{D}_j(k)]^2}{\sum_{k=1}^{N_{D_j}} [D_j(k)]^2}} \times 100 \right), \quad (46)$$

où  $w_{A_L}$  est le poids de la  $L^{ieme}$  bande d'approximation,  $w_{D_j}$  est le poids de la sous bande de détails de  $j^{ieme}$  niveau ;  $A_L$  et  $\tilde{A}_L$  sont les  $L^{ieme}$  coefficients de la bande d'approximation du signal original et le signal filtré, respectivement ;  $D_j$  et  $\tilde{D}_j$  sont les  $j^{ieme}$  coefficients de la bande de détails du signal original et le signal filtré, respectivement.

Cette mesure est un pourcentage moyenne pondéré de la racine de différence entre les coefficients de la sous bande d'ondelettes du signal original et le signal filtré avec des poids égaux aux entropies multi-échelles des sous-bandes correspondantes. Avec cette mesure, une représentation correcte de la distorsion du signal filtré dans toutes les sous bandes peut être obtenue [175]. Pour calculer cette mesure, les deux signaux doivent être décomposés en ondelettes jusqu'à  $L$  niveaux. Le nombre de niveaux dépend de la nature du signal et de la fréquence d'échantillonnage. En ECG, en plus des segments pointus (complexes QRS), il y a des ondes lentes comme les ondes P et T. Une bonne décomposition de l'ECG comprend une représentation décente des complexe QRS dans les coefficients de détail et des ondes P et T dans les coefficients d'approximation. Par conséquent, nous avons utilisé la décompositions en ondelettes biorthogonaux (Daubechies9/7) [221] pour le signal électrocardiogramme il est trouvé que  $L = 4$  est un bon choix pour la fréquence d'échantillonnage de  $128Hz$  [222].



---

---

## Bibliographie

---

- [1] Shirley Jones. *ECGsuccess : Exercises in ECG interpretation*. 2007.
- [2] Michel Fischbach and Daniel Thomas. *Guide pratique du cardiaque : prévention et suivi*. Frison-Roche, 2002.
- [3] Donald Venes. *Taber's cyclopedic medical dictionary*. FA Davis, 2017.
- [4] JR Cox, FM Nolle, HA Fozzard, and GC Oliver. AZTEC, a preprocessing program for real-time ECG rhythm analysis. *IEEE Transactions on Biomedical Engineering*, (2) :128–129, 1968.
- [5] John P Abenstein and Willis J Tompkins. A new data-reduction algorithm for real-time ECG analysis. *IEEE Transactions on Biomedical Engineering*, (1) :43–48, 1982.
- [6] Masa Ishijima, Soon-Bum Shin, Gene H Hostetter, and Jack Sklansky. Scan-along polygonal approximation for data compression of electrocardiograms. *IEEE Transactions on Biomedical Engineering*, (11) :723–729, 1983.
- [7] Hideki Imai, Nobuyoshi Kiraura, and Yutaka Yoshida. An efficient encoding method for electrocardiography using spline functions. *Systems and Computers in Japan*, 16(3) :85–94, 1985.
- [8] Ranveig Nygaard, Dag Haugland, and John Håkon Husøy. Signal compression by second order polynomials and piecewise non-interpolating approximation. 1999.
- [9] Daniel Tchiotsop, Didier Wolf, Valerie Louis-Dorr, and Rene Husson. ECG data compression using jacobi polynomials. pages 1863–1867, 2007.
- [10] Daniel Tchiotsop. *Modélisations polynomiales des signaux ECG. applications à la compression*. 2007.
- [11] Patrick E McSharry, Gari D Clifford, Lionel Tarassenko, and Leonard A Smith. A dynamical model for generating synthetic electrocardiogram signals. *IEEE Transactions on Biomedical Engineering*, 50(3) :289–294, 2003.

- [12] Ning Wang, Meng Joo Er, and Xian Yao Meng. A fast and accurate online self-organizing scheme for parsimonious fuzzy neural networks. *Neurocomputing*, 72(16) :3818–3829, 2009.
- [13] Honggui Han and Junfei Qiao. A self-organizing fuzzy neural network based on a growing-and-pruning algorithm. *IEEE Transactions on Fuzzy Systems*, 18(6) :1129–1143, 2010.
- [14] Honggui Han, Xiao-Long Wu, and Jun-Fei Qiao. Nonlinear systems modeling based on self-organizing fuzzy-neural-network with adaptive computation algorithm. *IEEE transactions on cybernetics*, 44(4) :554–564, 2014.
- [15] Hong-Gui Han, Zheng-Lai Lin, and Jun-Fei Qiao. Modeling of nonlinear systems using the self-organizing fuzzy neural network with adaptive gradient algorithm. *Neurocomputing*, 2017.
- [16] Cheng Chen and Fei-Yue Wang. A self-organizing neuro-fuzzy network based on first order effect sensitivity analysis. *Neurocomputing*, 118 :21–32, 2013.
- [17] José de Jesús Rubio. Sofmls : online self-organizing fuzzy modified least-squares network. *IEEE Transactions on Fuzzy Systems*, 17(6) :1296–1309, 2009.
- [18] Chia-Feng Juang and Cheng-Da Hsieh. A locally recurrent fuzzy neural network with support vector regression for dynamic-system modeling. *IEEE Transactions on Fuzzy Systems*, 18(2) :261–273, 2010.
- [19] Hosein Marzi, Ahmed Haj Darwish, and Humam Helfawi. Training anfis using the enhanced bees algorithm and least squares estimation. *Intelligent Automation & Soft Computing*, 23(2) :227–234, 2017.
- [20] Frumen Olivas, Fevrier Valdez, Oscar Castillo, and Patricia Melin. Dynamic parameter adaptation in particle swarm optimization using interval type-2 fuzzy logic. *Soft Computing*, 20(3) :1057–1070, 2016.
- [21] Mauricio A Sanchez, Oscar Castillo, and Juan R Castro. Information granule formation via the concept of uncertainty-based information with interval type-2 fuzzy sets representation and takagi–sugeno–kang consequents optimized with cuckoo search. *Applied Soft Computing*, 27 :602–609, 2015.
- [22] Fevrier Valdez, Juan Carlos Vazquez, Patricia Melin, and Oscar Castillo. Comparative study of the use of fuzzy logic in improving particle swarm optimization variants for mathematical functions using co-evolution. *Applied Soft Computing*, 2016.

- [23] Jonathan Perez, Fevrier Valdez, Oscar Castillo, Patricia Melin, Claudia Gonzalez, and Gabriela Martinez. Interval type-2 fuzzy logic for dynamic parameter adaptation in the bat algorithm. *Soft Computing*, pages 1–19, 2016.
- [24] Z Chalabi, N Berrached, and L Ilies. Détection des extrasystoles ventriculaires par les algorithmes som & lvq. 2005.
- [25] Themis P Exarchos, Markos G Tsipouras, Costas P Exarchos, Costas Papaloukas, Dimitrios I Fotiadis, and Lampros K Michalis. A methodology for the automated creation of fuzzy expert systems for ischaemic and arrhythmic beat classification based on a set of rules obtained by a decision tree. *Artificial Intelligence in medicine*, 40(3) :187–200, 2007.
- [26] Rym Besrou, Zied Lachiri, and Noureddine Ellouze. Détection de l'onde r d'un electrocardiogramme basée sur le produit multiéchelle.
- [27] Rosaria Silipo and Carlo Marchesi. Artificial neural networks for automatic ECG analysis. *IEEE transactions on signal processing*, 46(5) :1417–1425, 1998.
- [28] Liang-Yu Shyu, Ying-Hsuan Wu, and Weichih Hu. Using wavelet transform and fuzzy neural network for VPC detection from the holter ecg. *IEEE Transactions on Biomedical Engineering*, 51(7) :1269–1273, 2004.
- [29] Fredric M Ham and Soowhan Han. Classification of cardiac arrhythmias using fuzzy artmap. *IEEE Transactions on Biomedical Engineering*, 43(4) :425–429, 1996.
- [30] GH Kleisinger, L Barbosa, and JE Monzón. Neural-network detection of abnormal ventricular beats using temporal and morphological features of the electrocardiographic signal. 2000.
- [31] Jorge E Monzon and Maria I Pisarello. Cardiac beat classification using a fuzzy inference system. pages 5582–5584, 2005.
- [32] Vessela Krasteva and Irena Jekova. Assessment of ECG frequency and morphology parameters for automatic classification of life-threatening cardiac arrhythmias. *Phy-siological measurement*, 26(5) :707, 2005.
- [33] Reza Sameni, Mohammad B Shamsollahi, Christian Jutten, and Gari D Clifford. A nonlinear bayesian filtering framework for ECG denoising. *IEEE Transactions on Biomedical Engineering*, 54(12) :2172–2185, 2007.
- [34] Omid Sayadi and Mohammad Bagher Shamsollahi. ECG denoising and compression using a modified extended kalman filter structure. *IEEE Transactions on Biomedical Engineering*, 55(9) :2240–2248, 2008.

- [35] Hamed Danandeh Hesar and Maryam Mohebbi. ECG denoising using marginalized particle extended kalman filter with an automatic particle weighting strategy. *IEEE journal of biomedical and health informatics*, 21(3) :635–644, 2017.
- [36] Nitish V Thakor and Y-S Zhu. Applications of adaptive filtering to ECG analysis : noise cancellation and arrhythmia detection. *IEEE transactions on biomedical engineering*, 38(8) :785–794, 1991.
- [37] Pablo Laguna, Raimon Jané, Olivier Meste, Peter W Poon, Pere Caminal, Hervé Rix, and Nitish V Thakor. Adaptive filter for event-related bioelectric signals using an impulse correlated reference input : comparison with signal averaging techniques. *IEEE transactions on biomedical engineering*, 39(10) :1032–1044, 1992.
- [38] Paul Lander and Edward J Berbari. Time-frequency plane wiener filtering of the high-resolution ECG: Background and time-frequency representations. *IEEE transactions on biomedical engineering*, 44(4) :247–255, 1997.
- [39] HA Kestler, M Haschka, W Kratz, F Schwenker, G Palm, V Hombach, and M Hoher. De-noising of high-resolution ECG signals by combining the discrete wavelet transform with the wiener filter. In *Computers in Cardiology 1998*, pages 233–236. IEEE, 1998.
- [40] Sara Moein. An mlp neural network for ECG noise removal based on kalman filter. In *Advances in Computational Biology*, pages 109–116. Springer, 2010.
- [41] Kang-Ming Chang and Shing-Hong Liu. Gaussian noise filtering from ecg by wiener filter and ensemble empirical mode decomposition. *Journal of Signal Processing Systems*, 64(2) :249–264, 2011.
- [42] Jinseok Lee, David D McManus, Sneha Merchant, and Ki H Chon. Automatic motion and noise artifact detection in holter ECG data using empirical mode decomposition and statistical approaches. *IEEE Transactions on Biomedical Engineering*, 59(6) :1499–1506, 2012.
- [43] Md Ashfanor Kabir and Celia Shahnaz. Denoising of ECG signals based on noise reduction algorithms in EMD and wavelet domains. *Biomedical Signal Processing and Control*, 7(5) :481–489, 2012.
- [44] Suranai Pongpon Sri and Xiao-Hua Yu. An adaptive filtering approach for electrocardiogram (ECG) signal noise reduction using neural networks. *Neurocomputing*, 117 :206–213, 2013.
- [45] Md Abdul Awal, Sheikh Shanawaz Mostafa, Mohiuddin Ahmad, and Mohd Abdur Rashid. An adaptive level dependent wavelet thresholding for ECG denoising. *Bio-cybernetics and Biomedical Engineering*, 34(4) :238–249, 2014.

- [46] Jianhong Wang, Yongqiang Ye, Xiang Pan, Xudong Gao, and Chao Zhuang. Fractional zero-phase filtering based on the riemann–liouville integral. *Signal Processing*, 98 :150–157, 2014.
- [47] Jianhong Wang and Ye. Parallel-type fractional zero-phase filtering for ECG signal denoising. *Biomedical Signal Processing and Control*, 18 :36–41, 2015.
- [48] Wissam Jenkal and Rachid Latif. An efficient algorithm of ECG signal denoising using the adaptive dual threshold filter and the discrete wavelet transform. *Biocy-bernetics and Biomedical Engineering*, 36(3) :499–508, 2016.
- [49] Phuong Nguyen and Jong-Myon Kim. Adaptive ECG denoising using genetic algorithm-based thresholding and ensemble empirical mode decomposition. *Information Sciences*, 373 :499–511, 2016.
- [50] Ze Wang, Feng Wan, Chi Man Wong, and Liming Zhang. Adaptive fourier decomposition based ECG denoising. *Computers in biology and medicine*, 77 :195–205, 2016.
- [51] Alarka Sanyal, Arijit Baral, and Abhijit Lahiri. Application of framelet transform in filtering baseline drift from ECG signals. *Procedia Technology*, 4 :862–866, 2012.
- [52] Sakshi Agrawal and Anubha Gupta. Fractal and EMD based removal of baseline wander and powerline interference from ECG signals. *Computers in biology and medicine*, 43(11) :1889–1899, 2013.
- [53] Miroslav Zivanovic and Miriam González-Izal. Simultaneous powerline interference and baseline wander removal from ECG and emg signals by sinusoidal modeling. *Medical engineering & physics*, 35(10) :1431–1441, 2013.
- [54] Antonio Fasano and Valeria Villani. Baseline wander removal for bioelectrical signals by quadratic variation reduction. *Signal Processing*, 99 :48–57, 2014.
- [55] Praveen Gupta, Kamalesh Kumar Sharma, and Shiv Dutt Joshi. Baseline wander removal of electrocardiogram signals using multivariate empirical mode decomposition. *Healthcare technology letters*, 2(6) :164–166, 2015.
- [56] H Sharma and KK Sharma. Baseline wander removal of ECG signals using hilbertvibration decomposition. *Electronics Letters*, 51(6) :447–449, 2015.
- [57] Chen Zou, Yajie Qin, Chenglu Sun, Wei Li, and Wei Chen. Motion artifact removal based on periodical property for ECG monitoring with wearable systems. *Pervasive and Mobile Computing*, 40 :267–278, 2017.
- [58] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. Ch. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley. PhysioBank,

- PhysioToolkit, and PhysioNet : Components of a new research resource for complex physiologic signals. *Circulation*, 101(23) :e215–e220, 2000 (June 13). *Circulation Electronic Pages* : <http://circ.ahajournals.org/content/101/23/e215.full> PMID :1085218 ; doi : 10.1161/01.CIR.101.23.e215.
- [59] Balkine Khaddoumi. *Analyse et modelisation d'electrocardiogrammes dans le cas de pathologies ventriculaires*. PhD thesis, Nice, 2005.
- [60] Cabrol Christian and Vialle Raphael. *Anatomie du coeur humain*. *Universite Pierre et Marie Curie, France*, 2002.
- [61] Alfredo Illanes Manriquez. *Segmentation de l'electrocardiogramme pour la modelisation de la dynamique du QT lors de l'exercice du handgrip*. PhD thesis, 2008.
- [62] François Portet. *Pilotage d'algorithmes pour la reconnaissance en ligne d'arythmies cardiaques*. PhD thesis, Université Rennes 1, 2005.
- [63] Antonio Bayes de Luna. *Basic electrocardiography : normal and abnormal ECG patterns*. Wiley Online Library, 2007.
- [64] M Gabriel Khan. *Rapid ECG interpretation*. Springer Science & Business Media, 2008.
- [65] Gary M Friesen, Thomas C Jannett, Manal Afify Jadallah, Stanford L Yates, Stephen R Quint, and H Troy Nagle. A comparison of the noise sensitivity of nine qrs detection algorithms. *IEEE Transactions on biomedical engineering*, 37(1) :85–98, 1990.
- [66] Pauli Tikkanen. *Characterization and application of analysis methods for ECG and time interval variability data*. Oulun yliopisto, 1999.
- [67] Carlo J De Luca. *Surface electromyography : Detection and recording*. *DelSys Incorporated*, 10 :2011, 2002.
- [68] Association for the Advancement of Medical Instrumentation et al. Testing and reporting performance results of cardiac rhythm and st segment measurement algorithms. *ANSI/AAMI EC38*, 1998, 1998.
- [69] PhysioNet ECG database : PhysioBank Annotations. <https://www.physionet.org/physiobank/annotations.shtml>.
- [70] Lotfi A Zadeh. Fuzzy sets. *Information and control*, 8(3) :338–353, 1965.
- [71] JR Tong. *La logique floue*. *Hermes, Paris*, 91, 1995.
- [72] Jyh-Shing Roger Jang, Chuen-Tsai Sun, and Eiji Mizutani. *Neuro-fuzzy and soft computing : a computational approach to learning and machine intelligence*. 1997.
- [73] Timothy J Ross. *Fuzzy logic with engineering applications*. John Wiley & Sons, 2009.

- [74] Lotfi Asker Zadeh. The concept of a linguistic variable and its application to approximate reasoning. *Information sciences*, 8(3) :199–249, 1975.
- [75] Chin-Teng Lin et al. *Neural fuzzy systems : a neuro-fuzzy synergism to intelligent systems*. Prentice hall PTR, 1996.
- [76] NIKOS E Mastorakis. Modeling dynamical systems via the takagi-sugeno fuzzy model. *WSEAS Transactions on Systems*, 3(2) :668–676, 2004.
- [77] Kazuo Tanaka and Michio Sugeno. Introduction to fuzzy modeling. pages 63–89, 1998.
- [78] Nilesh N Karnik, Jerry M Mendel, and Qilian Liang. Type-2 fuzzy logic systems. *IEEE transactions on Fuzzy Systems*, 7(6) :643–658, 1999.
- [79] Nilesh N Karnik, Jerry M Mendel, and Qilian Liang. Type-2 fuzzy logic systems. *IEEE transactions on Fuzzy Systems*, 7(6) :643–658, 1999.
- [80] Qilian Liang and Jerry M Mendel. Interval type-2 fuzzy logic systems. In *Fuzzy Systems, 2000. FUZZ IEEE 2000. The Ninth IEEE International Conference on*, volume 1, pages 328–333. IEEE, 2000.
- [81] Mohammad Jamshidi, Nader Vadiee, and Timothy Ross. *Fuzzy logic and control : software and hardware applications*, volume 2. Pearson Education, 1993.
- [82] Jerry M Mendel. Fuzzy logic systems for engineering : a tutorial. *Proceedings of the IEEE*, 83(3) :345–377, 1995.
- [83] Lotfi A Zadeh. *Fuzzy sets, fuzzy logic, and fuzzy systems : selected papers by Lotfi A Zadeh*, volume 6. World Scientific, 1996.
- [84] Qilian Liang, Nilesh N Karnik, and Jerry M Mendel. Connection admission control in atm networks using survey-based type-2 fuzzy logic systems. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 30(3) :329–339, 2000.
- [85] Jerry M Mendel. Computing derivatives in interval type-2 fuzzy logic systems. *IEEE Transactions on Fuzzy Systems*, 12(1) :84–98, 2004.
- [86] Jerry M Mendel. Uncertainty, fuzzy logic, and signal processing. *Signal Processing*, 80(6) :913–933, 2000.
- [87] Jerry M Mendel and RI Bob John. Type-2 fuzzy sets made simple. *IEEE Transactions on fuzzy systems*, 10(2) :117–127, 2002.
- [88] Jerry M Mendel. Fuzzy logic systems for engineering : a tutorial. *Proceedings of the IEEE*, 83(3) :345–377, 1995.

- [89] Pierre Yves Glorennec. *Algorithmes d'apprentissage pour systèmes d'inférence floue*. Hermes, 1999.
- [90] Kevin Tai, Abdul-Rahman El-Sayed, Mohammad Biglarbegian, Claudia I Gonzalez, Oscar Castillo, and Shohel Mahmud. Review of recent type-2 fuzzy controller applications. *Algorithms*, 9(2) :39, 2016.
- [91] Nilesh N Karnik and Jerry M Mendel. Centroid of a type-2 fuzzy set. *Information Sciences*, 132(1) :195–220, 2001.
- [92] Jerry M Mendel. *Uncertain rule-based fuzzy logic systems : introduction and new directions*. Prentice Hall PTR Upper Saddle River, 2001.
- [93] Dongrui Wu and Jerry M Mendel. Enhanced karnik–mendel algorithms. *IEEE Transactions on Fuzzy Systems*, 17(4) :923–934, 2009.
- [94] Mahamed GH Omran. *Particle swarm optimization methods for pattern recognition and image processing*. PhD thesis, 2006.
- [95] Dan Simon. *Evolutionary optimization algorithms*. John Wiley & Sons, 2013.
- [96] James Kennedy. Swarm intelligence. In *Handbook of nature-inspired and innovative computing*, pages 187–219. Springer, 2006.
- [97] Carlos M Fonseca, Peter J Fleming, et al. Genetic algorithms for multiobjective optimization : Formulation discussion and generalization. In *Icga*, volume 93, pages 416–423, 1993.
- [98] Julio Barrera and Carlos A Coello Coello. Test function generators for assessing the performance of PSO algorithms in multimodal optimization. *Handbook of Swarm Intelligence, Adaptation, Learning, and Optimization*, 8 :89–117, 2011.
- [99] H Azzag, F Picarougne, C Guinot, and G Venturini. Un survol des algorithmes biomimétiques pour la classification. *Classification et fouille de données, RNTI-C*, 1, 2004.
- [100] Jason Brownlee. *Clever algorithms : nature-inspired programming recipes*. Jason Brownlee, 2011.
- [101] John H Holland. Adaptation in natural and artificial systems. an introductory analysis with application to biology, control, and artificial intelligence. *Ann Arbor, MI : University of Michigan Press*, 1975.
- [102] Swagatam Das, Ajith Abraham, and Amit Konar. Metaheuristic pattern clustering—an overview. In *Metaheuristic Clustering*, pages 1–62. Springer, 2009.
- [103] XH Shi, YC Liang, HP Lee, C Lu, and LM Wang. An improved ga and a novel PSO-GA-based hybrid algorithm. *Information Processing Letters*, 93(5) :255–261, 2005.

- [104] Kennedy J and Eberhart R. Particle swarm optimization. *Neural Networks, 1995. Proceedings., IEEE International Conference on*, 4 :1942–1948, 1995.
- [105] Craig W Reynolds. Flocks, herds and schools : A distributed behavioral model. *ACM SIGGRAPH computer graphics*, 21(4) :25–34, 1987.
- [106] Frank Heppner and Ulf Grenander. A stochastic nonlinear model for coordinated bird flocks. *The ubiquity of chaos*, pages 233–238, 1990.
- [107] Ilhem Boussaid. *Perfectionnement de metaheuristiques pour l'optimisation continue*. PhD thesis, Universite Paris-Est, 2013.
- [108] James Kennedy and Rui Mendes. Population structure and particle swarm performance. In *Evolutionary Computation, 2002. CEC'02. Proceedings of the 2002 Congress on*, volume 2, pages 1671–1676. IEEE, 2002.
- [109] Xin-She Yang. *Nature-inspired metaheuristic algorithms*. Luniver press, 2010.
- [110] Xin-She Yang. Firefly algorithm, levy flights and global optimization. *Research and development in intelligent systems XXVI*, pages 209–218, 2010.
- [111] Xin-She Yang. Firefly algorithm, stochastic test functions and design optimisation. *International Journal of Bio-Inspired Computation*, 2(2) :78–84, 2010.
- [112] Xin-She Yang. Firefly algorithms for multimodal optimization. In *International symposium on stochastic algorithms*, pages 169–178. Springer, 2009.
- [113] Dan Simon. Biogeography-based optimization. *IEEE transactions on evolutionary computation*, 12(6) :702–713, 2008.
- [114] Wenyin Gong, Zhihua Cai, Charles X Ling, and Hui Li. A real-coded biogeography-based optimization with mutation. *Applied Mathematics and Computation*, 216(9) :2749–2758, 2010.
- [115] Hongwei Mo, Zhidan Xu, Lifang Xu, Zhou Wu, and Haiping Ma. Constrained multiobjective biogeography optimization algorithm. *The Scientific World Journal*, 2014, 2014.
- [116] Wen-Fang Xie and Ahmad B Rad. Fuzzy on-line identification of SISO nonlinear systems. *Fuzzy sets and systems*, 107(3) :323–334, 1999.
- [117] Tor Arne Johansen and Robert Babuska. Multiobjective identification of takagi-sugeno fuzzy models. *IEEE Transactions on Fuzzy Systems*, 11(6) :847–860, 2003.
- [118] S Lee and Gary G Yen. Analysis of takagi-sugeno fuzzy models in system identification for model-based control. *Control and intelligent systems*, 32(2) :69–79, 2004.

- [119] Sai Sumathi, P Surekha, and P Surekha. Computational intelligence paradigms : theory and applications using matlab. 1, 2010.
- [120] K Chafaa, M Ghanai, and Khier Benmahammed. Fuzzy modelling using kalman filter. *IET Control Theory & Applications*, 1(1) :58–64, 2007.
- [121] Leandro dos Santos Coelho and B Meirelles Herrera. Fuzzy modeling using chaotic particle swarm approaches applied to a yo-yo motion system. pages 2293–2298, 2006.
- [122] Li Yong and Tang Ying-Gan. Chaotic system identification based on a fuzzy wiener model with particle swarm optimization. *Chinese Physics Letters*, 27(9) :090503, 2010.
- [123] Rahib H Abiyev, Okyay Kaynak, Tayseer Alshanableh, and Fakhreddin Mamedov. A type-2 neuro-fuzzy system based on clustering and gradient techniques applied to system identification and channel equalization. *Applied Soft Computing*, 11(1) :1396–1406, 2011.
- [124] Huaguang Zhang, Yanhong Luo, and Derong Liu. A new fuzzy identification method based on adaptive critic designs. *Advances in Neural Networks-ISNN 2006*, pages 804–809, 2006.
- [125] Nianyin Zeng, Zidong Wang, Yurong Li, Min Du, and Xiaohui Liu. Inference of nonlinear state-space models for sandwich-type lateral flow immunoassay using extended kalman filtering. *IEEE Transactions on Biomedical Engineering*, 58(7) :1959–1966, 2011.
- [126] Nianyin Zeng, Zidong Wang, Yurong Li, Min Du, and Xiaohui Liu. Identification of nonlinear lateral flow immunoassay state-space models via particle filter approach. *IEEE Transactions on Nanotechnology*, 11(2) :321–327, 2012.
- [127] TNE Greville. Spline functions, interpolation, and numerical quadrature. *Mathematical methods for digital computers*, 2 :156–168, 1967.
- [128] William H Press, Saul A Teukolsky, William T Vetterling, and Brian P Flannery. Numerical recipes in c : The art of scientific computing ; cambridge. 1992.
- [129] PhysioNet ECG database : The MIT-BIH Arrhythmia Database. <https://physionet.org/physiobank/database/mitdb/>.
- [130] Mohammed Assam Ouali, Mouna Ghanai, and Kheireddine Chafaa. A new type-2 fuzzy modelling and identification for electrophysiological signals : a comparison between pso, bbo, fa and ga approaches. *International Journal of Modelling, Identification and Control*, 29(2) :163–184, 2018.

- [131] Bart Kosko. Fuzzy systems as universal approximators. *IEEE transactions on computers*, 43(11) :1329–1333, 1994.
- [132] PhysioNet ECG database : The MIT-BIH Normal Sinus Rhythm Database. <https://physionet.org/physiobank/database/nsrdb/>.
- [133] Kumpati S Narendra and Kannan Parthasarathy. Identification and control of dynamical systems using neural networks. *IEEE Transactions on neural networks*, 1(1) :4–27, 1990.
- [134] M Reza Mashinchi and Ali Selamat. An improvement on genetic-based learning method for fuzzy artificial neural networks. *Applied Soft Computing*, 9(4) :1208–1216, 2009.
- [135] M Popescu, P Cristea, and A Bezerianos. High resolution ECG filtering using adaptive bayesian wavelet shrinkage. In *Computers in Cardiology 1998*, pages 401–404. IEEE, 1998.
- [136] Allan Kardec Barros, Ali Mansour, and Noboru Ohnishi. Removing artifacts from electrocardiographic signals using independent components analysis. *Neurocomputing*, 22(1) :173–186, 1998.
- [137] Vincenc Almenar and Antonio Albiol. A new adaptive scheme for ECG enhancement. *Signal Processing*, 75(3) :253–263, 1999.
- [138] PE Tikkanen. Nonlinear wavelet and wavelet packet denoising of electrocardiogram signal. *Biological cybernetics*, 80(4) :259–267, 1999.
- [139] Shahriar Iravanian and Leslie Tung. A novel algorithm for cardiac biosignal filtering based on filtered residue method. *IEEE Transactions on Biomedical Engineering*, 49(11) :1310–1317, 2002.
- [140] Ergun . Electrocardiogram signals de-noising using lifting-based discrete wavelet transform. *Computers in Biology and Medicine*, 34(6) :479–493, 2004.
- [141] S Poornachandra and N Kumaravel. Hyper-trim shrinkage for denoising of ECG signal. *Digital Signal Processing*, 15(3) :317–327, 2005.
- [142] Omid Sayadi and Mohammad Bagher Shamsollahi. ECG denoising with adaptive bionic wavelet transform. In *Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE*, pages 6597–6600. IEEE, 2006.
- [143] Manuel Blanco-Velasco, Binwei Weng, and Kenneth E Barner. ECG signal denoising and baseline wander correction based on the empirical mode decomposition. *Computers in biology and medicine*, 38(1) :1–13, 2008.

- [144] S Poornachandra. Wavelet-based denoising using subband dependent threshold for ecg signals. *Digital signal processing*, 18(1) :49–55, 2008.
- [145] Yunfeng Wu, Rangaraj M Rangayyan, Yachao Zhou, and Sin-Chun Ng. Filtering electrocardiographic signals using an unbiased and normalized adaptive noise reduction system. *Medical Engineering & Physics*, 31(1) :17–26, 2009.
- [146] CR Meyer and HN Keiser. Electrocardiogram baseline noise estimation and removal using cubic splines and state-space computation techniques. *Computers and Biomedical Research*, 10(5) :459–470, 1977.
- [147] JP Marques De Sa. Digital fir filtering for removal of ECG baseline wander. *Journal of Clinical Engineering*, 7(3) :235–240, 1982.
- [148] Jan A Van Alste and TS Schilder. Removal of base-line wander and power-line interference from the ECG by an efficient fir filter with a reduced number of taps. *IEEE transactions on biomedical engineering*, (12) :1052–1060, 1985.
- [149] Jan A van Alste, W Van Eck, and OE Herrmann. Ecg baseline wander reduction using linear phase filters. *Computers and Biomedical Research*, 19(5) :417–427, 1986.
- [150] L Sornmo. Time-varying digital filtering of ECG baseline wander. *Medical and Biological Engineering and Computing*, 31(5) :503–508, 1993.
- [151] Bachir Boucheham, Youcef Ferdi, and Mohamed Chawki Batouche. Piecewise linear correction of ECG baseline wander : a curve simplification approach. *Computer methods and programs in biomedicine*, 78(1) :1–10, 2005.
- [152] M Jacek and Norbert Henzel. ECG baseline wander and powerline interference reduction using nonlinear filter bank. *Signal processing*, 85(4) :781–793, 2005.
- [153] Mohammad Ali Tinati and Behzad Mozaffary. A wavelet packets approach to electrocardiograph baseline drift cancellation. *International journal of biomedical imaging*, 2006, 2006.
- [154] TY Ji, Z Lu, QH Wu, and Z Ji. Baseline normalisation of ECG signals using empirical mode decomposition and mathematical morphology. *Electronics letters*, 44(2) :1,2008.
- [155] Matteo Milanese, Nicola Martini, Nicola Vanello, Vincenzo Positano, Maria Filomena Santarelli, and Luigi Landini. Independent component analysis applied to the removal of motion artifacts from electrocardiographic signals. *Medical & biological engineering & computing*, 46(3) :251–261, 2008.

- [156] Xiao Hu, Zhong Xiao, and Ni Zhang. Removal of baseline wander from ECG signal based on a statistical weighted moving average filter. *Journal of Zhejiang University SCIENCE C*, 12(5) :397–403, 2011.
- [157] V Zarzoso, AK Nandi, and E Bacharakis. Maternal and foetal ecg separation using blind source separation methods. *Mathematical Medicine and Biology*, 14(3) :207–225, 1997.
- [158] Lieven De Lathauwer, Bart De Moor, and Joos Vandewalle. Fetal electrocardiogram extraction by blind source subspace separation. *IEEE transactions on biomedical engineering*, 47(5) :567–572, 2000.
- [159] Ali Khamene and Shahriar Negahdaripour. A new method for the extraction of fetal ECG from the composite abdominal signal. *IEEE Transactions on Biomedical Engineering*, 47(4) :507–516, 2000.
- [160] F Mochimaru, Y Fujimoto, and Y Ishikawa. Detecting the fetal electrocardiogram by wavelet theory-based methods. *Progress in Biomedical Research*, 7 :185–193, 2002.
- [161] Vincent Vigneron, Anisoara Paraschiv-Ionescu, Annabelle Azancot, Olivier Sibony, and Christian Jutten. Fetal electrocardiogram extraction based on non-stationary ica and wavelet denoising. In *Signal Processing and Its Applications, 2003. Proceedings. Seventh International Symposium on*, volume 2, pages 69–72. IEEE, 2003.
- [162] Khaled Assaleh and Hasan Al-Nashash. A novel technique for the extraction of fetal ECG using polynomial networks. *IEEE Transactions on Biomedical Engineering*, 52(6) :1148–1152, 2005.
- [163] Khaled Assaleh. Adaptive neuro-fuzzy inference systems for extracting fetal electrocardiogram. In *Signal Processing and Information Technology, 2006 IEEE International Symposium on*, pages 122–126. IEEE, 2006.
- [164] Michiyoshi Sato, Yoshitaka Kimura, Shinichi Chida, Takuya Ito, Norihiro Katayama, Kunihiro Okamura, and Mitsuyuki Nakao. A novel extraction method of fetal electrocardiogram from the composite abdominal signal. *IEEE transactions on biomedical engineering*, 54(1) :49–58, 2007.
- [165] Mohammad Niknazar, Bertrand Rivet, and Christian Jutten. Fetal ecg extraction by extended state kalman filtering based on single-channel recordings. *IEEE Transactions on Biomedical Engineering*, 60(5) :1345–1352, 2013.
- [166] Liang Han, Xiu-juan Pu, and Xiao-jun Chen. Method of fetal electrocardiogram extraction based on  $\nu$ -support vector regression. *IET Signal Processing*, 9(5) :430–439, 2015.

- [167] Hajar Ahmadiéh and Babak Mohammadzadeh Asl. Fetal ECG extraction via type-2 adaptive neuro-fuzzy inference systems. *Computer Methods and Programs in Bio-medicine*, 142 :101–108, 2017.
- [168] Mohammed Assam Ouali, Kheireddine Chafaa, Mouna Ghanai, Louis Moreno Lorente, and Dolores Blanco Rojas. ECG denoising using extended kalman filter. In *Computer Applications Technology (ICCAT), 2013 International Conference on*, pages 1–6. IEEE, 2013.
- [169] Mohammed Assam Ouali and Kheireddine Chafaa. Svd-based method for ECG denoising. In *Computer Applications Technology (ICCAT), 2013 International Conference on*, pages 1–4. IEEE, 2013.
- [170] Mohammed Assam Ouali, Mouna Ghanai, and Kheireddine Chafaa. Upper envelope detection of ECG signals for baseline wander correction : a pilot study. *Turkish Journal of Electrical Engineering & Computer Sciences*, 26(2) :803–816, 2018.
- [171] Mohammed Assam Ouali and Kheireddine Chafaa. Separation of composite maternal ECG using SVD decomposition. In *Computer Applications Technology (ICCAT), 2013 International Conference on*, pages 1–4. IEEE, 2013.
- [172] Tomohiro Takagi and Michio Sugeno. Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics*, (1) :116–132, 1985.
- [173] L-X Wang. Stable adaptive fuzzy control of nonlinear systems. *IEEE Transactions on fuzzy systems*, 1(2) :146–155, 1993.
- [174] PhysioNet ECG database : The MIT-BIH Noise Stress Test Database. <https://physionet.org/physiobank/database/nstdb/>.
- [175] M Sabarimalai Manikandan and Samarendra Dandapat. Multiscale entropy-based weighted distortion measure for ECG coding. *IEEE Signal Processing Letters*, 15 :829–832, 2008.
- [176] Simon S Haykin et al. *Kalman filtering and neural networks*. Wiley Online Library, 2001.
- [177] MS Grewal and AP Andrews. *Kalman filtering : theory and practice using matlab*, 2001.
- [178] Robert Grover Brown. *Introduction to random signal analysis and Kalman filtering*. John Wiley & Sons, 1983.
- [179] Pierre Borne, Frédéric Rotella, Geneviève Dauphin-Tanguy, Irène Zambettakis, and Jean Pierre Richard. *Commande et optimisation des processus*. Technip, 1990.

- [180] Brian DO Anderson and John B Moore. Optimal filtering. *Englewood Cliffs*, 21 :22–95, 1979.
- [181] Thomas Kailath, Ali H Sayed, and Babak Hassibi. *Linear estimation*, volume 1. Prentice Hall Upper Saddle River, NJ, 2000.
- [182] Eli Brookner. *Tracking and Kalman filtering made easy*,. Wiley Online Library, 1998.
- [183] AH Mohamed and KP Schwarz. Adaptive kalman filtering for ins/gps. *Journal of geodesy*, 73(4) :193–203, 1999.
- [184] David Skillicorn. *Understanding complex datasets : data mining with matrix decompositions*. CRC press, 2007.
- [185] Maurice Charbit. *Digital signal and image processing using MATLAB*, volume 666. John Wiley & Sons, 2010.
- [186] R Warlar and C Eswaran. Integer coefficient bandpass filter for the simultaneous removal of baseline wander, 50 and 100 hz interference from the ECG. *Medical and Biological Engineering and Computing*, 29(3) :333–336, 1991.
- [187] Leif Sornmo and Pablo Laguna. *Bioelectrical signal processing in cardiac and neurological applications*, volume 8. Academic Press, 2005.
- [188] Gari D Clifford, Francisco Azuaje, and P McSharry. Advanced methods and tools for ECG data analysis. norwood, ma, usa : Artech house, 2006.
- [189] L Thomas Sheffield, Alan Berson, Deborah Bragg-Remschel, Paul C Gillette, Russell E Hermes, L Hinkle, Harold Kennedy, David M Mirvis, and Charles Oliver. Aha special report. recommendations for standards of instrumentation and practice in the use of ambulatory electrocardiography. the task force of the committee on electrocardiography and cardiac electrophysiology of the council on clinical cardiology. *Circulation*, 71(3) :626A, 1985.
- [190] Paul Kligfield, Leonard S Gettes, James J Bailey, Rory Childers, Barbara J Deal, E William Hancock, Gerard van Herpen, Jan A Kors, Peter Macfarlane, David M Mirvis, et al. Recommendations for the standardization and interpretation of the electrocardiogram. *Circulation*, 115(10) :1306–1324, 2007.
- [191] Nicos Maglaveras, Telemachos Stamkopoulos, Konstantinos Diamantaras, Costas Pappas, and Michael Strintzis. ECG pattern recognition and classification using non-linear transformations and neural networks : a review. *International journal of medical informatics*, 52(1) :191–208, 1998.
- [192] Zümray Dokur and Tamer Ölmez. ECG beat classification by a novel hybrid neural network. *Computer methods and programs in biomedicine*, 66(2) :167–181, 2001.

- [193] Mehmet Engin. ECG beat classification using neuro-fuzzy network. *Pattern Recognition Letters*, 25(15) :1715–1722, 2004.
- [194] Yuksel ozbay, Rahime Ceylan, and Bekir Karlik. A fuzzy clustering neural network architecture for classification of ECG arrhythmias. *Computers in Biology and Medicine*, 36(4) :376–388, 2006.
- [195] Yeong Pong Meau, Fatimah Ibrahim, Selvanathan AL Narainasamy, and Razali Omar. Intelligent classification of electrocardiogram (ECG) signal using extended kalman filter (ekf) based neuro fuzzy system. *Computer Methods and Programs in Biomedicine*, 82(2) :157–168, 2006.
- [196] Sung-Nien Yu and Kuan-To Chou. A switchable scheme for ECG beat classification based on independent component analysis. *Expert Systems with Applications*, 33(4) :824–829, 2007.
- [197] Elif Derya Ubeyli. Ecg beats classification using multiclass support vector machines with error correcting output codes. *Digital Signal Processing*, 17(3) :675–684, 2007.
- [198] Sung-Nien Yu and Kuan-To Chou. Integration of independent component analysis and neural networks for ECG beat classification. *Expert Systems with Applications*, 34(4) :2841–2846, 2008.
- [199] Sung-Nien Yu and Kuan-To Chou. Selection of significant independent components for ECG beat classification. *Expert Systems with Applications*, 36(2) :2088–2096, 2009.
- [200] Elif Derya Ubeyli. Adaptive neuro-fuzzy inference system for classification of ECG signals using lyapunov exponents. *Computer methods and programs in biomedicine*, 93(3) :313–321, 2009.
- [201] Roshan Joy Martis, Chandan Chakraborty, and Ajoy K Ray. A two-stage mechanism for registration and classification of ECG using gaussian mixture model. *Pattern Recognition*, 42(11) :2979–2988, 2009.
- [202] Rahime Ceylan, Yüksel Özbay, and Bekir Karlik. A novel approach for classification of ecg arrhythmias : Type-2 fuzzy clustering neural network. *Expert Systems with Applications*, 36(3) :6721–6726, 2009.
- [203] Amit K Mishra and Shantanu Raghav. Local fractal dimension based ECG arrhythmia classification. *Biomedical Signal Processing and Control*, 5(2) :114–123, 2010.
- [204] Yüksel Özbay and Gülay Tezel. A new method for classification of ECG arrhythmias using neural network with adaptive activation function. *Digital Signal Processing*, 20(4) :1040–1049, 2010.

- [205] Mehmet Korurek and Berat Dogan. ECG beat classification using particle swarm optimization and radial basis function neural network. *Expert systems with Applications*, 37(12) :7563–7569, 2010.
- [206] S Gayathri, M Suchetha, and V Latha. ECG arrhythmia detection and classification using relevance vector machine. *Procedia Engineering*, 38 :1333–1339, 2012.
- [207] Jeen-Shing Wang, Wei-Chun Chiang, Yu-Liang Hsu, and Ya-Ting C Yang. ECG arrhythmia classification using a probabilistic neural network with a feature reduction method. *Neurocomputing*, 116 :38–45, 2013.
- [208] Zahia Zidelmal, Ahmed Amirou, Djaffar Ould-Abdeslam, and Jean Merckle. ECG beat classification using a cost sensitive classifier. *Computer methods and programs in biomedicine*, 111(3) :570–577, 2013.
- [209] Roshan Joy Martis, U Rajendra Acharya, and Lim Choo Min. ECG beat classification using pca, lda, ica and discrete wavelet transform. *Biomedical Signal Processing and Control*, 8(5) :437–448, 2013.
- [210] K Padmavathi and K Sri Ramakrishna. Classification of ECG signal during atrial fibrillation using autoregressive modeling. *Procedia Computer Science*, 46 :53–59, 2015.
- [211] Fatin A Elhaj, Naomie Salim, Arief R Harris, Tan Tian Swee, and Taqwa Ahmed. Arrhythmia recognition and classification using combined linear and nonlinear features of ecg signals. *Computer methods and programs in biomedicine*, 127 :52–63, 2016.
- [212] Shameer Faziludeen and Praveen Sankaran. ECG beat classification using evidentialk-nearest neighbours. *Procedia Computer Science*, 89 :499–505, 2016.
- [213] Shirin Shadmand and Behbood Mashoufi. A new personalized ECG signal classification algorithm using block-based neural network and particle swarm optimization. *Biomedical Signal Processing and Control*, 25 :12–23, 2016.
- [214] Hannu Olkkonen. Discrete wavelet transforms : Algorithms and applications. *In-Tech, Janeza Trdine*, 9 :51000, 2011.
- [215] Olivier Rioul and Martin Vetterli. Wavelets and signal processing. *IEEE signal processing magazine*, 8(4) :14–38, 1991.
- [216] C Sidney Burrus, Ramesh A Gopinath, and Haitao Guo. Introduction to wavelets and wavelet transforms : a primer. 1997.
- [217] Stephane G Mallat. A theory for multiresolution signal decomposition : the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, 11(7) :674–693, 1989.

- 
- [218] G Strang and T Nguyen. Wavelets and filter banks. wellesley–cambridge press, wellesley, massachusetts, 1996. Technical report, ISBN 0-9614088-7-1.
- [219] Hanchuan Peng, Fuhui Long, and Chris Ding. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Transactions on pattern analysis and machine intelligence*, 27(8) :1226–1238, 2005.
- [220] Guang-Bin Huang, Qin-Yu Zhu, and Chee-Kheong Siew. Extreme learning machine : theory and applications. *Neurocomputing*, 70(1) :489–501, 2006.
- [221] Marc Antonini, Michel Barlaud, Pierre Mathieu, and Ingrid Daubechies. Image coding using wavelet transform. *IEEE Transactions on image processing*, 1(2) :205–220, 1992.
- [222] M Sabarimalai Manikandan and Samarendra Dandapat. Wavelet energy based diagnostic distortion measure for ECG. *Biomedical Signal Processing and Control*, 2(2) :80–96, 2007.