

Biométrie par signaux physiologiques Samer Chantaf

► To cite this version:

Samer Chantaf. Biométrie par signaux physiologiques. Autre. Université Paris-Est, 2011. Français. NNT: 2011PEST1009 . tel-00778089

HAL Id: tel-00778089 https://theses.hal.science/tel-00778089

Submitted on 18 Jan2013

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers. L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



THESE DE DOCTORAT DE L'UNIVERSITE PARIS EST CRETEIL (UPEC) UFR de sciences et de technologie

Présenté par

Samer CHANTAF

Pour obtenir le grade de

DOCTEUR D'UNIVERSITE EN SCIENCES

Spécialité : SCIENCES DE L'INGENIEUR

Sujet de la thèse :

Biométrie par signaux physiologiques

Thèse préparée au sein du

Laboratoire Images, Signaux et Systèmes intelligents (LISSI, E.A. 3956)

Soutenue publiquement le 02/05/2011 devant le jury composé de :

Rapporteur	Mme	. Catherine Marque	Professeur	Université de Technologie de Compiègne
Rapporteur	M.	Oussama Bazzi	Professeur	Université Libanaise, Sciences III, Beyrouth
Rapporteur	Mme	. Edwige Pissaloux	Professeur	Université Pierre et Marie-Curie (UPMC)
Examinateur	M.	Jérôme Boudy	Maître de Conférences	Télécom Sud-Paris (Evry)
Examinateur	M.	Patrick Karasinski	Maître de Conférences	Université Paris-Est Créteil (UPEC)
Co-directeur	M.	Mohamad Khalil	Professeur	Université Libanaise, Génie I, Tripoli
Directeur	M.	Amine Nait-ali	Professeur	Université Paris-Est Créteil (UPEC)

Remerciements

Ce travail de recherche n'aurait pas été possible sans le soutien et la participation de plusieurs personnes auxquelles je souhaite exprimer toute ma gratitude.

Je remercie, en premier lieu, professeur Amine NAIT-ALI professeur à l'Université Paris Est Créteil (UPEC) et directeur de cette thèse, pour avoir assuré le suivi de cette thèse. Son expérience et son aide scientifique m'ont été essentielles. Sa disponibilité ainsi que l'attention qu'il a portée à ce travail ont été un atout précieux dans l'avancement de cette étude.

Mes plus vifs remerciements au Professeur Mohamad KHALIL, chef de centre de recherche à l'Université Libanaise et co-directeur de cette thèse, pour m'avoir accueilli au sein de son équipe de recherche. Qu'il soit assuré de ma reconnaissance et ma gratitude.

Je tiens à remercier également Monsieur le Professeur Yacine AMIRAT, Directeur du Laboratoire Images, Signaux et Systèmes Intelligents, pour m'avoir accueilli au sein de son laboratoire.

Je remercie Madame Catherine Marque, Professeur à l'Université de Technologie de Compiègne, d'avoir accepté également la lourde tâche de rapporteur.

Je tiens à remercier Madame Edwige Pissaloux, Professeur à l'Université Pierre et Marie-Curie, pour son intérêt à ce sujet de recherche et pour avoir accepté d'être rapporteur.

Je remercie Monsieur Oussama Bazzi, Professeur à l'Université Libanaise, d'avoir accepté également la lourde tâche de rapporteur.

Je remercie Monsieur Jérôme Boudy, Maître de Conférences, du département électronique et physique de Télécom Sud-Paris (Evry) pour avoir accepte de faire partie de mon jury.

Je souhaite témoigner également mes profonds remerciements à tous les membres et les doctorants du LISSI et spécialement Abbas EL DORR.

Enfin je suis reconnaissant, à ma femme, à mes parents pour leur soutien pendant ma thèse.

Table des matières

Introduction générale	9
Chapitre 1	.11
Etat de l'art sur la biométrie	.11
1.1 Introduction	.11
1.2 Définition de la biométrie	.11
1.3 Principe de fonctionnement	.12
1.4 Performances des systèmes	.13
1.5 Etat de l'art des techniques biométriques	.13
1.5.1 Introduction	.13
1.5.2 Modalités biométriques	.14
1.6 Objectif de la thèse	.18
1.7 Biométrie par signaux physiologiques	.20
1.7.1 Biométrie par l'ECG	.20
A. Le système cardiovasculaire	.20
B. Les dérivations électrocardiographies	.21
C. Analyse de l'ECG	.23
D. Les techniques biométriques par ECG	.24
1.7.2 Biométrie par EMG	.25
A. Muscle squelettique	.25
B. Organisation anatomique	.26
C. Electromyographie	.28
1.7.3 Biométrie par réponse motrice M	.29
A. Le système nerveux	.29
B. La conduction nerveuse	.29
1.8 Conclusion	.31
Chapitre 2	.32
Modélisation de l'ECG par réseau d'ondelettes	.32
2.1 Introduction	.32
2.2 Etat de l'art de la biométrie par ECG	.33
2.3 Nouvelle technique biométrique par l'ECG	.37
2.3.1 Introduction	.37
2.3.2 Prétraitement du signal ECG	.37
2.3.3 Détection des complexes QRS	.38
2.3.4 Segmentation du signal ECG	.39
2.3.5 Modélisation par réseau d'ondelette	.42
A. Réseau d'ondelettes	.42
B. Extraction des paramètres	.58
2.4 Conclusion	.60
Chapitre 3	.62
Caractérisation de l'EMG pour la biométrie	.62
3.1 Introduction	.62
I.1 Introduction	.63
I.2 SEMG	.63

I.3 Nouvelle technique biométrique par EMG	64
I.3.1 Introduction	64
I.3.2 Acquisition des SEMG	65
I.3.3 Estimation de la densité spectrale de puissance	65
A. Densité Spectrale de Puissance	65
B. Le périodogramme	66
C. La méthode de Welch	67
I.3.4 Extraction des paramètres à partir de la densité spectrale	69
A. Introduction	69
B. Paramètres spectraux	69
II. La biométrie par réponse motrice M	72
II.1 Introduction	72
II.2 Etude de la conduction nerveuse	72
A. Etude de la conduction motrice	72
B. Etude de la conduction sensitive	73
C. Etude de l'onde F	73
D. Etude du Réflexe H	73
II.3 La conduction nerveuse motrice M	74
II.4 Nouvelle technique biométrique par réponse motrice M	76
II.4.1 Introduction	76
II.4.2 Acquisition des réponses motrices	76
II.4.3 Modélisation et extraction des paramètres	77
3.2 Conclusion	78
Chapitre 4	80
Adaptation des paramètres et classification biométrique : résultats	80
4.1 Introduction	80
4.2 Classification	80
4.3 Réseau de neurones	81
4.3.1 Introduction	81
4.3.2 Structure du réseau neuronal artificiel	84
A. Réseau neuronal multicouche de type Feedforward	84
B. Différents types de réseaux neuronaux multicouches	85
4.4 Adaptation des paramètres et résultats	94
A. Résultats de la biométrie par ECG	94
A.1 Acquisition et traitement de l'ECG	94
A.2 Extraction des paramètres	95
A.3 Classification et résultats	96
A.4 Analyse	99
B. Résultats biométriques par EMG	102
B.1 Acquisition des SEMG	102
B.2 Estimation de la DSP et extraction des paramètres	102
B.3 Classification et résultats	103
B.4 Analyse	105
C. Résultats biométriques par réponse motrice M	107
C 1 Acquisition des réponses motrices	108
C.1 Acquisition des reponses motrices	107

	C.3 Classification et résultats	107
4.5	Conclusion	110
Co	nclusion générale et perspectives	111

Figure 1.1 : Diagramme bloc de l'identification biométrique12
Figure 1.2 : Performances des systèmes13
Figure 1.3: Points caractéristiques de l'empreinte digitale14
Figure 1.4: Distinction entre l'iris et la rétine15
Figure 1.5 : Méthode d'extraction des caractéristiques du visage16
Figure 1.6 : Bloc diagramme de l'identification par signaux physiologiques
Figure 1.7 : Propagation de l'influx à l'intérieur du cœur20
Figure 1.8 : Dérivations standard (bipolaires)21
Figure 1.9: Dérivations unipolaires périphériques22
Figure 1.10: Position des Electrodes Précordiales23
Figure 1.11: Battement d'un ECG23
Figure 1.12: Anatomie du muscle strié squelettique26
Figure 1.13: Exemple d'unité motrice27
Figure 1.14: schéma d'un neurone30
Figure 1.15: Transmission de l'influx nerveux30
Figure 2.1 : battement cardiaque présentant les points fiduciels
Figure 2.2: Détermination des points fiduciels34
Figure 2.3: Démonstration graphique des caractéristiques analytiques
Figure 2.4 : Schéma générale de notre méthode
Figure 2.5 : Organigramme de la procédure de détection des pics R
Figure 2.6 : Segmentation d'un signal40
Figure 2.7: (a) avant correction, (b) après correction41
Figure 2.8: Neurone non linéaire avec ondelette (wavelon)44
Figure 2.9: Structure du réseau d'ondelettes44
Figure 2.10: Ondelette multidimensionnelle créée par le produit tensoriel45
Figure 2.11: Exemple d'une ondelette radiale (inverse du chapeau mexicain)47
Figure 2.12 : Les paramètres de classification58
Figure 2.13 : (a) Battement moyenné (Individu 1); (b) Battement moyenné (Individu 2); (c)
10 ondelettes utilisées pour la modélisation (Individu 1) ; (d) 10 ondelettes utilisées pour la
modélisation (Individu 2)

Figure 2.14 : (a) le paramètre de translation de la deuxième ondelette; (b) le paramètre de
dilatation de la deuxième ondelette; (c) le paramètre de poids de la deuxième ondelette;60
Figure 3.1 : Schéma générale de l'approche biométrique par SEMG64
Figure 3.2 : Mesure des SEMG65
Figure 3.3: Paramétrage du spectre71
Figure 3.4 : Boucle réflexe Ia–Alpha74
Figure 3.5 : Schéma générale de notre méthode76
Figure 3.6 : (a) Position d'électrodes ; (b) Stimulation ; (c) Réponse motrice M77
Figure 3.7: (a) Réponse motrice M ; (b) Modélisation de la réponse M78
Figure 4.1 : Le modèle de neurone formel82
Figure 4.2 : Traits caractéristiques structurels d'un réseau neuronal à trois couches85
Figure 4.8 : Fonction gaussienne
Figure 4.9 : Neurone non linéaire avec une fonction gaussienne
Figure 4.10 : Structure d'un réseau RBFNN88
Figure 4.11 : (a) Signal Original ; (b) Signal Prétraité95
Figure 4.12: Modélisation de l'ECG: (a) battement moyenné; (b) 10 ondelettes utilisées
pour la modélisation ;96
(c) modèle de l'ECG96
Figure 4.13 : Structure du réseau RBFNN97
Table 1: Résultats de la performance d'identification dans le cas de séries de 5 battements
moyennés97
Table 2: Résultats de la performance d'identification dans le cas de séries de 10 battements
moyennés
Figure 5.14: Effet du bruit sur la performance99
Figure 4.15 : (a) signal ECG; (b) signal ECG avec SNR (10 dB); (c) signal ECG avec SNR
(20 dB) (d) signal ECG avec SNR (30 dB)100
Figure 4.16 : Variabilités du rythme cardiaque (VRC)101
Figure 4.17 : (a) position initiale des électrodes (b) déplacement des électrodes101
Figure 4.18 : Effet du déplacement d'électrodes102
Figure 4.19 : SEMG en réponse à une force 5Kg (a) DSP en cas de 5Kg (b) SEMG en
réponse à une force 10Kg (c) DSP en cas de 10Kg (d)103

Figure 4.20 : Structure du réseau RBFNN104
Table 3 : Résultats de la performance d'identification dans le cas d'une force d'intensité 5
Kg104
Table 4 : Résultats de la performance d'identification dans le cas d'une force d'intensité 10
Kg105
Figure 4.21 : Courbe de performances mettant en évidence la sensibilité de la technique
d'identification par rapport à l'effet de fatigue. Des variations très faibles sont constatées.
Figure 4.22 : Sensibilité de performances par rapport au déplacement des électrodes106
Figure 4.23 : Structure du réseau RBF108
Table 5: Résultats de la performance d'identification dans le cas d'une stimulation de
20mA
Table 6: Résultats de la performance d'identification dans le cas d'une stimulation de
30mA

Introduction générale

La biométrie est une alternative sécurisée des méthodes traditionnelles de vérification d'identité des individus tels que les mots de passe et autres. Vue la nécessité croissante du besoin de sécurité, la biométrie est en pleine croissance et la recherche de nouvelles techniques biométriques est d'actualité.

La biométrie utilise les caractéristiques anatomiques, physiologiques ou comportementales uniques à chacun afin de déterminer l'identité des individus. Il existe plusieurs types de méthodes biométriques tels que l'empreinte digitale, la géométrie de la main, la reconnaissance du visage, l'iris, etc. Malheureusement, et avec le développement des technologies de falsification, ces caractéristiques peuvent être falsifiées d'où la nécessité de recherche de nouvelles caractéristiques difficiles à imiter comme les signaux physiologiques.

L'utilisation des signaux physiologiques tels que l'ECG et l'EMG n'est pas très répandue en biométrie. Les signaux physiologiques présentent des différences et des caractéristiques spécifiques à chaque individu permettant ainsi de les utiliser comme outils biométriques. Plusieurs méthodes d'identification biométrique basées sur l'ECG ont été proposées tels que Biel et al. en 1999, Wang et al. en 2006 et Plataniotis et al. en 2006. Par contre, aucune modalité basée sur l'EMG n'a été suggérée.

Dans cette thèse, trois méthodes d'identification biométrique basées sur les signaux physiologiques (ECG et EMG) ont été développées. L'objectif de nos travaux consiste à étudier de nouvelles approches biométriques atypiques dont la reproduction est difficile. La première méthode est fondée sur l'identification biométrique par ECG alors que les deux autres méthodes sont basées, d'une part, sur les signaux EMG de surface en réponse à une intensité fixe, et d'autre part, sur les réponses motrices obtenues suite à une stimulation électrique.

Ce rapport comporte une description détaillée des méthodes d'identification biométriques proposées. Il est structuré, en quatre chapitres.

Dans le premier chapitre, nous présentons une étude bibliographique sur la biométrie ainsi que sur le système cardiovasculaire, les muscles squelettiques et le système nerveux. Nous décrivons également l'ECG et l'EMG.

Le deuxième chapitre est consacré à la description de la méthode d'identification biométrique par ECG proposée, notamment à travers leur modélisation par des réseaux d'ondelettes.

Le troisième chapitre est dédié à la description des modalités biométriques basées sur l'EMG de surface et les réponses motrices.

Le quatrième chapitre regroupe les différents résultats issus des techniques étudiées durant cette thèse.

Enfin, une conclusion et des perspectives seront présentées dans le dernier chapitre.

Chapitre 1

Etat de l'art sur la biométrie

1.1 Introduction

La biométrie vise à identifier les personnes à partir de leurs caractéristiques physiques. L'utilisation de la biométrie s'est répandue énormément dans la vie quotidienne et trouve de nombreuses applications ; pour pénétrer dans un lieu et y circuler librement, pour accéder au poste de travail, retirer de l'argent, etc. La biométrie tend à remplacer peu à peu les codes d'accès et les mots de passe qui peuvent être changées ou volées. De nombreux travaux de recherche ont été menés et en cherche toujours de nouvelles méthodes.

Ce chapitre présente un état de l'art sur la biométrie. La première partie est consacrée à la définition de la biométrie et la description des modalités biométriques les plus répandues. Dans la deuxième partie, nous décrivons le but de la thèse. Un diagramme bloc illustre les différentes étapes de nos méthodes biométriques.

La troisième partie concerne l'anatomie du système cardiovasculaire, des muscles squelettiques et du système nerveux. Nous décrivons l'ECG et l'EMG ainsi que la conduction nerveuse.

1.2 Définition de la biométrie

La biométrie consiste à utiliser des caractéristiques physiques afin de déterminer l'identité d'une personne. Ces caractéristiques utilisées doivent être fiables et infalsifiables. En plus, elles doivent être universelles, uniques pour chaque individu, permanentes ne variant pas avec le temps, enregistrables et finalement mesurables.

Il existe plusieurs appondus biométriques, les plus connues étant :

1. biologiques : Odeur, sang, salive, urine, ADN...

- 2. comportementales : La dynamique de la signature, la frappe dynamique au clavier, la voix, la démarche...
- 3. morphologiques : empreintes digitales, forme de la main, traits du visage, structure des réseaux veineux de l'œil.... Ces caractéristiques sont stables, ne varient pas avec l'âge de l'individu et ne sont pas affectées par les conditions psychologiques telles que les effets du stress comme dans le cas des caractéristiques comportementales.

Dans ce qui suit, nous décrivons les méthodes d'identification biométrique les plus répandues.

1.3 Principe de fonctionnement

Un système biométrique est un système de reconnaissance de forme qui consiste d'abord à capter l'information biométrique à analyser de l'individu (e.g. image ou signal) puis en extraire les éléments caractéristiques et finalement comparer ces caractéristiques avec d'autres déjà mémorisées dans la base de données [1]. Ces différentes étapes sont données dans la figure 1.1.



Figure 1.1 : Diagramme bloc de l'identification biométrique.

1.4 Performances des systèmes

Il est impossible d'obtenir l'égalité entre le fichier "signature" créé lors de l'apprentissage et le fichier "signature" créé lors de la vérification ; en effet on ne peut pas reproduire à l'identique les éléments d'origine (une image, un son...), utilisés pour les traitements informatiques. Les performances des systèmes d'authentifications biométriques s'expriment par :

- **T.F.R.** Taux de faux rejets (*False Rejection Rate*) : Pourcentage de personnes rejetées par erreur.
- **T.F.A.** Taux de fausses acceptations (*False acceptance Rate*) : Pourcentage d'acceptations par erreur.
- **T.E.E.** Taux d'erreur égales (*Equal Error Rate*), donne un point sur lequel le T.F.A. est égal au T.F.R (figure 1.2).



Figure 1.2 : Performances des systèmes.

1.5 Etat de l'art des techniques biométriques

1.5.1 Introduction

Il existe une grande variété de modalités biométriques et il en apparaît continûment de nouvelles. En fait, aucune modalité ne peut assurer à la fois les performances en reconnaissances une précision suffisante et un confort d'utilisation dans toutes les situations. De plus, quelle que soit la modalité, il existe toujours des personnes réfractaires [2]. Dans ce qui suit, nous ne décrivons que les modalités les plus communes, à savoir le visage, la parole, les empreintes digitales, le contour de la main et l'iris de l'œil.

1.5.2 Modalités biométriques

Il existe plusieurs caractéristiques morphologiques uniques pour un individu et chacune pouvant être mesurée a plusieurs façons:

• Empreintes digitales (finger-scan): les empreintes digitales sont les traces laissées par les sillons des pulpes digitales. Le dessin formé est unique et diffère d'un individu à un autre. En pratique, il est quasiment impossible d'utiliser toutes les informations fournies par ce dessin (car trop nombreuses pour chaque individu), donc on extrait les caractéristiques principales telles que les bifurcations de crêtes (figure 1.3), les « îles », les lignes qui disparaissent, etc,... Une empreinte digitale contient en moyenne une centaine de points caractéristiques ou les « minuties ». On peut extraire environ 40 de ces points de la zone scannée. Statistiquement, qu'il est impossible de trouver 12 points identiques chez 2 individus.



Figure 1.3: Points caractéristiques de l'empreinte digitale.

 Géométrie de la main / du doigt (hand-scan): Cette modalité biométrique est l'une des plus répandues. Elle consiste à mesurer plusieurs caractéristiques de la main telle que forme de la main, longueur et largeur des doigts, formes des articulations, longueurs inter-articulations, etc,... Cette technique, utilisant principalement de l'imagerie infrarouge, présente des TFA assez élevés, surtout entre personnes de la même famille ou des jumeaux.

• Iris (iris-scan): Cette modalité est basée sur l'étude de la partie de l'œil visible (figure 1.4) :



Figure 1.4: Distinction entre l'iris et la rétine [3].

Le sujet se place en face du capteur qui scanne l'iris. L'image de l'iris est très complexe mais pratiquement unique et indépendante du code génétique de l'individu, et presque infalsifiable. Les caractéristiques quasi-infinies de l'iris ne varient pratiquement pas pendant la vie d'une personne à l'exception de la couleur de l'iris qui peut changer mais ce qui n'a aucune influence puisque les images d'iris obtenues sont en noir et blanc. Cette technique peut être affectée par plusieurs facteurs tels que la distance entre l'œil et la caméra, les reflets, la détection de faux yeux etc. Pour diminuer le risque de mauvaise reconnaissance, on fait appel à certaines caractéristiques dynamiques de l'œil.

• Rétine (retina-scan): cette mesure biométrique est basée sur l'étude de la structure formée par les vaisseaux sanguins de la rétine qui diffère d'une personne à une autre, même entre les jumeaux. L'image de la rétine est acquise à une faible distance du capteur (i.e. moins de 30 cm) et fournit jusqu'à 400 points caractéristiques du sujet. Elle présente une stabilité durant la vie de la personne. Cette méthode est la plus difficile a mettre en œuvre et la plus complexe à falsifier.

• Visage (facial-scan): cette technique s'appuie sur une image de visage. Les caractéristiques utilisées pour l'identification doivent être uniques, invariables qui ne changent pas avec l'âge de la personne [1]. Elles sont extraites des zones du visage comme le haut des joues, les coins de la bouche (figure 1.5), etc.



Figure 1.5 : Méthode d'extraction des caractéristiques du visage [1].

 Système et configuration des veines (vein pattern-scan): cette méthode n'est pas encore très répandue. Elle est basée sur l'étude de la structure formée par le réseau des veines sur une partie du corps d'un individu, sur la main par exemple. En fait cette modalité est en général utilisée en combinaison avec d'autres modalités.

Outre les caractéristiques physiques, un individu possède également des caractéristiques comportementales qui lui sont propres:

- Dynamique des frappes au clavier (keystroke-scan): les frappes au clavier sont affectées par plusieurs facteurs : durée entre frappes, fréquence des erreurs ou durée globale nécessaire pour taper un texte. Cependant même si, ce comportement n'est pas unique à chaque individu il offre des informations discriminantes suffisantes permettant d'identifier un individu.
- **Reconnaissance vocale (voice-scan):** les données utilisées par la reconnaissance vocale proviennent à la fois de facteurs physiologiques et comportementaux. L'identification par

la voie est basée sur |la forme et la taille des appendices (bouche, cavités nasales et les lèvres) utilisées dans la synthèse du son. Les caractéristiques physiologiques de la voix d'un individu sont invariantes mais les caractéristiques comportementales changent avec le temps et avec l'âge, selon les conditions sanitaires (mal de gorge) et des états émotionnels, etc,...ce qui diminue l'exactitude du taux d'identification. Cette technique d'identification est sensible à un grand nombre de facteurs tels que le bruit.

• Dynamique des signatures (signature-scan): cette technique n'est pas très utilisée. Il s'agit d'une palette graphique munie d'un stylo mesurant les caractéristiques telles que la vitesse, l'ordre des frappes, la pression et les accélérations, le temps total, etc... lors de la signature. Cette technique n'est pas très précise car la signature varie et peut être affectée par des facteurs physiques et émotionnels.

D'autres techniques biométriques se développent actuellement telles que la biométrie par la géométrie des veines de la main [4], biométrie par l'empreinte palmaire [5], biométrie par la géométrie des veines du doigt [6], ...

Malgré leur fiabilité, les systèmes d'identification biométrique unimodaux ne garantissent pas la reconnaissance. La biométrie multimodale vient remédier à ce problème. Elle consiste à intégrer plusieurs méthodes biométriques dans un même système d'identification. Plusieurs méthodes ont été proposées dans ce cadre comme par exemple la fusion des modalités visage et iris [7].

A noter aussi que d'autres techniques biométriques sont en cours de développement au laboratoire LiSSi de l'Université Paris-Est Créteil (UEPC), comme la biométrie du cerveau et biométrie de la main sans contact.

Une autre modalité qui fait l'objet de notre thèse, est la biométrie par les signaux physiologiques, notamment, par l'ECG. La validité de l'utilisation de l'ECG en biométrie est basée sur l'existence de différences physiologiques et géométriques cardiaques entre les individus humains ce qui rend le signal ECG unique pour chacun. Les différences entre les signaux ECG des différents individus dominent dans la forme de l'onde, l'amplitude, l'intervalle PT en raison de la

différence des conditions physiques du cœur. En comparaison avec les autres modalités biométriques, l'ECG est plus universel et difficile à falsifier.

1.6 Objectif de la thèse

La reconnaissance biométrique promet la sécurité hermétique en identifiant un individu avec ses caractéristiques humaines innées. L'empreinte digitale humaine, la voix, le visage et l'iris sont juste quelques caractéristiques qui sont utilisées actuellement dans des systèmes de reconnaissance biométriques. Cependant, ces caractéristiques sont toujours falsifiables. Quelques exemples de falsification sont l'empreinte digitale 3D, modèles de visage, des enregistreurs audio pour la lecture de voix et des lentilles de contact avec des caractéristiques d'iris copiées. La recherche de nouvelles méthodes d'identification biométriques non falsifiables est très active dans ce domaine.

En comparaison avec les autres traits biométriques, les signaux physiologiques comme l'ECG, EMG... sont plus universels et difficiles à falsifier par l'utilisation de méthodes frauduleuses. Jusqu'à présent ces signaux ne sont pas largement utilisés dans les applications biométriques mais présentent des résultats prometteurs.

Notre sujet de thèse porte sur l'utilisation des signaux biologiques comme l'ECG et l'EMG en biométrie. L'approche proposée dans cette thèse est originale dans la mesure où les signaux enregistrés ne peuvent pas être volontairement modifiables (contrairement à une empreinte digitale pour laquelle une simple blessure rend son exploitation difficile). Bien qu'il soit possible de modifier notre rythme cardiaque (i.e. suite à un effort physique) ; modifier la forme du battement cardiaque (PQRST) n'est pas simple. En effet, notre système cardiaque génère une signature propre à chaque individu. Cette signature est robuste dans une période donnée (i.e. quelques mois, voire quelques années). Les signaux EMG présentent également des caractéristiques spécifiques à chaque individu ce qui permet de les utiliser pour différencier les individus et déterminer leur identité.

Dans ce rapport, nous proposons trois méthodes d'identification biométriques. La première méthode est basée sur l'ECG, alors que la deuxième est basée sur les signaux EMG de surface en

réponse à une force d'intensité fixe et la dernière méthode utilise les réponses motrices obtenues suite à une stimulation électrique.

Les signaux physiologiques utilisés sont acquis chez des personnes saines. Des techniques de modélisation et de classification fondées sur les réseaux d'ondelettes et les réseaux de neurones et d'estimation de densité spectrale de puissance ont été mises en œuvre.

Un bloc diagramme montre les différentes étapes de l'identification des différents individus à l'aide de signaux physiologiques. Ces étapes consistent d'abord à acquérir les signaux physiologiques. Ensuite, nous effectuons une analyse paramétrique pour extraire les caractéristiques nécessaires pour l'identification et finalement une identification automatique est effectuée par les réseaux de neurones.



Figure 1.6 : Bloc diagramme de l'identification par signaux physiologiques.

Dans la section suivante, nous faisons un rappel anatomique du système cardiovasculaire et de son activité électrique. Ensuite, nous décrivons la physiologie, l'anatomie des muscles

squelettiques. Nous présentons également un bref rappel anatomique du système nerveux périphérique et de la conduction nerveuse.

1.7 Biométrie par signaux physiologiques

1.7.1 Biométrie par l'ECG

A. Le système cardiovasculaire

Le cœur est une pompe à quatre chambres du système circulatoire. La fonction principale de pompage est assurée par les ventricules ; les oreillettes stockent le sang avant que les ventricules pompent.

Le cœur est composé de différents types de tissus (tissu nodal SA et AV, tissu auriculaire, Purkinje, et tissu ventriculaire). Les cellules représentatives de chaque type de tissu diffèrent anatomiquement d'une manière considérable. Elles sont électriquement excitables et chaque type génère son propre potentiel d'action ; dans ce cas, le cœur est assimilé à un générateur électrique. Ces potentiels sont mesurés à la surface de la peau et constituent l'électrocardiogramme ou ECG.



Figure 1.7 : Propagation de l'influx à l'intérieur du cœur.

L'activation électrique auriculaire dure environ 0,10 seconde en moyenne. La durée du ralentissement auriculo-ventriculaire est de 0,12 à 0,20 seconde, et celle de l'activation des ventricules est de 0,06 à 0,08 seconde.

B. Les dérivations électrocardiographies

L'ECG est enregistré par des électrodes placées sur la paroi thoracique et les membres. Il existe trois types de dérivations: bipolaires, unipolaires périphériques et unipolaires précordiales.

B.1 Dérivations bipolaires

Les dérivations bipolaires sont acquises par l'intermédiaire de 3 électrodes formant entre elles un triangle équilatéral:

- I ou D1 = bras droit, bras gauche.
- II ou D2 = bras droit, jambe gauche.
- III ou D3 = bras gauche, jambe gauche.

Ces trois dérivations forment les côtés du triangle d'EINTHOVEN. (Voir figure 1.8).



Figure 1.8 : Dérivations standard (bipolaires).

B.2 Dérivations unipolaires périphériques

Une électrode exploratrice est placée à la surface du corps, elle est reliée au pôle positif de l'électrocardiographe. Le pôle négatif de l'électrocardiographe est relié à une électrode neutre ou indifférente (borne centrale de WILSON).

- aVR = bras droit borne centrale.
- aVL = bras gauche borne centrale.
- aVF = jambe gauche borne centrale.

La ligne de chacune de ces trois dérivations passe par un des sommets du triangle et son centre géométrique (Voir figure 1.9). L'activité électrique du cœur humain est étudiée par l'enregistrement des dérivations bipolaires et unipolaires périphériques dans le plan frontal.



Figure 1.9: Dérivations unipolaires périphériques.

B.3 Dérivations unipolaires précordiales

L'électrode exploratrice est reliée au pôle positif de l'appareil, le pôle négatif à la borne centrale. Elles explorent l'activité électrique cardiaque dans un plan approximativement horizontal:

- V1 = 4ème espace intercostal droit au bord droit du sternum.
- V2 = 4ème espace intercostal gauche au bord gauche du sternum.
- V3 = entre V2 et V4.
- V4 = 5ème espace intercostal gauche, sur la ligne médio claviculaire gauche.
- V5 = sur la ligne axillaire antérieure à la même hauteur que V4.
- V6 = sur la ligne axillaire moyenne à la même hauteur que V4.



Figure 1.10: Position des Electrodes Précordiales.

C. Analyse de l'ECG

Un ECG est considéré comme normal quand les différents phénomènes électriques répondent à des critères de forme et de temps, et quand il existe un rythme sinusal régulier de fréquence normal. La figure 1.11 présente un tracé ECG avec les ondes P et T et le complexe QRS. Ces différentes vagues formant l'ECG représentent les séquences de dépolarisation et de repolarisation des oreillettes et des ventricules (figure 1.7). Le complexe QRS est la forme d'onde la plus saisissante de l'ECG puisqu'il reflète l'activité électrique du cœur pendant la contraction ventriculaire. En raison de sa forme caractéristique, il sert de base à la détermination automatisée de la fréquence cardiaque. La détection du QRS fournit les principes fondamentaux pour presque tous les algorithmes automatisés d'analyse de l'ECG [9].



Figure 1.11: Battement d'un ECG.

L'onde P

L'onde P correspond à la dépolarisation auriculaire et à la diffusion du signal électrique à travers les oreillettes droite et gauche, cette onde s'achève au niveau où le tracé rejoint la ligne de base. Sa durée est de 0.08 à 0.1 secondes, son amplitude inférieure à 2 mm, elle est monophasique, arrondie, et toujours positive.

Le complexe QRS

Le complexe QRS est formé de 3 ondes Q, R et S et correspond à la diffusion de l'influx électrique à travers les ventricules (dépolarisation ventriculaire) [10]. Il représente la dépolarisation ventriculaire et dure normalement entre 0.06 et 0.1 seconde. Cette durée courte indique que la dépolarisation ventriculaire est rapide.

L'onde Q est la première déflection négative du complexe QRS et l'onde R est la première déflection positive. Une déflection négative suit l'onde R, elle est appelée onde S. Ce complexe est d'une grande amplitude (signal de quelques millivolts).

L'onde T

L'onde T représente la repolarisation ventriculaire. Elle est plus longue en durée que la dépolarisation (la vitesse de conduction de l'onde de repolarisation est plus faible que celle de l'onde de dépolarisation). Elle survient pendant la diastole, et ne témoigne d'aucun événement mécanique. C'est un phénomène purement électrique, pendant lequel les ventricules redeviennent stimulables [11].

D. Les techniques biométriques par ECG

L'utilisation de l'ECG en biométrie est relativement nouvelle. En fait, il existe plusieurs méthodes biométriques basées sur l'ECG proposées précédemment. La première méthode a été proposée en 1999 par Biel et al [15]. Cette méthode est basée sur l'analyse de l'ECG. Plus tard, en 2006, Wang et al. [16] ont proposé une nouvelle méthode d'identification biométrique. Elle est basée sur la détection fiducielle. Cette méthode consiste à intégrer les caractéristiques analytiques et d'apparence extraites des signaux ECG pour l'identification humaine. La dernière

méthode, sans détection fiducielle, est appelée AC/DCT. Elle fut proposée par Plataniotis et al. en 2006 [17].

1.7.2 Biométrie par EMG

A. Muscle squelettique

Le mot muscle vient du mot Latin "musculus" qui signifie "petit souris". Les muscles peuvent être considérés comme les moteurs de l'organisme. Les propriétés des muscles: telles que l'excitabilité, la contractilité, l'élasticité et l'extensibilité leur permettent de générer force et mouvement. Les muscles sont chargés de convertir l'énergie chimique en énergie mécanique ; par cette opération, le muscle se raccourcit ou se contracte. Le système nerveux est indispensable à leur fonctionnement [12].

Il existe trois sortes de tissus musculaires et chacun joue un rôle particulier dans le maintien de l'homéostasie : les muscles cardiaques, lisses, et squelettiques.

- Les muscles cardiaques ne se trouvent que dans le cœur. Quand ils se contractent, le sang circule, apportant des nutriments aux cellules et les débarrassant de leurs déchets.
- Les muscles lisses se situent dans les parois des organes creux comme les intestins, les vaisseaux sanguins ou les poumons. La contraction d'un muscle lisse modifie le diamètre interne des organes creux, et permet donc de réguler des flux de substances à travers le tube digestif, de contrôler la pression sanguine et le flux sanguin ou de réguler le flux d'air au cours du cycle respiratoire.
- Les muscles squelettiques tiennent leur nom du fait qu'ils sont en général attachés au squelette. La contraction du muscle squelettique fait bouger une partie du corps par rapport à une autre, comme pour la flexion de l'avant-bras. La contraction coordonnée de divers muscles squelettiques permet au corps en son entier de mouvoir dans son environnement, comme lorsque l'on nage.

Dans ce qui suit, nous nous intéressons aux muscles squelettiques. Le corps humain compte plus de 600 muscles squelettiques, dont 125 paires de muscles principaux qui assurent les grandes postures et les grands mouvements. Leurs noms sont généralement liés à leur localisation (dorsal,

pectoral, brachial par exemple), leur taille (long, court), leur fonction (extenseur, fléchisseur, adducteur) ou leur nombre d'attaches (biceps, triceps).

B. Organisation anatomique

Le muscle squelettique humain consiste en des centaines de cellules individuelles de forme cylindrique appelées « fibres » liées entre elles par du tissu conjonctif. Un muscle squelettique est constitué de faisceaux musculaires formés eux-mêmes d'un ensemble de fibres musculaires. Chaque muscle est inséré sur l'os par l'intermédiaire de tendons constitués essentiellement de tissus fibreux, élastique et solide [12]. Outre les fibres musculaires et le tissu conjonctif qui le constituent, un muscle est parcouru par des vaisseaux sanguins et des fibres nerveuses (figure 1.12).



Figure 1.12: Anatomie du muscle strié squelettique [11].

L'activité normale d'un muscle squelettique est tributaire de son innervation. Chaque fibre musculaire squelettique est en contact avec une terminaison nerveuse qui régit son activité. Les

muscles squelettiques se contractent par la stimulation exercée par les fibres nerveuses motrices ou nerfs moteurs sous la forme d'impulsions nerveuses depuis le cerveau ou la moelle épinière jusqu'aux muscles squelettiques.

Les axones (ou fibres nerveuses) sont de longues extensions cylindriques des neurones. Les axones quittent la moelle épinière par les nerfs spinaux, et le cerveau par les nerfs crâniens, et sont distribués aux muscles squelettiques concernés sous la forme d'un nerf périphérique, qui est un ensemble de fibres nerveuses individuelles rassemblées comme les différents brins d'un câble. Arrivée au muscle, chaque fibre nerveuse se ramifie et innerve différentes fibres musculaires.

Bien qu'un seul neurone moteur puisse innerver différentes fibres musculaires, chaque fibre est innervée par un seul neurone moteur. La combinaison d'un seul neurone et de toutes les fibres musculaires qu'il contrôle est appelée unité motrice (figure 1.13). Quand un neurone moteur somatique est activé, toutes les fibres qu'il innerve répondent aux impulsions du neurone en générant leurs propres signaux électriques qui conduisent à la contraction des fibres musculaires activées.



Figure 1.13: Exemple d'unité motrice [12].

C. Electromyographie

Quand une unité motrice est activée, les fibres musculaires qui la composent génèrent et transmettent leurs propres impulsions électriques qui provoqueront finalement la contraction des fibres. Bien que l'impulsion électrique générée et transmise par chaque fibre soit très faible (moins de 100 μ v), le fait que plusieurs fibres transmettent simultanément induit une différence de voltage qui est assez importante pour être détectée par une paire d'électrodes sur la peau.

La détection, l'amplification et l'enregistrement des modifications du potentiel à la surface de la peau produit par la contraction du muscle squelettique sous-jacent est appelée électromyographie. L'enregistrement obtenu est appelé électromyographie. L'électromyographie (EMG) explore le système nerveux périphérique, qui comprend la moelle épinière, les nerfs périphériques et les muscles.

L'EMG permet d'étudier l'état des nerfs périphériques et la qualité de la contraction musculaire. Un muscle est commandé par un nerf périphérique qui assure la propagation de l'influx nerveux. Une des caractéristiques des fibres nerveuses est l'excitabilité ; en réponse à un courant électrique, elles réagissent en propageant l'influx nerveux jusqu'au muscle correspondant [13]. Il existe deux techniques complémentaires :

- EMG de détection : mesure l'activité électrique d'un muscle au repos et à la contraction volontaire ;
- EMG de stimulation : mesure la vitesse de conduction nerveuse après stimulation d'un nerf par un bref courant électrique.

Dans notre travail, nous utiliserons l'EMG de détection ou encore appelé le SEMG (EMG de surface) pour l'identification biométrique.

1.7.3 Biométrie par réponse motrice M

A. Le système nerveux

Le système nerveux périphérique est constitué de :

- Système moteur efférent allant de la moelle à la fibre musculaire ; il conduit l'influx nerveux du système nerveux central à un effecteur. L'élément fondamental est l'unité motrice [14].
- Système sensitif afférent allant des récepteurs périphériques spécifiques à la moelle ; il Conduit l'influx des récepteurs au système nerveux central.
- Système nerveux végétatif comportant des fibres afférentes et efférentes ou système autonome (SNA) assurant l'innervation des viscères (cœur, vaisseau, viscères) et de certaines structures de la peau ; il transmet une info vers les muscles lisses (système digestif, cardiovasculaire).

B. La conduction nerveuse

La conduction nerveuse, étant la fonction spécifique des nerfs, est une conduction électrochimique saltatoire. Il s'agit d'échanges d'ions de sodium au niveau des nœuds de Ranvier.

Transmission de l'influx nerveux

Le neurone, élément fonctionnel de base du système nerveux, est composé de trois parties : le soma contenant le noyau, les dendrites et l'axone (figure 1.14). Il est chargé négativement sur sa paroi interne et positivement sur sa paroi externe.



Figure 1.14: schéma d'un neurone [14].

Le potentiel d'action émis par le neurone se propage le long de l'axone sans perdre en intensité.

L'influx nerveux est transmis au sein du complexe synaptique : les neurotransmetteurs libérés par le bouton synaptique se fixent sur des récepteurs. Les canaux activés par ces récepteurs s'ouvrent et un grand nombre d'ions circulent dans le cas d'une synapse excitatrice produisant une dépolarisation, où au contraire ferment totalement le passage dans le cas d'une synapse inhibitrice produisant une hyperpolarisation (figure 1.15).



Figure 1.15: Transmission de l'influx nerveux [14].

La plaque motrice est le contact entre le neurone et une cellule musculaire. À ce niveau, le neuromédiateur est libéré et également la membrane musculaire se dépolarise et suite à un influx nerveux, une contraction musculaire a lieu.

Dans notre travail, nous utilisons la réponse motrice M résultant de la stimulation d'un nerf moteur afin d'identifier les différents individus.

1.8 Conclusion

Dans la première partie du chapitre, nous avons d'abord introduit les idées de base de la biométrie. Nous avons défini la biométrie et les différentes catégories de technologies biométriques. Ensuite nous avons décrit le principe de fonctionnement des systèmes biométriques ainsi que les modalités biométriques les plus utilisées.

Dans la deuxième partie, nous avons mis en évidence l'objectif de notre thèse en présentant les différentes méthodes d'identification d'individus. Un diagramme bloc montre les différentes parties de notre travail (figure 1.6)

Dans la troisième partie, nous avons présenté un bref rappel anatomique du système cardiovasculaire et de l'ECG ainsi que des muscles squelettiques et l'EMG. Nous avons décrit également le système nerveux périphérique et la conduction nerveuse.

Dans le chapitre suivant, nous présenterons notre méthode d'identification biométrique basée sur l'analyse de l'ECG.

Chapitre 2

Modélisation de l'ECG par réseau d'ondelettes

2.1 Introduction

La reconnaissance biométrique promet la sécurité hermétique en identifiant un individu avec ses caractéristiques humaines innées. L'empreinte digitale humaine, la voix, le visage et l'iris sont juste quelques caractéristiques qui sont utilisées actuellement dans des systèmes de reconnaissance biométriques. Cependant, ces caractéristiques sont toujours falsifiables. Quelques exemples de falsification sont l'empreinte digitale 3D, les modèles de visage, des enregistreurs audio pour la lecture de voix et des lentilles de contact avec des caractéristiques d'iris copiées.

Jusqu'à présent les signaux biologiques provenant du corps humain, comme le potentiel électrique généré par le cœur, ne sont pas encore utilisés dans les applications biométriques. Les premières études montrent que le signal ECG contient des caractéristiques spécifiques à chaque personne.

La validité d'utiliser l'ECG comme un schéma de reconnaissance biométrique est soutenue par le fait que les différences physiologiques et géométriques du cœur des différents individus montrent l'unicité de leurs signaux ECG. Plusieurs méthodes d'identification biométrique basées sur l'ECG ont été proposées par Biel et al. en 1999, Wang et al. en 2006 et Plataniotis et al. en 2006. Dans ce chapitre, nous présentons une nouvelle méthode d'identification biométrique par l'ECG. La première partie présente un état de l'art des différentes méthodes d'identification des individus par l'ECG. Dans la deuxième partie, nous exposerons la méthode d'identification biométrique par ECG que nous avons développée, y compris les outils de modélisation utilisés, tels que les réseaux d'ondelettes. Ces derniers seront largement détaillés.

2.2 Etat de l'art de la biométrie par ECG

En se basant sur les travaux publiés, plusieurs méthodes de reconnaissance d'individus par ECG ont été proposées.

Par exemple, l'approche publiée en 2001, [15] nécessite les trois étapes principales suivantes :

- 1. Acquisition d'un signal ECG à 12 dérivations,
- 2. Extraction des caractéristiques,
- 3. Classification.

Les caractéristiques utilisées pour la classification (i.e. distances entre les différentes ondes et amplitudes des ondes) sont délivrées par la machine d'électrocardiographie (360 caractéristiques pour chaque personne). Le calcul de la matrice de corrélation montre une forte corrélation entre les différentes « voies » pour une caractéristique spécifique. La première réduction consiste à utiliser seulement les données provenant des dérivations des membres à cause de la facilité de connexion des électrodes.

L'utilisation des dérivations des membres réduit le nombre des caractéristiques à 180. Pour réduire encore la quantité d'information, la matrice de corrélation est étudiée de nouveau. On élimine les caractéristiques ayant une grande corrélation avec les autres. Cela permettra de réduire le nombre de caractéristiques à 12. Ensuite, la réduction est basée sur des tests.

La classification est effectuée par la méthode SIMCA (Soft Independent Modeling of Class Analogy). La première étape de la modélisation SIMCA consiste à créer le modèle ACP (Analyse de Composantes Principales) pour chaque classe.

Une nouvelle approche basée sur la détection fiducielle a été proposée plus tard [16]. Cette technique utilise les attributs analytiques et d'apparence pour la classification des individus. Les points 'fiduciels' sont représentés dans la figure 2.1.



Figure 2.1 : Battement cardiaque présentant les points fiduciels [16].

• Extraction des paramètres analytiques

Après détection du pic R, les positions de Q, S, P et T sont déterminées pour trouver les maxima et les minima locaux séparément. Afin de localiser les points L', P', S' et T', on se base sur la technique illustrée dans la figure 2.2.



Figure 2.2: Détermination des points fiduciels [16].

Dans cette méthode, les points X et Z sont fixés et on cherche par descente de X à trouver le point qui maximise la somme des distances a+b. Les attributs extraits sont les distances temporelles et d'amplitude entre ces points 'fiduciel'. Les caractéristiques temporelles sont normalisées par la distance P'T' pour fournir moins de variabilité par rapport au rythme cardiaque. La figure 2.3 représente ces attributs graphiquement.



Figure 2.3: Démonstration graphique des caractéristiques analytiques [16].

• Extraction des caractéristiques d'apparence

La PCA (principal component analysis) et la LDA (linear discriminant analysis) sont des méthodes de transformation de domaine utilisées pour la réduction de données et l'extraction de caractéristiques.

La technique PCA est une technique d'apprentissage non supervisé qui procure une représentation optimale de l'entrée dans un espace de dimension plus petit. Par ailleurs, LDA est une autre approche, que l'on utilise pour la réduction de dimension et l'extraction de caractéristiques. Contrairement à la PCA, le LDA est une technique d'apprentissage supervisée.

• Intégration des caractéristiques analytiques et d'apparence

Les caractéristiques analytiques représentent une information locale tandis que les caractéristiques d'apparence représentent des formes holistiques. Une intégration efficace de ces 2 types de caractéristiques en un seul vecteur augmente la performance de connaissance.
Une simple intégration consiste en la concaténation des 2 types des caractéristiques. Les caractéristiques analytiques extraites incluent des attributs temporels et d'amplitude. Ils utilisent la LDA comme classificateur et Wilks' lambda pour la sélection de caractéristique [16].

Wilks' lambda est une statistique utilisée dans l'analyse multi-variée qui mesure les différences entre la moyenne des différentes classes sur une combinaison de variables dépendantes, et ainsi peut être utilisé comme un test de l'importance des caractéristiques.

Dans [17], la méthode proposée est basée sur la combinaison de l'auto-corrélation et de DCT (Discrete Cosine Transform). Cette méthode est appelée AC/DCT. Elle nécessite les 4 étapes suivantes :

- 1- Fenêtrage : le tracé ECG est segmenté sans recouvrement. La durée de chaque segment doit être plus longue que la longueur moyenne du battement cardiaque, de telle façon que plusieurs pouls soient inclus.
- 2- Estimation de l'auto-corrélation normalisée de chaque segment,
- 3- DCT sur le 'décalage' du signal de corrélation,
- 4- Classification basée sur les coefficients significatifs de la DCT.

La motivation de l'utilisation des caractéristiques basées sur l'auto-corrélation est de détecter les formes non aléatoires. L'auto-corrélation encastre une information sur les caractéristiques les plus représentatives du signal. Elle donne des informations très importantes pour la distinction des sujets. La dimension des caractéristiques d'auto-corrélation est grande. La DCT est ensuite appliquée sur les coefficients d'AC pour réduire leur dimension.

Comme il a été signalé précédemment, une nouvelle approche d'identification biométrique utilisant les signaux ECG sera étudiée. Cette technique est basée sur l'analyse paramétrique. Elle consiste à modéliser le battement cardiaque par le réseau d'ondelettes pour extraire les caractéristiques significatives (i.e. translation, dilatation et poids) des différentes ondelettes. Ensuite, ces paramètres seront utilisés pour l'identification des individus.

Dans la section suivante, considérée comme étant le noyau de ce rapport, nous développerons en détail le principe de base de notre méthode d'identification.

2.3 Nouvelle technique biométrique par l'ECG

2.3.1 Introduction

Dans cette section, nous élaborons les différentes étapes appliquées sur le signal ECG de chaque individu existant dans notre base de données (voir chapitre 4). Le schéma général de notre méthode est présenté dans la figure 2.4. Plusieurs phases sont prises en considération, à savoir :

- 1. le prétraitement de l'ECG, la détection des pics,
- 2. la segmentation, le moyennage de l'ECG,
- 3. la modélisation par réseau d'ondelettes,
- 4. extraction des paramètres,
- 5. classification par réseau de neurones RBF.



Figure 2.4 : Schéma général de notre méthode.

2.3.2 Prétraitement du signal ECG

L'ECG est acquis à partir de trois électrodes placées sur les membres supérieurs droit et gauche et le membre inferieur droit. Habituellement, l'ECG contient du bruit, notamment, ainsi que d'autres types de bruits d'origine musculaire, etc. Ces bruits ont comme effet de dégrader la qualité des paramètres extraits. Par conséquent, une phase de prétraitement s'avère nécessaire. Après un filtrage passe-bande dans la gamme 1-40 Hz, la ligne de base est supprimée par la méthode de L. Keselbrener, M. Keselbrener et S. Akselrod [18]. Cette technique consiste à lisser le signal par un filtre médian non-linéaire permettant d'extraire la dérivée de l'ECG (i.e. seules les variations très lentes sont conservées). Une simple soustraction du signal original de signal obtenu permet d'obtenir une version corrigée (figure 2.5).



(a) Signal original avec ligne de base



(b) Ligne de base éliminée par filtre médian non linéaire



Soustraction (a-b) Figure 2.5 : Organigramme de la procédure de détection des pics R.

2.3.3 Détection des complexes QRS

Pour détecter les pics R, la même technique proposée par L. Keselbrener et al. A été choisie. Après avoir corrigé la ligne de base, la détection des pics R est réalisée par seuillage absolu. Pour la localisation des pics R, il faut déterminer à la fois l'amplitude du pic et l'instant d'apparition de ce pic.

Chaque point du signal sera donc comparer par rapport à un seuil. Le point vérifiant cette condition ainsi que tous les points successifs au-dessus du seuil sont stockés jusqu'à retrouver une valeur inférieure au seuil. Une fois tous les points du pic R situés au dessus du seuil stockés, on cherche le maximum de ces points. Ce maximum correspond à l'amplitude du pic R, et son instant d'apparition correspond à l'instant d'apparition du pic dans le signal ECG [10].

Deux vecteurs sont donc créés. L'un contenant l'amplitude des pics R et l'autre les instants d'apparition correspondant à chaque pic. Il arrive parfois que le signal ECG présente des artéfacts au niveau du pic R. Cet artéfact est considéré comme étant un pic R.

En fait, lorsque la différence entre les instants d'apparition de deux pics successifs est inférieure à 0.1 seconde, un artéfact est présent. Ainsi, nous précisons un minimum à l'intervalle entre deux positions successives de pics. Par contre, la prédiction de la position réelle du pic est impossible, donc, nous calculons la moyenne des instants d'apparition de deux pseudo-pics. Ceci supposera que le pic R se situerait au milieu des deux pseudo-cycles.

2.3.4 Segmentation du signal ECG

La segmentation est effectuée pour assurer un bon moyennage des signaux ECG. Le but de cette technique est la mise en place d'une matrice ECG contenant un seul complexe QRS sur chaque segment.

La procédure est la suivante: considérons W le vecteur des positions des complexes QRS du signal ECG et Wa son vecteur dérivé W, tel que:

$$Wa(i) = W(i+1) - W(i)$$
 avec $i = 1, 2, ..., L$ (2.1)

Où L est la taille du vecteur W. Une illustration graphique est nécessaire pour expliquer les différentes démarches de cette segmentation (figure 2.6).

Nous constatons que le terme Wa(i) correspond, sur la figure 2.6, au nombre d'échantillons entre les complexes d'indices i et i + 1. Comme le montre cette figure, l'échantillon W(i) - nmarque le début du segment S_i . En effet, ce dernier est défini comme suit:

$$S_i = [x(W(i) - n) \quad x(W(i) - n + 1) \quad \cdots \quad x(W(i) - n - 1)] \quad (2.2)$$

Le nombre d'échantillons du segment S_i est égal à Wa(i).



Figure 2.6 : Segmentation d'un signal.

Cependant, les segments obtenus sont de tailles différentes (figure 2.7.a). Dans ce cas de figure, la taille de chaque segment est normalisée en extrapolant par des échantillons dont les valeurs sont égales à celles des derniers échantillons [19].

Par conséquent, la nouvelle taille des segments est celle du segment qui possède le plus grand nombre d'échantillons:

Autrement dit, on additionne à chaque segment d'indice $i:[L_m - L_i]$ échantillons (à l'exception du segment de taille L_m). De ce fait, la nouvelle taille serait égale à L_m .

$$L_m = \max[L_i] \tag{2.3}$$

La figure 2.7 représente l'illustration graphique des segments avant et après ajout des échantillons.



Mathématiquement, la matrice ECG contenant les segments, est obtenue comme suit :

Segment 1:
$$S_1 = [x_{11}x_{12}...x_{1L1}]$$

Segment 2: $S_2 = [x_{21}x_{22}...x_{2L2}]$

Ainsi de suite, jusqu'aux segments d'ordre m et n:

Segment m:
$$S_m = [x_{m1}x_{m2}...x_{mLm}]$$

Segment n: $S_n = [x_{n1}x_{n2}...x_{nLn}]$

Où L_i est la taille du segment S_i et L_m , la taille maximale de tout les segments. D'où la matrice ECG, notée M:

$$M = \begin{bmatrix} x_{11} & \dots & x_{1L1} \\ x_{m1} & \vdots & x_{mLm} \\ x_{n1} & \cdots & x_{nLn} \end{bmatrix}$$
(2.4)

2.3.5 Modélisation par réseau d'ondelettes

La modélisation des battements cardiaques est l'étape principale de notre travail. Cette modélisation est effectuée par les ondelettes et contribue à l'extraction des paramètres servant à l'identification des individus.

Il existe plusieurs outils mathématiques utilisés pour la modélisation. Dans le cadre de notre travail, nous avons utilisé le réseau d'ondelettes pour modéliser les battements cardiaques. Les réseaux d'ondelettes utilisent la transformée en ondelettes comme noyau. Dans la section suivante, nous aborderons les réseaux d'ondelettes ainsi que leurs caractéristiques.

A. Réseau d'ondelettes

La théorie des ondelettes s'étant rapidement développée par ailleurs, elle offre aujourd'hui des algorithmes très efficaces pour analyser, identifier, estimer et compresser des signaux ou des fonctions.

Les réseaux d'ondelettes sont une classe des réseaux de neurones. Ils résultent de la combinaison de la théorie d'ondelettes avec les réseaux de neurones multicouche de type Feedforward [20-22]. Les réseaux d'ondelettes utilisent les fonctions d'ondelettes comme fonctions d'activation. Les méthodes de construction du réseau sont développées en utilisant les caractéristiques théoriques de la transformée d'ondelettes.

L'utilisation des ondelettes dans les réseaux neuronaux a été proposée par Zhang et Benveniste [21] et Pati et Krishnaprasad [20]. Les ondelettes considérées sont non orthogonales mais elles forment une 'frame'. Dans ce cas, le réseau d'ondelettes est considéré comme un cas particulier du réseau neuronal RBFNN, J. Zhang et al. [23] ont présenté un réseau d'ondelettes basé sur une base d'ondelettes orthogonales et quelques résultats expérimentaux pour comparer ce réseau d'ondelettes avec les deux autres réseaux multicouches: MLP et RBFNN.

Les avantages essentiels du réseau d'ondelettes permettent d'obtenir une phase d'initialisation qui peut être guidée afin d'éviter le risque d'avoir des minimums locaux pendant la phase d'apprentissage.

Dans cette section, nous décrivons la structure d'un réseau d'ondelettes et le type d'ondelettes choisi pour construire des approximations multidimensionnelles ainsi que la phase d'initialisation d'un réseau d'ondelettes et la technique de choix du nombre de neurones cachés dans ce réseau.

A.1 Structure du réseau d'ondelettes

Dans la décomposition d'une fonction $f(x) \in L^2(R)$ en ondelettes, la transformée en ondelettes discrète possède un inverse:

$$f(x) = \sum_{m,n} \langle \psi_{m,n}, f \rangle \psi_{m,n}(x) = \sum_{m,n} \beta_{m,n} \psi_{m,n}(x) \qquad m, n \in \mathbb{Z}$$
(2.5)

Où $L^2(R)$ est l'ensemble des fonctions de R de carré intégrable et $\psi_{m,n}(x)$ est l'ondelette dilatée et translatée de l'ondelette mère $\psi(x)$. Cette formule est similaire à l'équation représentative du réseau RBFNN dont la sortie est une combinaison linéaire des fonctions gaussiennes pondérées par les poids de connexions de la couche de sortie qui est linéaire. D'après cette équation, nous constatons que le réseau d'ondelettes est un réseau multicouche de type feedforward constitué de trois couches: une couche d'entrée, une couche cachée où les fonctions gaussiennes sont remplacées par des ondelettes radiales et une couche de sortie linéaire.

Soit $\psi : \mathbb{R}^p \to \mathbb{R}$ l'ondelette mère choisie. Le réseau d'ondelettes est défini par la relation $N_{\theta_N}^{d,T}$: $\mathbb{R}^p \to \mathbb{R}$, telle que:

$$N_{\theta_{N}}^{d,T}(X) = \sum_{i=1}^{h} \omega_{i} \psi_{i}(X, d, T) = \sum_{i=1}^{h} \omega_{i} \psi(d_{i}(X - T_{i}))$$
(2.6)

Où :

- *h* : nombre de neurones (ondelettes) du réseau
- *ω_i* ∈ *R* : poids de connexion qui existe entre *i*^{ème} ondelette de la couche cachée et la sortie linéaire du réseau.
- $d_i \in R$: paramètre de dilatation de la $i^{\text{ème}}$ ondelette.
- $T_i \in \mathbb{R}^p$: vecteur de translation de la $i^{\text{ème}}$ ondelette.
- $X \in \mathbb{R}^p$: vecteur d'entrée du réseau.

Les figures 2.8 et 2.9 présentent le schéma du neurone avec ondelette et la structure du réseau d'ondelettes. Les paramètres du réseau neuronal $\{\omega_i, d_i, T_i\}$ seront déterminés pendant la phase d'initialisation à partir de la base d'apprentissage θ_N . Dans cette section, nous présenterons une nouvelle technique d'initialisation du réseau d'ondelettes, la méthode de sélection de régresseurs.







Figure 2.9: Structure du réseau d'ondelettes.

A.2 Equation représentative du réseau d'ondelettes

En pratique, l'équation représentative non linéaire du réseau d'ondelettes est modifiée et devient:

$$N_{\theta_{N}}^{d,T}(X) = \sum_{i=1}^{h} \omega_{i} \psi(d_{i}(X - T_{i})) + \sum_{j=1}^{p} \upsilon_{j} x_{j} + \theta \qquad (2.7)$$

Soit en représentation vectorielle:

$$N_{\theta_N}^{d,T}(X) = W^T \Psi + V^T X + \theta \qquad (2.8)$$

Où :

- θ : seuil
- V = (v₁, v₂,..., v_p)^T ∈ R^p: vecteur de paramètres linéaires des connexions qui relient
 l'entrée du réseau a la sortie linéaire
- $W = (\omega_1, \omega_2, \dots, \omega_h)^T \in \mathbb{R}^h$ et $\Psi = (\psi_1, \psi_2, \dots, \psi_h)^T$.

La partie linéaire $V^T X + \theta$ permet de bien capturer les propriétés linéaires de la fonction non linéaire à identifier. $\{\omega_i, d_i, T_i, \upsilon_j, \theta\}$ sont les paramètres du réseau d'ondelettes , $1 \le i \le h \text{ et} 1 \le j \le p$. le nombre de paramètres du réseau est: h(p+2) + p + 1.

A.3 Choix du type d'ondelette



Figure 2.10: Ondelette multidimensionnelle créée par le produit tensoriel.

D'après la relation $f(x) = \sum_{m,n} \langle \psi_{m,n}, f \rangle \psi_{m,n}(x)$, on constate qu'on n'est capable d'aborder que des problèmes unidimensionnels. S. Mallat [24] a introduit la notion de construction des ondelettes multidimensionnelles à partir des ondelettes à une seule variable en utilisant le produit tensoriel.

La figure 2.10 nous montre que le calcul non linéaire au niveau de chaque ondelette multidimensionnelle créée par le produit tensoriel est proportionnel au nombre de dimensions p du vecteur d'entrée du réseau ce qui signifie que le temps de calcul (dans les phases d'initialisation et d'apprentissage du réseau) pour la construction d'un réseau d'ondelettes de grande taille est beaucoup plus lourd qu'un réseau de neurone classique où le calcul non linéaire dans chaque neurone caractérisé par une fonction sigmoïde est indépendant de p.

Une autre alternative palliant à cette limitation, l'utilisation des ondelettes radiales est utilisée dans cette étude [25]. Dans ce contexte, la complexité de calcul est similaire avec celle d'un réseau de neurone classique, quelque soit p.

Définition: une paire des fonctions radiales φ , $\psi \in L^2(\mathbb{R}^p)$ sont admissibles en tant qu'ondelettes si elles satisfont la condition:

$$\int_{0}^{+\infty} a^{-1}\hat{\varphi}(aw)\hat{\psi}(aw)da = 1 \quad \forall w \in \mathbb{R}^{p} \quad (2.9)$$

$\hat{\varphi}$ et $\hat{\psi}$ sont respectivement les transformées de Fourier de φ et ψ .

L'ondelette radiale ψ choisie dans notre modélisation est l'inverse du "chapeau mexicain" vue sa ressemblance avec le signal ECG.

$$\psi(X) = (||X||^2 - p)e^{-\frac{||X||^2}{2}}$$
 (2.10)

 $\operatorname{Ou} \|X\|^2 = X^T X$, $\|X\|$ est la norme euclidienne du vecteur X.

Exemple: si p = 1 alors $\psi(x) = (x^2 - 1)e^{-\frac{x^2}{2}}$ (figure 2.11)



Figure 2.11: Exemple d'une ondelette radiale (inverse du chapeau mexicain).

A.4 Initialisation du réseau d'ondelettes

En général, pour modéliser un système non linéaire quelconque, la conception d'un estimateur ou d'un réseau de neurone multicouche consiste à bien choisir la classe de l'estimateur qui dépend certainement de la nature du problème considéré, et à développer une bonne technique d'initialisation capable de déterminer efficacement les paramètres de ce modèle à partir d'une base d'apprentissage bien définie. Cette technique est très adaptée pour modéliser des systèmes non linéaires par des modèles de type "boîte noire" [26]-[27].

L'un des défauts du réseau de neurone multicouche entraîné par l'algorithme de la rétropropagation réside dans le choix du point de départ du réseau qui se fait d'une façon aléatoire, ce qui augmente la probabilité de blocage du système neuronal dans un minimum local. Le réseau d'ondelettes, initialisé par la méthode de sélection de régresseurs [28]-[29] et combiné avec un algorithme d'apprentissage efficace est un bon remède pour construire des estimateurs très performants et réclamant un temps de calcul le plus faible possible.

La sélection de régresseurs consiste d'abord à créer une librairie Γ de versions translatées et dilatées d'une ondelette mère ψ . Chaque version sera considérée comme un régresseur. La construction de cette librairie est basée sur la base d'apprentissage θ_N avec N est le nombre

total de points dans la base. L'étape suivante consiste à sélectionner le sous-ensemble optimal de régresseurs Γ^{opt} de Γ ($\Gamma^{opt} \subset \Gamma$). Les ondelettes de ce sous-ensemble optimal seront ensuite utilisées dans la couche cachée du réseau d'ondelettes.

• Construction de la librairie d'ondelettes Γ

La librairie d'ondelettes Γ est constituée d'un ensemble d'ondelettes ou de régresseurs. La taille de cette librairie est fixe et contient un nombre fini de régresseurs.

Soit l'ondelette mère ψ : $R^p \to R$, la construction de la librairie d'ondelettes Γ consiste à sélectionner quelques sous-ensembles de la famille d'ondelettes F_a dont les différents paramètres des ondelettes varient continûment:

$$F_a = \{ \psi(d(X - T)); d \in R^*_+, T \in R^p \} \quad (2.11)$$

La création de la librairie d'ondelettes présente un problème similaire à celui de discrétisation de l'inverse de la transformée en ondelettes continue. Après une discrétisation des paramètres de dilatation et de translation, la famille F_a sera définie par:

$$F_{a} = \{\psi(d_{0}^{n}X - Mt_{0}); n \in \mathbb{Z}, M \in \mathbb{Z}^{p}\}$$
(2.12)

Où d_0 , $t_0 > 0$ sont respectivement les pas de discrétisation de dilatation et de translation.

En général, on cherche à identifier une fonction f(X) dans un domaine $D \subset \mathbb{R}^p$ bien défini ce qui entraîne la définition de deux sous-ensembles: $E_d \operatorname{et} E_t$, tels que $n \subset E_d \subset Z$ et $M \in E_t \subset Z^p$ avec *n* représentant le nombre de niveaux de résolution désirés pour assurer une bonne approximation. En pratique, cinq ou six niveaux seront suffisants. La famille d'ondelettes précédente devient:

$$F_{a} = \{\psi(d_{0}^{n}X - Mt_{0}); n \in E_{d}, M \in E_{t}\} \quad (2.13)$$

Il est préférable de réduire au maximum la redondance de cette présentation. Pour cela, on choisit des valeurs de d_0 et de t_0 pour lesquels les $\psi(d_0^n X - Mt_0)$ constituent une base orthonormale: $d_0 = 2$ et $t_0 = 1$.

Pour assurer une bonne phase de sélection des ondelettes (phase d'initialisation) et pour faciliter l'apprentissage, on normalise les ondelettes candidates et la librairie Γ devient:

$$\Gamma = \{\psi_i : \psi_i(X) = \kappa_i^n \psi(d_i(X - T_i)), \kappa_i^n = (\sum_{j=1}^N [\psi(d_i(X - T_i))]^2)^{-\frac{1}{2}}, i = 1...H\}$$
(2.14)

Où:

- N : nombre de points dans la base d'apprentissage θ_N

- H: nombre des ondelettes candidates dans la librairie Γ .
- $d_i = d_0^n$ et $T_i = M t_0 d_0^{-n}$

Sélection du sous-ensemble optimal d'ondelettes Γ^{opt} de Γ

Le problème classique dans l'analyse de régression est la sélection des meilleurs régresseurs d'un ensemble [22]. Dans notre cas, l'ensemble des régresseurs est la librairie d'ondelettes Γ . Le but de cette étape est de sélectionner de la librairie Γ le sous-ensemble optimal $\Gamma^{opt} \subset \Gamma$ qui contient un nombre fini d'ondelettes h, $h \leq H$, tout en utilisant la base d'apprentissage θ_N et ceci pour construire la régression non linéaire:

$$(N_{\theta_N}^{d,T})_h(X) = \sum_{j \in J_h^{opt}} \omega_j \psi_j(X) \quad (2.15)$$

Où J_h^{opt} est le sous-ensemble d'indices de $\{1, 2, ..., H\}$ correspondant a Γ^{opt} tel que: dim $(J_h^{opt}) = h$. Le problème peut être résumé comme suit:

Soit χ_h l'ensemble de tous les sous-ensembles J_h qui contiennent h éléments de $\{1, 2, ..., H\}$. Le problème consiste donc à trouver le sous-ensemble optimal $J_h^{opt} \in \chi_h$ qui minimise la fonction d'erreur:

$$E(J_h) = \frac{1}{N} \sum_{i=1}^{N} \frac{1}{2} (y_i - \sum_{j \in J_h} \omega_j \psi_j(X_i))^2 \quad (2.16)$$

 y_i est la sortie désirée du réseau qui correspond au vecteur d'entrée du réseau $X_i((X_i, y_i) \in \theta_N)$.

A noter que le calcul de l'ensemble de poids linéaires $W_{J_h} = \{\omega_j\}_{j \in J_h}$ de chaque sous-ensemble J_h est assuré par la méthode des moindres carrés (Least Squares Method).

Dans cette section, on supposera que le nombre d'ondelettes h dans la couche cachée est connu et fixe. Dans le paragraphe suivant, on montrera comment déterminer la valeur de h.

Pour trouver le sous-ensemble Γ_h^{opt} , on doit examiner tous les sous-ensembles Γ_h de Γ qui contient *h* ondelettes. Le nombre de ces sous-ensembles est la combinaison $C_h^H = \frac{H!}{h!(H-h)!}$ qui peut être très grande. C'est pourquoi une autre technique de recherche du sous-ensemble optimal J_h^{opt} sera adoptée.

Dans ce qui suit, nous présenterons quelques nouvelles notations qui seront utilisées par la suite:

- u_{j} :

$$u_{j} = (\psi_{j}(X_{1}), \dots, \psi_{j}(X_{N}))^{T}$$
(2.17)

Où $\psi_i \in \Gamma$ et $\theta_N = \{(X_1, y_1), \dots, (X_N, y_N)\}.$

Comme les ondelettes de Γ sont normalisées, alors:

$$u_j^T u_j = 1, j = 1, ..., H$$
 (2.18)

-U :

$$U = \{u_1, \dots, u_H\}$$
(2.19)

- y:

$$y = \{y_1, ..., y_N\}^T$$
 (2.20)

Où $y_1,...,y_N$ sont les sorties désirées du réseau d'ondelettes.

Soit $span(\{u_j : j \in J_h\})$ l'espace qui est couvert linéairement par les vecteurs u_j . Le problème précédent est équivalent donc à sélectionner h vecteurs u_j de U pour minimiser la fonction d'erreur, ou la distance euclidienne entre le vecteur des sorties désirées y et l'espace $span(\{u_j : j \in J_h\})$.

• Algorithme de sélection de régresseurs: stepwise selection by orthogonalization

Cet algorithme consiste d'abord à choisir l'ondelette de Γ qui approxime au mieux la base d'apprentissage θ_N puis choisir successivement à chaque itération l'ondelette qui approxime au mieux θ_N en considérant l'effet des ondelettes déjà choisies. Donc, à chaque étape on doit choisir un vecteur $u_i \in U$.

Récemment, cette méthode a été utilisée pour les réseaux neuronaux RBFNN et pour la modélisation d'autres problèmes non linéaires par Chen et al. [31]-[32]. On présentera la version de l'algorithme de sélection légèrement modifié et ceci pour améliorer l'efficacité du calcul.

On suppose, à l'étape k de cette procédure, que les k-1 ondelettes précédemment choisies correspondent aux vecteurs $u_{0_1}, \dots, u_{0_{k-1}}$. Pour choisir la $k^{\text{ème}}$ ondelette, on doit calculer la distance entre y et l'espace $span(u_{o_1}, \dots, u_{o_{k-1}}, u_j)$ où $j = 1, \dots, H$ et $j \neq o_1, \dots, o_{k-1}$. Pour un calcul efficace, on orthogonalise les vecteurs u_j récemment sélectionnés avec les vecteurs $u_{0_i}, (i = 1, \dots, k-1)$ déjà sélectionnés. Supposons que $u_{0_1}, \dots, u_{0_{k-1}}$ soient déjà orthonormés et renommés $s_{0_1}, \dots, s_{0_{k-1}}$ alors

$$span(u_{o_1},...,u_{o_{k-1}},u_j) = span(s_{o_1},...,s_{o_{k-1}},u_j)$$
 (2.21)

Pour chaque $j = 1, \dots, H$ et $j \neq o_1, \dots, o_{k-1}$, on calcule:

$$p_{j} = u_{j} - ((u_{j}^{T} s_{o1}) s_{o1} + \dots + (u_{j}^{T} s_{ok-1}) s_{ok-1})$$
(2.22)

$$q_{j} = \frac{p_{j}}{\left(p_{j}^{T} p_{j}\right)^{\frac{1}{2}}}$$
(2.23)

On cherche donc le vecteur u_j ou q_j qui minimise la fonction:

$$J(u_{j}) = J(q_{j})$$

$$= [y - (\widetilde{\omega}_{o1}s_{o1} + \dots + \widetilde{\omega}_{ok-1}s_{ok-1} + \widetilde{\omega}_{j}q_{j})]^{T}[y - (\widetilde{\omega}_{o1}s_{o1} + \dots + \widetilde{\omega}_{ok-1}s_{ok-1} + \widetilde{\omega}_{j}q_{j})]$$

$$= [y - S_{j}\widetilde{W}_{j}]^{T}[y - S_{j}\widetilde{W}_{j}] \qquad (2.24)$$

Où:
$$S_j = (s_{o1}, \dots, s_{ok-1}, q_j)$$
 et $\widetilde{W}_j = (\widetilde{\omega}_{o1}, \dots, \widetilde{\omega}_{ok-1}, \widetilde{\omega}_j)^T = (S_j^T S_j)^{-1} S_j^T y = S_j^T y$ avec $S_j^T S_j = I$

Cette égalité est due à l'orthonormalité de vecteurs $s_{o1},...,s_{ok-1}$ et q_j . La fonction $J(u_j)$ devient:

$$J(u_{j}) = y^{T} y + \widetilde{W}_{j}^{T} S_{j}^{T} S_{j} \widetilde{W}_{j} - 2\widetilde{W}_{j}^{T} S_{j}^{T} y$$
$$= y^{T} y + \widetilde{W}_{j}^{T} \widetilde{W}_{j} - 2\widetilde{W}_{j}^{T} S_{j}^{T} y \qquad (2.25)$$

Comme $\widetilde{W}_j = S_j^T y$, alors:

$$J(u_{j}) = y^{T} y + \widetilde{W}_{j}^{T} \widetilde{W}_{j} - 2\widetilde{W}_{j}^{T} \widetilde{W}_{j}$$
$$= y^{T} y - \widetilde{W}_{j}^{T} \widetilde{W}_{j}$$
$$= y^{T} y - (\widetilde{\omega}_{o1}^{2} + \dots + \widetilde{\omega}_{ok-1}^{2} + \widetilde{\omega}_{j}^{2}) \qquad (2.26)$$

Par conséquent, la minimisation de $J(u_j)$ équivaut à la maximisation de la somme $(\tilde{\omega}_{o1}^2 + \ldots + \tilde{\omega}_{ok-1}^2 + \tilde{\omega}_j^2)$. D'après la relation $\tilde{W}_j = S_j^T y$, on peut écrire:

$$\widetilde{\omega}_{oi} = s_{oi}^{T} y, i = 1, \dots, k - 1$$
(2.27)

$$\widetilde{\omega}_j = q_j^T y \tag{2.28}$$

Alors la somme $(\tilde{\omega}_{o1}^2 + \ldots + \tilde{\omega}_{ok-1}^2)$ est indépendante de q_j . On conclut donc que la minimisation de $J(u_j)$ est équivalente a la maximisation de $\tilde{\omega}_j^2 = (q_j^T y)^2$.

Après *h* itérations, toutes les ondelettes sont choisies et le réseau d'ondelettes sera défini par l'ensemble des ondelettes $\{\psi_{ok}(X): k \in \{1, ..., h\}\}$ tel que:

$$(N_{\theta_{N}}^{d,T})_{h}(X) = \sum_{k=1}^{h} \omega_{ok} \psi_{ok}(X)$$
(2.29)

Il reste à déterminer les valeurs des poids linéaires ω_{ok} où o_k $(k = 1, ..., h) \in \{o_1, ..., o_h\}$.

Si on fait la combinaison de deux vecteurs $p_j \text{ et } q_j$, $j = o_k$, alors:

$$u_{ok} = ((u_{ok}^{T} s_{o1}) s_{o1} + \dots + (u_{ok}^{T} s_{ok-1}) s_{ok-1}) + p_{ok}$$

= $((u_{ok}^{T} s_{o1}) s_{o1} + \dots + (u_{ok}^{T} s_{ok-1}) s_{ok-1}) + (p_{ok}^{T} p_{ok})^{\frac{1}{2}} q_{ok}$
= $((u_{ok}^{T} s_{o1}) s_{o1} + \dots + (u_{ok}^{T} s_{ok-1}) s_{ok-1}) + (p_{ok}^{T} p_{ok})^{\frac{1}{2}} s_{ok}$
= $\alpha_{1k} s_{o1} + \dots + \alpha_{k-1k} s_{ok-1} + \alpha_{kk} s_{ok}$ (2.30)

Où :

$$\alpha_{ik} = u_{ok}^{T} \omega_{oi}, i = 1, \dots, k - 1$$
(2.31)
$$\alpha_{kk} = (p_{ok}^{T} p_{ok})^{\frac{1}{2}}$$
(2.32)

Par conséquent:
$$(s_{o1},...,s_{oh})A = (u_{o1},...,u_{oh})$$
 (2.33)

A est une matrice triangulaire:

$$A = \begin{pmatrix} \alpha_{11} & \alpha_{12} & \alpha_{13} & \dots & \alpha_{1h} \\ 0 & \alpha_{22} & \alpha_{23} & \dots & \alpha_{2h} \\ 0 & 0 & \alpha_{33} & \dots & \alpha_{3h} \\ \vdots & \vdots & \ddots & \ddots & & \vdots \\ 0 & 0 & \dots & 0 & \alpha_{h-1h-1} & \alpha_{h-1h} \\ 0 & 0 & \dots & 0 & \alpha_{hh} \end{pmatrix}$$
(2.34)

Les paramètres w_{ok} peuvent être calculés en résolvant le système d'équations linéaires suivant:

 $A(\omega_{a1},\ldots,\omega_{ab})^T = (\widetilde{\omega}_{a1},\ldots,\widetilde{\omega}_{ab})^T \quad (2.35)$

Car:

$$y = (s_{o1}, \dots, s_{oh})(\widetilde{\omega}_{o1}, \dots, \widetilde{\omega}_{oh})^{T} + R_{h}$$

$$= (u_{o1}, \dots, u_{oh})(\omega_{o1}, \dots, \omega_{oh})^{T} + R_{h} \qquad (2.36)$$

 R_h est le terme d'erreur.

Cette technique de régression est mathématiquement équivalente à l'algorithme classique de Gram-Schmidt [33], mais elle est plus stable numériquement et moins coûteuse au niveau du temps de calcul. La procédure d'orthogonalisation des vecteurs u_j utilisée dans cette technique est équivalente à la factorisation de la matrice $U = \{u_{o1}, u_{o2}, ..., u_{oh}\}$ (les vecteurs $u_{o1}, u_{o2}, ..., u_{oh}$ sont linéairement indépendants):

$$U = QA \tag{2.37}$$

 $Q = \{q_{o1}, q_{o2}, ..., q_{oh}\}$ où les vecteurs $q_{o1}, q_{o2}, ..., q_{oh}$ sont orthonormés et la matrice A est une matrice triangulaire supérieure. $\{o_1, o_2, ..., o_h\}$ est l'ensemble d'indices représentant les différentes ondelettes choisies de la librairie d'ondelette et h est le nombre de ces ondelettes choisies. Après la sélection de h vecteurs linéairement indépendants, les poids linéaires du réseau d'ondelettes:

$$N_{\theta_{N}}^{d,T}(X) = \sum_{k=1}^{h} \omega_{ok} \psi_{ok}(X) \quad (2.38)$$

Peuvent être calculés en résolvant un système d'équations linéaires:

$$Uw = y \qquad (2.39)$$

et

$$\omega = (\omega_{o1}, \omega_{o1}, \dots, \omega_{oh})^T$$

Cependant comme la matrice Q est composée de h vecteurs $q_{ok}(k = 1, 2, ..., h)$ orthonormés, alors la résolution du système d'équations linéaires U = QA est équivalente à la résolution du système:

$$Aw = Q^T y \quad (2.40)$$

Où

$$Q^T Q = I$$
.

• Résumé de l'algorithme

Étape 1:

Posons $J_H = \{1, 2, ..., H\}$ Trouver $o_1 = \arg \max_{j \in J_H} (u_j^T y)^2$ Alors: $\widetilde{\omega}_{o1} = u_{o1}^T y$ $s_{o1} = u_{o1}$ $\alpha_{11} = 1$ $p_j^{(1)} = u_j$ $j \in J_H, j \neq o_1$

Étape k (k = 2,...,h):

$$J_{k} = J_{k-1} - \{o_{k-1}\}$$

Pour chaque $j \in J_k$, calculer:

$$p_{j}^{(k)} = p_{j}^{k-1} - (u_{j}^{T} s_{ok-1}) s_{ok-1}$$
$$J_{k} = J_{k} - \{j : p_{j}^{(k)} = 0\}$$

Trouver:
$$o_k = \arg \max_{j \in J_H} \frac{((p_j^{(k)})^T y)^2}{(p_j^{(k)})^T (p_j^{(k)})}$$

Alors:

$$s_{ok} = ((p_{ok}^{(k)})^T p_{ok}^{(k)})^{-\frac{1}{2}} p_{ok}^{(k)}$$

$$\widetilde{\omega} = s_{ok}^T y$$

$$\alpha_{ik} = u_{ok}^T s_{oi} \qquad i = 1, \dots, k - 1$$

$$\alpha_{kk} = ((p_{ok}^{(k)})^T p_{ok}^{(k)})^{\frac{1}{2}}$$

Étape k + 1: résoudre le système d'équations linéaires:

$$A(\omega_{o1},\ldots,\omega_{oh})^{T} = (\widetilde{\omega}_{o1},\ldots,\widetilde{\omega}_{oh})^{T}$$

Afin de déterminer les valeurs de w_{ok} , $k \in \{1, ..., h\}$, du réseau d'ondelette

$$(N_{\theta_N}^{d,T})_h(X) = \sum_{k=1}^h \omega_{ok} \psi_{ok}(X)$$

Deux autres techniques heuristiques peuvent être adoptées pour sélectionner les meilleurs régresseurs de la librairie d'ondelettes Γ déjà créée:

1. The residual based selection: Cette technique consiste à choisir, en premier lieu, l'ondelette qui approxime au mieux la base d'apprentissage θ_N , puis de sélectionner d'une manière itérative à chaque étape l'ondelette qui approxime au mieux le résidu de l'approximation réalisée à l'étape précédente. Contrairement à ce que nous présentions précédemment, cette technique ne prend pas en considération l'interaction ou la nonorthogonalité des ondelettes de la librairie Γ . Dans la littérature sur l'analyse de régression classique [20], cette méthode est considérée comme une méthode très simple mais elle n'est pas très efficace. 2. Backward elimination: Cette technique consiste à éliminer successivement à chaque étape une ondelette de la librairie Γ. Si h est le nombre d'ondelette (déjà fixé) de la couche cachée du réseau, alors on devra éliminer H − h ondelettes de la librairie Γ. Ce qui nous ramène à effectue H − h étapes de calculs afin de choisir les h ondelette du réseau. Du point de vue performance, les deux algorithmes offrent des résultats presque identiques.

A.5 Choix du nombre de neurones cachés dans un réseau d'ondelettes.

Dans le paragraphe précédent, on a décrit la méthode de sélection de régresseurs et on a supposé que le nombre d'ondelettes h à sélectionner pour construire le réseau d'ondelette était connu. Mais en générale ce n'est pas le cas et le choix de h est très difficile et très fortement lié à la nature du problème non linéaire à modéliser.

La performance de l'algorithme de sélection de régresseurs sera contrôlée par le calcul du terme d'erreur $J_{FPE}(N_{\theta_N}^{d,T})$ « Akaike's Final Prediction Error Criterion » [26] :

$$J_{FPE}(N_{\theta_{N}}^{d,T}) = \frac{1 + \frac{n_{\omega}}{N}}{1 - \frac{n_{\omega}}{N}} \cdot \frac{1}{2N} \sum_{i=1}^{N} (N_{\theta_{N}}^{d,T}(X_{i}) - y_{i})^{2} = F_{p} \cdot MSE \quad (2.41)$$

Où n_w est le nombre de paramètres (les paramètres de dilatation et de translation et les paramètres linéaire) du réseau $N_{\theta_N}^{d,T}$, $(X_i, y_i) \in \theta_N$ est un point désiré de la base d'apprentissage et N est le nombre de points (X_i, y_i) dans la base θ_N . Si p est la dimension du vecteur d'entrée X_i , alors $n_w = h(p+2) + p + 1$.

 $F_{p} = (1 + \frac{n_{w}}{N})/(1 - \frac{n_{w}}{N}) \text{ est le facteur de pénalité et } MSE = \frac{1}{2N} \sum_{i=1}^{N} N_{\theta_{N}}^{d,T} (X_{i}) - y_{i})^{2} \text{ est l'erreur quadratique moyenne.}$

 $J_{FPE}(N_{\theta_N}^{d,T})$ n'est donc que le produit entre l'erreur *MSE* et le facteur de pénalité F_p . On doit choisir *h* de façon que l'erreur *MSE* soit minimisée, mais comment choisir *h*? L'objectif est d'identifier une fonction non linéaire quelconque $f: \mathbb{R}^P \to \mathbb{R}$ avec un nombre de paramètres suffisamment petit. Le nombre de ces paramètres, ou le nombre d'ondelette, dépend bien sûr de la solution désirée, c'est-à-dire de la précision souhaitée du modèle. Pendant la phase d'initialisation, on doit observer l'évolution de la fonction d'erreur *MSE* ou $J_{FPE}(N_{\theta_N}^{d,T})$, et on peut choisir le bon point de départ du réseau pouvant conduire pendant la phase d'apprentissage vers le minimum global désiré du modèle.

Si le nombre d'ondelettes sélectionnées pendant la phase d'initialisation est très importante, on risque quelques fois de ne pas utiliser la phase d'apprentissage. Le minimum désiré du réseau peut être alors atteint à la fin de la phase d'initialisation. Dans ce cas, l'utilisation du réseau de neurones n'a aucun sens, et on peut considérer l'estimateur de la fonction f(X) comme une combinaison linéaire des ondelettes de la librairie Γ qui a été construit seulement par la méthode de sélection de régresseurs.

B. Extraction des paramètres

La modélisation des battements cardiaques contribue à l'extraction des paramètres nécessaires à la classification des individus. Les paramètres de classification sont les paramètres des différentes ondelettes à savoir la translation, la dilatation et le poids. Ces trois paramètres sont les principales caractéristiques des ondelettes. Le coefficient de translation (t) représente le déplacement de l'ondelette le long du signal et le coefficient de dilatation (d) représente l'échelle de l'ondelette alors que le poids (w) exprime son amplitude (figure 2.12).



Figure 2.12 : Les paramètres de classification.

Exemple

La figure 2.13 (a-d) montre 2 battements cardiaques provenant de 2 individus différents et les 10 ondelettes utilisées pour la modélisation de chaque battement.

La figure 2.14 (a-c) présente les paramètres de translation, dilatation et poids de la deuxième ondelette utilisée dans la modélisation des 120 battements cardiaques de chaque individu. Nous constatons que ces paramètres diffèrent d'un individu à un autre ce qui explique la validité de les utiliser pour la classification.



Figure 2.13 : (a) Battement moyenné (Individu 1); (b) Battement moyenné (Individu 2); (c) 10 ondelettes utilisées pour la modélisation (Individu 1) ; (d) 10 ondelettes utilisées pour la modélisation (Individu 2).



Figure 2.14 : (a) le paramètre de translation de la deuxième ondelette; (b) le paramètre de dilatation de la deuxième ondelette; (c) le paramètre de poids de la deuxième ondelette;

2.4 Conclusion

Dans la première partie de ce chapitre, nous avons résumé dans un premier temps, les différentes méthodes d'identification biométrique basée sur l'ECG. Nous avons ensuite développé notre propre méthode d'identification biométrique. L'approche en question est fondée sur l'analyse paramétrique des battements cardiaques. La technique proposée nécessite une phase d'apprentissage utilisant 120 battements et une phase d'identification utilisant 100 battements.

Dans la phase d'apprentissage, 5 ou 10 battements sont moyennés, puis modélisés par réseau d'ondelettes. Dix ondelettes ont été donc utilisées. Les coefficients correspondant à ces ondelettes sont présentés à l'entrée d'un réseau de neurones.

Dans la même section, nous avons également décrit les réseaux d'ondelettes inspirés de la théorie de réseaux de neurones et de la décomposition d'une fonction quelconque en ondelettes. Nous avons présenté ensuite la structure du réseau d'ondelettes. La construction du réseau d'ondelettes est basée sur l'algorithme de sélection de régresseurs « Stepwise Selection by Orthogonalization ». Les réseaux d'ondelettes sont utilisés pour modéliser les battements cardiaques afin d'extraire les paramètres nécessaires pour la classification et l'identification des individus. Finalement, nous avons montré un exemple illustrant la différence entre les paramètres extraits des différentes ondelettes entre les différents individus.

Dans le chapitre suivant, nous présenterons deux méthodes d'identification biométrique basées sur les signaux EMG. Il sera étudié, d'une part, la biométrie en réponse à contraction musculaire volontaire et d'autre part, la biométrie impliquant les réponses motrices.

Chapitre 3

Caractérisation de l'EMG pour la biométrie

3.1 Introduction

Les signaux électromyogrammes (EMG), sont des signaux biologiques électriques enregistrés au niveau des muscles. Ils fournissent des informations diverses sur l'état des nerfs périphériques et des muscles. Plusieurs méthodes complémentaires d'exploration peuvent être employées successivement au cours d'un examen [35].

On distingue :

- examen électromyographique EMG, dit aussi EMG de « détection ».
- étude de la conduction nerveuse (motrice, sensitive, réflexe...) et étude de la transmission neuromusculaire.

Des études montrent que les signaux EMG comportent des caractéristiques spécifiques pour chaque individu ce qui permet de les utiliser pour différencier les individus et déterminer leurs identités.

Ce chapitre sera divisé en deux parties.

Dans la première partie du chapitre, nous présentons une méthode d'identification biométrique basée sur les signaux EMG de surface (SEMG) en réponse à une force d'intensité fixe. L'utilisation des signaux EMG en biométrie est nouvelle. Elle fait actuellement l'objet d'une étude au laboratoire LiSSi de l'UPEC. En effet, à ce jour, il n'existe aucune méthode biométrique connue utilisant les EMG. Dans cette partie, nous décrivons d'abord les SEMG, puis nous décrirons des différentes étapes de la méthode qu'on a utilisée pour identifier les individus.

Dans la deuxième partie de ce chapitre, nous exposons une nouvelle méthode d'identification biométrique basée sur les réponses motrices M résultant de l'étude de la conduction nerveuse motrice. Ce type de biométrie est également nouveau et l'équipe de recherche LiSSi de l'UPEC est en train de le développer actuellement. La première section de cette partie est consacrée à la description de l'étude de la conduction nerveuse et de ses différents types. Ensuite, nous aborderons la conduction nerveuse motrice qui constitue la base de notre méthode. Dans la deuxième section, nous décrivons les différentes étapes de notre méthode d'identification par réponse motrice M que nous avons appliquée pour identifier les individus.

I. La biométrie par EMG

I.1 Introduction

Un électromyogramme est un examen qui consiste à analyser l'activité électrique des muscles. Comme décrit précédemment, il existe plusieurs types d'examens EMG. Dans cette partie, nous nous intéressons à l'EMG de détection ou l'EMG de surface (SEMG). Le SEMG ne nécessite pas une stimulation électrique. Les activités électriques enregistrées sont produites spontanément au cours d'une contraction volontaire. Ces activités produisent des informations sur l'état fonctionnel des muscles et de leur innervation. Outre sa fonction médicale, les SEMG sont orientés dans le cadre de notre thèse pour des applications d'authentification et d'identification.

I.2 SEMG

Quand les muscles se contractent, de l'électricité au niveau des signaux (microvolt) est créés dans le muscle et peut être mesuré à partir de la surface du corps. La procédure de mesure de l'activité électrique musculaire à partir de la peau est appelée électromyographie de surface (SEMG) [36].

L'EMG de surface (SEMG) a quelques caractéristiques intéressantes : son acquisition est indolore et L'EMG peut s'avérer utile dans l'avenir pour aider à surveiller la progression des troubles des nerfs et des muscles.

Le SEMG permet aussi d'évaluer l'état fonctionnel des muscles squelettiques et aider à la formation et la réadaptation neuromusculaire. Le courant électrique faible, ou le signal généré par les muscles actifs, est détecté par des capteurs placés sur la peau directement au-dessus des

muscles. Le SEMG, outre sa fonction comme outil de diagnostic, est utilisé ici pour des objectifs de reconnaissance d'individus.

I.3 Nouvelle technique biométrique par EMG

I.3.1 Introduction

Le signal électromyogramme (EMG) est constitué d'une série de trains de potentiel d'action des unités motrices détectés par des électrodes placées sur la surface de la peau. Ce signal est appelé électromyogramme de surface (SEMG).

Comme nous allons le montrer plus loin, l'approche en question consiste à calculer la densité spectrale de puissance (DSP) à partir des réponses EMG. La DSP sera donc ensuite modélisée et les paramètres extraits seront utilisés comme information biométrique.

Dans ce qui suit, nous présenterons les différentes étapes appliquées aux signaux SEMG. La figure 3.1 présente le schéma général de notre méthode, à savoir, l'estimation de la DSP, l'extraction des paramètres fréquentiels et enfin la classification par réseau de neurones RBF.



Figure 3.1 : Schéma général de l'approche biométrique par SEMG.

I.3.2 Acquisition des SEMG

L'enregistrement des signaux SEMG a été effectué au laboratoire LiSSi de l'Université Paris-Est Créteil (UPEC). Ces signaux sont acquis en utilisant un système BIOPAC. Les signaux ont été recueillis à l'aide de 3 électrodes placées sur le bras droit comme le montre la figure 3.2. Des forces d'intensité de 5 Kg et 10 Kg sont appliqués sur le capteur. La durée de chaque signal est 3 secondes.



Figure 3.2 : Mesure des SEMG.

Les signaux réels dont nous disposons ont été obtenus sur 10 personnes saines : 9 hommes et une femme. Dans un premier temps, notre méthode consiste à estimer la densité spectrale de puissance des SEMG acquis.

I.3.3 Estimation de la densité spectrale de puissance

L'estimation de la densité spectrale de puissance d'un signal EMG est très importante car c'est à partir de cette densité que nous allons calculer les paramètres pertinents que l'on doit utiliser pour l'identification des individus. La méthode en question estime la DSP par la technique de Welch [38]. Un rappel est donné dans la sous-section suivante.

A. Densité Spectrale de Puissance

La densité spectrale de puissance est un outil fondamental pour l'étude des processus aléatoires. Elle représente la répartition de la puissance sur l'axe des fréquences. Dans la théorie des processus aléatoires, cette définition constitue le théorème suivant : Pour définir la Densité Spectrale de Puissance (DSP) du processus $\{X_n\}$, on applique la relation de Plancherel dans la définition de la puissance moyenne :

$$P_{moy} = \lim_{N \to \infty} \frac{1}{2N+1} E(\int_{(\frac{1}{T})} |X_N(f)|^2 df)$$

$$= \int_{(\frac{1}{T})} \lim_{N \to \infty} \frac{1}{2N+1} E(|X_N(f)|^2) df$$
(3.1)

Où :

$$X_N(f) = \sum_{|n| \le N} X_n e^{-2j\pi n f T}$$
(3.2)

est la transformée de Fourier du processus tronqué à (-N, N). Il vient alors naturellement la définition suivante de la *densité spectrale de puissance* (DSP) :

$$S(f) = \lim_{N \to \infty} \frac{1}{2N+1} E(|X_N(f)|^2)$$
(3.3)

Il existe deux types d'estimation de la DSP : paramétrique et non-paramétrique. Dans notre ce travail, nous utilisons l'approche non-paramétrique basée sur le périodogramme.

B. Le périodogramme

Le périodogramme est une méthode d'estimation de la densité spectrale de puissance d'un signal. La méthode directe de calcul du périodogramme utilise la transformée de Fourier rapide (*FFT*) du signal.

Cette méthode permet de calculer rapidement la densité spectrale de puissance d'un signal échantillonné de durée finie, même s'il est périodique. Cet estimateur est biaisé et présente une variance non nulle. On a $Var\{\hat{S}_{per}(w)\}=S_x^2(w)$ quel que soit N [39]-[40]. Cet estimateur donc est inconsistant, la variance du périodogramme étant très grande.

Pour améliorer les performances de l'estimateur précédent, Bartlett [42]-[43] a proposé une modification au périodogramme.

En réalité, parmi les méthodes d'estimation non paramétriques, on utilise plutôt la méthode du périodogramme moyenné modifié ou méthode de Welch [42].

C. La méthode de Welch

En 1967, Welch proposa deux modifications à la méthode de Bartlett. La première est de permettre aux séquences $x_i(n)$ de se recouvrir et la seconde est de rajouter une fenêtre à chacune de ces séquences, produisant ainsi un ensemble de périodogrammes modifiés qui sont moyennés. En supposant que les séquences successives sont décalées de D ($\leq L$) échantillons et que chacune d'entre elles est de longueur L, la *i*-ème séquence est donnée par:

$$x_i(n) = x(n+iD), \quad n = 0,1,...,L-1$$

(3.4)

Ainsi, la quantité de recouvrement (overlap) entre $x_i(n)$ et $x_{i+1}(n)$ est L-D points, si K séquences couvrent les N données du signal.

Alors :

$$N = L + D(K - 1)$$
(3.5)

Par exemple, sans recouvrement (D = L) on a $K = \frac{N}{L}$ sections de longueur L comme dans la méthode de Bartlett. D'un autre côté, si les séquences se recouvrent de 50% $(D = \frac{L}{2})$, alors on peut former

$$K = 2\frac{N}{L} - 1 \tag{3.6}$$

sections de longueur L. On peut maintenir la même résolution (longueur de section) que la méthode de Bartlett tout en doublant le nombre de périodogrammes modifiés qui sont moyennés ($K \approx \frac{2N}{L}$), réduisant ainsi la variance. Cependant, avec 50% de recouvrement, on peut aussi former

$$K = \frac{N}{L} - 1 \tag{3.7}$$

sections de longueur 2L. On peut donc améliorer la résolution et maintenir la même variance que la méthode de Bartlett.

Par conséquent, en permettant les séquences de se recouvrir, il est possible d'augmenter le nombre et/ou la longueur des séquences qui sont moyennées, pour arriver à un compromis entre la réduction de la variance et une meilleure résolution.

La méthode de Welch peut s'écrire directement en fonction de x(n):

$$\hat{S}_{W}(w) = \frac{1}{KLU} \sum_{i=0}^{K-1} \left| \sum_{n=0}^{L-1} w(n) x(n+iD) \exp(-jwn) \right|^{2}$$
(3.8)

Où en fonction du périodogramme modifié:

$$\hat{S}_{W}(w) = \frac{1}{K} \sum_{i=0}^{K-1} \hat{S}_{per.m}^{(i)}(w)$$
(3.9)

On peut montrer que:

$$E\left\{\hat{S}_{W}(w)\right\} = E\left\{\hat{S}_{per.m}(w)\right\} = \frac{1}{2\pi L U}S_{x}(w)*|W(w)|^{2}$$
(3.10)

où W(w) est la transformée de Fourier de la fenêtre w(n). Ainsi, la méthode de Welch est asymptotiquement non-biaisée. La résolution dépend de la fenêtre.

La méthode de Welch est la méthode non paramétrique la plus utilisée pour estimer un spectre [39], [40], [43], car elle réduit davantage la variance de l'estimateur que celle de Bartlett [39]-[41].

Suite à l'estimation de la DSP, nous extractions les paramètres de classification.

I.3.4 Extraction des paramètres à partir de la densité spectrale

A. Introduction

L'extraction des paramètres des signaux est une étape essentielle avant la classification. Il faut extraire les paramètres pertinents, discriminants et les plus adaptés au signal.

Les paramètres de classification dans notre méthode sont extraits à partir de la DSP. Deux types de paramètres peuvent être extraits directement de la densité spectrale des signaux réels ou simulés : paramètres spectraux et paramètres statistiques (i.e. valeur moyenne, écart type, puissance, dissymétrie, etc.). Nous utilisons les paramètres spectraux ou fréquentiels. Les paramètres extraits sont : la puissance, le kurtosis, la fréquence médiane, les déciles, le coefficient de dissymétrie et la fréquence pic.

Dans ce qui suit, nous décrivons ces paramètres spectraux.

B. Paramètres spectraux

• Puissance de signal

Elle représente la répartition de l'énergie M_0 (Moment d'ordre 0) du signal sur l'axe des fréquences, avec le Moment d'ordre r donné par l'expression :

$$M_{r} = 2\int_{0}^{\infty} f^{r} S_{x}(f) df$$
(3.11)

 $S_x(f)$ est la densité spectrale du signal.

• Fréquence moyenne

Elle représente la moyenne statistique du signal.

$$MPF = \frac{M_1}{M_0} \tag{3.12}$$

• Coefficient d'aplatissement (Kurtosis)

Le kurtosis caractérise la forme de pic ou l'aplatissement relatif d'une distribution comparée à une distribution normale. Un kurtosis positif indique une distribution relativement pointue, tandis qu'un kurtosis négatif signale une distribution relativement aplatie. Il est donné par la formule :

$$CA = \frac{M_4^*}{M_2^{2^*}}$$
(3.13)

• Fréquence médiane

La médiane partage la distribution de la densité spectrale en deux parties : 50% des données sont plus petites que la médiane, 50% sont plus grandes.

La médiane est calculée par:

$$\int_{0}^{Fmed} S_{x}(f)df = \int_{Fmed}^{F\max} S_{x}(f)df$$
(3.14)

• Déciles

On a vu que la médiane partage la distribution de la densité spectrale en deux parties. On peut généraliser le partage de cette distribution en quatre, en dix, en cent, ou en un nombre quelconque de parties. Les valeurs ainsi obtenues sont appelées des quartiles, des déciles, des percentiles (ou centiles), ou des quantiles.

$$\int_{f_F-1}^{f_F} S_x(f) df = k \int_0^{F \max} S_x(f) df \quad 0 < k \le 1$$
(3.15)



Figure 3.3: Paramétrage du spectre.

La figure 3.3 montre les déciles permettent de témoigner de la forme fine du spectre, la MPF représente sa moyenne statistique.

• Coefficient de dissymétrie

Ce paramètre donne des informations concernant la forme de la densité spectrale du point de vue symétrique. Il est défini par:

$$CD = \frac{M_{3}^{*}}{\sqrt{M_{2}^{3^{*}}}}$$

$$M_{r}^{*} = 2\int_{0}^{\infty} (f - MPF)^{r} S_{x}(f) df$$
(3.16)

• Fréquence pic

La Fréquence pic est la fréquence pour laquelle la fonction de densité spectrale atteint un maximum.

Ces paramètres extraits sont présentés à l'entrée du réseau neural artificiel RBF afin d'identifier l'identité des individus.
II. La biométrie par réponse motrice M

II.1 Introduction

L'étude de la conduction nerveuse mesure la vitesse de conduction nerveuse en enregistrant le temps séparant l'envoi d'une impulsion dans un nerf, et sa réception sur un muscle sain. Cette vitesse permet d'estimer la capacité du nerf à transporter l'influx. Ces méthodes consistent à stimuler le nerf en lui délivrant une petite impulsion électrique. La réponse conduite par le nerf est enregistrée à l'aide d'électrodes autocollantes disposées à distance. L'utilité de cette étude nerveuse dépasse les limites du domaine médical. Elle constitue un outil biométrique efficace que le LiSSi (UEPC) est en train de développer, notamment à travers de cette thèse.

Dans cette partie, nous décrivons d'abord l'étude de la conduction nerveuse et ses différents types. Nous présenterons ensuite, la conduction nerveuse motrice. Les différentes étapes d'identification biométrique seront détaillées, étape par étape.

II.2 Etude de la conduction nerveuse

L'étude de la conduction nerveuse est une technique ancienne. Elle se résume dans ce qui suit : étude de la conduction motrice, étude de la conduction sensitive, étude de l'onde F et étude des réflexes.

Dans ce qui suit, nous décrivons brièvement ces différents types de conduction.

A. Etude de la conduction motrice

L'étude des vitesses de conduction motrice nécessite la stimulation d'un nerf moteur en deux points avec une impulsion électrique de quelques millièmes d'Ampère. Le muscle génère une réponse qui est recueillie à l'aide d'électrodes. L'étude de la conduction motrice mesure la vitesse de propagation du courant électrique le long du nerf, appelée vitesse de conduction motrice. La vitesse de conduction des fibres nerveuses les plus rapides est généralement déterminée.

B. Etude de la conduction sensitive

L'étude des vitesses de conduction sensitive nécessite encore une stimulation électrique des nerfs sensitifs d'intensité inférieure à celle utilisée dans l'étude de la conduction motrice. Cette étude permet de calculer la vitesse de conduction des fibres sensitives.

C. Etude de l'onde F

L'onde F est un potentiel d'action de longue latence généré par un muscle suite à une stimulation supramaximale du nerf. Généralement, plusieurs stimuli supramaximaux sont nécessaires avant qu'une réponse F soit observée. De plus seulement quelques stimuli atteignent les cellules de la corne antérieure au moment convenable pour les dépolariser. L'onde F se produit lorsque le stimulus se déplace le long des fibres motrices et atteint la cellule de la corne antérieure à un temps critique pour la dépolariser. La réponse se propage le long de l'axone et provoque une contraction minimale du muscle. L'onde F est toujours précédée d'une réponse motrice de faible amplitude de l'ordre de 0.2-0.5 mV.

Parce que les différentes cellules de la corne antérieure sont activées à des moments différents, la forme et la latence des ondes F sont différents les uns des autres. Classiquement 10 à 20 ondes F sont obtenues et l'onde ayant la plus courte latence est utilisée.

D. Etude du Réflexe H

L'évaluation de l'excitabilité réflexe des motoneurones par une stimulation électrique afférente est connue, dans la littérature, sous le nom de la « réponse H » [44]. La réponse H est initialement décrite par Paul Hoffmann en 1910 d'où son nom [45]. Cette réponse électromyographique est obtenue par la sollicitation de la boucle réflexe <u>Ia–Alpha</u> par stimulation électrique du nerf musculaire mixte (figure 3.4). L'impulsion électrique est ajustée de manière à atteindre le seuil d'excitabilité des seules fibres nerveuses sensitives, sans solliciter les fibres nerveuses motrices de ce nerf. Le résultat de cette stimulation est une réponse électromyographique tardive (appelée réponse H) par rapport à la réponse M (qui représente la réponse motrice directe et précoce des fibres musculaires dont le nerf est stimulé) et elle est

considérée comme une réponse indirecte recrutant les motoneurones de façon réflexe par mise en jeu des afférences fusoriales Ia.



Figure 3.4 : Boucle réflexe <u>Ia-Alpha</u>.

Dans notre travail, nous utilisons la conduction nerveuse motrice qui sera décrite en détail dans ce qui suit.

II.3 La conduction nerveuse motrice M

Pour examiner les propriétés de conduction des fibres nerveuses motrices, un nerf mixte est stimulé électriquement avec un seul stimulus de courte durée. La réponse M est l'expression électromyographique de la contraction du muscle provoquée par stimulation directe des fibres motrices Alpha du nerf musculaire. HOFFMANN (1910 ; 1918) suggérait que la réponse motrice M correspond à l'activation directe des motoneurones Alpha par la stimulation de son nerf moteur [45]-[46].

Les potentiels d'action sont générés dans les axones des motoneurones alpha qui innervent les fibres musculaires extrafusales du muscle squelettique et sont directement responsables de l'ouverture de leur contraction. Les potentiels d'action évoqués du nerf se propagent le long des fibres motrices et activent les jonctions neuromusculaires des axones moteurs stimulés. La transmission synaptique au niveau des jonctions neuromusculaires entre les axones moteurs et les fibres musculaires produit des potentiels d'action musculaires sur les fibres musculaires innervés et déclenche une contraction des fibres musculaires. Dans l'étude de la conduction nerveuse motrice, nous mesurons l'onde qui précède la contraction musculaire réelle, l'onde M.

L'amplitude de cette onde est proportionnelle au nombre de fibres musculaires dépolarisées, et est donc un reflet de l'ampleur de l'activation des fibres musculaires produites à la suite de la stimulation du nerf moteur.

En augmentant l'amplitude du courant de stimulation du nerf moteur, plus d'axones moteurs sont stimulés et par suite une contraction maximale se produit. A ce niveau de stimulation, l'amplitude de l'onde M ne croît plus ; tous les axones moteurs situés directement sous le stimulateur sont excités, le nombre maximum de jonctions neuromusculaires est déclenché et les potentiels d'action sont générés sur les membranes de toutes les fibres musculaires innervées [47].

L'allure de la réponse M est identique à celles des réponses réflexes H, mais sa latence est très brève et son amplitude maximale est plus élevée puisqu'elle représente la sollicitation synchrone de toutes les unités motrices qui composent le muscle dont l'activité est recueillie par les électrodes de surface. Sur un muscle riche en fibres lentes, tel le muscle Soléaire [48], la réponse M est évoquée à une intensité de courant plus importante, du fait du seuil plus élevé des axones moteurs. A partir du seuil d'apparition, la réponse M croît progressivement pour atteindre une amplitude maximale stable.

L'utilisation de la réponse motrice M n'est plus limitée pour l'étude de la vitesse de la conduction nerveuse motrice. Dans ce chapitre, la réponse M est présentée comme outil biométrique utilisée pour déterminer l'identité des individus.

Dans la section suivante, nous développerons une nouvelle méthode d'identification biométrique basée sur la réponse M.

II.4 Nouvelle technique biométrique par réponse motrice M

II.4.1 Introduction

La réponse M résulte de la contraction du muscle suite à une stimulation directe des fibres motrices Alpha du nerf musculaire. Cette réponse est captée par des électrodes de surface placée sur la peau. La réponse motrice permet d'évaluer la conduction électrique des nerfs moteurs.

Dans cette partie, nous proposons la première méthode d'identification biométrique basée sur la réponse motrice M captée suite à une stimulation électrique. Cette technique d'identification consiste à modéliser les réponses M par réseaux d'ondelettes afin d'extraire les paramètres (translation, dilatation et poids) des différentes ondelettes utilisés pour identifier les individus. Le diagramme bloc de la technique proposée est présenté dans la figure 3.5. Dans ce qui suit, nous décrivons les différentes étapes de cette méthode.



Figure 3.5 : Schéma générale de notre méthode.

II.4.2 Acquisition des réponses motrices

Les réponses motrices M sont acquises à l'Hôpital gouvernemental de Rafic Hariri par le système KEYPOINT suite à une stimulation électrique d'intensité 20 mA et 30 mA. Les signaux ont été recueillis par l'intermédiaire de trois électrodes placées sur la main droite comme le

montre la figure 3.6(a). 20 stimulations électriques successives sont effectuées sur le nerf moteur de la main (figure 3.6(b)). La réponse M est enregistrée à partir du thénar (figure 3.6 (c)).



Figure 3.6 : (a) Position d'électrodes ; (b) Stimulation ; (c) Réponse motrice M.

II.4.3 Modélisation et extraction des paramètres

La modélisation des réponses motrices est le noyau de notre méthode. Les réponses M sont modélisées par réseaux d'ondelettes (décrits dans le deuxième chapitre). Chaque réponse est modélisée par 8 ondelettes. L'ondelette utilisée est le chapeau mexicain inverse. Les paramètres (translation, dilatation et poids) sont extraits des différentes ondelettes. Ces paramètres sont utilisés pour identifier les individus (figure 3.7(a)-(b)).



3.2 Conclusion

Dans ce chapitre, nous avons présenté deux méthodes d'identification biométrique. La première méthode est basée sur les signaux EMG de surface et la deuxième est basée sur les réponses motrices.

Dans la première partie de ce chapitre, nous avons abordé la méthode d'identification biométrique par EMG de surface (SEMG) que nous avons utilisée pour identifier les différents individus. Nous avons d'abord fait un rappel sur les signaux EMG de surface. Ensuite, nous avons décrit les différentes étapes de notre technique. L'identification des individus est effectuée par leur SEMG. Les signaux SEMG sont obtenus suite à une force d'intensité 5Kg et 10 Kg. Notre technique consiste à estimer d'abord la DSP des SEMG par la méthode de Welch puis extraire les paramètres spectraux qui sont utilisés dans la classification.

Dans la deuxième partie de ce chapitre nous avons développé notre méthode d'identification biométrique basée sur les réponses motrices M. Dans la première section de cette partie, nous avons présenté l'étude de la conduction nerveuse et ses différentes composantes et spécialement la conduction nerveuse motrice utilisée dans notre travail. Dans la deuxième section, nous avons décrit les différentes étapes de notre méthode. L'identification par réponse M consiste d'abord à modéliser les réponses motrices, acquises suite à une stimulation électrique, par réseaux d'ondelettes pour extraire les paramètres de classification.

Dans le chapitre suivant, nous présenterons la méthode de classification utilisée dans les différentes techniques d'identification par ECG, EMG et réponses M que nous avons proposées. Les résultats de classification biométrique seront ainsi présentés et discutés.

Chapitre 4

Adaptation des paramètres et classification biométrique : résultats

4.1 Introduction

Ce chapitre est consacré à la description de la méthode de classification utilisée dans les différentes méthodes biométriques présentées dans les chapitres précédents.

Dans la première partie, nous présenterons les différents types de classification : classification supervisée et classification non-supervisée.

La deuxième partie concerne les réseaux de neurones artificiels. Nous présentons une introduction aux réseaux neuronaux artificiels ainsi que les structures de neurones biologiques et formels. Nous exposons ensuite les différents types de réseaux de neurones artificiels et nous détaillons le réseau RBF utilisé dans notre méthode et l'algorithme d'apprentissage adopté pour entrainer ce type de réseau. Nous évoquerons aussi les structures du neurone biologique et du neurone formel ainsi que les différents types de réseaux de neurones artificiels.

La dernière partie de ce chapitre est dédiée à la présentation des résultats de classification biométrique de chaque méthode proposée dans les chapitres précédents et l'analyse de l'efficacité et de la performance de chacune.

4.2 Classification

Une fois les paramètres déterminés, la technique de classification doit être convenablement choisie. Nous présentons dans ce paragraphe un aperçu des méthodes classiquement utilisées, parmi lesquelles s'effectuera notre choix.

Les techniques de classification peuvent se regrouper en deux grandes familles [49]:

- La classification non supervisée : elle consiste à regrouper des éléments ayant un comportement similaire (au sens d'un critère à définir) dans des classes inconnues au préalable. Il n'y a donc pas lieu de disposer ici d'un ensemble d'apprentissage. La règle de classification consiste alors à découper l'espace en plusieurs sous-espaces selon le critère de similarité reliant les éléments.
- 2. La classification supervisée : consiste à classer des éléments d'un ensemble à partir de la connaissance à priori d'un ensemble d'apprentissage (l'ensemble d'apprentissage étant défini comme un ensemble d'observations dont on connaît pour chacune la classe à laquelle elle appartient). La règle de classification consiste d'abord à découper l'espace de représentation des éléments à classer et à attribuer à chacune des zones de ce découpage une des classes définies a priori (c'est la phase d'apprentissage), puis à classer les éléments en fonction de leur position dans l'espace ainsi structuré (c'est la phase de classement).

Dans le cadre de cette thèse, nous avons utilisé la classification supervisée.

4.3 Réseau de neurones

4.3.1 Introduction

Haykin propose la définition suivante [50]: « Un réseau de neurones est un processus distribué de manière massivement parallèle, qui a une propension naturelle à mémoriser des connaissances de façon expérimentale et de les rendre disponibles pour utilisation. Il ressemble au cerveau en deux points:

- 1. La connaissance est acquise au travers d'un processus d'apprentissage;
- 2. Les poids des connections entre les neurones sont utilisés pour mémoriser la connaissance.»

C'est sur base de cette définition que repose l'élaboration des réseaux de neurones artificiels. Un réseau de neurones est tout simplement considéré comme étant un ensemble de neurones formels connectés entre eux.

Neurone formel

Schéma fonctionnel

La première étude systématique du neurone artificiel est due au neuropsychiatre McCulloch et au logicien Pitts [51].

Le neurone formel, étant une représentation mathématique d'un neurone biologique, possède plusieurs entrées et une sortie. Son travail consiste à calculer la somme pondérée des entrées reçues puis appliquer à cette valeur une fonction d'activation et ainsi la sortie du neurone est la valeur finale obtenue.

Le neurone formel constitue l'unité élémentaire des réseaux de neurones artificiels. Associé à ses semblables, il calcule des fonctions arbitrairement complexes. Les entrées reçues proviennent de neurones appartenant à un niveau situé en amont. Un poids w représentatif de la force de la connexion est associé à chaque entrée. Chaque neurone possède une sortie unique et se ramifie ensuite pour alimenter un nombre variable de neurones situés en aval. Un poids est associé à chaque connexion.



Figure 4.1 : Le modèle de neurone formel.

Un neurone formel est défini par les paramètres suivants:

La somme u_j des sorties x_d avec 1≤ j ≤ d de neurones de la couche amont, connectés au neurone j, pondérées par les poids w_{dj} distribués aux différentes connexions, telle que :

$$u_{j} = \sum_{j=1}^{d} w_{dj} x_{d} = \sum_{0}^{d} w_{dj} x_{d} + \theta_{j}$$
(4.1)

Où :

- d est le nombre de neurones de la couche de la couche amont ;
- w_{dj} est le poids de la connexion dirigée du neurone d vers le neurone j:
- un poids positif indique un effet excitateur du neurone émetteur (d) vers le neurone récepteur (j);
- un poids négatif représente un effet inhibiteur.

$$w_{0i} = \theta_i \text{ et } x_0 = +1 \tag{4.2}$$

La somme u_j d'un neurone joue un rôle très important. Cette somme représente l'activation ou l'entrée totale du neurone.

- 2. Le seuil θ_j propre au neurone j est un nombre réel et représente la limite à partir de laquelle le neurone s'activera. Ce seuil peut jouer le rôle de poids de la connexion qui existe entre l'entrée fixée à +1 et le neurone j.
- 3. La fonction d'activation φ peut prendre différentes formes, telles que : fonction non linéaire, fonction à seuil binaire, fonction linéaire à seuil, etc.
- 4. La sortie du neurone y_j est fonction de la somme pondérée u_j , telle que :

$$y_j = \varphi(u_j) \tag{4.3}$$

4.3.2 Structure du réseau neuronal artificiel

Ce réseau neuronal artificiel est considérée comme un ensemble d'automates appartenant à des couches différentes, chacun étant relié à d'autres automates (à tous ou à certains) à partir des connexions représentées par les poids, dont il reçoit des impulsions, étant lui-même chargé de fournir une impulsion.

La topologie du réseau est déterminée par la structure des connexions entre les différents neurones déterminés.

On en distingue trois catégories :

- A. réseau neuronal multicouche de type Feedforward.
- B. réseau récurrent.
- C. réseau cellulaire.

Dans notre rapport, nous nous limitons au réseau de type Feedforward qu'on a utilisé dans notre démarche.

A. Réseau neuronal multicouche de type Feedforward

Un réseau neuronal de type Feedforward peut être simple, s'il se compose d'une seule couche (couches d'entrée et de sortie sont confondus) ou multicouche s'il est constitué de plusieurs couches : une couche d'entrée, plusieurs couches cachées (internes ou intermédiaires entre les couches d'entrée et de sortie) et une couche de sortie.

Dans ce type de réseaux, deux couches successives sont complètement connectées et toutes les connexions sont unidirectionnelles (direction : entrée-sortie), mais il n'y a pas de connexions entre deux neurones quelconques d'une même couche. La propagation de données se fait de l'entrée vers la sortie. Ce réseau est considéré comme un système neuronal non linéaire statique.



Figure 4.2 : Traits caractéristiques structurels d'un réseau neuronal à trois couches [53].

B. Différents types de réseaux neuronaux multicouches

La construction d'un réseau neuronal multicouche de type Feedforward pour l'identification d'une fonction non linéaire à plusieurs variables dépend de plusieurs points :

- Le choix de la fonction d'activation de neurones cachés. Le choix d'une fonction d'activation appropriée d'un neurone caché est crucial pour la performance d'un réseau neuronal et il dépend des propriétés suivantes de cette fonction [53] : locale, globale, orthogonale, non- orthogonale,....
- 2. Le choix de la topologie du réseau, c'est-à-dire le choix du nombre de couches et de neurones cachés. La détermination du nombre de couches et de neurones cachés est un problème très fortement lié à la complexité de la fonction non linéaire à identifier. Plus la fonction est fortement non linéaire, plus le nombre de points qui existent dans la base d'apprentissage θ_N augmente et plus le nombre de couches et de neurones cachés devient élevé.
- 3. L'initialisation du réseau ou le choix du point de départ du réseau avant de lancer la phase d'apprentissage. Deux types de réseaux neuronaux ont étés utilisés, chacun étant

basé sur une base de fonctions d'activation différente et possédant une procédure d'initialisation adaptée aux paramètres de la fonction d'activation choisie :

- (a) Le réseau ABFNN (Affine- Basis- Function Neural Network) ou le perceptron multicouche MLP (multilayer perceptron).
- (b) Le réseau RBFNN (Radial- Basis- Function Neural Network or localized Receptive Field Network).
- 4. L'apprentissage du réseau.

B.1 Perceptron multicouche MLP

Les Multilayer Perceptron (MLP) appartiennent aux réseaux multicouches [54] : ils ne possèdent donc pas de boucle de retour, ils sont « Feedforward ». Ils sont constitués de plusieurs couches cachées et d'une couche de sortie en général non linéaire. Les MLP possèdent une fonction d'activation de type sigmoïde ou de Heaviside. Ils utilisent la rétropropagation du gradient qui utilise une erreur quadratique moyenne comme algorithme d'apprentissage.

L'équation représentative non linéaire de la k^{ime} sortie $(1 \le k \le q)$ d'un perceptron multicouche MLP constitué d'une couche d'entrée, de plusieurs couches cachées et d'une couche de sortie est donnée par :

$$\left(N^{W}_{\Theta_{N}}\right)_{k}\left(X\right) = f_{s}\left(\sum_{j=1}^{h_{r}} w_{sj}f_{c}\left(\sum_{k=1}^{h_{r-1}} w_{jk}f_{c}\left(\dots f_{c}\left(\sum_{i=1}^{p} w_{l_{i}x_{i}} + \theta_{l}\right)\dots\right) + \theta_{j}\right) + \theta_{s}\right)$$
(4.5)

 f_s est la fonction d'activation du neurone de sortie et f_c est celle d'un neurone appartenant à une couche cachée. f_c est toujours non linéaire mais f_s peut être linéaire ou non linéaire. $X = (x_1, x_2, ..., x_p)^T$ est le vecteur d'entrée du réseau, Θ_N est la base d'apprentissage et W est l'ensemble de paramètres du réseau (poids w_{jk} et seuil θ_j). w_{jk} est le poids de la connexion qui existe entre le k^{eme} neurone d'une couche amont et le j^{eme} neurone de la couche aval et θ_j est le seuil propre au neurone j.

B.2 Réseau à fonctions de base radiales (RBF)

Les réseaux à fonctions de base radiales (RBF) sont l'un de modèles connexionnistes les mieux connus [56]. Ils sont constitués de trois couches : entrée x, couche cachée non linéaire et sortie linéaire. Une condition nécessaire et suffisante pour qu'une fonction soit une fonction d'activation dans un réseau de type RBF est qu'elle ne soit pas un polynôme pair [56].

La fonction souvent utilisée dans ce type de réseau est une fonction symétrique et radiale. Elle peut être :

• Gaussienne :

$$\phi_{\sigma,T}(X) = e^{-\frac{\|X-T\|^2}{2\sigma^2}} \quad \sigma \succ 0 \tag{4.6}$$

• L'inverse de la fonction multiquadratique :

$$\phi_{c,T}(X) = \frac{1}{\sqrt{c^2 + \|X - T\|^2}} \qquad c \succ 0 \tag{4.7}$$

Où $X = (x_1, x_2, ..., x_p)^T \in \mathbb{R}^p$ est le vecteur d'entrée, $T = (t_1, t_2, ..., t_p)^T \in \mathbb{R}^p$ est le vecteur qui représente le centre de la fonction d'activation d'un neurone caché et σ et c sont les paramètres qui jouent le rôle de seuil du neurone associé à cette fonction.

Notons que la fonction Gaussienne est la plus adéquate des applications pratiques.

Exemple: si p = 1, $t_1 = 0$ et $\sigma = 1$, alors $\phi(x) = e^{-\frac{x^2}{2}}$ (figure 5.8)



Figure 4.8 : Fonction gaussienne.







Figure 4.10 : Structure d'un réseau RBFNN.

Les figures 4.9 et 4.10 présentent respectivement le schéma d'un neurone qui possède la fonction gaussienne comme fonction d'activation et la structure d'un réseau RBFNN.

B.2.1 Equation représentative du réseau RBF

L'équation représentative non linéaire de la k^{ime} sortie ($1 \le k \le q$) d'un réseau RBF peut s'écrire :

$$\left(N_{\Theta_N}^{\sigma,T} \right)_k \left(X \right) = \sum_{i=1}^h w_{ki} \phi_i \left(X, \sigma, T \right) = \sum_{i=1}^h w_{ki} \phi \frac{\left(X - T_i \right)}{\sqrt{2\sigma_i}}$$
(4.8)

h est le nombre de neurones dans la couche cachée et w_{ki} est le poids de la connexion qui existe entre le $i^{\hat{e}me}$ neurone caché et la $k^{\hat{e}me}$ sortie du réseau.

En pratique, cette équation est modifiée et elle devient :

$$\left(\begin{array}{c}N_{\Theta_{N}}^{\sigma,T}\end{array}\right)_{k}\left(X\right) = \sum_{i=1}^{h} w_{ki} \phi \left(\frac{\left(X-T_{i}\right)}{\sqrt{2}\sigma_{i}}\right) + \sum_{j=1}^{p} v_{kj} x_{j} + \theta_{k}$$
(4.9)

Soit, en notation vectorielle :

$$\left(N_{\Theta_{N}}^{\sigma,T}\right)_{k}\left(X\right) = W^{T}\Psi + V^{T}X + \theta_{k}$$

$$(4.10)$$

Où :

- θ_k : seuil ;

- $V = (v_{k1}, v_{k2}, ..., v_{kp})^T \in \mathbb{R}^p$: vecteur de paramètres linéaires des connexions qui relient l'entrée du réseau à la k^{ime} sortie ;

-
$$W = (w_{k1}, w_{k2}, ..., w_{kh})^T \in \mathbb{R}^h$$
 et $\Psi = (\psi_1, \psi_2, ..., \psi_h)^T$.

La partie linéaire $V^T X + \theta_k$ permet de bien capturer les propriétés linéaires de la fonction non linéaire à identifier. $\{\sigma_i, T_i, w_{ki}, v_{kj}, \theta_k\}$ est l'ensemble de paramètres du réseau RBFNN, $1 \le i \le h$ et $1 \le j \le p$. Le nombre de paramètres de ce réseau est : h(p+q+1)+qp+q.

B.2.2 Initialisation du réseau RBF

Les centres de fonctions gaussiennes sont souvent initialisés par des exemples d'entrée du réseau choisis aléatoirement dans la base d'apprentissage. Le choix de la valeur de départ de la déviation (variance) σ de chaque fonction d'activation n'est pas aisé. La variance est souvent déterminée expérimentalement. Le nombre de neurones cachés de ce type de réseau est encore déterminé expérimentalement. Les poids linéaires $\{w_{ki}, v_{kj}, \theta_k\}$ peuvent être déterminés en résolvant un système d'équations linéaires.

B.2.3 Apprentissage du réseau RBF

La phase d'apprentissage est la phase où les paramètres du réseau subissent des modifications suivant des règles appelés règles d'apprentissage, jusqu'à stabilisation du réseau, c'est-à-dire

jusqu'à ce que la sortie désirée soit à peu près obtenue. Pour générer l'apprentissage du réseau, il faut créer une base de données dans un domaine bien défini appelé la base d'apprentissage et qui contiendra toutes les informations à mémoriser dans le réseau.

On distingue deux modes d'apprentissage :

- Apprentissage supervisé : il consiste à fournir au réseau des exemples à mémoriser pour les comparer ensuite avec les vecteurs obtenus à la sortie du réseau lors de la phase d'apprentissage.
- b. *Apprentissage non supervisé* : dans ce mode, on n'a pas besoin d'une base de sorties désirées et le réseau évolue tout seul jusqu'à l'obtention la sortie souhaitée.

L'apprentissage du réseau RBF consiste à déterminer son architecture (le nombre h de fonctions radiales) et à fixer les valeurs des paramètres. La valeur h des fonctions radiales est déterminée empiriquement.

L'apprentissage d'un réseau RBF est de type supervisé : on dispose d'un ensemble d'apprentissage constitué de *N* couples (vecteur d'entrée, valeur cible) :

$$(x_1, y_1), \dots, (x_i, y_i), \quad x_i \in \mathbb{R}^d, y_i \in \mathbb{R}$$
 (4.11)

et du coût associé à chaque exemple auquel on ajoute éventuellement un terme de régularisation :

$$E_i = \frac{1}{2} (y_i - F(x_i))^2$$
 (4.12)

Les modèles RBF présentent une caractéristique importante : on peut diviser les paramètres en trois groupes : les centres T, les largeurs σ et les poids w.

Plusieurs algorithmes ont été proposés pour l'apprentissage des réseaux RBF. L'algorithme OLS (Orthogonal Least Squares) [57] est une procédure efficace pour l'apprentissage d'un réseau RBF parcimonieux. Un mécanisme simple peut être construit dans l'algorithme pour éviter automatiquement tout mauvais conditionnement des problèmes d'apprentissage. D'autres techniques ont été proposées comme la régularisation. Cette technique est utilisée pour les larges

réseaux [58-59]. Certains chercheurs ont combiné les techniques de régularisation avec le principe parcimonieux [60-61].

La combinaison de la régularisation d'ordre zéro avec l'algorithme OLS génère un nouveau algorithme d'apprentissage appelé ROLS (Regularized Orthogonal Least Squares). La régularisation d'ordre zéro est une technique équivalente au « simple weight-decaying » de la méthode de descente de gradient.

Algorithme ROLS

Le critère d'erreur utilisé dans l'algorithme OLS est l'erreur quadratique totale donnée par : $e^T e$. Dans certaines circonstances, le critère des moindres carrées peut causer un sur-apprentissage. Pour éviter ce phénomène, on applique les techniques de régularisation. En 1993, Orr a mis en évidence un nouvel algorithme RFS (Regularized forward selection) dont l'erreur est exprimée par :

$$e^T e + \lambda W^T W \tag{4.13}$$

Avec $\lambda \ge 0$ le paramètre de régularisation. L'algorithme RFS sélectionne à la fois un centre du modèle complet. Chaque sélection est choisie pour minimiser l'erreur quadratique régularisée (5.13). L'inconvénient principal de cet algorithme est qu'il ne peut pas utiliser un plan orthogonal et par suite nécessite plus de calcul que l'algorithme OLS.

La combinaison de la régularisation d'ordre zéro et l'algorithme OLS produit une procédure efficace pour la sélection des sous-ensembles.

Soit la décomposition orthogonale de la matrice de régression Φ donnée par :

$$\Phi = W\!A \tag{4.14}$$

Où :

$$A = \begin{bmatrix} 1 & \alpha_{1,2} & \cdots & \alpha_{1,N} \\ 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & \alpha_{N-1,N} \\ 0 & \cdots & 0 & 1 \end{bmatrix}$$

et

$$W = \left(w_1, w_2, \dots, w_N\right)$$

Avec des colonnes orthogonales satisfaisant

$$w_i^T w_i = 0, \quad si \quad i \neq j$$

Le modèle complet devient :

$$d = Wg + e \tag{4.15}$$

Avec *d* la sortie désirée du réseau, *d* le vecteur de poids orthogonal $g = (g_1, ..., g_N)^T$ et le vecteur de poids original satisfait le système triangulaire.

$$AW = g \tag{4.16}$$

A et g étant connus, W peut être déterminé à partir de (4.16). L'orthogonalisation peut être effectuée par la méthode de Gram-Schmidt ou la transformation de Housholder.

Dans l'algorithme ROLS, l'erreur est définie par :

$$e^T e + \lambda g^T g \tag{4.17}$$

Cette erreur est identique à celle de l'équation (4.17) et ceci grâce à la relation (4.16). Après quelques simples calculs, l'erreur régularisée est exprimée par :

$$e^{T}e + \lambda g^{T}g = d^{T}d - \sum_{i=1}^{N} (w_{i}^{T}w_{i} + \lambda)g_{i}^{2}$$
(4.18)

La normalisation de la relation (4.18) par $d^T d$ donne :

$$(e^{T}e + \lambda g^{T}g)/d^{T}d = 1 - \sum_{i=1}^{N} (w_{i}^{T}w_{i} + \lambda)g_{i}^{2}/d^{T}d \qquad (4.19)$$

Comme dans le cas de l'algorithme OLS [23], le rapport de réduction de l'erreur régularisée est définie par :

$$[rerr]_{i} = (w_{i}^{T}w_{i} + \lambda)g_{i}^{2}/d^{T}d \qquad (4.20)$$

En se basant sur ce rapport, les régresseurs significatifs sont sélectionnés suivant la procédure forward-regression comme dans le cas de l'algorithme OLS [57]. La sélection s'arrête au h^{ième} iteration quand :

$$1 - \sum_{k=1}^{h} [rerr]_k < \xi \tag{4.21}$$

est satisfaite, où $0 < \xi < 1$ est une tolérance choisie. Cela produit un réseau de sous-ensembles contenant *h* régresseurs significatifs.

Choix du paramètre de régularisation

La valeur appropriée de λ dépend du système sous-jacent générant la base d'apprentissage et le choix de la fonction de base $\Phi(.)$. Le choix de la meilleure valeur de λ a été abordé dans la littérature statistique [61-62]. La meilleure approche pour la sélection du paramètre de régularisation est d'adopter l'interprétation bayésienne et calculer la meilleure valeur du paramètre de régularisation par la procédure de preuve [63].

L'application de l'approche bayésienne sur l'algorithme ROLS donne la procédure d'itération suivante pour estimer λ . L'algorithme construit un modèle du réseau à partir d'une valeur initiale λ .

La valeur de λ est mise à jour suivant la formule suivante :

$$\lambda = \frac{\gamma \ e^{T} e}{N - \gamma g^{T} g} \tag{4.22}$$

Où :

$$\gamma = \sum_{i=1}^{h} \frac{w_i^T w_i}{w_i^T w_i + \lambda}$$
(4.23)

est le nombre de mesures du bon paramètre [63]. Après quelques itérations, la valeur appropriée de λ est déterminée.

4.4 Adaptation des paramètres et résultats

Dans cette section, des résultats de classification issus de l'application des méthodes d'identification biométrique par ECG, EMG et réponses motrice M, seront présentés.

A. Résultats de la biométrie par ECG

A.1 Acquisition et traitement de l'ECG

L'acquisition des signaux ECG s'est effectuée, au laboratoire LiSSi de l'Université Paris-Est Créteil (UPEC), en utilisant un système BIOPAC. Une base de données a été constituée grâce à 10 sujets volontaires (8 femmes et 2 hommes) ne présentant aucun problème cardiaque. Leurs âges varient entre 25 à 40 ans. Chaque signal enregistré est échantillonné à une fréquence de 200 Hz. Les signaux ECG sont dans un premier temps prétraités afin d'éliminer le bruit, corriger la ligne de base et détecter ensuite les ondes R (figure 4.11).

Après détection des ondes R, les signaux ECG sont segmentés afin de calculer un battement de référence moyenné. Le battement moyenné est calculé pour des séries de 5et 10 battements.



Figure 4.11 : (a) Signal Original ; (b) Signal Prétraité.

A.2 Extraction des paramètres

Chaque battement moyenné est modélisé par 10 ondelettes, du type chapeau mexicain inverse. Suite à la modélisation, les paramètres (translation, dilatation et poids) des différentes ondelettes sont extraits, puis injectés à l'entrée du réseau neuronal pour classifier et identifier les différents individus.

La figure 4.12 (a) montre un battement cardiaque moyenné et la figure 4.12 (b) met en évidence la modélisation du battement par 10 ondelettes. La figure 4.12 (c) représente la sortie du réseau d'ondelettes qui constitue le modèle du battement original.



Figure 4.12: Modélisation de l'ECG: (a) battement moyenné; (b) 10 ondelettes utilisées pour la modélisation ; (c) modèle de l'ECG.

A.3 Classification et résultats

La classification est effectuée par le réseau RBF. Le réseau RBF est constitué d'une couche d'entrée contenant 30 entrées correspondant aux paramètres extraits des ondelettes, d'une couche cachée composée de 10 neurones dont la fonction d'activation est la fonction gaussienne et d'une couche de sortie contenant 10 neurones égal aux nombres d'individus à identifier (figure 4.13). 120 battements cardiaques moyennés sont utilisés pendant la phase d'apprentissage du réseau de neurones.

La performance d'identification est analysée en faisant varier le nombre de battements utilisés pour identifier les différents individus. 20, 40, 60, 80 et 100 battements ont été pris en considération.



Figure 4.13 : Structure du réseau RBFNN.

La table 1 montre les performances de classification correspondant à chaque individu dans le cas d'utilisation de séries de 5 battements moyennés dans la phase d'apprentissage.

Nombre du					
battement	Individu 1	Individu 2	Individu 3	Individu 4	Individu 5
cardiaque	(%)	(%)	(%)	(%)	(%)
20	40%	37%	42%	40%	40%
40	60%	57%	55%	50%	50%
60	74%	72%	68%	70%	69%
80	77%	75%	74%	75%	75%
100	80%	78%	79%	80%	78%
Nombre du					
battement	Individu 6	Individu 7	Individu 8	Individu 9	Individu 10
cardiaque	(%)	(%)	(%)	(%)	(%)
20	50%	47%	40%	45%	50%
40	65%	55%	55%	50%	58%
60	70%	67%	70%	67%	64%
80	75%	75%	77%	74%	73%
100	79%	80%	80%	78%	78%

Table 1: Résultats de la performance d'identification dans le cas de séries de 5 battements moyennés [64].

Les résultats de la table 1 montrent que la meilleure performance d'identification pour chaque individu est obtenue lorsque l'on utilise 100 battements dans cette phase. Cette performance correspond à 80%.

La table 2, correspondant au cas d'utilisation de séries de 10 battements moyennés dans la phase d'apprentissage, montre que la meilleure performance d'identification atteinte est de 75%. Cette performance est obtenue lorsque l'on utilise 100 battements dans la phase d'identification.

Nombre du					
battement	Individu 1	Individu 2	Individu 3	Individu 4	Individu 5
cardiaque	(%)	(%)	(%)	(%)	(%)
20	25%	25%	25%	25%	25%
40	50%	50%	50%	40%	40%
60	50%	55%	50%	45%	55%
80	63%	65%	65%	60%	63%
100	70%	73%	70%	70%	70%
Nombre du					
battement	Individu 6	Individu 7	Individu 8	Individu 9	Individu 10
cardiaque	(%)	(%)	(%)	(%)	(%)
20	25%	25%	25%	25%	25%
40	50%	40%	45%	50%	40%
60	50%	55%	50%	50%	50%
80	65%	60%	60%	65%	63%
100	75%	70%	70%	75%	73%

Table 2: Résultats de la performance d'identification dans le cas de séries de 10 battements moyennés [64].

Par conséquent, en se basant sur les résultats obtenus, nous concluons que les meilleurs résultats sont obtenus lorsqu'il est utilisé 100 battements dans la phase d'identification. En particulier, la performance obtenue en utilisant des séries de 5 battements moyennés dans la phase d'apprentissage conduit à une meilleure performance que pour des séries de 10 battements.

Comme déjà décrit précédemment, 120 battements moyennés sur des séries de 5 et 10 battements sont utilisés dans la phase d'apprentissage. Dans le premier cas, nous obtenons 24 battements moyennés alors que dans le deuxième cas 12 battements sont obtenus. Par suite, avec 24 battements moyennés le réseau neuronal est plus entrainé qu'avec 12 battements ce qui permet

d'obtenir une meilleure performance d'identification en utilisant des séries de 5 battements que des séries de 10.

A.4 Analyse

Afin de pouvoir quantifier objectivement, les approches proposées, une analyse de la sensibilité des performances d'identification par rapport au bruit, à la variabilité du rythme cardiaque, et à la position des électrodes, seront présentés.

1. Effet du bruit

Afin d'étudier l'effet du bruit sur les performances d'identification, un bruit Gaussien dont les caractéristiques peuvent être maitrisées, a été ajouté au signal réel ECG. Les performances sont analysées en fonction du rapport signal sur bruit (SNR) exprimé en dB, selon l'équation suivante :

$$SNR_{dB} = 10\log_{10}\left(\frac{Energie \ de \ signal}{Energie \ de \ bruit}\right)$$
(4.24)

La figure 4.14 montre que la performance décroît quand le SNR est inferieur à 30 dB. Par exemple, à 10 dB la performance est de 20%. Elle atteint 60% à 20 dB.



Figure 4.14: Effet du bruit sur la performance [64].

La figure 4.15 (a)-(d) montre, respectivement, le signal ECG original et sa version bruitée par un bruit gaussien a 10 dB, 20 dB et 30 dB.



Figure 4.15 : (a) signal ECG; (b) signal ECG avec SNR (10 dB); (c) signal ECG avec SNR (20 dB) (d) signal ECG avec SNR (30 dB) [64].

2. Effet de la variabilité du rythme cardiaque (VRC)

Pour l'étude de l'effet de la VRC, le sujet sain effectue une activité physique avant l'acquisition de son signal ECG. La figure 4.16 montre que la VRC n'a, pratiquement, aucun effet sur la performance.



Figure 4.16 : Variabilités du rythme cardiaque (VRC) [64].

3. Effet du déplacement des électrodes

Finalement, nous étudions l'effet du déplacement des électrodes sur la performance d'identification. Les électrodes sont légèrement déplacées de leur position initiale comme le montre la figure 4.17 (approximativement de 3 cm). D'après la figure 4.18, nous constatons que ce déplacement n'affecte pas sensiblement la performance d'identification du système.



Figure 4.17 : (a) position initiale des électrodes (b) déplacement des électrodes.



Figure 4.18 : Effet du déplacement d'électrodes [64].

B. Résultats biométriques par EMG

B.1 Acquisition des SEMG

Comme décrit précédemment, les signaux SEMG sont acquis chez 10 sujets sains (9 hommes et une femme) dont l'âge varie entre 25 et 40 ans. La base de données que nous avons constituée est composée de 120 acquisitions. Dans chaque expérience d'apprentissage ou d'identification, le sujet doit appliquer, sur le capteur, une force de 5 kg (60 acquisitions) ou 10 kg (60 acquisitions) sur une durée de trois secondes. Le signal SEMG ainsi enregistré est échantillonné à une fréquence de 2000 Hz.

B.2 Estimation de la DSP et extraction des paramètres

Afin de modéliser les SEMG enregistrés, leurs DSP sont dans un premier temps estimées par la technique de Welch. Un exemple illustré sur la figure 4.19 (a)-(d) montre deux DSP de SEMG estimée correspondant à des forces de 5Kg et 10 Kg.



Figure 4.19 : SEMG en réponse à une force 5Kg (a) DSP en cas de 5Kg (b) SEMG en réponse à une force 10Kg (c) DSP en cas de 10Kg (d).

B.3 Classification et résultats

La classification des données est assurée par le réseau de neurones RBF. Elle s'effectue en deux phases, à savoir, la phase d'apprentissage et la phase d'identification. Pour chaque individu, 30 contractions sont utilisées dans la phase d'apprentissage. Les performances du système proposé sont évaluées en faisant évoluer le nombre de contractions utilisées pour identifier les individus (10, 15, 20, 25 et 30 contractions).

Le réseau RBF utilisé est constitué d'une couche d'entrée contenant 15 entrées correspondant aux paramètres extraits de la DSP, d'une couche cachée composée de 10 neurones et d'une couche de sortie dont le nombre de sorties est égal aux nombres des individus à identifier (figure 4.20). La fonction d'activation utilisée est la fonction gaussienne (figure 4.8).



Figure 4.20 : Structure du réseau RBFNN.

Dans la table 3, nous présentons les performances de classification correspondant à chaque individu dans le cas d'analyse de contractions en réponse à une force d'intensité 5Kg dans la phase d'apprentissage.

On pourra remarquer que la meilleure performance d'identification (80%) est atteinte lorsque l'on utilise 30 contractions dans la phase d'identification. Les expériences montrent que cette performance reste invariable lorsque l'on utilise plus de 30 contractions.

Nombre du	Individu 1	Individu 2	Individu 3	Individu 4	Individu 5
Contraction	(%)	(%)	(%)	(%)	(%)
10	60%	50%	50%	50%	50%
15	73%	67%	67%	73%	67%
20	75%	75%	75%	75%	75%
25	76%	76%	76%	76%	76%
30	80%	80%	77%	80%	77%
Nombre du	Individu 6	Individu 7	Individu 8	Individu 9	Individu 10
contraction	(%)	(%)	(%)	(%)	(%)
10	60%	50%	50%	50%	60%
15	67%	73%	73%	67%	67%
20	75%	75%	75%	75%	75%
25	75%	76%	76%	76%	76%
30	80%	80%	80%	77%	80%

Table 3 : Résultats de la performance d'identification dans le cas d'une force d'intensité 5 Kg.

Nombre du	Individu 1	Individu 2	Individu 3	Individu 4	Individu 5
Contraction	(%)	(%)	(%)	(%)	(%)
10	40%	30%	30%	30%	40%
15	47%	53%	47%	47%	47%
20	55%	60%	60%	60%	55%
25	60%	64%	64%	64%	60%
30	70%	67%	70%	67%	70%
Nombre du	Individu 6	Individu 7	Individu 8	Individu 9	Individu 10
contraction	(%)	(%)	(%)	(%)	(%)
10	30%	40%	30%	40%	30%
15	53%	47%	53%	47%	53%
20	60%	55%	60%	55%	60%
25	64%	60%	64%	60%	64%
30	70%	67%	67%	70%	67%

Table 4 : Résultats de la performance d'identification dans le cas d'une force d'intensité 10 Kg

La table 4 correspond à la situation où une force de 10 kg est appliquée au capteur, dans la phase d'apprentissage. Les résultats montrent que la meilleure performance d'identification atteinte est de 70%. Cette performance est obtenue lorsque l'on utilise 30 contractions dans la phase d'identification.

Par ailleurs, nous remarquons que les performances obtenues en réponse à une force de 5Kg sont meilleures à celles obtenues en réponse à une force de 10 Kg. Ceci s'explique par le fait qu'à des intensités élevées, un phénomène de fatigue est constaté. Par conséquent, l'énergie produite par le muscle fluctue, produisant ainsi une modification dans le contenu fréquentiel du signal EMG [65].

B.4 Analyse

La technique d'identification biométrique proposée est analysée dans les deux situations différentes : (1) effet de la fatigue (2) effet des déplacements d'électrodes sur les performances d'identification lorsque la force appliquée sur le capteur est de 5 Kg.

1. Effet de la fatigue

Pour étudier l'effet de la fatigue sur la performance, l'individu effectue un effort physique (pushup). La figure 4.21 montre que la fatigue n'a aucun effet sur la performance d'identification.



Figure 4.21 : Courbe de performances mettant en évidence la sensibilité de la technique d'identification par rapport à l'effet de fatigue. Des variations très faibles sont constatées.

2. Effet du déplacement des électrodes

Les électrodes sont légèrement déplacées de leur position initiale (approximativement de 3 cm). Comme le montre la figure 4.22, le déplacement des électrodes ne semble pas affecter les performances d'identifications.



Figure 4.22 : Sensibilité de performances par rapport au déplacement des électrodes.

C. Résultats biométriques par réponse motrice M

C.1 Acquisition des réponses motrices

Les réponses motrices M sont enregistrées chez 10 sujets sains (8 hommes et 2 femmes) en utilisant une stimulation électrique d'intensité 20 mA et 30 mA. La base de données ainsi constituée comporte 300 réponses motrices dont 30 réponses de chaque individu provenant de chaque intensité de stimulation. La fréquence d'échantillonnage de chaque réponse est 1 Hz.

C.2 Modélisation et extraction des paramètres

Les réponses M sont modélisées par 8 ondelettes. Comme nous l'avons signalé précédemment, le chapeau mexicain inverse a été utilisé. Cette modélisation permet l'extraction de paramètres caractéristiques (i.e. translation, dilatation et poids) qui seront utilisés dans la phase identification.

C.3 Classification et résultats

La classification est effectuée par le réseau RBF. L'entrée du réseau est constituée des paramètres extraits des différentes ondelettes. Notre réseau est entrainé par 15 réponses M pour chaque individu. L'identification est effectuée en modifiant le nombre de réponses utilisées. Nous utilisons 5, 10 et 15 réponses.

Le réseau RBF est constitué d'une couche d'entrée contenant 24 entrées correspondant aux paramètres extraits des ondelettes, d'une couche cachée à 10 neurones et d'une couche de sortie. Le nombre de sorties du réseau neuronal est égal aux nombres des individus à identifier (figure 4.23). La fonction d'activation utilisée est la fonction gaussienne (figure 4.8).


Figure 4.23 : Structure du réseau RBF.

La table 5 montre les performances de classification correspondant à chaque individu dans le cas de réponses obtenues suite à une stimulation de 20 mA.

Nombre de	Individu 1	Individu 2	Individu 3	Individu 4	Individu 5
Réponses	(%)	(%)	(%)	(%)	(%)
5	80%	100%	80%	80%	80%
10	90%	100%	90%	90%	90%
15	93%	100%	93%	93%	93%
Nombre de	Individu 6	Individu 7	Individu 8	Individu 9	Individu 10
réponses	(%)	(%)	(%)	(%)	(%)
5	80%	100%	100%	80%	80%
10	90%	100%	100%	90%	90%
15	93%	100%	100%	93%	93%

Table 5: Résultats de la performance d'identification dans le cas d'une stimulation de 20mA.

D'après la table 5, nous remarquons que les meilleures performances sont obtenues lorsqu'il est utilisé 15 réponses dans la phase d'identification. Ces performances varient entre 93% et 100%. Lorsqu'une une stimulation à 30 mA est utilisée, les résultats (table 6) montrent que les performances d'identification varient également entre 93% et 100%. 15 réponses motrices dans la phase d'identification sont utilisées.

Nombre de	Individu 1	Individu 2	Individu 3	Individu 4	Individu 5
Réponses	(%)	(%)	(%)	(%)	(%)
5	80%	100%	100%	80%	80%
10	90%	100%	100%	90%	90%
15	93%	100%	100%	93%	93%
Nombre de réponses	Individu 6 (%)	Individu 7 (%)	Individu 8 (%)	Individu 9 (%)	Individu 10 (%)
5	80%	100%	100%	80%	80%
10	90%	100%	100%	90%	90%
15	93%	100%	100%	93%	93%

Table 6: Résultats de la performance d'identification dans le cas d'une stimulation de 30mA.

Par conséquent, d'après les résultats obtenus précédemment, nous concluons que les meilleures performances sont obtenues lorsque l'on utilise 15 réponses M dans la phase d'identification. Ces performances varient légèrement avec l'intensité de stimulation. En fait, il a été constaté que les performances sont légèrement supérieures dans le cas d'une stimulation à 30 mA que le cas d'une stimulation à 20 mA. Ceci s'explique par le fait que lorsque l'on augmente l'amplitude de stimulation électrique, le nombre d'axones moteurs stimulés augmente et par conséquent, l'amplitude de l'onde M augmente ce qui permet d'obtenir un modèle plus précis et par suite des paramètres plus stables. L'amplitude de l'onde M augmente avec le courant de stimulation jusqu'à ce qu'une contraction maximale se produit. A ce niveau de stimulation, l'amplitude de l'onde M ne croît plus.

4.5 Conclusion

Dans ce chapitre, nous avons dans un premier temps défini les différents types de classification. Nous avons introduit les réseaux neuronaux artificiels et les différents types de réseaux neuronaux multicouches de type Feedforward. Nous avons décrit le réseau RBF que l'on a utilisé dans la phase de classification. L'algorithme ROLS est utilisé pour l'apprentissage du réseau RBF. Finalement, nous avons présenté les résultats des trois méthodes d'identification biométriques par signaux physiologiques.

L'identification biométrique par ECG proposée nécessite une phase d'apprentissage du réseau RBF avec 120 battements ensuite une phase d'identification utilisant 100 battements. Dans la phase d'apprentissage, 5 ou 10 battements sont moyennés et ensuite modélisés par réseau d'ondelettes (10 ondelettes sont utilisées). Les coefficients correspondant à ces ondelettes sont présentés à l'entrée d'un réseau de neurones. Cette méthode conduit à une performance de 80% lorsqu'il est utilisé des séries de 5 battements moyennés dans la phase d'apprentissage. Les performances s'améliorent en augmentant le nombre de battements utilisés pour l'identification. Notons finalement que notre méthode est insensible au bruit, à la variabilité du rythme cardiaque et au déplacement des électrodes.

Dans la deuxième technique, l'identification par EMG, le réseau RBF est entrainé par 30 contractions pour chaque individu. Cette méthode conduit à une performance de 80% lorsque l'on utilise dans la phase d'identification des contractions en réponse à une force de 5Kg. Cette performance semble être invariante à l'augmentation du nombre de contractions pour l'identification. La fatigue et le déplacement des électrodes n'affectent pas la performance. Dans le cas de l'identification par réponse M, l'apprentissage du réseau RBF nécessite 15 réponses motrices et également nous utilisons 15 réponses pour la phase d'identification. Notre méthode permet d'obtenir une performance d'identification moyenne de 95%.

Finalement, nous concluons que l'identification des individus par réponse motrice semble être particulièrement efficace et très prometteuse.

Conclusion générale et perspectives

Dans le domaine de la biométrie, les techniques les plus utilisées et les plus répandues utilisent, entre autres, la forme de la main, l'iris, l'empreinte digitale ou les détails du visage. Mais ces caractéristiques peuvent être modifiées et par suite la sécurité n'est plus assurée. L'approche proposée dans cette thèse est originale dans la mesure où les signaux enregistrés ne peuvent pas être volontairement modifiables (contrairement à une empreinte digitale pour laquelle une simple blessure rend son exploitation difficile).

Au cours de ce travail, nous avons développé trois méthodes d'identification biométrique basées sur les signaux physiologiques ECG et EMG.

La première méthode mise en évidence utilise les signaux ECG pour identifier les différents individus. Cette méthode comporte d'abord une phase de prétraitement de l'ECG visant à éliminer tout bruit dû à la ligne de base, d'origine musculaire, etc. dégradant la qualité des paramètres extraits afin de détecter les pics R. Une segmentation est par suite effectuée permettant d'obtenir une matrice ECG contenant un seul complexe QRS sur chaque segment. Plus tard les signaux ECG sont moyennés. Le battement moyenné est calculé pour des séries de 5 et 10 battements. L'étape suivante consiste à modéliser les battements cardiaques par réseaux d'ondelettes puis extraire les paramètres (translation, dilatation et poids) des différentes ondelettes utilisées dans la modélisation. Chaque battement est modélisé par 10 ondelettes de type chapeau mexicain inverse, Ces paramètres extraits sont par la suite injectés à l'entrée du réseau neuronal RBF afin d'identifier les individus. Le réseau utilisé est constituée d'une couche d'entrée contenant 30 entrées correspondant au nombre des paramètres extraits, d'une couche cachée et d'une couche de sortie dont le nombre de sorties est égal au nombre des personnes à identifier. La fonction d'activation de la couche cachée est la fonction gaussienne. Le réseau est entrainé utilisant 120 battements cardiaques moyennés. Cette approche est robuste, elle procure des performances de 92%, et elle est particulièrement sensible au bruit.

Outre l'identification par ECG, la possibilité d'utiliser le signal EMG comme signal d'identification a été explorée. La deuxième méthode développée est basée sur l'identification par les signaux EMG en réponse à une force d'une intensité fixe de 5 Kg et 10 Kg. Cette

technique consiste à calculer la densité spectrale de puissance des signaux EMG par la méthode de Welch puis extraire les paramètres fréquentiels les plus significatifs pour l'identification biométrique tels que la puissance, le kurtosis, la fréquence médiane, les déciles, le coefficient de dissymétrie et la fréquence pic. La classification est réalisée par le réseau RBF. Ce réseau est constitué d'une couche d'entrée contenant 15 entrées correspondant aux paramètres extraits de la DSP, d'une couche cachée composée de 5 neurones et dont la fonction d'activation utilisée est la fonction gaussienne et d'une couche de sortie dont le nombre de sorties est égal aux nombres des individus à identifier. 30 contractions sont utilisées pour l'apprentissage du réseau. Cette technique présente une insensibilité aux bruits et fournit des performances de 80%.

La dernière méthode d'identification biométrique proposée utilise les réponses motrices. Les réponses sont obtenues suite à une stimulation électrique d'intensité 20 mA et 30 mA. Les techniques de modélisation et de classification fondées sur les réseaux d'ondelettes et les réseaux de neurones (RBF) ont été mises en œuvre. Les paramètres de classification sont extraits des ondelettes utilisées dans la modélisation (à savoir translation, dilatation et poids). Le réseau RBF utilisé est composé d'une couche d'entrée contenant 24 entrées correspondant aux paramètres extraits des ondelettes, d'une couche cachée à 5 neurones et de fonction d'activation gaussienne et d'une couche de sortie et dont le nombre de sorties est égal aux nombres des individus à identifier. 15 réponses motrices sont utilisées dans la phase d'apprentissage. Une performance de 95% a été obtenue. Ceci est considéré comme un taux de reconnaissance très intéressant. De plus, les études statistiques montrent que notre méthode n'est sensible à aucun type de bruit, rendant ainsi cette technique, particulièrement attractive.

Cette thèse nous ouvre plusieurs perspectives, notamment pour les études à venir, que l'on résume comme suit :

- Les méthodes proposées peuvent être améliorées en prenant en considération d'autres conditions d'acquisition et en procèdant à des évaluations sur de grandes bases de données (e.g. une centaine d'individus).
- Il serait intéressant d'évaluer la variabilité et la sensibilité des méthodologies étudiées, par rapport à l'âge des individus.

- De nouvelles méthodes basées sur les classes de Cohonen ou les classes de Hopfield doivent être testées et comparées.
- Il serait intéressant de développer des techniques hybrides, fondées sur la fusion des paramètres EMG-ECG.
- Finalement, il est important d'étudier l'acceptabilité du système et sa portabilité en optimisant le système d'acquisition par rapport aux applications de biométrie.

Liste de publications

- Chantaf, S., Naït-Ali, A., Karasinski, P. and Khalil, M. 'ECG modelling using wavelet networks: application to biometrics', *Int. J. Biometrics*, Vol.2, No.3, pp.236-249, 2010.
- 2. Chantaf, S., Naït-Ali, A., Karasinski, P. and Khalil, M. 'Biometrics using SEMG signals' (En cours de soumission).
- 3. Chantaf, S., Naït-Ali, A., Karasinski, P. and Khalil, M. 'Biometrics using M response' (En cours de soumission).

Bibliographie

[1] Jain, A.K., Ross, A. and Prabhakar, S. 'An introduction to biometric recognition', IEEE Transactions on Circuits and Systems for Video Technology, Vol. 14, No. 1, pp.4–20, 2004.

[2] Leroux J., Lamadelaine P., Dorizzi B., Guerrier C., La biométrie – Techniques et usages. Date de publication: April 10, 2004.

[3] Maaref H., Lelandais-Bonadè S., Vigneron V., Djemal K. et Montagne C., Traitement et Analyse de Données et d'Images - Biométrie (TADIB), Evaluation AERES à l'Université d'Evry Val d'Essonne, Décembre 2008.

[4] M. Shahin, A. Badawi, and M. Kamel, "Biometric Authentication Using Fast Correlation of Near Infrared Hand Vein Patterns", International Journal of Biological and Medical Sciences vol.2, no.3, 2007.

[5] Bouchemha A., Nait-Ali A., Doghmane N., "A Robust Technique to Characterize the Palmprint using Radon Transform and Delaunay Triangulation" International Journal of Computer Applications (0975 – 8887) Volume 10– No.10, November 2010.

[6] Jian-Da Wu, Siou-Huan Ye, "Driver identification using finger-vein patterns with Radon transform and neural network" Expert Systems with Applications 36, pp. 5793–5799, 2009.

[7] Morizet N., Reconnaissance Biométrique par Fusion Multimodale du Visage et de l'Iris, Thèse Signal et Images, Télécom Paris [ENST], 2009.

[8] Israel S. A., Scruggs W. T., Worek W. J., and Irvine J. M., "Fusing Face and ECG for Personal Identification". Proceedings of the 32nd Applied Imagery Pattern Recognition Workshop IEEE, pp.226-231, 2003.

[9] D. Benatia. "Analyse et traitement du signal ECG par la transformée en ondelettes, Application à la compression et au stockage de données médicales", Rapport annuel de projet de recherche. Université de Batna, Algérie, 2006.

[10] Hoekema R., Uijien G. J. H., et van Oosterom A., "Geometrical. Aspects of the Interindividual Variability of Miltilead ECG Recordings," IEEE Transactions on Biomedical Engineering, vol..48, no.5, pp.551-559, 2001.

[11] Klabunde, R.E., Cardiovascular Physiology Concepts, Lippincott Williams & Wilkins, 2005.

[12] Mekrami S., Brignol T.N., « Le muscle squelettique », Juin 2003.

[13] Reference du site vulgaris-médical (<u>www.vulgaris-medical.com</u>).

[14] Forestier, N. et Fournier, E., « Neuro-pathologie ». Chapitre 2 - Pathologie du Nerf Périphérique. pp 33-34, 2000.

[15] Biel, L., Pettersson, O., Philipson, L. and Wide, P. "ECG analysis: a new approach in human identification." IEEE Transactions on Instrumentation and Measurement, Vol 50, No.30, pp.808-812, 2001.

[16] Wang, Y., Plataniotis, K.N. and Hatzinakos, D. 'Integrating analytic and appearance attributes for human identification from ECG signal', Proceedings of Biometrics Symposiums (BSYM '06), Baltimore, MD, USA, 2006.

[17] Plataniotis, K. N., Hatzinakos, D. and Lee, J. K. M. "ECG biometric recognition without fiducial detection," in *Proceedings of Biometrics Symposiums (BSYM '06)*, Baltimore, Md, USA, 2006.

[18] Keselbrener L., Keselbrener M. and Akselrod S., Non-linear High-Pass for R-wave Detection in ECG Signal, Med. Eng. Phys., vol. 19, N°5, pp.481-484, 1997.

[19] R. Borsali Thèse : « Compression paramétrique du signal électrocardiographique : application aux arythmies cardiaques ». Université Paris-Est Val de Marne, UFR de Sciences et de Technologie, Créteil, France, Juin 2007.

[20] Pati, Y. C. and Krishnaprasad, P. S. "Analysis and synthesis of feed-forward neural networks using discrete affine wavelet transformations," IEEE *Trans. Neural Networks*, Vol. 4, pp. 73–85, 1993.

[21] Zhang, Q. and Benveniste, A. "Wavelet networks," *IEEE Trans. Neural Networks*, Vol. 3, pp. 889–898, 1992.

[22] Zhang, Q.H. "Using Wavelet Network in Nonparametric Estimation," *IEEE Trans.Neural Networks*, Vol.8, pp.227-236, 1997.

[23] J. Zhang, G.G. Walter, Y. Miao, and W.N.W .Lee, "Wavelet Neural Networks for function learning" *IEEE Trans. signal process*, Vol.43, No.6, pp.1485-1497, June 1995.

[24] S. Mallat, "A theory for multiresolution signal decomposition: The wavelet transform," *IEEE Trans. Pattern Anal. Machine Intell.*, Vol.11, pp.674-693,July 1989.

[25] Q. Zhang, "Wavelets networks: The radial structure and an efficient initialization procedure," *Technical Report of Linköping University*, LITH-ISY-I-1423, Oct 1992.

[26] J. Sjöberg, Q. Zhang, L. Ljung, A. Benveniste, B. Deylon, P.Y. Glorennec, H. Hjalmarson, and A. Juditsky, "Nonlinear black-box modeling in system identification: Unified overview," *Automatica*, Vol.31, no.12, pp.1691-1724, 1995.

[27] A. Juditsky, "Wavelet estimators: Adapting to unknown smoothness," Technical Report IRISA, June 1994.

[28] Q. Zhang, "Using Wavelet Network in Nonparametric Estimation," Publication Interne 833, IRISA, June 1994.

[29] Zhang, Q.H. "Using Wavelet Network in Nonparametric Estimation," *IEEE Trans.Neural Networks*, Vol.8, pp.227-236, 1997.

[30] N. Draper and H. Smith, "Applied regression analysis, Series in Probability and Mathematical Statistics," Wiley, 1981.Second edition.

[31] S. Chen, S. Billings, and W. Luo, "Orthogonal least squares methods and their application to non-linear system identification," *Int. J. Control*, Vol.50, no.5, pp.1873-1896, 1989.

[32] S. Chen, C. Cown, and P. Grant, "Orthogonal least squares learning algorithm for radial basis function networks," IEEE Trans. on Neural Networks, Vol.2, pp.302-309, March 1991.

[33] A. Björk, "Numerics of Gram-Schmidt orthogonalization," Linear Algebra Application, Vol.197-198, pp.297-316, 1994.

[34] A. Akaike, "Fitting autoregressive models for prediction," Ann. Inst. Stat. Math., Vol.21, pp. 243-247, 1969.

[35] Fournier, E. « Neuro-pathologie ». Chapitre 3 - Examen électromyographique et étude de la conduction. pp. 63, 2000.

[36] Basmajian JV, de Luca CJ. Muscles Alive – The Functions Revealed by Electromyography. The Williams & Wilkins Company; Baltimore, 1985.

[37] Dûchene J., Goubel F. Surface Electromyogram during voluntary contraction: processing tools and relation to physiological events, Crit. Rev. in Biomed. Eng., 21: 4: 313-397, 1993.

[38] Marple S. L. Digital spectral analysis with applications. Prentice-Hall, Englewood Cliffs, NJ, USA, 1987.

[39] Kay S. Modern Spectral Estimation Theory & Application. Englewood Cliffs, Prentice Hall, NJ, USA, 1988.

[40] Orfandis S. J. Optimum Signal Processing an Introduction, McGraw-Hill international editions, Singapore, 1990.

[41] Kunt M., Bellanger M., De Coulon F., Gueguen C., Hasler M., Moreau N., Vetterli M. Techniques modernes de traitement numérique des signaux. Presses polytechniques et universitaires romandes, Lausanne, 1991.

[42] Proakis J. G., Manolakis D. G., Digital signal processing principles, Algorithms, and Applications. Englewood Cliffs, Prentice- Hall, NJ, 1996.

[43] Bartlett M. Smoothing periodograms from time series with continuous spectra. *Nature*, vol. 161, pp. 686-687,1948.

[44] Magladery J.W. and Mcdouagal D.B. Jr. Electrophysiological studies of nerve and reflex activity in normal man. Identification of certain reflexes in electromyogram and the conduction velocity of peripheral nerve fibers. Bull Johns Hopkins Hosp 86: 265-290, 1950.

[45] Hoffmann P. Beitrag zur Kenntnis der menschlichen Reflexe mit besonderer Berucksichtigung der elektrischen Erscheinungen. Arch Anat Physiol.; 1:223–246, 1910.

[46] Hoffmann P. Uber die beziehungen der sehnenreflexe zur wilkürlichen bewegung und zum tonus. Z. Biol., 68: 351-370. 1918.

[47] Robinson, A.J., Snyder-Mackler, L. "Clinical Electrophysiology: Electrotherapy and Testing Procedures", Third edition, chapter 12: Clinical electrophysiologic Examination and Evaluation, (page 424), Lippincott Williams and Wilkins, Baltimore, MD, 2007.

[48] Johnson M.A., Polgar J., Weightman D. and Appleton D. Data on the distribution of fiber types in thirty six human muscles. An autopsy study. *J. Neurolog. Sci.*, 18: 111-129. 1973.

[49] Bruno S., Modélisation de Signaux Physiologiques en vue d'une Classification Automatique du Sommeil, Thèse de doctorat de l'Université de Rennes 1, Janvier 2006.

[50] S. Haykin Neural Networks - A comprehensive Foundation Macmillan College Publishing Company, New York, 1994.

[51] R. Lippmann An Introduction To Computing with Neural Nets IEEE ASSP Magazine, volume 4, n° 2, pp 4-22, Avril 1987.

[52] Y. Harkouss, Thèse: "Application des réseaux de neurones à la modélisation de composants et de dispositifs microondes non linéaires", thèse de doctorat, université de Limoges, décembre 1998.

[53] P. Van der Smagt and F. Groen, '' Approximation with neural networks : Between local and global approximation,'' *International Conference on Neural Networks*, Perth, Austarlia 1995.

[54] C.M.Bishop, Neural Networks for Pattern Recognition. 1995.

[55] Frederic TRUCHETET. Ondelettes pour le signal numerique, collection traitement du signal, edition HERMES, Paris, 1998.

[56] T. Chen and H. Chen," Approximation capability to functions of several variables, non linear functional and operators by radial basis function neural networks, "IEEE Trans. Neural Networks, 904-910, 1995.

[57] S. Chen, S. Billings, and W. Luo, "Orthogonal least squares methods and their application to non-linear system identification," *Int. J. Control*, Vol.50, no.5, pp.1873-1896, 1989.

[58] Pocclo, T., and Girosi, F., Networks for approximation and learning. *Proceedings of the Institution of Electrical and Electronics Engineers*, 78, 1481-1497,1990.

[59] BISHOP, C., "improving the generalization properties of radial basis function neural networks". *Neural Computation*, 3, 579-588, 1991.

[60] BARRON, A. R., and XIAO, X., "Discussion of multivariate adaptive regression splines". *Annals of Statistics*, 19, 67-82, 1991.

[61] ORR, M. J. L., Regularized centre recruitment in radial basis function networks. Research Report, No. 59, Centre for Cognitive Science, University of Edinburgh, U.K, 1993.

[62] HOERL, A.E., and KENNARD, R.W., Ridge regression: biased estimation for nonorthogonal problems. *Technometrics*, 12, 55-67, 1970.

[63] MACKAY, D. J. C., Bayesian interpolation. Neural Computation, 4, 415-447, 1992.

[64] Chantaf, S., Naït-Ali, A., Karasinski, P. and Khalil, M. 'ECG modelling using wavelet networks: application to biometrics', *Int. J. Biometrics*, Vol.2, No.3, pp.236-249, 2010.

[65] El Falou, W. Une approche de la segmentation dans des signaux de longue durée fortement bruités. Application en ergonomie. PhD thesis. Université de Technologie de Troyes, Troyes, France, 2002.