



ÉCOLE DOCTORALE *MATHEMATIQUES, INFORMATIQUE, PHYSIQUE THEORIQUE ET INGENIERIE DES SYSTEMES - MIPTIS*

Laboratoire PRISME / Laboratoire Traitement du Signal

THÈSE EN COTUTELLE INTERNATIONALE présentée par :

Hichem BENGACEMI

Soutenue le : **03 juin 2021**

pour obtenir le grade de :

**Docteur de Université d'Orléans
et de l'Ecole Militaire Polytechnique (EMP), Algérie**

Discipline/ Spécialité : **Electronique**

**L'Analyse de signaux EMG et leur application
au diagnostic de la maladie de Parkinson**

JURY :

M. Belouchrani Adel	Pr, ENP. Algérie	Président du jury
M. Abed-Meraïm Karim	Pr, Université d'Orléans. France	
M. Amine NAIT-ALI	Pr, Univ. Paris-Est-Créteil. France	
M. Guiatni Mohamed	Pr, EMP. Algérie	
M. Boubchir Larbi	MC HdR, Univ.Paris-8. France	
M. Bensalah Mustapha	MC HdR, EMP. Algérie	
M. Mesloub Ammar	MC HdR, EMP. Algérie	
M. Buttelli Olivier	MC HdR, Université d'Orléans. France	

Invité:

M. Gharbi Abdenour Hacine	MCB, Univ. Bordj Bou Arreridj. Algérie
---------------------------	--

DÉDICACE

*A la mémoire de mes oncles **Mohamed** et **Larbi** ;*

*A ma grande mère **Zohra** et ma tante **Ghezala** ;*

*A ma mère **Oureida** et mon père **Lamri** ;*

A ma femme et mes souers ;

*A mes fils : **Mohamed yaakoub**, **Ishak** et **Youcef** ;*

*A ma nièce **Sadjida** et mes neveux **Iyad** et **Ahmed** ;*

A ma belle famille ;

A toute ma famille.

...

REMERCIEMENTS

Je tiens à exprimer mes vifs remerciements à ma famille, mes parents, ma femme et mes sœurs pour leurs soutiens constants et leurs encouragements qui m'ont permis de surmonter toutes les difficultés morales et matérielles.

Je tiens à remercier Monsieur **Karim ABED-MERAIM**, Professeur à l'Université d'Orléans, qui m'a encadré tout au long des travaux de cette thèse et qui m'a fait partager ses excellentes connaissances. Qu'il soit aussi remercié pour sa gentillesse, sa disponibilité permanente et pour les nombreux encouragements qu'il m'a prodigués. Cette thèse est le fruit d'une collaboration de plus de cinq années avec lui. C'est à ses côtés que j'ai compris ce que rigueur et précision voulaient dire.

Un remerciement très particulier à Monsieur **OULD ALI Abdelaziz**, MC-A à l'Université de Mostaganem, qui m'a enseigné et encadré tout au long de mon parcours universitaire ainsi que pour avoir lu et corrigé ma thèse. Ses conseils de rédaction ont été très précieux. Il a été toujours un grand frère pour moi.

J'adresse tous mes remerciements à Monsieur **MESLOUB Amar**, MC-A à l'Ecole Militaire Polytechnique de Bordj El Bahri, ainsi qu'à Monsieur **BUTTELLI Olivier**, MC HdR de l'université d'Orléans, de l'honneur qu'ils m'ont fait en acceptant d'être mes co-encadreurs.

Je tiens à remercier tous les membres de mon jury. Je remercie Monsieur **BELOUCHRANI Adel**, Professeur à l'Ecole Nationale Polytechnique(ENP)d'El Harrache, Monsieur **GUIATNI Mohamed**, Professeur à l'Ecole Militaire Polytechnique de Bordj El Bahri, Monsieur **NAIT-ALI Amine**, Professeur à l'Université Paris-Est-Créteil (UPEC) France, Monsieur **BOUB-CHIR Larbi**, MC HdR à l'Université Paris-8 France, Monsieur **BEN SALAH Mustapha**, MC-A à l'EMP de Bordj El Bahri et Monsieur **HACINE GHARBI Abdenour**, MCA à l'uni-

versité de Bordj Bou Arreridj d'avoir accepté d'être membres examinateurs de cette thèse.

Je remercie tout particulièrement Monsieur **HACINE GHARBI Abdenour** MCA à l'université de Bordj Bou Arreridj et Monsieur **RAVIER Philippe** MC HdR de l'université d'Orléans, pour leurs nombreux conseils, leurs bonnes humeurs et leurs disponibilités. Je leur présente toute ma reconnaissance.

Mes vifs remerciement vont aussi à Monsieur **BENKEDJOUH Tarak**, MC-A à l'EMP, de m'avoir supporté tout au long de cette thèse, de m'avoir procuré l'aide matérielle et morale nécessaires. Sans oublier mes amis et frères **LAIB Zohir**, **SAYAH Chawki**, **REKIK Ouahbi**, **ABID Mourad**, **DJEMAA Adel**, **BOUDJELLEL Abdelwahab** et **AMED-SID Farid** les personnes qui, sans leurs aides précieuses et leurs encouragements, ce travail n'aurait jamais pu s'accomplir.

Je ne peux manquer cette occasion pour adresser un remerciement particulier à Monsieur **MAALI Abdelmadjid**, chef de l'Unité d'Enseignement & Recherche Signal et Communication à l'EMP, ainsi que toute l'équipe du laboratoire Traitement du Signal.

Je tiens aussi à remercier toute l'équipe de la **D.E.M.T** de l'Hôpital Central de l'Armée pour leurs encouragements et soutien moral.

A toutes les personnes qui m'ont aidé et soutenu de près ou de loin durant cette thèse à l'EMP, à Orléans ou ailleurs, je leur dis un grand merci.

Sommaire

Dédicace	i
Remerciements	ii
Liste des figures	viii
Liste des tableaux	xi
Liste des Symboles et abréviations	xiv
Introduction Générale.	1
1 Généralités sur la physiologie de muscle et le signal EMG de surface	8
1.1 Introduction	10
1.2 Application de l'électromyographie	11
1.2.1 Neurologie	11
1.2.2 Ergonomie	12
1.2.3 Mouvement et analyse de la marche	13
1.2.4 Réhabilitation	14
1.2.5 Biofeedback (rétroaction biologique)	14
1.2.6 Contrôle de prothèse	15
1.3 Maladie de Parkinson et contrôle postural	15
1.3.1 Maladie de Parkinson	16
1.3.2 Posture et contrôle postural	18
1.4 Physiologie neuro-musculaire du muscle	20
1.4.1 Muscle	20
1.4.2 Anatomie et physiologie du muscle squelettique	21
1.4.3 Unité motrice	22
1.4.4 Potentiel d'action	24

1.4.5	Train de potentiels d'action et recrutement temporel	25
1.4.6	Recrutement spatial des Unités Motrices	27
1.5	Signal EMG	27
1.5.1	Définition	27
1.5.2	Mesure du signal électromyographique	28
1.5.3	Modèles analytiques du signal EMG	29
1.5.4	Bruits affectant le signal EMG	32
1.6	Conclusion	33
2	Détection de l'activité électromyographique	34
2.1	Introduction	36
2.2	Formulation du problème	40
2.3	Principales méthodes de détection d'activité EMG	40
2.3.1	Méthode à double seuil (ou en anglais Double-threshold)	40
2.3.2	Méthode des ondelettes (en anglais Wavelet-based method)	41
2.3.3	Technique TKEO	41
2.3.4	Méthode basée sur l'entropie d'échantillon (en anglais Sample Entropy)	42
2.3.5	Méthode de la racine quadratique moyenne (en anglais RMS based method)	42
2.4	Méthode : ALED et ses variantes : Approches non supervisées	43
2.4.1	Principales étapes de la méthode ALED	43
2.4.2	Méthode ALED modifiée : M-ALED	45
2.4.3	Méthode FM-ALED	46
2.4.4	Méthode OM-ALED	50
2.5	Méthode supervisée : basée sur l'utilisation des HMM	52
2.5.1	Modélisation HMM du signal EMG	53
2.5.2	Modèles HMM	55
2.5.3	Système de segmentation basé sur la modélisation HMM	56
2.5.4	Extraction des attributs basée sur la transformée en ondelettes	57
2.6	Résultats et discussions	59
2.6.1	Outils d'analyse de performances	60
2.6.2	Paramètres des simulations des méthodes dans l'état de l'art	61
2.6.3	Performances des techniques ALED	62
2.6.4	Performances de l'approche HMM	66

2.6.5	Comparaison des performances avec quelques méthodes de segmentation	72
2.7	Discussion	75
2.8	Conclusion	77
3	Diagnostic de la maladie de Parkinson basé sur le signal EMG de surface	78
3.1	Introduction	79
3.2	Diagnostic de la MP en utilisant les bouffées d'activité EMG	81
3.2.1	Méthodologie de classification	81
3.2.2	Mesures de la précision de classification et la règle de vote majoritaire	94
3.2.3	Résultats et discussion	96
3.3	Diagnostic de la MP par les modèles HMM	103
3.3.1	Méthodologie de diagnostic et de classification	104
3.4	Résultats et discussion	106
3.5	Conclusion	109
4	Décomposition du signal EMG de surface en TPAUM par la séparation de sources	111
4.1	Introduction	112
4.2	Formulation de problème	114
4.3	Modélisation mathématique	114
4.3.1	Parcimonie et estimation des TPAUM	117
4.3.2	Décorrélacion des TPAUM estimés	120
4.4	Simulations, résultats et discussion	124
4.4.1	Paramètres de simulation	124
4.4.2	Résultats et discussion	124
4.5	Conclusion	127
	Conclusion générale et perspectives	131
A	Description de notre base de données	133
B	Dérivation de probabilité de fausse alarme et de détection du CA-CFAR à gauche	135
B.1	Calcul de probabilité de fausse alarme et de détection	135
B.2	Simulation numériques	137
B.3	Résultats de simulation	138
C	Différents types d'attributs	140

D	Modélisation du signal EMG par la prédiction linéaire fractionnelle : FLP	143
D.1	Modèle mathématique des coefficients FLP	143
D.2	Performance de modélisation FLP pour le signal EMG	145

LISTE DES FIGURES

1.1	Plans du corps humain [1].	19
1.2	vue en coupe d'un squelettique [2].	22
1.3	vue d'une unité motrice [3].	23
1.4	Phases du potentiel d'action.	25
1.5	Génération du potentiel d'action [4].	26
1.6	Exemple de train de potentiels d'action d'unité motrice [5].	26
1.7	[6] (a) le signal EMG et (b) courbe de force pendant une contraction musculaire isométrique.	27
1.8	Schémas synoptique de génération du signal EMG.	31
2.1	(a) Signal EMG de surface et sa transformée TKEO, (b) nature d'impulsivité de la transformée TKEO du signal.	46
2.2	Schémas de détection de CA-CFAR à gauche.	49
2.3	Organigramme des méthodes proposées.	51
2.4	Détection d'onset affinée	52
2.5	(a) signal EMGs et sa segmentation, (b) Évolution de la variance estimée de bruit of des méthodes ALED et OM-ALED	53
2.6	Etape d'extraction des caractéristiques.	54
2.7	Exemple d'un model HMM [7].	56
2.8	La segmentation du signal EMG basée sur le modèle HMM.	57
2.9	Processus d'extraction des attributs LPC / DWE / LWE / WCC. [8].	59

2.10	Segmentation automatique du signal EMG réel des muscles : (a) Left Vastus (avec bruit = 3 trames et la taille de trame = 280 échantillons) pour $R_e = 8.16$, (b) Right Soleus (avec bruit = 1 trame et la taille de trame = 78 échantillons) pour $R_e = 2.628$, (c) Left Gastroc (avec bruit = 4 trames et la taille de trame = 256 échantillons) pour $R_e = 11.056$. (d) Right Soleus (avec bruit = 3 trames et la taille de trame = 432 échantillons) pour $R_e = 7.762$	62
2.11	Probabilité d'erreur d'un signal EMGs synthétique pour un SNR = 20 dB pour différentes valeurs des tailles de bruits ν	63
2.12	segmentation FOM-ALED d'un signal EMGs synthétique : SNR = 20 dB, statistique d'ordre $q = 70\%$, taille des trames d'analyse = 256 et $R_e = 1.40$	64
2.13	Segmentation automatique d'un signal EMGs réel d'un sujet sain ($Control_6$) avec l'approche HMM pour le muscle <i>Right Soleus</i> avec $Re = 2.71\%$ ($N_{GMM} = 3$, $N_{states} = 2$, $L_{decomp} = 4$, ondelette = <i>Coif5</i> et une trame de durée = 66.45ms).	72
2.14	Segmentation automatique d'un signal EMGs réel d'un sujet Parkinsoniens ($Park_5$) avec l'approche HMM pour le muscle <i>Right Soleus</i> avec <i>Right Soleus</i> muscle with $Re = 6.06\%$ ($N_{GMM} = 3$, $N_{states} = 2$, $L_{decomp} = 4$, ondelette = <i>Coif5</i> and et une trame de durée = 66.45ms).	73
2.15	Comparaison de taux d'erreur Re moyen et l'écart type pour le muscle RSol soléaire droite pour les sujets sains et Parkinsoniens.	74
2.16	Comparaison de taux d'erreur Re avec la moyenne et l'écart type pour le muscle RSol soléaire droite pour les sujets sains et Parkinsoniens.	74
3.1	Méthodologie adoptée de diagnostic et d'analyse de performances.	82
3.2	Processus d'extraction des attributs	85
3.3	hyperplan 1-dimensionnel qui sépare les cas en fonction de leurs catégories	87
3.4	marge optimisée entre les vecteurs supports	88
3.5	Points séparés par une région non linéaire.	89
3.6	Séparations avec des limites très complexes.	89
3.7	K-plus proche voisin.	90
3.8	Réseau de neurones artificiel simple	92
3.9	Algorithme de calcul de la fonction de transfert	93
3.10	Exemple d'une topologie ANN.	95
3.11	Segmentation et classification du signal EMG basées sur les modèles HMM.	105
4.1	Génération du signal EMG.	115

4.2	Modèle de données convolutif des signaux EMG de surface. (a) Les motoneurones (MNs) conduisent l'activité électrique des fibres musculaires et des unités motrices dispersées spatialement et amplifient les informations sur la commande neurale. (b) L'activité des alpha motoneurones est modélisée par une série de fonctions delta discrètes, représentant les temps de décharge s_i . Les unités motrices convoluent ces séries de deltas avec des PAUM. Le volume de conduction agit comme un filtre passe-bas, ainsi les PAUM sont mesurés par les différents capteurs.	116
4.3	Mélange de trois sources générées avec les fréquences de décharges $FR = (2, 4, 8)$, observées par cinq capteurs.	125
4.4	Décomposition du signal EMGs(a) trois (03) sources générées (b) trois (03) sources estimées.	125
4.5	Convergence de critère de parcimonie pour trois (03) sources et $\lambda = (0.2, 0.5, 0.8)$.125	
4.6	Décomposition du signal EMGs (a) quatre (04) sources générées (b) quatre (04) sources estimées.	126
4.7	Convergence de critère de parcimonie pour quatre (04) sources et $\lambda = (0.2, 0.5, 0.8)$.126	
B.2	Probabilité d'erreur pour ($m = 10, m = 20$) et $SNR=20$ dB avec $P(H_0) = P(H_1) = 0.5$	138

LISTE DES TABLEAUX

2.1	Détermination du pas d'adaptation de la méthode ALED $R = \text{var}_{\text{current}}/\text{var}_{\text{old}}$	45
2.2	Comparaison du taux d'erreur du signal EMGs synthétique.	64
2.3	Comparaison du taux d'erreur, de la moyenne et de l'écart type (STD) de la détection des bouffées d'activité EMG du muscle RSol : right soleus des sujets saints	65
2.4	Comparaison du taux d'erreur, de la moyenne et de l'écart type (STD) de la détection des bouffées d'activité EMG du muscle RSol : right soleus des sujets Parkinsoniens.	66
2.5	Taux d'erreur de la détection des bouffées d'activité EMG pour les muscles : RSol : right soleus, LSol : left soleus, RGas : right Gastrocnemius, LGas : Left Gastrocnemius, RTA : right tibialis anterior, LTA : left tibialis anterior, RVlat : right vastus lateralis, LVlat : left vastus lateralis, RBfem : right biceps femoris, IBfem : left biceps femoris	67
2.6	Comparaison des performance en <i>Acc</i> % pour les descripteurs DWE, LPC, LWE and WCC en utilisant ' <i>Sym4</i> ' et $L_{\text{decomp}} = 4$ avec une trame d'analyse égale à 66.45 ms. L'étoile * indique que le <i>Re</i> est calculé uniquement pour les séquences correctement classifiées.	69
2.7	Comparaison des performances en <i>Acc</i> (%) et <i>Re</i> (%) pour le descripteur DWE en utilisant ' <i>Sym4</i> ' pour différentes durées des trames d'analyse.	69
2.8	Les performances en termes de <i>Acc</i> (%), <i>Re</i> (%) et L_{decomp} optimal pour des caractéristiques pour LWE en utilisant la familles des ondelettes Daubechies .	71

2.9	Les performances en termes de Acc (%), Re (%) et L_{decomp} optimal pour des caractéristiques pour LWE en utilisant la familles des ondelettes Symlets . . .	71
2.10	Les performances en termes de Acc (%), Re (%) et L_{decomp} optimal pour des caractéristiques pour LWE en utilisant la familles des ondelettes Coiflets . . .	71
2.11	La moyenne, l'écart type (STD) et la valeur absolue de erreur de latence (ALE) des durées de bouffées d'activités pour le muscle RSol right <i>soleus</i> pour des sujets sains et parkinsoniens.	72
2.12	Comparaison de taux d'erreur Re pour le muscle RSol <i>soléaire</i> droite pour les sujets sains et Parkinsoniens.	73
2.13	Comparaison : moyenne, écart type (STD) et erreur absolue de latence (ALE) de durées de bouffées d'activités EMG pour le muscle RSol <i>soléaire</i> droite de sujets $Control_6$ et $Park_5$	75
3.1	Description des signaux EMGs pour les sujets de contrôle.	83
3.2	Description des signaux EMGs pour les sujets Parkinsoniens.	83
3.3	Les performances en termes de CR (%) et la durée de trame d'analyse pour la méthode ANN pour les différents caractéristiques.	98
3.4	Les performances en termes de CR (%) et la durée de trame d'analyse pour la méthode SVM pour les différents caractéristiques.	99
3.5	Les performances en termes de CR (%) et la durée de trame d'analyse pour la méthode KNN pour les différents caractéristiques.	100
3.6	Les performances en termes de CR (%) et la durée de trame d'analyse pour la méthode LDA pour les différents caractéristiques.	100
3.7	Les performances en termes de CR (%) et la durée de trame d'analyse pour la méthode GMM pour les différents caractéristiques.	101
3.8	Les performances en termes de CR (%) et L_{decomp} optimal pour WCC et ANN en utilisant la familles des ondelettes Daubechies	102
3.9	Les performances en termes de CR (%) et L_{decomp} optimal pour WCC et ANN en utilisant la familles des ondelettes Symlets	102
3.10	Les performances en termes de CR (%) et L_{decomp} optimal pour WCC et ANN en utilisant la familles des ondelettes Coiflets	102
3.11	Performances en termes de CR (%) pour une base de données labellisée et segmentée en utilisant WCC, ANN, $Coif_5$, $L_{decomp} = 4$ et la durée de la trame d'analyse = 132.91 <i>ms</i>	103

3.12 Comparaison des performance en <i>Acc %</i> et <i>CRS %</i> pour les descripteurs DWE, LPC, LWE et WCC en utilisant ' <i>Coif5</i> ' et $L_{decomp} = 4$ avec une trame d'analyse égale à 66.45 ms.	107
3.13 Comparaison des performances en <i>Acc %</i> et <i>CRS %</i> pour le descripteur LWE en utilisant ' <i>Coif5</i> ' pour différentes durées des trames d'analyse.	108
3.14 Les performances en termes de <i>Acc %</i> , <i>CRS %</i> et L_{decomp} optimal pour LWE en utilisant la familles des ondelettes Daubechies	109
3.15 Les performances en termes de <i>Acc %</i> , <i>CRS %</i> et L_{decomp} optimal pour LWE en utilisant la familles des ondelettes Symlets	109
3.16 Les performances en termes de <i>Acc %</i> , <i>CRS %</i> et L_{decomp} optimal pour LWE en utilisant la familles des ondelettes Coiflets	109
B.1 Latence entre onset réel et estime de l'activité EMG pour le muscle Soléaire droit pour les sujets Parkinsoniens	139
B.2 Latence entre onset réel et estime de l'activité EMG pour le muscle Soléaire droit pour les sujets sains	139
C.1 Attributs temporels.	140
C.2 Attributs fréquentiels.	141
C.3 Attributs statistiques.	141
C.4 Attributs temps-fréquence.	142
D.1 Performance de modélisation du signal EMGs pour les sujets sains	146
D.2 Performance de modélisation du signal EMGs pour les sujets Parkinsoniens	146

LISTE DES SYMBOLES ET ABRÉVIATIONS

<i>EMG</i>	électromyographie
<i>EMGs</i>	électromyographie de surface
<i>EEG</i>	Électroencéphalographie
<i>EOG</i>	électro-oculographie
<i>ECG</i>	électrocardiogramme
<i>SLA</i>	Sclérose Latérale Amyotrophique
<i>SNC</i>	Système Nerveux Central
<i>FM</i>	Fibre Musculaire
<i>MN</i>	Moto-Neurone
<i>TT</i>	Tubules Transverses
<i>UM</i>	Unité Motrice
<i>PA</i>	Potentiel d'Action
<i>PAFS</i>	Potentiel d'Action des Fibres Singulières
<i>PAUM</i>	Potentiel d'Action de l'Unité Motrice
<i>MUAP</i>	Motor Unit Action Potential
<i>TPAUM</i>	Trains de Potentiels d'Action d'UM
<i>FD</i>	fréquence des décharges
<i>IID</i>	Intervalles Inter-Décharge
<i>TIN</i>	Train d'Impulsion Nerveux
<i>CMV</i>	Contraction Maximale Volontaire
<i>MP</i>	Maladie de Parkinson

- RSB* rapport signal sur bruit
- PLI* Power Line Interference
- ALED* Adaptive Linear Energy Detector
- M – ALED* Modified ALED
- OM – ALED* Order M-ALED
- FM – ALED* Fine M-ALED
- FOM – ALED* Fine OM-ALED
- CFAR* Constant False Alarm Rate
- CA – CFAR* Cell-Averaging CFAR
- CUI* Cell Under Investigation
- P_{fa} probabilité de fausse alarme
- P_{miss} probability of missing
- P_e probabilité d'erreur
- R_e Rate Error
- iid* Independent and identically distributed
- FLP* fractional linear prediction
- AR* autoregression
- LPC* Linear Prediction Coefficients
- DWT* Discrete Wavelet Transform
- CWT* Continous Wavelet Transform
- WPT* Wavelet Packet Transform
- WCC* Wavelet Cepstral Coefficient
- LWE* Log Wavelet decomposition based Energy
- EMD* Empirical Mode Decomposition
- STFT* Short Time Fourier transform
- ANN* artificial neural network
- PNN* probabilistic neural network
- SVM* Support Vector Machine
- LDA* Linear Discriminant Analysis

<i>HMM</i>	Hidden Markov models
<i>GMM</i>	Gaussian Mixture model
<i>MLP</i>	Multi-Layer Perceptron
<i>COG</i>	Centre de Gravité
<i>COP</i>	Centre des Pressions
<i>VoIP</i>	Voice over Internet Protocol
<i>TKEO</i>	Teager-Kaiser Energy Operator
<i>RMS</i>	Rate Mean Square
<i>ALE</i>	Absolute latency error
<i>STD</i>	Standard Deviation
<i>Sol</i>	muscle Soléus
<i>TA</i>	muscle Tibial antérieur
<i>Vlat</i>	muscle vastus lateralis
<i>Bfem</i>	muscle biceps fémoral
<i>VLSI</i>	muscle gastrocnémien (Gas)
<i>MIMO</i>	(Multi-inputs multi-outputs)
<i>SR</i>	Sparse Representation
<i>BSS</i>	Blind Source Separation
<i>CBSS</i>	Convolutive Blind Source Separation via Sparse Representation

INTRODUCTION GÉNÉRALE

Contexte général

Les signaux biomédicaux servent à décrire des phénomènes physiologiques et jouent un rôle primordial dans l'évaluation et le diagnostic de différentes pathologies, où nous pouvons citer à titre d'exemple : le signal EEG, le signal EMG, le signal ECG, le signal EOG, le signal EGG,...etc. Dans cette thèse, nous nous intéressons au signal électromyographique (EMG). Celui-ci mesure l'activité électrique musculaire, permet l'étude, l'évaluation et le diagnostic des maladies neuromusculaires [9] (neuropathiques telles que la maladie de Parkinson, la Sclérose Latérale Amyotrophique (SLA) [10], les troubles de la transmission neuromusculaire, myopathies,...etc). Il est utilisé aussi pour l'évaluation de troubles du contrôle moteur.

La réalisation de nos activités quotidiennes, comme la marche, le vélo ou un simple maintien d'une posture droite, implique la contraction simultanée de plusieurs muscles. Ces contractions musculaires, à leur tour, sont le fruit de commandes en provenance du système nerveux central (SNC). Ce SNC contrôle la posture et les mouvements, d'une manière générale, à travers l'activation des unités motrices (UM). Ces UM présentent les plus petites structures fonctionnelles du muscle, qui produisent une activité électrique. Cette dernière peut être détectée par la technique de l'électromyographie intramusculaire ou de surface (EMGs) qui est l'objet de cette thèse. Le caractère stochastique du signal EMGs est dû principalement à la superposition des trains de potentiels d'action d'UM (TPAUM) (recrutement spatial). Les TPAUM sont caractérisés par leurs instants de décharge (recrutement temporel), ainsi que par la forme des potentiels d'action (PA), qui dépend de certains facteurs méthodologiques et de facteurs intrinsèques liés au muscle.

Ces dernières années, l'étude des signaux EMG a permis le développement de plusieurs applications visant l'amélioration de l'interface muscle-machine. Parmi ces applications,, le contrôle de prothèses robotisées : la bioprothèse ou prothèse intelligente [11]; l'exosquelette [12]. Cela concerne également le contrôle de la chaise roulante [13], le pilotage d'aéronef [14] ou encore l'informatique grand public [15]. Les méthodes de traitement du signal EMG, nécessitent d'être améliorées davantage parce qu'elles révèlent un manque de reproductibilité. De plus, la plupart des applications technologiques, citées précédemment, sont encore au stade de développement, notamment, le signal EMG de par sa nature complexe et propriété multifactorielle. C'est pourquoi, il est encore nécessaire d'améliorer les méthodes actuelles de traitement de ce signal neurophysiologique.

La maladie de Parkinson (MP) est une maladie neurodégénérative décrite, pour la pre-

mière fois, en 1817 par le médecin anglais James Parkinson. Cette maladie est définie cliniquement par des troubles moteurs, des troubles de mouvements et de la perte de contrôle postural. Elle est caractérisée par plusieurs symptômes où on peut citer : instabilité posturale et troubles de la marche, tremblement du repos, rigidité, Akinésie et Bradykinésie.

La MP n'est pas toujours facile à diagnostiquer. Son diagnostic repose généralement sur l'examen neurologique réalisé par le médecin et les symptômes décrits par le patient. Plusieurs travaux de recherche sont effectués pour l'analyse, l'évaluation et l'identification de la MP à travers plusieurs approches que nous pouvons citer : l'écriture manuscrite (en anglais Hand writing) [16], l'analyse et l'évaluation de la marche à travers l'enregistrement des intervalles de foulées [17, 18, 19, 20], l'analyse de la voix (en anglais voice analysis) [21], l'imagerie médicale [22, 23], l'analyse des signaux d'électrovestibulographie (EVestG), qui sont en fait la réponse vestibulaire modulée par des signaux cérébraux corticaux [24] et l'analyse de la marche en utilisant les signaux EMG de surface, qui est le cœur des travaux réalisés dans la présente thèse [25, 26, 27].

D'une manière générale, nous pouvons trouver dans l'analyse du signal EMG plusieurs domaines de recherche, répertoriés principalement en trois domaines. Le premier regroupe les méthodes de détection de l'activité EMG, le second relève de la classification de ces activités EMG et le dernier domaine traite la décomposition de ces activités EMG en TPAUM. Cette analyse dépend toujours du domaine d'application. Dans les travaux de cette thèse, nous avons utilisé des signaux EMG de surface : synthétiques et réels. Ces derniers sont enregistrés sur les membres inférieurs caractérisant la marche, dans le cadre d'un projet ECOTECH [28].

L'un des paramètres les plus pertinents dans l'étude du signal EMG est la détection du début de l'activité électromyographique (onset) ainsi que la fin (offset) de cette activité. La tâche de détection de l'onset est une application de la théorie de décision statistique utilisée pour détecter un signal noyé dans un bruit et extraire des informations relatives à la présence ou à l'absence de certains événements d'intérêt. Cette dernière théorie trouve ses applications dans plusieurs domaines notamment : radar, communication, traitement d'images, traitement de la parole, la sismologie et la biomédecine.

La détection de l'activité EMG dans le signal EMG est d'une importance capitale pour les applications sur l'interaction muscle-machine. Dans les travaux de cette thèse, nous nous intéressons à la surveillance et la détection de l'activité EMG à travers la détection de bouffées (ou zone) d'activité EMG. Cette dernière consiste en la détection du début et de la fin d'une activité musculaire sur le signal EMGs d'une manière automatique. Pour ce faire,

plusieurs algorithmes semblent bien fonctionner en combinant à la fois, une bonne précision et un nombre d'opérations restreint. Cette détection présente une importante tâche dans l'intérêt, par exemple, d'économiser les ressources du processeur afin de n'extraire les caractéristiques du signal que lorsque c'est utile et surtout de segmenter les zones d'activité musculaire pour la détection de mouvement.

Plusieurs travaux de recherche ont été menés dans le domaine de la détection et la surveillance de l'activité EMG. Dans [29, 30, 31, 32, 33, 34], une attention particulière a été principalement accordée à la détection du premier onset. Dans [35, 36, 37, 38, 39, 40, 41, 42, 43], les travaux de recherche ont porté plus généralement sur le suivi complet de l'activité EMG (début/fin ou en anglais onset/offset). Cela étant, toutes ces méthodes peuvent être catégorisées en méthodes non supervisées et méthodes supervisées. Cependant, il est important de souligner l'apport de l'expertise humaine dans la sélection des zones d'intérêt. Dans les travaux de cette thèse, notamment, dans ce domaine de détection, nous allons développer deux approches, la première est une méthode non supervisée et adaptative nommée FM-ALED. La deuxième est une méthode supervisée qui consiste à utiliser la chaîne de Markov combinée avec la transformée en ondelettes.

Une fois les zones d'activité EMG sont détectées, nous cherchons à caractériser ces bouffés d'activité EMG et à extraire de l'information sous formes de caractéristiques, appelées aussi attributs (ou en anglais features). Ces derniers vont être utilisées pour déterminer, par exemple, quel type de mouvement a été effectué ou quelle maladie présentée dans ces bouffés d'activités EMG. Cette tâche est appelée une opération de classification ou de diagnostic, effectuée par un système de classification. Ce système de classification doit prendre en compte des éléments de comparaison pour déterminer quel type de maladie. Ces caractéristiques extraites du signal EMG doivent être significatives. Ces caractéristiques des signaux EMG sont nombreuses, et nous nous concentrerons sur celles les plus utilisées dans la littérature.

L'extraction de ces caractéristiques joue un rôle essentiel pour obtenir un système de classification robuste. Ce processus transforme le signal EMG de surface brute en un vecteur ou une séquence de vecteurs des caractéristiques, obtenues par un calcul simple ou complexe. Généralement, les caractéristiques utilisées dans l'analyse des signaux EMG peuvent être catégorisées en attributs temporels : les plus utilisés dans la littérature, sont les coefficients LPC [52, 53], Kurtosis [54], Histogramme du signal EMG [53], coefficients cépsaux [55], entropie [40], Skewness[56], la racine de la moyenne quadratique (ou en anglais Root Mean Square)[57, 58, 55, 59], prédiction linéaire fractionnelle (fractional linear predic-

tion FLP en anglais) [60], qui sont considérées comme des caractéristiques temporelles. Par contre, dans le domaine fréquentiel, on peut citer : l'énergie [61], la décomposition en ondelettes [61], la transformée de fourrier à court termes (ou anglais Short Time Fourier transform STFT) [62] et la puissance totale (ou en anglais total power) [55]. Pour l'analyse dans le domaine temps fréquence, on trouve aussi la transformée en ondelette discrète (discrete wavelet transform DWT en anglais) [63], la transformée en ondelette continue (continuous wavelet transform CWT en anglais) [64], la décomposition en mode empirique (empirical mode decomposition EMD)[64], la transformée en ondelettes en paquets (Wavelet Packet Transform WPT en anglais)[63].

Une fois les caractéristiques du signal EMG sont extraites, celles-ci sont entrées dans un système de classification qui, grâce à une phase d'apprentissage, permet d'identifier si le patient est touché par la maladie de Parkinson [65, 66, 67, 18, 68, 69]. Encore une fois, beaucoup d'algorithmes existent pour réaliser cette opération. Toutefois, on trouve dans la littérature les réseaux de neurones artificiels (en anglais artificial neural network ANN) [25], le réseau neuronal probabiliste (en anglais probabilistic neural network PNN) [70], la machine à vecteur de support (en anglais support vector machine SVM) [71], l'analyse discriminante linéaire (en anglais linear discriminant analysis LDA) et la technique K-moyennes (ou en anglais K-means).

Dans les travaux de cette thèse, notamment, dans le domaine classification, nous allons présenter deux approches. La première consiste à faire classifier les zones d'activité EMG en se basant sur les techniques existantes dans la littérature. La deuxième approche consiste à classifier tous le signal EMG de surface en se basant sur les modèles de Marcov cachés (ou en anglais hidden marcov models HMM) combinés avec la transformée en ondelette.

Après avoir segmenté, identifié et classifié les régions d'activité EMG du signal EMG, une méthode de décomposition est présentée. Cette méthode permet la décomposition du signal EMG de surface en trains de potentiels d'action d'unité motrice (TPAUM). Dans cette partie, nous nous intéressons uniquement aux signaux EMG synthétiques.

Organisation du Manuscrit

Le présent manuscrit comporte quatre chapitres principaux. Le premier chapitre est consacré à un état de l'art de la problématique traitée. On y présente des concepts de base en : physiologie neuromusculaire, la posture et la maladie de Parkinson, le signal EMG et ses principes de génération de même que les différents bruits qui l'affectent. Les trois chapitres

qui suivent représentent chacun un domaine de recherche dans l'analyse de signaux EMG et qui constituent le corps de notre travail. Le deuxième chapitre décrit la partie segmentation du signal EMG de surface en région d'activité EMG et en région de non activité EMG (bruit) où nous allons présenter deux approches. La première concerne une méthode non supervisée, adaptative qui est la méthode FM-ALED et la deuxième approche présente une méthode non supervisée où nous utilisons le modèle HMM combiné avec la transformée en ondelettes. Le troisième chapitre traite le problème de classification et de l'identification de la maladie de Parkinson en utilisant deux approches. La première ne traite que les régions actives par contre la deuxième traite tout le signal EMG de surface et donc ne nécessite pas l'étape de segmentation. Le quatrième chapitre est dédié à la partie décomposition du signal EMG en TPAUM exploitant la propriété de parcimonie. Ces chapitres comportent chacun une partie discussion et une conclusion où nous interprétons les résultats obtenus, faisons le point sur l'atteinte des objectifs visés et énumérons des perspectives pour d'éventuels travaux futures. Nous clôturons cette thèse par une conclusion générale résumant l'essentiel des travaux réalisés et traçant quelques perspectives.

Liste de publications et conférences

Certains travaux de recherche présentés dans cette thèse, ont été publiés ou soumis pour publication à des revues et conférences comme suit :

Articles de revues scientifiques :

1. Bengacemi H, Abed-Meraim K, Buttelli O, Ouldali A, and Mesloub A."A new detection method for EMG activity monitoring." *Medical & Biological Engineering & Computing* 58, no. 2 (2020) : 319-334.
2. Bengacemi, H, Hacine Gharbi, A., Ravier, P. Abed-Meraim, K. and Buttelli, O. Surface EMG signal segmentation based on HMM modelling : application on Parkinson's disease. *Biomedical Signal Processing and Control*, Novembre, 5 (2020) (submitted).

Papiers conférences :

1. Bengacemi H, Mesloub A, Ouldali A, Abed-Meraim K. Adaptive Linear Energy Detector based on onset and offset electromyography activity detection. 6th International Conference on Systems and Control (ICSC), 2017 2017 May 7 (pp. 409-413). IEEE. DOI : 10.1109/ICoSC.2017.7958651

2. Bengacemi H, Ouldali A, Abed-Meraim K, Buttelli O and Mesloub A ; Onset Electromyography Activity detection using CFAR Technique. 5th International Conference on Image and Signal Processing and their Applications (ISPA) 3-4 December 2017, Mostaganem Algeria.
3. Bengacemi H, Ouldali A, Abed-Meraim K, Buttelli O and Mesloub A ; Burst sEMG Activity Detection using Modified Adaptive Linear Energy Detector. 5th International Conference on Image and Signal Processing and their Applications (ISPA) 3-4 December 2017, Mostaganem Algeria .
4. Bengacemi H, Mesloub A, Abed-Meraim K, Ouldali A and Buttelli O. (2019, April). EMG signal for Parkinson's disease classification using FLP and ANN. In 1st Conference on Electrical Engineering (CEE 2019), Algies Algeria.
5. Bengacemi H, Hacine Gharbi A, Ravier P, Abed-Meraim K and Buttelli O. Surface EMG signal classification for Parkinson's disease using WCC descriptors and ANN classifier, 10-Th The International Conference on Pattern Recognition Applications and Methods (ICPRAM). 4-6 February 2021.

CHAPITRE 1

GÉNÉRALITÉS SUR LA PHYSIOLOGIE DE MUSCLE ET LE SIGNAL EMG DE SURFACE

Contents

1.1	Introduction	10
1.2	Application de l'électromyographie	11
1.2.1	Neurologie	11
1.2.2	Ergonomie	12
1.2.3	Mouvement et analyse de la marche	13
1.2.4	Réhabilitation	14
1.2.5	Biofeedback (rétroaction biologique)	14
1.2.6	Contrôle de prosthèse	15
1.3	Maladie de Parkinson et contrôle postural	15
1.3.1	Maladie de Parkinson	16
1.3.2	Posture et contrôle postural	18
1.4	Physiologie neuro-musculaire du muscle	20
1.4.1	Muscle	20
1.4.2	Anatomie et physiologie du muscle squelettique	21
1.4.3	Unité motrice	22
1.4.4	Potentiel d'action	24
1.4.5	Train de potentiels d'action et recrutement temporel	25
1.4.6	Recrutement spatial des Unités Motrices	27
1.5	Signal EMG	27

1.5.1	Définition	27
1.5.2	Mesure du signal électromyographique	28
1.5.3	Modèles analytiques du signal EMG	29
1.5.4	Bruits affectant le signal EMG	32
1.6	Conclusion	33

1.1 Introduction

Le corps humain est un système très complexe et fortement couplé. Il nécessite de l'électricité pour son bon fonctionnement. Cette électricité est présente à travers des courants électriques véhiculés par le système nerveux central et périphérique. En effet, à titre d'exemple lorsqu'une personne fait bouger un muscle, des décharges électriques se produisent alors [72]. L'ordre ainsi donné (bouger un muscle) est transformé instantanément dans le cerveau (la source) en un courant électrique qui circule en direction du muscle (le récepteur) à travers des nerfs (le canal de transmission).

Les premiers travaux sur l'activité électrique accompagnant la contraction musculaire furent entrepris à la fin du 18ème siècle et au début du 19ème siècle [73, 74, 72, 75]. En effet, les premiers balbutiements débiteront avec l'avènement de l'électricité. Depuis de nombreux travaux de recherche furent menés, sur cette activité électrique, pour donner naissance, à une nouvelle technique médicale communément appelée l'électromyographie (EMG) dont l'intérêt n'est plus à démontrer dans le diagnostic des maladies neurologiques par exemple [76, 77, 78]. L'EMG est définie en médecine comme étant l'enregistrement graphique de la contraction musculaire du point de vue de son activité électrique et les signaux liés à celle-ci sont appelés signaux électromyographiques (signaux EMG) [79].

En 1773, Walsh avait été en mesure de démontrer clairement que le tissu musculaire peut générer une étincelle d'électricité [80]. Plus tard en 1790, au cours d'une série d'études sur les muscles de la grenouille, Galvani a mis en évidence l'existence d'une relation entre la contraction des muscles et l'électricité [81]. En 1838 et grâce à l'utilisation des premiers galvanomètres, Carlo Matteucci a montré que les courants électriques sont générés par les muscles pendant leur contraction. Par la suite, au cours des 19ème et 20ème siècle, les études portant sur l'activité électrique des muscles en contraction foisonnèrent. Cette pléthore des travaux sur les techniques EMG ne nous permettent pas de présenter ces approches en totalité. Néanmoins, nous ne pouvons pas passer sous silence le fait qu'en 1949, le prix Nobel de médecine fut attribué à H. Gasser S et à J. Erlanger. Ils ont été récompensés pour leurs travaux sur l'utilisation de l'oscilloscope pour la visualisation de la forme du signal EMG. Enfin, il est important de signaler que les avancées scientifiques de l'EMG sont en grande partie dues aux nouveaux algorithmes du traitement de signal ainsi qu'à l'augmentation de la capacité de calcul informatique.

Le présent chapitre s'inscrit dans le cadre de l'étude et l'analyse des signaux EMG dans le but de trouver d'éventuelles applications dans le diagnostic de la maladie de Parkinson

(MP) généralement connue par la rupture du contrôle postural. Aussi afin de mieux cerner cette problématique, nous articulons le présent chapitre autour des quatre points suivants :

- La section 1.2 traite succinctement des applications de l'EMG telles que : la neurologie, l'ergonomie, le mouvement et l'analyse de la marche ;
- Dans la section 1.3, nous abordons très brièvement la MP et l'aspect biomécanique du corps humain ;
- La section 1.4 est consacrée principalement à la physiologie neuromusculaire du muscle ;
- Dans la section 1.5, nous abordons les notions relatives aux signaux EMG. Nous y présentons tout particulièrement les différents modèles mathématiques adoptés pour représenter de tels types de signaux ainsi que les différents types de bruit susceptibles de les affecter.

1.2 Application de l'électromyographie

L'EMG est largement utilisée dans de nombreuses applications biomédicales. Dans ce paragraphe, nous décrivons brièvement les applications de l'EMG en neurologie, ergonomie, mouvement et analyse de la marche, réadaptation, biofeedback et contrôle des prothèses.

1.2.1 Neurologie

La neurologie est la spécialité médicale qui s'intéresse à tous les aspects du diagnostic, l'évaluation et le traitement des maladies du système nerveux. Comme le système nerveux est intimement lié à tous les aspects de la vie quotidienne du patient, toute anomalie qui pourrait affecter ce système engendrera des conséquences graves et des maladies néfastes. Parmi les maladies les plus connues, nous retrouvons la MP, l'épilepsie et les atteintes du système nerveux périphériques. Le diagnostic d'une maladie neurologique (troubles neurologiques) est possible à l'aide de l'enregistrement à partir de la sortie du système nerveux en termes d'activation musculaire par l'EMG de surface [82]. Les maladies du système nerveux central sont souvent accompagnées de changements dans la sortie motrice [83]. Ces changements qui peuvent être une perte ou une diminution de la motricité peuvent se traduire par une faiblesse de la contraction musculaire ou une paralysie totale du muscle (perte totale de la capacité de contracter un muscle à volonté). Les mouvements involontaires tels que

les tics, les tremblements, la rigidité et la dystonie (résultant de la voix altérée) résultent souvent des maladies dans les noyaux gris centraux [84].

Deux approches basées sur l'EMG de surface sont essentiellement utilisées pour évaluer ce genre de maladies [85, 86, 87, 88, 78, 89, 90] :

1. La première est l'utilisation de l'EMG multicanaux appliquée à de nombreux muscles, connue sous le nom polomyographie [91]. Dans ce cas, le modèle de l'activation des muscles est étudié soit au repos ou pendant un type d'activité comme la marche et le mouvement spéciale de la main. Des informations complémentaires, pour un meilleur diagnostic, sont très souvent recueillies lors de la mesure de l'EMG de surface par, des capteurs tels que des accéléromètres placés au niveau des pieds au contact du sol et parfois des enregistrements vidéo.
2. La deuxième approche est basée sur la simulation d'un réflexe. Elle est effectuée généralement par la stimulation électrique d'un nerf périphérique suivi de la mesure de la réponse du système nerveux central. Une analyse précise de la chronologie relative des modèles d'activation par le système nerveux central en utilisant l'EMG, a été un outil important dans de nombreuses études de réhabilitation et de contrôle moteur. Dans ce contexte, l'EMG est seulement utilisé comme un marqueur de la manière dont le système nerveux central contrôle les muscles lors de certaines tâches différentes, comme la marche ou la course.

1.2.2 Ergonomie

En ergonomie, la charge physique représente l'un des aspects les plus importants à traiter dans la conception du travail des tâches à exécuter et des lieux de travail. Le principal objectif de l'ergonomie est la facilitation des tâches de l'être humain lors de l'exécution d'une activité ou d'un travail donné. En ergonomie, l'activité musculaire au cours du temps peut être obtenue à partir des signaux EMG de surface en deux étapes :

1. La première étape convertit le signal brut EMG en un paramètre pertinent tout en préservant sa variation dans le temps ;
2. La seconde étape consiste en la réduction des données par l'application d'algorithmes de plus en plus performants et l'utilisation de plusieurs modèles statistiques.

Les paramètres d'amplitude et les paramètres spectraux sont principalement utilisés pour représenter l'activité musculaire. Les mesures d'amplitude sont principalement liées à des forces, des couples, et l'activation des muscles, tandis que les variables spectrales sont prin-

ciement liées aux différents aspects de la fatigue. Cette dernière est un concept fondamental en matière d'ergonomie. En effet, le principe de base est que la fatigue doit être le plus souvent évitée ou retardée le plus longtemps possible [92, 93], la fatigue peut être définie de nombreuses façons incluant à la fois un grand nombre de phénomènes physiologiques indépendants ainsi que des phénomènes psychologiques. En effet, dans la vie professionnelle de nombreuses personnes sont très exposées à la fois à des exigences psychologiques et physiologiques en raison de leur travail. Des exemples de conditions de travail associés à ces deux types de stress sont : le travail à la chaîne d'assemblage traditionnelle et le travail aux caisses des supermarchés [94].

1.2.3 Mouvement et analyse de la marche

L'étude du mouvement humain et du contrôle moteur tire un grand avantage de l'utilisation de l'électromyogramme, en particulier, de l'électromyographie de surface (EMGs). Cette étude est le rôle de la kinésiologie. Dans de nombreuses applications d'analyse de mouvement, cette dernière ne dépend pas uniquement des signaux EMGs mais également d'autres quantités de nature mécanique. Les applications de l'EMG dans l'analyse du mouvement sont nombreuses et différentes :

- Étude des stratégies du contrôle moteur, qui est l'activation des muscles agonistes, antagonistes et synergiques ;
- Étude mécanique de la contraction musculaire ;
- Analyse de la marche ;
- Identification des facteurs physiopathologiques ;
- Évaluation de la charge de travail en biomécanique professionnelle ;
- Biofeedback dans la rééducation motrice.

Un exemple d'application des stratégies du contrôle moteur, l'étude du comportement des différents muscles lorsque la posture d'un sujet est mécaniquement stimulée. A cet effet, les signaux EMGs provenant du muscle tibial antérieur (TA) et la partie interne du muscle gastrocnémien (GM) des deux jambes sont utilisés conjointement avec une cinématique articulaire. d'une manière générale, les signaux EMGs ont été utilisés dans l'analyse de la marche avant même l'avènement de systèmes optoélectroniques modernes pour les enquêtes cinématiques. Ils sont utilisés pour être comparés à ceux des sujets atteints de pathologies liées au mouvement lors de la marche.

Un profil physiopathologique peut être établi pour représenter synthétiquement l'importance relative des facteurs physiopathologiques de la performance du patient. Une telle procédure peut aider le clinicien à prendre des décisions au sujet de la thérapie. Dans ces cas, l'information EMGs est très importante et doit être considérée conjointement avec les autres variables biomécaniques.

1.2.4 Réhabilitation

La réhabilitation se réfère à tout processus qui vise à rétablir le patient à un niveau précédent de la santé. Différents types ou expressions du processus de réadaptation se focalisent sur la tâche de la restauration d'au moins une fonction de la partie endommagée du corps ou en utilisant le processus de rééducation pour aider l'individu à compenser les dommages qui ne peuvent pas être réparés. Dans ce contexte, l'EMG est utilisé dans trois niveaux :

- L'investigation et de l'évaluation du problème pathologique afin de gérer une bonne rééducation ;
- L'investigation et le suivi de l'évolution des processus de réhabilitation et de la direction du mouvement du patient en utilisant la technique de biofeedback ;
- Le signal EMG est utilisé comme un outil efficace dans les investigations des douleurs du dos et du cou.

1.2.5 Biofeedback (rétroaction biologique)

Le biofeedback est un processus par lequel les sorties des systèmes du corps peuvent être mesurés et rétro-activés pour le corps à travers les éléments de perception. Cliniquement, le biofeedback est une technique de traitement dans laquelle les gens sont entraînés à améliorer leur santé en utilisant des signaux de leur propre corps. Dans les signaux sEMG, les activités musculaires des différents muscles peuvent être mesurées électriquement. Le niveau d'activité musculaire est généralement corrélé avec l'amplitude du signal EMGs. Cette relation entre l'activité musculaire et l'activité électrique est utilisée dans le système de rétroaction biologique qui permet au patient de contrôler ses activités musculaires. Le biofeedback sEMG peut être utilisé pour évaluer et traiter une variété de troubles musculo-squelettiques ou neuromusculaires.

Puisque les muscles sont contrôlés et réglementés par de nombreuses parties du cerveau, moelle épinière et du système nerveux périphérique, cliniquement, il est utile de regrouper

et d'examiner trois domaines : les émotions, la posture et le mouvement. La dysfonction musculaire peut survenir pour de nombreuses raisons ; certains d'entre elles sont liées à la pathologie du tissu musculaire, certaines d'autres sont liées à un traumatisme ou à une blessure, et d'autres sont liées aux modes d'utilisation ou d'abus. Une fois que l'étiologie (connaissance des causes) est mieux comprise, le biofeedback peut être l'un des éléments de traitement pour restaurer le programme moteur normal qui a été altéré.

La plupart des stratégies de formation (ou d'entraînement) du biofeedback EMGs commencent par aider le patient à trouver, de manière proprioceptive (encourageante) le muscle dysfonctionnel. Le but est d'apprendre à l'isoler des autres muscles. Cela signifie apprendre à le contracter seul, sans la concertation des muscles environnants ou synergiques. La rétroaction visuelle en utilisant l'affichage chronologique des séries de signaux EMGs soient bruts ou transformés est généralement utilisée pour guider les efforts du patient. Historiquement le biofeedback sEMG a été principalement utilisé comme une rétroaction pour affaiblir l'excitation et pour aider à la détente. En général, on enseigne au patient une technique générale ou systémique de relaxation qui est assistée par EMG biofeedback.

1.2.6 Contrôle de prothèse

Le signal myoélectrique de surface est une entrée de système efficace et importante pour le contrôle de prothèses motorisées. Cette approche de contrôle, à commande myoélectrique, a trouvé une large utilisation pour les personnes ayant subi une amputation des membres supérieurs ou congénitalement déficients. Dans ces systèmes, les paramètres de contrôle volontaires des signaux myo-électriques provenant d'un muscle ou d'un groupe de muscles sont utilisés pour sélectionner et moduler une fonction d'une prothèse multifonction.

1.3 Maladie de Parkinson et contrôle postural

Dans ce paragraphe, nous allons essayer de présenter de façon assez générale la MP et la notion de contrôle postural. Nous y verrons aussi les notions très importantes d'équilibre statique et d'équilibre dynamique.

1.3.1 Maladie de Parkinson

a). Définition

La MP est une maladie du cerveau décrite pour la première fois par le médecin anglais James Parkinson en 1817 [95]. C'est une maladie neuro-dégénérative qui se manifeste principalement par des troubles du mouvement et la perte du contrôle postural [96, 97]. Elle s'explique par la perte de cellules dans une partie du cerveau appelée : la substance noire. Ces cellules sont responsables de la production d'un élément chimique appelé dopamine, qui agit comme messager entre les cellules du cerveau impliquées dans le contrôle du mouvement [98, 99].

b). Symptômes de la maladie de Parkinson

Nous pouvons distinguer quatre signes cardinaux qui sont à l'origine des manifestations cliniques de la MP [100] :

- **Tremblement de repos** : celui-ci est le signe le plus connu dans la maladie de Parkinson. Chez plus de 70 % des malades, il est considéré comme le premier symptôme. Il s'agit d'un tremblement qui commence généralement de façon unilatérale, d'un seul côté du corps, au niveau du pied ou de la main. À mesure que la maladie progresse, le tremblement pourra éventuellement affecter les membres du côté opposé. La caractéristique principale de ce tremblement, est son atténuation lors de l'exécution de mouvements volontaires, ce qui le distingue des autres formes de tremblement.
- **Akinésie et Bradykinésie** :
 - L'akinésie et la bradykinésie sont des signes qui, cliniquement, se définissent par une rareté (akinésie) et une lenteur (bradykinésie) des mouvements ;
 - Au niveau du visage, on observe une diminution de l'expression faciale et du clignement des yeux ;
 - La voix peut devenir monotone et basse. Nous notons aussi des difficultés dans l'exécution des mouvements et une lenteur dans leur exécution.
- **Rigidité** : celle-ci consiste en une augmentation du tonus musculaire. Elle peut se manifester par une diminution du balancement du bras du côté du corps affecté par la MP.
- **Instabilité posturale** : cette dernière est une manifestation tardive de la MP, qui n'apparaît qu'après de nombreuses années d'évolution. L'instabilité posturale

se manifeste par des troubles de l'équilibre, qui provoquent fréquemment des chutes.

c). **Évolution de la maladie de Parkinson**

Comme la MP est causée par une perte progressive des neurones dopaminergiques impliqués dans la maîtrise des mouvements volontaires, les gens consultent en général pour des problèmes moteurs [101, 102]. Parmi les autres causes, de consultation, en relation avec la maladie les médecins rapportent une perte de dextérité fine ou de la micrographie (écriture qui devient de plus en plus petite) [103].

L'évolution de la maladie dans le temps est très difficile à prédire [104]. Certaines personnes atteintes de la MP voient la progression de leurs symptômes s'étaler sur plusieurs décennies tandis que d'autres verront leur état se détériorer plus rapidement [104]. Nous présentons, ci-après, un résumé très simplifié de l'évolution typique de la maladie de Parkinson chez un sujet non traité. Cette évolution est définie selon l'échelle de Hoehn et Yahr (1967) [105] :

- **Stade 1** : les symptômes sont unilatéraux et comprennent au moins deux des trois symptômes suivants : tremblement de repos, raideur ou akinésie ;
- **Stade 2** : les symptômes commencent à devenir bilatéraux et peuvent alors inclure des problèmes d'élocution, une posture déformée et des difficultés à marcher ;
- **Stade 3** : les symptômes bilatéraux s'aggravent et des problèmes d'équilibre peuvent apparaître. L'autonomie de la personne n'est généralement pas affectée.
- **Stade 4** : l'invalidité est présente, mais l'autonomie de la personne n'est généralement pas affectée. La bradykinésie est plus prononcée de même que les fluctuations, si elles sont présentes.
- **Stade 5** La personne est confinée à un fauteuil roulant ou doit rester alitée.

d). **Diagnostic de la maladie de Parkinson**

Le diagnostic de la MP n'est pas toujours facile à établir [104]. Il repose exclusivement sur l'examen neurologique réalisé par le médecin et les symptômes décrits par le patient cités auparavant. Néanmoins, avec le développement technologique et l'avènement d'outils de calcul de plus en plus performant, nous assistons ces dernières années au développement de nouveaux outils de diagnostic de la maladie basés sur la discipline du traitement du signal [106, 107]. En effet, plusieurs approches ont été rapportées dans la littérature pour le diagnostic de la MP en termes de détection et de classification. Nous pouvons citer : l'évaluation de la marche en utilisant l'enregistrement par intervalles de foulée [17, 18], l'écriture manuscrite [16],

l'accélérométrie [66], l'analyse de voix [21] et l'analyse de la marche à l'aide des enregistrements EMG de surface (EMGs) [25, 26, 27] sur lesquels nous reviendrons ultérieurement. En effet, nous allons aborder dans cette thèse, à travers le signal EMGs, le problème de contrôle postural caractérisé partiellement par les membres inférieurs. Pour cela, nous allons présenter dans la partie suivante quelques notions sur la posture et le contrôle postural.

1.3.2 Posture et contrôle postural

Dans ce paragraphe, nous allons définir la posture ainsi que les différentes lois d'équilibre qui la caractérisent.

a). Définition

Définir une posture revient à décrire une attitude, la configuration géométrique du corps à-travers un agencement particulier des segments corporels les uns par rapport aux autres à un instant donné [108, 109]. Par ailleurs, pour maintenir la posture les lois de l'équilibre doivent être respectées.

b). Conditions générales d'équilibre

Nous distinguons deux types de l'équilibre à savoir l'équilibre statique et l'équilibre dynamique [110].

b.1). Équilibre statique

D'un point de vue mécanique, l'équilibre postural (ou équilibre statique) d'un corps solide rigide est caractérisé par [111] :

- Une résultante des forces extérieures nulle ;
- Un moment résultant des forces extérieures nul.

Dans les conditions terrestres et dans le cas où le corps solide est soumis uniquement à deux forces : le poids du solide, appliqué au centre de gravité (COG), et la force de réaction du support, appliquée au centre des pressions (COP) de la surface de sustentation, l'équilibre postural suppose deux conditions [111] :

- La résultante des forces de réaction du support et le poids du sujet doivent être égaux et opposés ;
- Les points d'application de ces deux forces doivent se trouver sur une même verticale, en l'occurrence la ligne de gravité.

Cependant, ces deux conditions ne sont pas vérifiées dans la pratique. En effet, chez l'être humain en station debout l'équilibre postural statique au sens

strict n'existe pas, car le corps oscille en permanence [112]. Le maintien de l'équilibre postural nécessite l'intervention de force d'origines musculaires et ligamentaires [113, 114]. De ce fait, il est assimilé à un phénomène physiologique actif résultant de réactions de soutien antigravitaires.

b.2). Équilibre Dynamique

La loi de la dynamique impose que la résultante et /ou le moment résultant des forces extérieures appliqués au système ne soient plus nuls [115, 116]. En effet, au cours du mouvement et tout particulièrement lors de l'initiation de la marche, une dissociation entre *COP* et *COG* a nécessairement lieu. Ces deux points présentent ainsi des trajectoires différentes [111].

Lors de la marche, le corps peut être associé, comme dans la posture, à un système oscillant. En effet, le mouvement périodique de la marche caractérisé par la fréquence des pas induit des mouvements oscillants du corps nécessitant un contrôle postural. La fréquence des oscillations dans le plan sagittal est deux fois plus élevée que dans le plan frontal induisant une amplitude d'oscillations entre *COG* et *COP* dans le plan sagittal inférieur à celle du plan frontal [117] (voir la Fig.1.1). C'est sur cette configuration d'équilibre postural initial que le mouve-




FIGURE 1.1 – Plans du corps humain [1].

ment survient. Pour que l'homme puisse se mouvoir et se déplacer, il est donc nécessaire que le milieu externe offre un support sur lequel il puisse prendre appui

et créer les forces de réaction qui permettront la rupture de l'équilibre postural. Une telle nécessité résulte des lois de la mécanique [111] :

- La loi de la résultante dynamique ;
- La loi du moment cinétique.

Ces lois nous permettent de relier à chaque instant les forces et le mouvement. Dans les travaux de cette thèse, nous allons exploiter des enregistrements électromyographiques des membres inférieures caractérisant la marche des sujets sains et des patients atteints de la MP. Ces enregistrements sont réalisés dans le cadre du projet ECOTECH [28]. A cet effet, nous allons présenter dans le prochain paragraphe un aperçu sur la physiologie neuromusculaire. Nous insisterons tout particulièrement sur les notions d'unité motrice, de potentiels d'action et de train de potentiels d'action.

1.4 Physiologie neuro-musculaire du muscle

L'EMG explore le système nerveux périphérique, qui comprend la moelle épinière, les nerfs périphériques et les muscles. Le signal EMG est un moyen de mesure de l'activité électrique de muscle. Toutefois, avant d'aborder ce type de signaux, nous allons définir la physiologie du muscle et sa composition.

1.4.1 Muscle

Les muscles sont des tissus du corps humain capables de se contracter et de produire un mouvement, composés principalement de fibres musculaires. Ils assurent notamment le déplacement des segments corporels, la contraction cardiaque ou encore les fonctions de vasoconstriction/vasodilatation. Un tissu musculaire est composé de cellules musculaires appelées myocytes ou fibres musculaires (*FM*). A cet effet, nous distinguons trois types de muscle [118] :

- **Muscle lisse** ou muscle involontaire qui se trouve dans les parois des structures et des organes telles que l'œsophage, l'estomac, les intestins, les bronches, l'utérus, l'urètre, la vessie, les vaisseaux sanguins et les muscles érecteurs du poil ;
- **Muscle strié cardiaque (myocarde)** ou muscle autonome, dont la structure est proche de celle du muscle squelettique. Le myocarde se retrouve uniquement dans le cœur ;
- **Muscles striés squelettiques (contractions volontaires)** : Les muscles squelettiques

sont les muscles sous contrôle volontaire du système nerveux central. Le corps humain comprend environ 600 muscles présents chez tous les individus sains. Parmi les muscles striés squelettiques les plus connus, nous pouvons citer les biceps, les quadriceps ou les abdominaux. Ils sont attachés par à l'os via des tendons et permettent des mouvements volontaires tels que la locomotion et le maintien de la posture.

toute la suite, nous allons nous intéresser aux muscles striés et le contrôle d'une commande volontaire. pour cela, nous abordons maintenant et de manière assez succincte l'anatomie et la physiologie de ce type de muscle.

1.4.2 Anatomie et physiologie du muscle squelettique

Le muscle squelettique est formé de multiples faisceaux, composés d'un grand nombre d'éléments de base, qui est la cellule allongée appelée FM. Le nombre de ces FM varie de quelques centaines jusqu'à plusieurs centaines de milliers, Ce nombre dépend de la taille du muscle considéré et de sa spécialisation fonctionnelle. La FM de l'être humain a une longueur pouvant varier de $100 \mu m$ à $30 cm$ et un diamètre variant de 10 à $100 \mu m$ [2].

Les muscles squelettiques sont attachés au squelette via des tendons ou des fascias, permettant la liaison mécanique entre les fibres et les OS. Chaque FM est composée d'une membrane cellulaire appelée sarcolemme et de myofibrilles à l'intérieur réunies en faisceaux (voir Fig.1.2). Ces myofibrilles sont formées d'unités contractiles, nommées sarcomères, disposées en série. L'actine et la myosine sont à la base de la contractilité des sarcomères qui sont constitués par un assemblage de filaments parallèles d'actine (filaments minces) et de myosine-II (filaments épais) [119].

La FM est innervée par un moto-neurone (MN) dont le corps cellulaire est localisé dans la corne ventrale de la moelle épinière. Les FM sont liées au motoneurone par une jonction appelée jonction neuromusculaire (JNM). Cette dernière assure la transmission de la commande motrice du système nerveux central vers la périphérie via un signal électrique, appelé potentiel d'action (PA). Ce dernier se propage le long de la membrane du MN puis le long du sarcolemme qui s'invagine régulièrement pour former des tubules transverses (TT) le long de la FM. Au niveau des TT, le signal électrique est internalisé et transformé en signal chimique (couplage électromécanique) qui déclenchera la contraction des sarcomères. On distingue trois types de fibre musculaire, présentées comme suit [119] :

- **Fibre de type I** : appelée aussi à contraction lente ou fibres rouges. Elles forment beaucoup plus les muscles rouges. Ces fibres sont peu fatigables, utilisées lors des

exercices peu puissants et prolongées (maintien de la posture). De petits diamètre et très vascularisées ;

- **Fibre de type II** : appelée aussi à contraction rapide ou fibre blanches. Elles sont localisées dans les muscles pâles, très fatigables, utilisées les exercices brefs mais intenses. De grand diamètre, peu vascularisées ;
- **Fibre de type IIa** : ce sont des fibres intermédiaires dont le pourcentage varie selon les muscles de l'organisme et selon l'individu.




FIGURE 1.2 – vue en coupe d'un squelette [2].

1.4.3 Unité motrice

L'unité motrice (UM) est l'unité fonctionnelle élémentaire qui produit le mouvement. Elle est formée principalement par [120, 119] :

- Le corps d'une cellule nerveuse motrice (neurone moteur ou moto-neurone) situé dans la moelle épinière ;
- L'axone est représenté le prolongement de moto-neurone. Ce dernier chemine dans le nerf périphérique ;
- Ensemble des FM que le MN innerve.

Les FM d'une UM varient en fonction du muscle étudié et de son type [121] : d'une dizaine pour le droit externe à 2000 environ pour le quadriceps fémoral. Ce nombre est ainsi lié au rôle fonctionnel du muscle et à la capacité fonctionnelle de ces fibres, dont la contraction peut être lente ou rapide : les UM de type lent comportent généralement un plus petit nombre de FM que celles de type rapide. En outre, chaque UM est composée de fibres d'un seul type. La distribution des fibres au sein de l'UM est reportée comme étant aléatoire sur une région ellipsoïdale [121] (voir Fig.1.3). La régulation de la force musculaire au sein du




FIGURE 1.3 – vue d'une unité motrice [3].

muscle est effectuée au moyen de deux modes opératoires :

1. un premier mode au niveau de l'UM par la modulation de la fréquence de décharge (FD), également appelée ¹ *recrutement temporel* [122] ;
2. un second mode au niveau musculaire par la modulation du nombre d'UM recrutées ou *recrutement spatial*.

1. nous reviendrons ultérieurement sur la définition mathématique de la FD.

1.4.4 Potentiel d'action

Le potentiel d'action (*PA*) est un phénomène électrique, caractérisé principalement par deux propriétés [120, 119] :

- lorsqu'il se développe, il le fait d'une manière *tout ou rien* ;
- lorsqu'il est émis en un point, il se propage sans atténuation.

En particulier, le *PA* se présente sous la forme d'une onde qui se déroule ou s'exécute trois phases :

- **Phase de dé-polarisation** : cette phase dure de 2 à 3 *ms*, connue par une inversion de la polarité membranaire et donne le *PA* (membrane chargée négativement à l'extérieur et positivement à l'intérieur). Ce phénomène est produit par le mouvement transmembranaire d'ions [123], entrée d'ions sodium (Na^+) suivie d'une sortie d'ions potassium (K^+) à travers l'ouverture de canaux ioniques électro-sensibles spécifiques à ces ions. Cette inversion de polarité est un phénomène local, ce qui induit une différence de répartition de charge entre la portion de membrane dépolarisée et celles limitrophes de polarité inverse puisque ces dernières sont au repos ;
- **Phase de repolarisation** : cette phase est également rapide (comprise entre 1 et 3 *ms* en moyenne pour la plupart des cellules excitables), le potentiel de membrane revenant alors vers son niveau initial ;
- **Phase d'hyperpolarisation** : souvent, à la fin de la phase de la repolarisation, le potentiel de membrane atteint une valeur plus négative que le niveau du potentiel de repos : c'est la phase d'hyperpolarisation. Le retour à la valeur de potentiel initiale se fait alors selon un décours relativement lent (quelques millisecondes).

Les trois phases de génération du *PA* sont présentées dans la Fig.1.4. Une FM n'est jamais activée seule mais avec un ensemble des FM appartenant à la même UM, [124]. Les *PA* qui se propagent le long des fibres créent une activité électrique qui peut être détectée aussi bien par les techniques invasive ou non. En fait, Le potentiel détecté reflétant les activités de toutes les fibres, est une combinaison de tous les *PA* des fibres singulières (*PAFS*) appartenant à une même UM et fournissant ainsi le *PA* de l'UM (*PAUM*). La Fig.1.5 représente le *PAUM* comme la résultante des potentiels générés par chacune de ses fibres. Chaque FM à l'intérieur de l'UM (sur le côté gauche de la Fig.1.5) contribue au potentiel détecté (sur la droite de la Fig.1.5). Ainsi, le *PAUM* joue un rôle important dans l'analyse et la compréhension des propriétés des signaux myoélectriques et enfin, le *PAUM* constitue la base du signal EMG.




FIGURE 1.4 – Phases du potentiel d'action.

1.4.5 Train de potentiels d'action et recrutement temporel

Comme un PA ne permet pas une contraction effective au niveau du muscle, il est alors nécessaire pour le système neuromusculaire de générer des trains de PAUM (voir Fig.1.6) qui favoriseront la fusion des réponses mécaniques élémentaires (aussi appelées secousses). Cette fusion sera d'autant plus importante que les TPAUM seront denses et donc réalisés à des FD plus élevées. La régulation de la tension mécanique au niveau de l'UM se réalisera donc en modulant ces FD et la force augmentera avec le taux de décharge [120].

Par ailleurs, il est important de noter que, la stratégie de recrutement des UM dépend également de la fatigue musculaire [125, 126] et des phénomènes de synchronisation de FD entre UM apparaissent modifiant alors la force appliquée.

La FD est définie par l'inverse de la moyenne des intervalle inter-décharge (IID), varie de quelques décharges par seconde à, dans un cas extrême sur l'adducteur du pouce, cinquante décharges par seconde [127]. La FD instantanée de ce même muscle pouvant atteindre cent




FIGURE 1.5 – Génération du potentiel d'action [4].




FIGURE 1.6 – Exemple de train de potentiels d'action d'unité motrice [5].

cinquante décharges par seconde.

Dans le cas d'une contraction isotonique (tension mécanique stable) et isométrique (longueur musculaire fixe) la FD moyenne d'UM est constante, mais nous observons que l'IID subit une "gigue" temporelle aléatoire (en anglais : jitter) [128, 129]. Il est important de ne pas la confondre avec la "gigue" neuromusculaire provoquée par un retard aléatoire du temps de transmission du PA dans les jonctions neuromusculaires composant l'UM [130], qui induit une légère déformation du PAUM entre deux décharges. Nous faisons référence ici à la gigue produite par le MN lui-même. Clamann[129] modélise les IID par une distribution gaussienne tronquée.

1.4.6 Recrutement spatial des Unités Motrices

La seconde modalité de recrutement des UM est spatiale et joue sur le nombre d'UM actives pour réguler la force. Le principe de la taille de Henneman [131, 132, 2, 133] énonce, dans le cas d'une montée de force progressive (voir Fig.1.7), que l'ordre de recrutement des UM est lié à la taille de leur MN, les plus petites unités étant recrutées en premier. Par ailleurs, l'évolution du recrutement des UM dépend du muscle étudié. Par exemple, il a été rapporté dans [2] que les petits muscles recrutaient la grande majorité de leurs UM dès 50% de la contraction maximale volontaire (%CMV) alors que pour de plus gros muscles, le recrutement spatial restait prépondérant jusqu'à 70 %CMV.




FIGURE 1.7 – [6] (a) le signal EMG et (b) courbe de force pendant une contraction musculaire isométrique.

1.5 Signal EMG

ce paragraphe est consacré essentiellement au signal EMG. Nous y présentons les techniques de mesure de ce type de signaux. Par ailleurs, une attention toute particulière est accordée à la modélisation mathématique de ces signaux ainsi qu'aux bruits les entachant.

1.5.1 Définition

EMG est l'enregistrement graphique de l'activité électrique d'un nerf et d'un muscle au repos, excité ou se contractant volontairement. La forme de l'onde enregistrée peut être évaluée par son amplitude (exprimée en microvolts), sa durée, son nombre de phases et sa polarité [119]. Cette technique est utilisée dans le but de diagnostiquer les pathologies neuromusculaires, en cas des trouble nerveux comme une neuropathie périphérique, mais

aussi en physiologie de l'exercice pour l'évaluation de la fatigue musculaire et l'étude comparative des muscles impliqués dans la locomotion [119].

1.5.2 Mesure du signal électromyographique

Le PA émis par les FM appartenant aux UM recrutées émettent un champ électrostatique mesurable à distance. La mesure et l'identification des signaux (PAUM) sont complexes [5]. Deux principales techniques de mesure en fonction de la méthode et du domaine d'étude existent [134, 135] :

- **Méthode invasive** : Chaque décharge d'une UM donne lieu à un PAUM et si l'activité se situe dans la zone de captation de l'électrode implantée, un signal sera enregistré. D'une décharge à l'autre, la forme d'un PAUM est relativement constante lorsque les relations spatiales entre l'électrode d'enregistrement et l'UM demeurent fixes. Dans l'examen invasif, on utilise des aiguilles ou fils fins implantés dans le muscle généralement de diamètre $0,25 \mu m$. Cet examen précis, fournit un signal peu bruité car proche de la source d'émissions (fibres musculaires) et avec un nombre d'UM mesurés assez faible ce qui permet une bonne identification des PAUM. C'est un examen de choix pour l'étude des muscles profonds. Pour la méthode invasive deux types d'électrodes :
 - Électrodes intramusculaires de type aiguille utilisées en clinique pour préciser le diagnostic ;
 - Électrodes intramusculaires implantées : ce sont des câbles minces insérés dans les fibres. Ils sont avant tout utilisés en recherche. Cependant ce type d'examen est très douloureux et ne peut pas être généralisé au muscle entier.
- **Méthode non invasive (de surface)** : L'EMG de surface permet d'analyser le système neuromusculaire. Cette méthode est dite de surface car les électrodes qui recueillent le signal sont placées directement sur la peau au regard du muscle à étudier. C'est un examen non invasif qui utilise des électrodes auto-adhésives. Il représente la méthode la plus courante et un examen de choix pour les muscles superficiels. Il est très souvent utilisé pour l'étude du mouvement. Cet examen, utilisé aussi par ailleurs, nécessite une rigueur de mesures et de préparation. Celà étant, l'éloignement de l'électrode au regard des fibres émettrices de signaux réduit considérablement l'amplitude du signal et diminue ainsi le rapport signal sur bruit (*RSB*). De plus, bien qu'offrant une vue plus globale du muscle, nous obser-

vons en général, un mélange très important de PAUM, communément appelé signal EMG de surface, qui complexifie leur identification. La Fig.1.8 illustre le processus de génération de ce type de signaux [136, 135].

1.5.3 Modèles analytiques du signal EMG

Il existe plusieurs modèles dans la littérature pour représenter le signal EMG. Un des modèles du signal EMG [134, 64] est donné par l'équation (1.1) :

$$x(n) = \sum_{r=0}^{N-1} h(r)e(n-r) + w(n) \quad (1.1)$$

où : $x(n)$ représente le signal EMG, $e(n)$ représente les impulsions (en anglais : firing impulse), $h(r)$ est le PAUM, $w(n)$ le est bruit additif supposé gaussien de moyenne nulle et enfin N est le nombre des impulsions des UM.

Un autre modèle existe pour représenter les signaux EMG. Ce dernier couramment adopté, et qui le sera dans toute la suite de cette thèse, est basé sur l'utilisation des TPAUM. En effet, le signal EMG peut alors être décrit comme étant la somme de tous les trains d'impulsion générés par chaque UM [5] :

$$x_i(t) = \sum_j TPAUM_{i,j}(t) + n_i(t) \quad (1.2)$$

où : $x_i(t)$ est le signal EMG mesuré par l'électrode i , $n_i(t)$ représente le bruit contaminant le capteur de mesure. Quant au TPAUM, ce dernier peut être modélisé à son tour par la somme d'impulsions arrivant à différentes instants [5] :

$$TPAUM_{i,j}(t) = \sum_{k \in \mathbb{Z}} h_{i,j}(t - \mathbb{I}_{k,j}) \quad (1.3)$$

où j est l'indice de l'UM considérée, $\mathbb{I}_{k,j}$ représente l'instant d'arrivée du PAUM d'indice k de l'UM j , et $h_{i,j}$ est le PAUM de l'UM j mesuré par le capteur i . Enfin, le PAUM possède une distribution spatiale et par conséquent la mesure dépend naturellement de la localisation de l'électrode.

Cela étant, l'équation (1.3) peut être réécrite autrement en introduisant la notion de

train d'impulsion nerveux (*TIN*) noté $s_j(t)$. Ainsi [5, 135] :

$$TPAUM = h_{i,j}(t) \otimes s_j(t) \quad (1.4)$$

où le symbole \otimes est l'opérateur de convolution et le *TIN* est défini par :

$$s_j(t) = \sum_{k \in \mathbb{Z}} \delta(t - \mathbb{I}_{k,j}) \quad (1.5)$$

Nous soulignons au passage que le *TIN* est indépendant du point de mesure. Il correspond aux impulsions brutes, modélisées par des impulsions de Dirac, générées par le MN. Par ailleurs, en injectant les équations (1.5) et (1.4) dans l'équation (1.2), nous obtenons :

$$x_i(t) = \sum_j \left(h_{i,j}(t) \otimes \sum_{k \in \mathbb{Z}} \delta(t - \mathbb{I}_{k,j}) \right) + n_i(t) \quad (1.6)$$

Il est largement admis dans la littérature que le TPAUM n'est pas strictement périodique (il est cyclo-stationnaire [5]). Lors d'une contraction isométrique à force constante et sans fatigue, l'IID précédemment introduit est en moyenne constante avec un délai additif aléatoire. Le modèle d'IID peut s'écrire [5] :

$$\mathbb{I}_{k,j} = kT_j + \tau_{k,j} \quad (1.7)$$

où T_i désigne la période moyenne de décharge de l'UM i , définie comme étant l'inverse de la FD et $\tau_{k,j}$ est une gigue temporelle aléatoire.

A partir de l'équation (1.7), on peut définir deux modèles de giges $\tau_{k,j}$:

- **Modèle simplifié** : dans ce modèle la gigue $\tau_{k,j}$ est caractérisée par une variable aléatoire stationnaire indépendante et identiquement distribuée (*iid*) de distribution Gaussienne. L'équation (1.6) s'écrit alors :

$$x_i(t) = \sum_j \left(h_{i,j}(t) \otimes \sum_{k \in \mathbb{Z}} \delta(t - kT_j + \tau_{k,j}) \right) + n_i(t) \quad (1.8)$$

- **Modèle dit réaliste parce qu'il correspond au mieux aux observations de Clamman [129]** : dans ce modèle la variation de l'IID est caractérisée par une variation aléatoire *iid* de distribution Gaussienne [129]. Dans ce cas, on considère $\mathbb{I}_{k,j} - \mathbb{I}_{k-1,j} = T_j + \tau_{k,j} - \tau_{k-1,j}$ comme une distribution gaussienne ce qui fait que la gigue est indé-

pendante de la valeur précédente, définie comme suit [5] :

$$\tau_{k,j} = \tau_{k-1,j} + \varepsilon_{k,j} = \sum_{p=0}^k \varepsilon_{p,j} \quad (1.9)$$

où $\varepsilon_{k,j}$ est une variable *iid* de distribution Gaussienne de moyenne nulle. Par convention on pose $\tau_{0,j} = \varepsilon_{0,j}$. En conséquence $\tau_{k,j}$ est une marche aléatoire. L'équation (1.6) s'écrit finalement :

$$x_i(t) = \sum_j \left(h_{i,j}(t) \otimes \sum_{k \in \mathbb{Z}} \delta \left(t - kT_j + \sum_{p=0}^k \varepsilon_{p,j} \right) \right) + n_i(t) \quad (1.10)$$

A partir cette équation, nous pouvons simuler le signal EMG en générant indépendamment les activités de chaque *UM* puis en réalisant un mélange de celles-ci.




FIGURE 1.8 – Schémas synoptique de génération du signal EMG.

Une autre manière courante et simple existe pour simuler le signal EMG à partir de

modèle de densité spectrale de puissance d'EMG. Sheedyk et al [137, 5] proposent le modèle suivant :

$$DSP_{EMG}(f) = k \cdot \frac{f_H^4 \cdot f^2}{(f^2 + f_L^2) \cdot (f^2 + f_H^2)^2} \quad (1.11)$$

où f_L et f_H représentent respectivement les valeurs limites de fréquences basses et hautes du spectre EMG, k est un facteur d'amplitude. Le signal EMG peut alors être simulé par un bruit blanc filtré par la racine carrée de l'équation (1.11).

1.5.4 Bruits affectant le signal EMG

L'amplitude du signal EMG varie entre 0-10 mV (+5 à -5) [134, 6]. Les signaux EMG sont généralement affectés par plusieurs types de bruit à savoir [64] :

- Bruit électronique (en anglais : Inherent Noise in the Electrode) : Tous les équipements électronique génèrent du bruit qui peut être réduit en utilisant de composants électroniques de bonne qualité [134]. La fréquence de ce bruit varie entre milliers d'hertz.
- Bruit dû aux mouvements (en anglais : Movement Artifact) : Ce bruit est dû aux mouvements des câbles de connexion entre électrode et l'amplificateur. L'interface entre la surface de détection de l'électrode et la peau crée aussi de l'artefact [134]. L'ordre de grandeur de ce bruit varie de 0 à 10 Hz [64].
- Bruit Électromagnétique : Le corps humain se comporte comme une antenne, il émet en continuité les radiations magnétiques et électriques ce qui génère du bruit électromagnétique. L'amplitude de ce bruit est trois fois plus grande que le signal désiré [64]. Nous pouvons éliminer ce bruit par l'utilisation d'un filtre passe haut ou par la méthode PLI (en anglais : Power Line Interference) [64].
- Bruit Gross Talk : L'enregistrement du signal EMG indésirable du groupe musculaire est généralement appelé Gross Talk . Ce dernier affecte le signal désiré ce qui induit une mauvaise interprétation médicale. Nous pouvons réduire ce bruit soit par le choix de la taille de l'électrode, soit par le choix de la distance inter électrode [64, 6].
- Bruit interne (en anglais ; Internal Noise) : C'est un bruit qui affecte la qualité de signal, il est dû aux facteurs anatomiques, biochimiques, et physiologiques. Ces facteurs sont le nombre de FM, ses positions, ainsi que l'épaisseur de la peau. Nous pouvons le réduire en utilisant un filtre passe haut spatial [64].
- Instabilité inhérente du signal (en anglais Inherent Instability of signal) : Le signal

EMG est de nature quasi-aléatoire où la partie de 0 à 20 Hz est généralement instable à cause du nombre d'impulsions des UM (en anglais firing rate of the motorunits) [134, 64]

- Artefact de l'électrocardiogramme (ECG) : L'activité électrique du cœur interfere généralement avec le signal EMG de surface. Nous pouvons éliminer ce type de bruit en utilisant un filtrage passe haut à 100 Hz.

1.6 Conclusion

Nous avons vu à travers ce chapitre des connaissances de base sur : la maladie de Parkinson, la physiologie des muscles et l'électromyographie (EMG) notamment le signal EMG de surface. Nous avons aussi vu l'intérêt du signal EMG comme un moyen utile dans l'analyse et le diagnostic des problèmes neurophysiologiques. Deux approches de segmentation du signal EMGs feront l'objet de chapitre 2. Ces deux approches seront utilisées pour détecter les bouffées d'activité EMG (début(onset)/fin(offset)). Ces dernières seront ultérieurement utilisées dans le diagnostic de la MP.

CHAPITRE 2

DÉTECTION DE L'ACTIVITÉ ÉLECTROMYOGRAPHIQUE

Contents

2.1	Introduction	36
2.2	Formulation du problème	40
2.3	Principales méthodes de détection d'activité EMG	40
2.3.1	Méthode à double seuil (ou en anglais Double-threshold)	40
2.3.2	Méthode des ondelettes (en anglais Wavelet-based method)	41
2.3.3	Technique TKEO	41
2.3.4	Méthode basée sur l'entropie d'échantillon (en anglais Sample Entropy)	42
2.3.5	Méthode de la racine quadratique moyenne (en anglais RMS based method)	42
2.4	Méthode : ALED et ses variantes : Approches non supervisées	43
2.4.1	Principales étapes de la méthode ALED	43
2.4.2	Méthode ALED modifiée : M-ALED	45
2.4.3	Méthode FM-ALED	46
2.4.4	Méthode OM-ALED	50
2.5	Méthode supervisée : basée sur l'utilisation des HMM	52
2.5.1	Modélisation HMM du signal EMG	53
2.5.2	Modèles HMM	55
2.5.3	Système de segmentation basé sur la modélisation HMM	56
2.5.4	Extraction des attributs basée sur la transformée en ondelettes	57
2.6	Résultats et discussions	59
2.6.1	Outils d'analyse de performances	60
2.6.2	Paramètres des simulations des méthodes dans l'état de l'art	61
2.6.3	Performances des techniques ALED	62

2.6.4	Performances de l'approche HMM	66
2.6.5	Comparaison des performances avec quelques méthodes de segmentation	72
2.7	Discussion	75
2.8	Conclusion	77

2.1 Introduction

D'une manière générale, la théorie de la détection a pour principaux objectifs la détection d'un signal noyé dans un bruit et l'extraction des informations relatives à la présence ou à l'absence de certains événements d'intérêt. Elle trouve ses applications dans plusieurs domaines notamment : radar, télécommunications, traitement d'images, traitement de la parole, sismologie et biomédecine [138].

La détection précise des événements discrets dans le signal EMG est une tâche très importante dans l'analyse du système locomoteur. A titre d'exemple, le changement de la phase dans une activité quelconque est directement associé à une initiation rapide de la réponse moteur. Dans ce chapitre, nous allons nous intéresser à la surveillance et au contrôle de l'activité électromyographique à travers la détection de bouffés d'activités EMG (onset/offset).

A ce titre de nombreux travaux de recherche ont été menés dans le domaine de la détection et la surveillance de l'activité EMG. Dans [29, 30, 31, 32, 33, 34], une attention particulière est principalement accordée à la détection du premier onset. Dans [35, 36, 37, 38, 39, 40, 41, 42, 43], les travaux de recherche ont porté plus généralement sur le suivi complet de l'activité EMG (onset/offset). Cela étant, toutes ces méthodes peuvent être catégorisées en méthodes non supervisées et méthodes supervisées. La première catégorie de méthodes englobe en son sein de nombreuses techniques. Nous pouvons citer : les méthodes à simple et double seuillage [35, 44], les méthodes basées sur les décisions statistiques [30, 31, 45, 46], les méthodes probabilistes [43], les méthodes basées sur la transformée en ondelettes [37], les méthodes non-linéaires basées sur l'opérateur énergie [47, 48, 33] et enfin les méthodes basées sur le clustering [49]. La seconde catégorie de méthodes, dites supervisées, nécessite quant à elle une phase d'apprentissage basée sur la segmentation d'une part des zones d'activité EMG et d'autre part des zones de non activité EMG [50, 51].

Ce chapitre, nous allons aborder le problème de la détection et de la surveillance de l'activité EMG, en proposant deux nouvelles approches :

- 1- La première, appartenant aux méthodes dites non supervisées, est basée sur l'association de deux techniques empruntées respectivement au traitement du signal radar et au traitement de la parole. Les deux techniques, en question, se sont révélées être des détecteurs hautement efficaces. Il s'agit de la méthode dite « taux de probabilité de fausse alarme constant » (en anglais constant false alarm rate CFAR) [139] et de la méthode dite « détecteur d'énergie linéaire adaptatif » (en anglais adaptive

linear energy detector ALED); en réalité une version plutôt modifiée de ALED que nous avons développée et notée M-ALED et sur laquelle nous reviendrons ultérieurement. Les performances de l'association de ces deux techniques sont évaluées via des enregistrements de signaux EMG réels et synthétiques.

Cette association n'est pas fortuite. En effet, elle est adoptée en raison en grande partie de la similitude de la problématique étudiée avec celles rencontrées dans les systèmes radar et le traitement de la parole, La technique CFAR consiste en la maximisation de la probabilité de détection tout en contrôlant la probabilité de fausse alarme [139]. Elle est asymptotiquement équivalente au test du rapport de vraisemblance généralisé où les paramètres sont inconnus et estimés en utilisant l'approche du maximum de vraisemblance. Par conséquent, la technique CFAR est asymptotiquement optimal en supposant que le modèle statistique considéré est connu et représente correctement les données. En revanche, lorsque celles-ci sont non stationnaires et que leur modèle statistique est complexe et mal connu, une solution alternative a été envisagée dans [140]. Celle-ci est basée sur la technique ALED et a été utilisée dans la détection d'activité vocale pour identifier les segments de parole et de non-parole dans un signal audio. Enfin, la technique ALED a été utilisée dans d'autres applications telles que : les systèmes VoIP (Voice over Internet Protocol) [141], la téléphonie mains libres, la téléconférence audio et la reconnaissance vocale [142].

- 2- La deuxième approche, appartenant aux méthodes dites supervisées, est basée sur l'association des modèles de Markov cachés (en anglais Hidden Markov models HMM) et de la transformée discrète en ondelettes (en anglais discret wavelet transform DWT). L'approche proposée est réalisée en deux phases principales. La première est une phase d'apprentissage, qui sert à la construction des classes (région d'activité EMG et région de non activité EMG), en modélisant les signaux EMG par des HMM. La deuxième phase concerne le test et la validation et a pour rôle d'évaluer les performances du système à l'aide de la base de données de test du projet ECOTECH [28]. Les deux phases nécessitent l'étape d'extraction des caractéristiques sous forme de descripteurs.

Les HMM ont été largement étudiés et utilisés dans la reconnaissance automatique de la parole. Récemment, cette technique a été utilisée avec un grand succès pour les systèmes de surveillance et de diagnostic médicaux tels que la classification de signaux ECG [143], la classification de signaux EEG [144] et l'identification des ap-

pareils électriques [145]. Les HMM ont été également utilisée pour le diagnostic de la maladie de Parkinson (MP) en utilisant les données de marche brutes [146]. Par ailleurs, ceux-ci ont été combinés avec le méthode des machines à vecteurs de support (en anglais support vectors machines SVM) pour la reconnaissance des gestes à l'aide de signaux EMG dans le but de contrôler les prothèses des membres supérieurs [147]. Dans [148], les auteurs ont combiné les HMM et le perceptron multi-couches (en anglais multilayer perceptron MLP) pour la reconnaissance d'émotions à partir de signaux EMG.

L'objectif principal de ce chapitre est de présenter les méthodes développées pour la détection de bouffées d'activité EMG, dans le contexte facile (contrôlé) et dans le contexte difficile (non contrôlé) où le signal acquis est parfois de qualité médiocre (présence de bruit d'artefact [149]), et où les bruits, qui affectent le signal utile, sont parfois non stationnaires comme cela est le cas de l'activité EMG des Parkinsoniens. Aussi, les principaux résultats et contributions de ce chapitre peuvent être énumérés comme suit :

1. Nous avons exploré les spécificités du signal EMG et présenté les différents bruits susceptibles de l'affecter. Par ailleurs, nous avons analysé les forces et les faiblesses du détecteur ALED qui nous ont permis de proposer, pour la première fois à notre connaissance, une version modifiée de ALED, notée M-ALED, afin d'améliorer la robustesse du détecteur vis à vis du bruit et des interférences. Cela s'est traduit par une réduction de la probabilité d'erreur de détection supérieure à 20% par rapport à la méthode ALED originale. Il faut souligner que ce résultat n'a été rendu possible que grâce à la fois d'une part
 - 1.1. à la réalisation d'un pré-conditionnement du signal EMG en utilisant l'opérateur d'énergie de Teager-Kaiser (en anglais Teager-Kaiser Energy Operator TKEO) qui permet d'améliorer le rapport signal sur bruit (en anglais signal to noise ratio SNR) [32]
 - 1.2. à l'utilisation des statistiques d'ordre qui permettent, en présence d'impulsivité du signal, d'améliorer l'estimation de l'énergie.
2. La plupart des méthodes de détection d'activité EMG supposent la variance du bruit de mesure (communément appelée ligne de base du signal) a priori connue ou préalablement estimée à partir d'un enregistrement en l'absence de toute activité EMG. Toutefois, dans certains contextes défavorables où une telle hypothèse n'est plus valable (par exemple dans un contexte non contrôlé), la proposition d'une solution adaptée au contexte s'avère être indispensable. Dans ce but, nous allons introduire

une méthode efficace basée sur les statistiques d'ordre pour l'estimation de la première variance du bruit. Cette méthode a été incorporée dans le détecteur M-ALED pour donner lieu à une nouvelle méthode de détection d'activité EMG notée OM-ALED (la lettre "O" est adoptée ici pour signifier statistique d'ordre).

3. Il est important de noter que La détection, par les méthodes dites ALED, est réalisée à l'échelon de la trame : c'est à dire que nous détectons la trame où se produit le début ou la fin de l'activité EMG. Cet aspect constitue, bien évidemment, une limitation des dites méthodes puisqu'il est plutôt nécessaire de réaliser une détection à l'échelon de l'échantillon. Ceci peut être réalisé en ayant recours à une étape supplémentaire où un affinage est opéré à l'intérieur de la trame (postérieurement aux traitements ALED). Ce faisant, les performances, d'estimation des instants de début (onset) et de fin (offset) de l'activité EMG, se trouveront, alors, grandement améliorées. Dans ce but, nous proposons d'associer la technique CFAR aux méthodes dites ALED. Il s'agit alors principalement de FM-ALED et FOM-ALED (la lettre "F" est adoptée ici pour signifier affinage ou "Fine" en anglais).
4. Nous allons proposer une méthode supervisée basée sur l'association des HMM à la DWT. Nous avons exploité le principal avantage de la décomposition en ondelettes pour extraire les informations impulsives des potentiels d'action des unités motrices (PAUM). Puis, nous avons adapté la modélisation HMM à la segmentation automatique du signal EMG.
5. Enfin, sur la base de signaux EMG de surface synthétiques et réels, nous effectuons une évaluation des performances, des approches proposées, et nous les comparons avec quelques méthodes qui existent dans la littérature.

Le reste de ce chapitre est organisé comme suit :

- La section 2.2 est consacrée à la formulation du problème.
- La section 2.3 est dédiée à la revue des principales méthodes de détection d'activité EMG existantes.
- La section 2.4 est réservée à présentation de la méthode ALED proposée et ses versions.
- La section 2.4.3 est consacrée à l'adaptation et du développement de la technique CFAR et à son utilisation pour la détection de début d'activité EMG (onset).
- La section 2.6 est réservée à l'analyse et la discussion des performances des techniques proposées.
- La section 2.8 est dédiée aux remarques et conclusions.

2.2 Formulation du problème

Le problème abordé dans ce chapitre traite de l'extraction et l'obtention des informations dans l'activité EMG des muscles, en se basant sur le signal enregistré $x(n)$. Dans ce but, nous considérons N observations $\{x(n)\}_{n=1:N}$ du signal EMG à partir desquelles, nous allons déterminer si un échantillon donné de $x(n)$ contient un signal $s(n)$ noyé dans un bruit aléatoire $w(n)$ (activité EMG) ou non. Dans ce dernier cas, $x(n)$ n'est qu'une manifestation de différents types de bruit (pas d'activité EMG). D'une manière générale, cela correspond au test binaire suivant :

$$\Gamma : \begin{cases} H_0 : & \text{non activité EMG} \\ H_1 : & \text{activité EMG} \end{cases} \quad (2.1)$$

2.3 Principales méthodes de détection d'activité EMG

Nous présentons dans ce paragraphe quelques techniques de détection d'activité EMG les plus couramment utilisées dans la littérature scientifique.

2.3.1 Méthode à double seuil (ou en anglais Double-threshold)

Dans cette méthode, les données EMG sont d'abord blanchies et supposées gaussiennes [35]. Ensuite, la méthode calcule une valeur de seuil pour une probabilité de fausse alarme fixée préalablement en supposant que la variance du bruit est a priori connue. Enfin, l'activité EMG est déclarée si l'énergie instantanée de r parmi m échantillons successifs est supérieure au premier seuil choisi. Nous listons ci dessous les principales étapes de cette méthode :

- Un seuil \mathcal{T} est calculé à partir de la formule de probabilité citée dans [35] correspondant à une P_{fa} choisie (typiquement $P_{fa} = 0.05$) et en utilisant une puissance de bruit connue (ou estimée a priori).
- Une activité EMG est déclarée si le module au carré d'au moins r parmi m échantillons successifs (m est la taille de la fenêtre choisie) est supérieur au seuil \mathcal{T} .
- Une activité musculaire de durée inférieure à $30ms$ n'a aucun effet sur le contrôle du mouvement de l'articulation pendant la démarche, une étape de post-traitement est considérée, consistant à supprimer toutes les transitions d'une durée inférieure à $30ms$.

2.3.2 Méthode des ondelettes (en anglais Wavelet-based method)

Cette méthode est basée sur le principe de détection de la présence des PAUM dans le signal EMG de surface en utilisant la transformé en ondelettes continue (en anglais continuous wavelet transform CWT), avec un choix particulier de la forme d'onde et d'un paramètre d'échelle adéquat [37]. Ensuite, l'amplitude du signal dans le domaine de la transformée en ondelettes est comparée à un seuil égale au niveau de bruit multiplié par une constante. Les étapes de cette méthode sont les suivants [37] :

- Calcul de la fonction

$$\eta(t) = \max_a(CWT(a, t)) \quad (2.2)$$

où a est un paramètre d'échelle choisi en prenant en compte la forme et la durée du PAUM.

- Calcul du niveau de bruit M dans une région de bruit (sans activité EMG) en utilisant $M = \max(\eta(t))$ pour $0 < t < T_{Noise}$, où T_{Noise} définit la région de bruit.
- L'activité EMG est déclarée lorsque $\eta(t)$ est supérieure au seuil $th = \gamma M$ où $\gamma > 1$.

2.3.3 Technique TKEO

De nombreux travaux de recherche ont utilisé la méthode TKEO $\psi(x(n))$ pour conditionner le signal EMG [36, 32, 33, 150]. Le TKEO d'un signal discret est donné par [150] :

$$\psi(x(n)) = x^2(n) - x(n+1)x(n-1) \quad (2.3)$$

En utilisant cette équation, le TKEO permet d'améliorer en sortie le SNR [36].

Cela étant, l'activité EMG est déclarée lorsque le résultat, de la transformation TKEO, dépasse un seuil calculé a priori à partir d'une région où seul le bruit, noté $w(n)$ et supposé gaussien, existe (c'est à dire à partir d'une région où aucune activité EMG n'est constatée) [150] :

$$\psi(x(n)) > th : \text{activité EMG décidée} \quad (2.4)$$

où le seuil th est donné par [36, 32, 33] :

$$th = \mu_{Noise} + J \cdot \sigma_{Noise} \quad (2.5)$$

où $J > 3$ (de sorte à contrôler la probabilité de fausse alarme) et μ_{Noise} et σ_{Noise} sont respectivement la moyenne et l'écart-type de $\psi(w(n))$ qui représente la transformation TKEO

appliqué dans la région où seul le bruit $w(n)$ existe.

2.3.4 Méthode basée sur l'entropie d'échantillon (en anglais Sample Entropy)

Cette méthode statistique utilise l'entropie comme mesure de la complexité des systèmes dynamiques, décrivant les informations liées à la variabilité du signal. Dans la méthode d'entropie d'échantillons (SampEn) [151, 40], le signal EMG original est segmenté en une série de séquences chevauchant des trames d'analyse. Ensuite, un paramètre de mesure d'entropie est calculé sur chaque trame d'analyse [151, 40].

$$\text{SampEn}(x, m, r) = -\ln(A^m(r)/B^m(r)) \quad (2.6)$$

Dans l'équation (2.6), $B^m(r)$ représente la probabilité que m points de deux séquences sont égaux. Cette probabilité est calculée en comptant le nombre moyen de paires de vecteurs, pour lesquelles la distance est inférieure à la tolérance r . De même, $A^m(r)$ est défini pour une dimension d'intégration de $m + 1$.

où m représente un nombre de points, r représente une distance, $A^m(r)$ est définie pour une dimension d'intégration $m+1$ et enfin $B^m(r)$ représente la probabilité que m points de deux séquences soient égaux [151, 40].

Une fois le paramètre de mesure d'entropie calculé, nous décidons du début de l'activité musculaire lorsque [151, 40] :

$$\text{SampEn}(x, m, r) > \text{seuil prédéfini} \quad (2.7)$$

2.3.5 Méthode de la racine quadratique moyenne (en anglais RMS based method)

La méthode de la racine quadratique moyenne (RMS) a été introduite pour la détection de l'activité musculaire en se basant sur le niveau d'énergie du signal [38]. Tout d'abord, le signal EMG est divisé en trames d'analyse avec une longueur de 15 échantillons afin d'approximer les données brutes par des échantillons réduits correspondant à la valeur moyenne de chaque trame. Puis la valeur absolue du signal échantillonné est calculée pour avoir une estimation du RMS local. L'activité du signal est déclarée lorsque celle-ci (RMS local de trame d'analyse) dépasse un seuil choisi comme 25% à 45% de la valeur RMS

moyenne.

2.4 Méthode : ALED et ses variantes : Approches non supervisées

Dans ce paragraphe, nous commençons par introduire la méthode ALED puis nous présentons, dans un premier temps, deux de ses variantes préalablement citées à savoir M-ALED et OM-ALED. La méthode ALED est basée sur l'analyse de l'énergie d'un signal. Cette approche a été largement utilisée dans la détection d'activité vocale. Cependant, pour prendre en compte la grande variabilité locale de l'amplitude du signal EMG (comme indiqué dans la Fig.2.1), nous divisons le signal EMG en trames non chevauchantes puis nous calculons l'énergie de chacune d'entre elles. Par la suite, pour décider ou non d'une activité EMG, l'énergie du signal est comparée au niveau de puissance du bruit estimé en considérant l'hypothèse d'absence d'activité EMG comme le font les méthodes existantes. Toutefois, contrairement aux autres méthodes, le niveau de bruit est constamment mis à jour et adapté, aux variations du signal non stationnaire, dans l'approche ALED.

Le début d'activité (onset) est déclaré à chaque fois une trame d'absence d'activité EMG est suivie d'une trame d'activité EMG. L'instant de début est choisi comme le moment de début de la trame active. De même, la fin de l'activité est déclarée si une trame d'activité EMG est suivie d'une trame de non activité EMG. L'instant de la fin (offset) est choisi comme le moment de fin de la trame active. Ainsi, pour mieux appréhender la méthode ALED, nous présentons ci-dessous les principales étapes de mise en œuvre de cette approche.

2.4.1 Principales étapes de la méthode ALED

Comme mentionné précédemment, la méthode ALED est basée sur le calcul de niveau d'énergie du signal et procède comme suit [141, 152, 153] :

- Segmentation du signal $x(n)$ en trames d'une taille uniforme de L échantillons. La j^{eme} trame considérée peut être représentée dans le domaine temporel par :

$$Trame_j = \{x((j-1)L+1), x((j-1)L+2), \dots, x((j)L)\} \quad (2.8)$$

- Estimation de la puissance du signal de chaque trame d'analyse par moyennage tem-

porel comme suit :

$$E_j = \frac{1}{L} \sum_{i=(j-1)L+1}^{jL} x^2(i) \quad (2.9)$$

- Évaluation de la variance du bruit initiale en considérant les v premières trames selon l'équation

$$Th = \frac{1}{v} \sum_{j=1}^v E_j \quad (2.10)$$

où Th représente le niveau de la ligne de base.

- Pour chaque nouvelle trame d'analyse, nous appliquons la décision ALED afin de statuer sur son activité EMG.

$$\begin{cases} \text{Si } E_j > \lambda Th, \lambda > 1 & \text{La trame présente une activité EMG} \\ \text{Sinon} & \text{La trame présente une non activité EMG} \end{cases} \quad (2.11)$$

où λTh est la valeur de seuil utilisée dans la prise de décision. Le paramètre λ nous permet de contrôler le compromis entre les probabilités de fausse alarme et celle de détection.

- La valeur de seuil est un paramètre important pour distinguer l'absence d'activité EMG des signaux actifs (contraction myoélectrique). Si aucune décision d'activité n'est pas prise, cette valeur de seuil est utilisée pour réévaluer le seuil de variance de bruit selon la règle de mise à jour suivante :

$$Th_{New} = (1 - P)Th_{Previous} + PTh_{Current} \quad (2.12)$$

où Th_{New} est la valeur actualisée du niveau de puissance de bruit, $Th_{Previous}$ est sa valeur précédente et $Th_{Current}$ est l'estimation de la variance de la trame actuelle. P est le pas index du processus d'adaptation (pris dans l'intervalle $[0, 1]$). Le processus adaptatif, donné dans l'équation (2.12), est appliqué lorsqu'aucune décision d'activité n'est prise. Sinon, si une décision d'activité est prise, l'estimation de la variance du bruit reste inchangée et est utilisée pour tester la trame suivante.

Les performances de la technique ALED dépendent fortement de la valeur du pas d'index P . Cette dernière est choisie en fonction du rapport R entre la variance d'erreur d'estimation de la trame de bruit actuelle ($var_{current}$) et la variance d'erreur d'es-

timation des trames de bruit précédemment traitées (var_{old}), définies comme suit :

$$var_{current} = \frac{1}{L} \sum_{i=(j-1)L+1}^{jL} (x^2(i) - E_j)^2 \quad (2.13)$$

$$var_{old} = \frac{1}{N_r L} \sum_{i \in I} (x^2(i) - th)^2 \quad (2.14)$$

où I est l'indice de taille $N_r L$ qui correspond aux plus récentes trames de bruit utilisées pour évaluer Th . Les valeurs du pas d'index P sont données dans le tableau 2.1 [141].

TABLE 2.1 – Détermination du pas d'adaptation de la méthode ALED $R = var_{current}/var_{old}$

Classification	P
$R \geq 1.25$	0.25
$1.25 \geq R \geq 1.10$	0.20
$1.10 \geq R \geq 1.00$	0.15
$1.00 \geq R$	0.10

2.4.2 Methode ALED modifiée : M-ALED

Dans cette partie, nous introduisons deux principales modifications à la méthode ALED. La première consiste au conditionnement du signal EMG de surface en utilisant le TKEO afin de réduire l'effet de bruit et ce faisant améliorer le rapport signal sur bruit (SNR) [33], la seconde modification consiste en l'utilisation des statistiques d'ordre pour mieux estimer l'énergie et gérer l'impulsivité du signal. Nous présentons maintenant de façon assez succincte la méthode M-ALED :

1. Pour augmenter le SNR, le signal EMG est conditionné en utilisant le TKEO comme suit :

$$z(n) = x^2(n) - x(n+1)x(n-1) \quad (2.15)$$

La Fig.2.1.a montre, comme escompté, un gain de 4 dB en termes de SNR après utilisation du TKEO

2. Même si effectivement le TKEO améliore le SNR, il s'avère tout de même inadapté en présence d'impulsivités du signal tel qu'illustré dans la Fig.2.1.b. En effet, dans cette situation l'équation (2.9) n'arrive pas à estimer correctement l'énergie moyenne de la trame considérée. Pour remédier à ce problème, nous proposons d'utiliser les

statistiques d'ordre qui sont généralement robustes contre le problème d'impulsivité du signal [154]. Dans cette thèse, nous utilisons la médiane (*au lieu de la moyenne*) qui correspond à la valeur centrale E_j des $z(n)$ triés (*dans l'ordre croissant ou décroissant*) de la j^{eme} trame.

$$E_j = \text{median}(\{|z(i)|, (j-1)L+1 \leq i \leq Lj\}) \quad (2.16)$$

3. Enfin, le reste des étapes de la méthode M-ALED s'effectuent de la même manière que la méthode ALED originale.

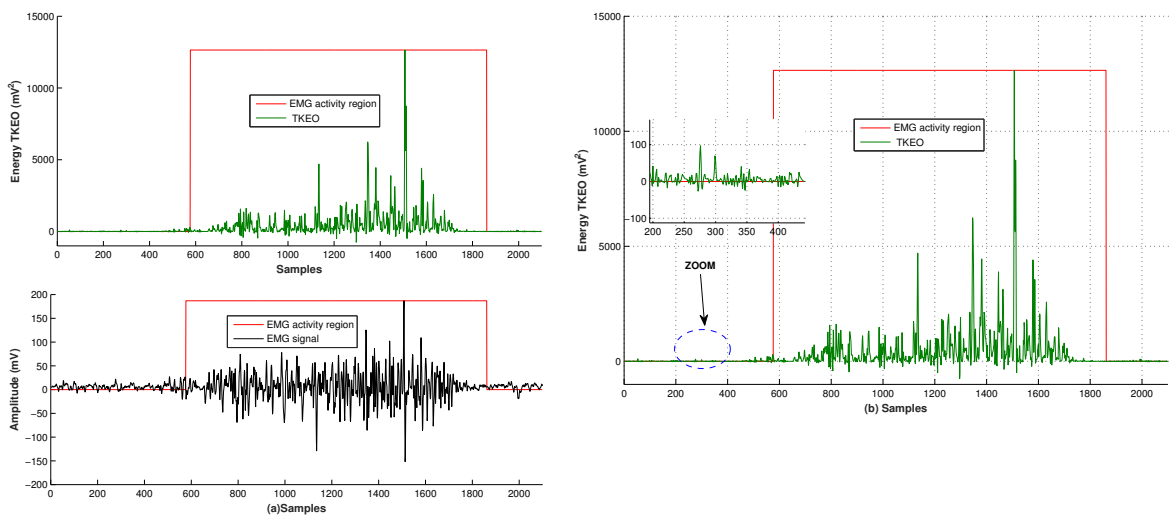


FIGURE 2.1 – (a) Signal EMG de surface et sa transformée TKEO, (b) nature d'impulsivité de la transformée TKEO du signal.

2.4.3 Méthode FM-ALED

Dans la méthode M-ALED, dont le principe est basé sur la segmentation du signal EMG, la précision de l'estimation de l'onset et de l'offset dépend de la taille de la trame d'analyse. En effet, la première trame active utilisée pour l'estimation de l'onset¹ est le plus souvent une trame contenant à la fois des échantillons du bruit et du signal utile (voir l'exemple illustratif sur la Fig.2.4). Inversement la dernière trame active, utilisée pour estimer l'offset, est le plus souvent une trame contenant à la fois des échantillons du signal utile et du bruit. Ainsi, pour affiner l'estimation des moments de début et de fin des périodes d'activité, nous proposons pour la première fois à notre connaissance de zoomer à l'intérieur de la trame

1. La première trame active suit une période de non-activité

de transition (c'est-à-dire celle dans laquelle l'offset/ l'onset a été détecté) et ses voisines en utilisant l'approche CFAR. Celle-ci procède échantillon par échantillon, ce qui signifie que la décision est prise au niveau échantillon.

a.). **Technique Constant False Alarm Rate (CFAR)**

La technique CFAR a été largement utilisée dans les radars et les télécommunications [155, 139]. Dans cette thèse, nous proposons d'adapter l'approche CFAR à notre problématique. En effet, nous allons l'utiliser en association avec la méthode ALED, pour affiner les estimations, d'apparition ou de disparition de l'activité EMG, préalablement obtenues par celle-ci. Nous signalons au passage, et par souci de simplification, que l'annexe B présente les résultats de détection du premier onset par la méthode CFAR. L'intérêt d'une telle initiative découle de l'hypothèse gaussienne i.i.d qui s'applique correctement dans la région de non activité EMG (absence du signal utile) contrairement à la région activité EMG où cette même hypothèse ne constitue pas une bonne approximation.

Cela étant, nous présentons maintenant le schéma de détection adaptative qui permet de prendre en compte la non-stationnarité du signal et la variation temporelle de la puissance du bruit dont la puissance est estimée en utilisant une fenêtre locale de M échantillons. En adoptant la terminologie utilisée dans le traitement du signal radar, nous nous référons aux échantillons de la fenêtre locale en tant que cellules de référence et à l'échantillon auquel la détection est appliquée en tant que cellule sous test (en anglais Cell Under Investigation CUI) (comme illustré dans la Fig.2.2). Chaque cellule de référence est composée d'un seul échantillon. La puissance de bruit est ensuite estimée à l'aide des mesures effectuées dans la fenêtre de référence. Les cellules de garde sont les cellules au voisinage immédiat à gauche de la CUI. Elles sont exclues du processus d'estimation afin d'éviter tout débordement de la part de la CUI. Le facteur d'échelle T est choisi de telle sorte que la probabilité de fausse alarme P_{fa} soit fixée à une valeur constante choisie.

Le processus de seuillage adaptatif décrit ci-dessus est connu sous le nom de CFAR à cellules moyennées (en anglais cell-averaging CFAR). Plus précisément, le problème de détection présenté dans l'équation (D.1) peut être exprimé comme suit :

$$\Gamma : \begin{cases} H_0 : x(n) = w(n) \\ H_1 : x(n) = s(n) + w(n) \end{cases} \Leftrightarrow \begin{cases} H_0 : \sigma_x^2 = \sigma_w^2 \\ H_1 : \sigma_x^2 = \sigma_s^2 + \sigma_w^2 \end{cases} \quad (2.17)$$

où $s(n)$, $w(n)$ et $x(n)$ sont supposés être des processus aléatoires gaussiens de moyenne nulle indépendants et identiquement distribués (i.i.d). Nous considérons ces hypothèses simplificatrices pour mieux expliquer le principe du CFAR et montrer comment sa probabilité de fausses alarmes est obtenue. Cependant, dans de nombreux cas, le caractère normal n'est pas requis. Dans les hypothèses précédentes où chaque CUI est composée d'un seul échantillon, le modèle de données est défini comme suit :

$$z(n) = |x(n)|^2 \quad (2.18)$$

où $z(n) \sim \chi_2(1, \sigma_x^2)$ est la distribution du khi deux d'un degré de liberté et de variance σ_x^2 .

L'estimation de la puissance du bruit est faite en moyennant l'énergie des cellules de référence $M = 2m$ donnée par ² :

$$U = \sum_{n=1}^M z(n) = \sum_{n=1}^{2m} |x(n)|^2 \quad (2.19)$$

a.1) . Calcul de la probabilité de fausse alarme

Nous sommes dans le cas où $x(n) = w(n)$ pour lequel : $z(n) \sim \chi_2(1, \sigma_z^2 = \sigma_w^2)$. La probabilité de fausse alarme correspond à :

$$P_{fa} = P(H_1/H_0) = P(z(n) > T.U) \quad (2.20)$$

En d'autres termes :

$$P_{fa} = \int_0^{+\infty} f_Z(z) P(U < \frac{z}{T}) dz = \int_0^{+\infty} f_Z(z) F_U(\frac{z}{T}) dz \quad (2.21)$$

où $F_U(\frac{z}{T})$ est la fonction cumulative de U , utilisant la fonction de densité de distribution du Chi-deux centrée avec un seul degré de liberté, donnée par :

$$f_Z(z) = \frac{1}{\sqrt{2\pi\sigma_w^2}} z^{-\frac{1}{2}} \exp\left(\frac{-z}{2\sigma_w^2}\right) \quad (2.22)$$

2. Généralement, la taille de la fenêtre est prise même dans la plupart des papiers CFAR. Donc, pour simplifier, nous considérons ce cas ici et omettons la constante de normalisation $1/M$ car elle est intégrée au facteur de seuil T .




FIGURE 2.2 – Schémas de détection de CA-CFAR à gauche.

et la fonction cumulative de U est donnée par :

$$F_U\left(\frac{z}{T}\right) = 1 - \exp\left(-\frac{z}{2T\sigma_w^2}\right) \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{z}{2T\sigma_w^2}\right)^k, \quad z \geq 0 \quad (2.23)$$

ce qui donne [156] :

$$P_{fa} = 1 - \sum_{k=1}^{m-1} \frac{1}{k!} \cdot \frac{\Gamma(k+1/2)}{\Gamma(1/2)} \cdot \frac{\sqrt{T}}{(T+1)^{k+1/2}} \quad (2.24)$$

Cette formule peut être utilisée pour choisir de seuil T pour une Probabilité de fausse alarme. Dans les cas où le modèle statistique de bruit est inconnu, le moyen le plus simple de définir la valeur seuil T pour une P_{fa} donnée serait de le faire de manière expérimentale, comme nous l'avons fait pour les expériences de simulation présentées dans l'annexe.

a.2). Calcul de la probabilité d'oubli

Sous l'hypothèse H_1 , nous avons pris $z(n) \sim \chi_2(1, \sigma_z^2 = \sigma_s^2 + \sigma_w^2)$. La probabilité de détection manquée ou la probabilité d'oubli $P_{miss} = 1 - P_d$ correspond à :

$$P_{miss} = P(H_0/H_1) = P(z(n) < T.U) \quad (2.25)$$

$$P_{miss} = \int_0^{+\infty} f_Z(z)P(U > \frac{z}{T})dz = \int_0^{+\infty} f_Z(z)\left(1 - F_U\left(\frac{z}{T}\right)\right)dz \quad (2.26)$$

En utilisant la fonction cumulative présentée précédemment, la probabilité d'oubli est égale [156] :

$$P_{miss} = \sum_{k=1}^{m-1} \frac{1}{k!} \cdot \frac{\Gamma(k + 1/2)}{\Gamma(1/2)} \cdot (1 + SNR)^k \frac{\sqrt{T}}{(T + SNR + 1)^{k+1/2}} \quad (2.27)$$

Où $SNR = \frac{\sigma_s^2}{\sigma_w^2}$

b.). Principe de la méthode FM-ALED

La méthode FM-ALED proposée incorpore les étapes supplémentaires suivantes à la méthode M-ALED :

- Pour la détection d'onset, la FM-ALED applique la technique CFAR sur les échantillons du signal de la trame de transition détectée et de la précédente (comme indiqué sur la Fig.2.4).
- De même, pour la détection d'offset, la FM-ALED applique le CFAR sur les échantillons du signal de la trame de transition détectée et de la suivante, après avoir utilisé une inversion de temps sur le signal obtenu.

Dans la figure 2.3, nous proposons un organigramme résumant les étapes de la méthode ALED avec ses versions.

2.4.4 Méthode OM-ALED

Les méthodes ALED et M-ALED évaluent la ligne de base initiale du signal en prenant les v premières trames d'analyse, comme le montre l'équation (2.10). Cependant, dans un contexte non contrôlé de l'activité EMG, une telle hypothèse n'est pas nécessairement valide et les v trames initiales peuvent chevaucher avec une région d'activité du signal EMG, comme le montre la Fig.2.5.a. Toutefois, l'expérience montre qu'il est aisé de remarquer que tous les enregistrements EMG n'ont pas de régions de non activité alternant avec des

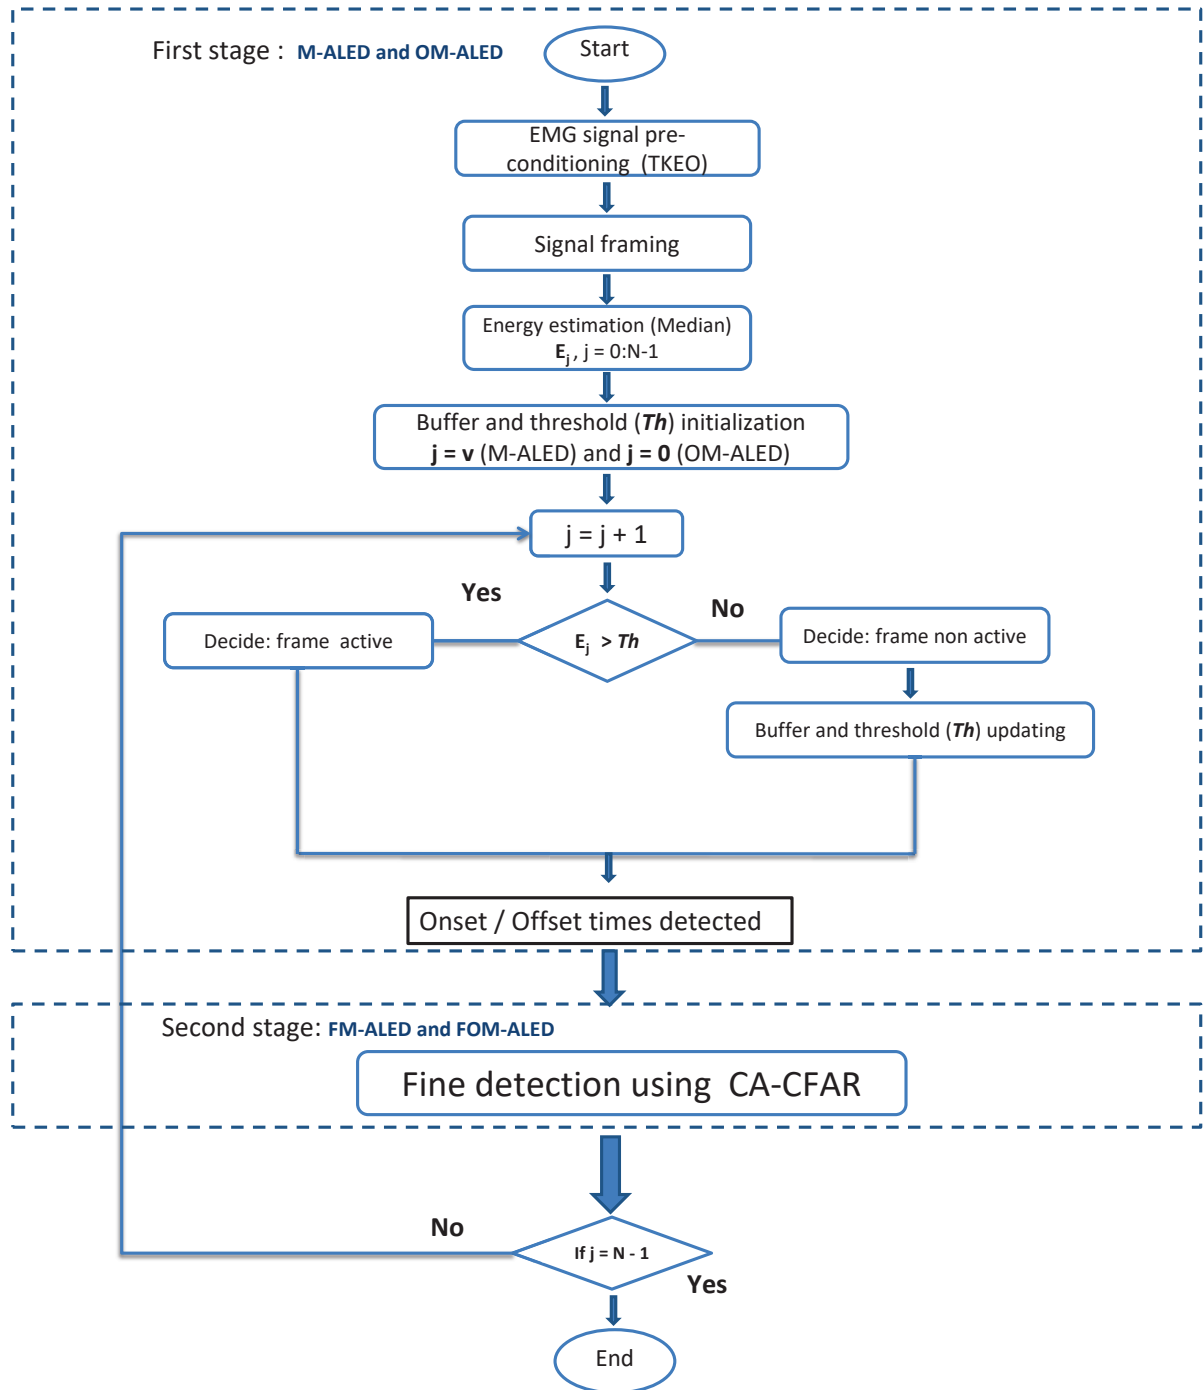


FIGURE 2.3 – Organigramme des méthodes proposées.

régions d'activité. Cette constatation peut être exploitée pour obtenir une première estimation de la variance du bruit. Pour y parvenir, nous proposons d'utiliser à nouveau les statistiques d'ordre du signal (trier les échantillons du signal en fonction d'un ordre croissant) pour ensuite estimer la variance initiale du bruit sous forme du q -ème quantile du signal (typiquement $50\% \leq q \leq 75\%$).




FIGURE 2.4 – Détection d'onset affinée .

De la Fig.2.5.b, nous pouvons observer l'amélioration en terme de qualité d'estimation de la variance de bruit pour le signal EMG présenté dans la Fig.2.5.a. Les tracés présentés montrent l'évolution de l'estimation de la puissance de bruit pour la M-ALED initiée comme dans l'équation (2.10), l'OM-ALED avec $q = 70\%$ et une variance de bruit de référence estimée par moyenne temporelle à partir des régions de non activité (bruit) uniquement du signal, présenté en vert. Deux principales remarques peuvent être tirées de cet exemple illustratif :

1. L'utilisation des statistiques d'ordre dans un tel contexte fournit une meilleure estimation initiale de la variance du bruit par rapport à l'approche standard ;
2. L'un des principaux avantages des méthodes de type ALED est le fait que même si nous commençons par une estimation de référence de signal erronée, la méthode est en mesure de la corriger et de l'améliorer tout au long de son processus de mise à jour itérative.

2.5 Méthode supervisée : basée sur l'utilisation des HMM

Dans cette partie, nous présentons une approche supervisée de segmentation du signal EMG basée sur les HMM. Un tel système peut être considéré comme un système de reconnaissance de formes qui nécessite une phase d'apprentissage et une phase de test et validation. La première phase consiste en la modélisation de la configuration temporelle des classes. La deuxième phase consiste en la reconnaissance et le test pour identifier les différentes classes de segments du signal EMG. Par conséquent, une base de données de signaux EMG, pour les deux phases, est nécessaire pour concevoir le système de segmentation. Les




FIGURE 2.5 – (a) signal EMGs et sa segmentation, (b) Évolution de la variance estimée de bruit of des méthodes ALED et OM-ALED

deux phases nécessitent une étape d'extraction des caractéristiques pour convertir chaque signal en une séquence de vecteurs de caractéristiques, qui peuvent être considérés comme une séquence d'entrée d'observation dans les étapes de modélisation ou de classification.

2.5.1 Modélisation HMM du signal EMG

La segmentation du signal est le processus d'identification des frontières (début et fin) de chaque classe. Le système de segmentation du signal peut être réalisé en utilisant des techniques de modélisation statistique telles que les modèles de mélange gaussiens (GMM) et les HMM. Un tel système peut être considéré comme un système de reconnaissance de formes qui nécessite une phase d'apprentissage pour modéliser les classes de formes temporelles et une phase de reconnaissance pour identifier les différentes classes de segments de signal d'entrée. Par conséquent, la formation et le test de bases de données de signaux sont nécessaires pour concevoir le système de segmentation. Les deux phases nécessitent une étape d'extraction de caractéristiques pour convertir chaque signal en séquence de vecteurs de caractéristiques obtenus en divisant le signal en fenêtres chevauchantes et calculer à partir de chaque fenêtre un ensemble de caractéristiques qui constitue le vecteur de caractéristiques (voir Fig.2.6). Cette séquence de vecteurs peut être considérée comme une séquence d'entrée d'observations dans les étapes de modélisation ou de classification.

En particulier, dans la tâche de reconnaissance vocale, le processus de segmentation du signal a pour objectif d'identifier les limites des segments de phonèmes, de mots ou de phrases en utilisant respectivement le modèle acoustique, le modèle lexical et le modèle de langage. Le système basé sur les modèles HMM peut être implémenté à l'aide de la bi-

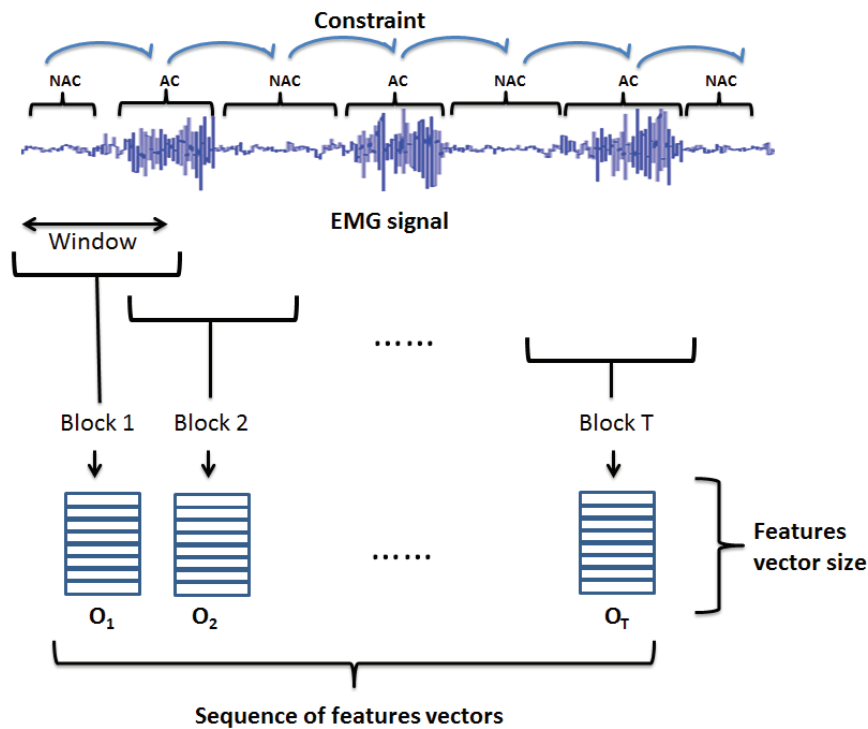


FIGURE 2.6 – Etape d'extraction des caractéristiques.

bibliothèque d'outils HTK (ou en anglais Hidden Markov Model Toolkit) qui a été conçue tout d'abord pour le système de reconnaissance vocale y compris la modélisation acoustique, lexicale et linguistique [157]. Cette boîte à outils permet de modéliser chaque phonème par un modèle HMM de N_{states} (signifié nombre d'états), chacun associé au modèle GMM des composants gaussiens N_{GMM} (signifié nombre de gaussiennes) pour modéliser la densité de probabilité de l'observation. Les paramètres des modèles HMM sont estimés à l'aide de l'algorithme Baum-Walsh intégré qui est implémenté dans le logiciel HTK en utilisant la commande HEREST. La phase de reconnaissance peut être réalisée avec l'algorithme de Viterbi en utilisant la commande HVITE par rapport à un modèle de langage et un dictionnaire [157]. Néanmoins, le système basé sur des modèles HMM utilisant la bibliothèque d'outils HTK a été utilisé pour d'autres applications telles que l'identification d'appareils électriques [8] et la reconnaissance d'émotions [158]. Dans cette thèse, nous utilisons cette boîte à outils pour segmenter le signal EMG en régions (modèles) de classe d'activité (AC) et régions de classe sans activité (NAC). Le signal EMG est considéré comme une séquence de régions successives des classes AC et NAC, chacune étant représentée par une séquence d'observations (séquence de vecteurs caractéristiques) et modélisée par HMM (voir Fig.2.6). Les paramètres de chaque modèle de classe AC ou NAC sont estimés à partir de la phase d'apprentissage. En considérant la même approche que pour la segmentation

du signal vocal, la segmentation du signal EMG utilise l'algorithme de Viterbi pour reconnaître la séquence de classes en utilisant le HMM formé par rapport à un modèle de langage qui représente la contrainte sur la séquence de classes autorisée.

2.5.2 Modèles HMM

Le HMM est un modèle statistique utilisé pour représenter l'évolution de la dynamique temporelle dans des séries chronologiques ou des séquences d'observations temporelles. Le phénomène modélisé par HMM est un processus aléatoire et inobservable qui génère des observations aléatoires. Ainsi, un modèle HMM résulte de l'association de deux processus stochastiques : un processus inobservable $Q(t)$ (processus d'états) et un processus observable $O(t)$. En général, le $Q(t)$ est une chaîne de Markov qui est supposée être à chaque instant t dans un état $q_t = i (1 \leq i \leq K)$ qui émet une observation o_t avec la distribution de probabilité $b_i(o) = P(o|q = i)$ [159, 7].

Soit chaque région représentée par une séquence de vecteurs caractéristiques ou séquence d'observations $O(t)$ définie comme :

$$O = o_1, o_2, \dots, o_T \quad (2.28)$$

Où o_t est le vecteur de caractéristiques observé au temps t et la séquence d'états Q donnée par :

$$Q = q_1, q_2, \dots, q_T \quad (2.29)$$

Le modèle HMM peut être considéré comme une machine probabiliste d'états finis décrite par un ensemble de nœuds (ou états) reliés entre eux par des arcs de transitions (voir Fig.2.7). Chaque état $i (1 \leq i \leq K)$ à l'instant t est associé à une distribution de probabilité $b_i(o) = P(o|q_t = i)$ d'observation o et à chaque transition de l'état i à l'état j est associée une probabilité de transition $a_{ij} = P(q_t = j | q_{t-1} = i)$ [159, 7]. Si les observations sont définies dans un espace continu, alors la fonction de densité de probabilité d'émission d'observation dans l'état j peut être représentée par un modèle GMM de M composants, donné par [157] :

$$b_j(o_t) = \sum_{i=1}^M \frac{c_i}{\sqrt{(2\pi)^d |\Sigma_i|}} \exp\left(-\frac{1}{2}(o_t - \mu_i)^* \cdot \Sigma_i^{-1} \cdot (o_t - \mu_i)\right) \quad (2.30)$$

Où : μ_i et Σ_i représentent la moyenne et la matrice de covariance de la i^{eme} Composante Gaussienne, c_i le poids de la i^{eme} Gaussienne satisfaisant la condition : $\sum_{i=1}^M c_i = 1$




FIGURE 2.7 – Exemple d'un model HMM [7].

Les paramètres de base d'un modèle HMM sont donnés comme suit :

- La matrice de transition des états $A = \{a_{ij}\}$.
- La matrice de distribution de probabilité d'observation $B = \{b_i(o)\}$.
- La probabilité d'état initial $\pi = \{\pi_i \mid P(q_1 = i)\}$.

HMM peut s'écrire sous la forme : $\lambda = (A, B, \pi)$.

Étant donné plusieurs modèles HMM λ et une séquence d'observations d'entrée O , la phase d'apprentissage consiste à estimer les paramètres appropriés du modèle HMM qui maximisent la probabilité $P(O \setminus \lambda)$. En pratique, la réestimation des paramètres du modèle HMM peuvent être effectués à l'aide de l'algorithme Baum-Welch. La phase de reconnaissance a pour objectif de trouver le meilleur modèle HMM qui maximise la probabilité $P(\lambda \setminus O)$. Cette phase peut être réalisée à l'aide de l'algorithme de Viterbi.

2.5.3 Système de segmentation basé sur la modélisation HMM

La Fig.2.8 illustre le diagramme de notre système de segmentation. Dans la phase d'apprentissage, chaque classe de région est modélisée par un modèle HMM de N_{states} états, chacun étant représenté par un modèle GMM de N_{GMM} gaussiennes avec une matrice de covariance diagonale. Les paramètres des modèles HMM et GMM sont estimés à l'aide de la commande HEREST de l'outil HTK, appliquée sur la séquence de vecteurs de caractéristiques extraits des signaux EMG de la base de données d'apprentissage, utilisée du projet ECOTECH [28]. De plus, cette estimation nécessite la transcription du texte de référence qui contient la séquence de classe de chaque signal. Les séquences de vecteurs de caractéristiques sont extraites en utilisant une analyse en ondelettes appliquée sur chaque signal

EMG. Cet aspect sera présenté dans la paragraphe 2.5.4.

Dans la phase de segmentation, la commande HVITE de l'outil HTK utilise les modèles HMM formés et le modèle de contraintes (modèle de langage) pour transcrire chaque séquence de vecteurs de caractéristiques d'entrée en séquence de classes (AC et NAC) et détecter les limites de leurs segments [157, 160]. Le problème des contraintes consiste à accepter seule la séquence des classes dans laquelle chaque étiquette AC est suivie par l'étiquette NAC (voir Fig.2.6).

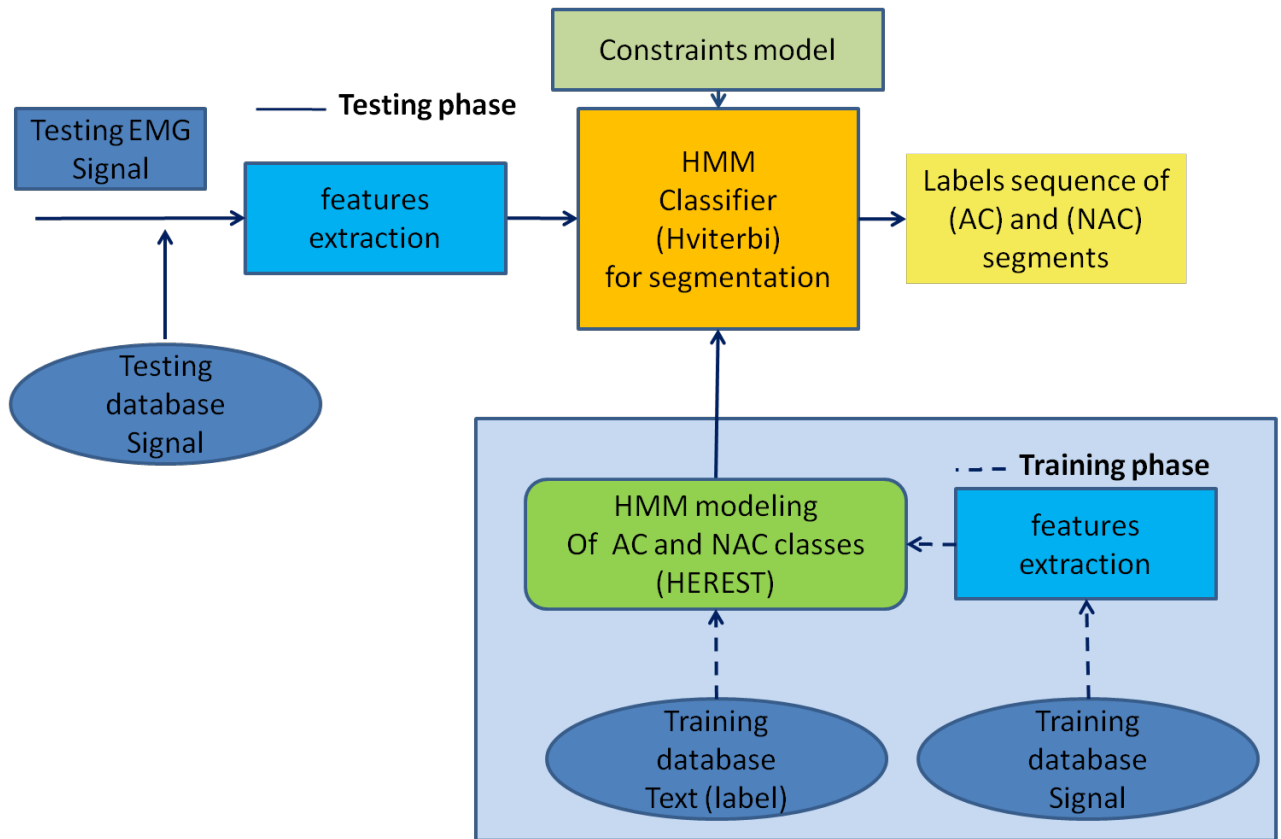


FIGURE 2.8 – La segmentation du signal EMG basée sur le modèle HMM.

Enfin, l'évaluation des performances peut être effectuée à l'aide de la commande HRE-SULTS de l'outil HTK qui compare chaque transcription de test d'un signal EMG à sa trans-cription de référence correspondante [157]. Le résultat de l'identification des segments est évalué en utilisant la précision *Acc* définie dans le paragraphe 2.6.1.

2.5.4 Extraction des attributs basée sur la transformée en ondelettes

La transformée en ondelettes a été largement utilisée comme une technique d'analyse de signal dans les systèmes de reconnaissance de formes afin d'extraire un ensemble de ca-ractéristiques de chaque fenêtre d'analyse d'un signal. Le succès de cette technique repose

essentiellement sur la flexibilité apportée par l'ondelette mère dont le choix dépend des propriétés des données ainsi que de l'application visée. Par exemple, la propriété d'orthogonalité entre les membres d'une famille d'ondelettes est souhaitable à des fins de compression tandis que la propriété de compacité est souhaitable pour l'analyse et la détection de données impulsives. De plus, la transformée en ondelettes est particulièrement adaptée à l'analyse de données issues du monde réel en raison de sa propriété d'échelle qui est conforme à de nombreux comportements physiques : les événements de longue durée doivent être analysés avec de longues formes d'ondes lentes tandis que les événements de courte durée ou impulsifs doivent être analysés avec des formes d'ondes courtes rapides. L'outil est donc adapté pour extraire correctement la formation d'impulsions des PAUM générés par l'activité EMG car l'analyse par la transformée en ondelettes est réalisée par des opérations de translation et de dilatation d'une seule forme d'onde localisée dans l'espace temporelle par le biais de l'ondelette mère. Les informations impulsives peuvent donc être localisées avec précision et le contenu de l'information analysé avec précision. Dans ce but, les auteurs [37] ont proposé la fonction Hermite – Rodriguez de premier ordre. La CWT a été utilisée dans [161] pour l'identification des PA uniques dans le domaine temporelle. Les auteurs argumentent ce choix par l'effet de filtrage du volume de conduction qui se produit entre le signal source prenant son origine profonde au niveau de la fibre et le signal détecté PAUM à la surface de la peau produit différents PAUM qui peuvent être considérés comme des versions dilatées et atténuées d'une seule forme. Cette observation motive l'utilisation d'ondelettes à condition qu'une ondelette mère de forme similaire existe ou puisse être créée. Lors de l'utilisation de la DWT, les coefficients de décomposition sont calculés à différentes échelles jusqu'à la profondeur de décomposition dyadique maximale p (à choisir a priori ou fixée au maximum comme $\log_2(N)$ où N est le nombre d'échantillons de données dans la fenêtre d'analyse). A chaque échelle ou niveau de décomposition j , un ensemble $d_j[n]$ (indexé par n) de coefficients d'ondelettes $N_j = \frac{N}{2^j}$ est calculé (d signifié les coefficients détails). Le dernier niveau de décomposition p produit l'ensemble a (a signifié les coefficients d'approximation). Par conséquent, une énergie d'ondelettes discrète (DWE) peut être calculée à chaque échelle comme :

$$\begin{cases} E(d_j) = \sum_{n=0}^{N_j-1} |d_j[n]|^2 & \text{for } j = 1, \dots, p \\ E(a_p) = \sum_{n=0}^{N_p-1} |a_p[n]|^2 \end{cases} \quad (2.31)$$

Enfin, l'ensemble des caractéristiques extraites de chaque fenêtre d'analyse d'un signal est composé des énergies des coefficients d'ondelettes $E(d_1), E(d_2), \dots, E(d_p), E(a_p)$, qui fait une analyse d'énergie sur les bandes spectrales consulaires des données (du plus haut au plus bas lorsque j passe de 1 à p). Afin d'extraire d'autres descripteurs possibles, dans [8] les auteurs ont utilisé (voir Fig.2.9) :

- le DWE normalisé sur l'énergie totale de la fenêtre d'analyse ;
- le logarithme de l'énergie des ondelettes (LWE) ;
- les coefficients cepstraux d'ondelette sont calculés à partir de la transformée en cosinus discrète (DCT) de LWE (voir Fig.2.9).

Dans cette thèse, nous avons étudié l'impact de ces descripteurs sur les résultats de performance de la segmentation du signal EMG. Pour cela, différentes expériences ont été menées pour avoir une configuration optimale.

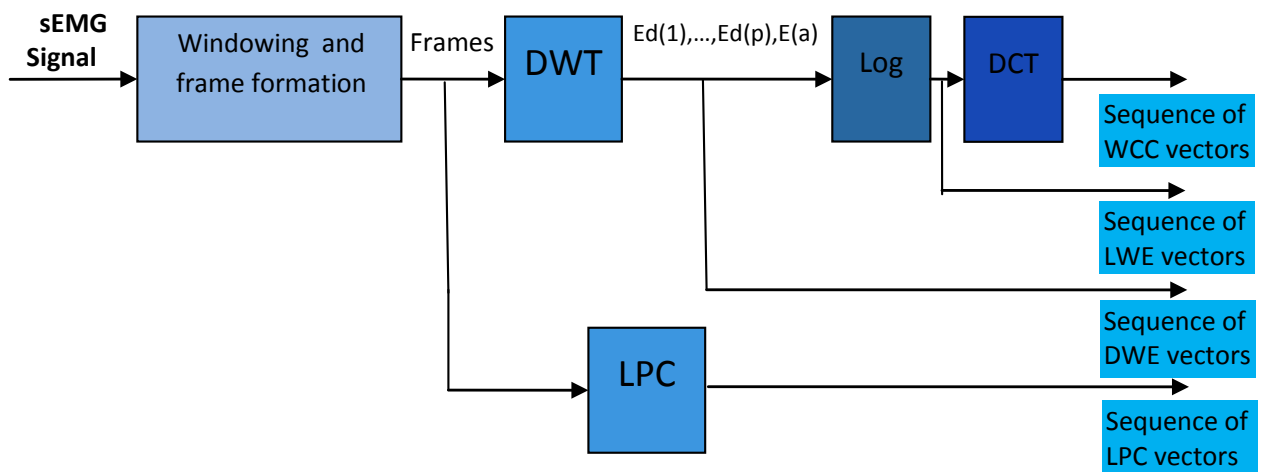


FIGURE 2.9 – Processus d'extraction des attributs LPC / DWE / LWE / WCC. [8].

2.6 Résultats et discussions

Pour évaluer les méthodes proposées, nous avons pris des signaux EMG de surface (EMGs) synthétiques et réels segmentés manuellement par un expert.³ Les données synthétiques sont générées via le modèle proposé dans [162] tandis que les données réelles proviennent de la base de données de [28]. Des techniques de type ALED et HMM sont ensuite appliquées pour détecter automatiquement les instants de début et de fin de l'activité

3. Cette expertise a été réalisée dans le cadre du projet ECOTECH où la segmentation du signal EMG a été réalisée par des chercheurs biomédicaux utilisant l'inspection visuelle [28].

EMG. À des fins de comparaison, les résultats obtenus sont comparés à ceux des méthodes énumérées dans les paragraphes précédents.

2.6.1 Outils d'analyse de performances

Afin d'évaluer les performances des méthodes proposées, nous avons principalement considéré deux critères, à savoir :

1. la précision de classification (Acc);
2. le taux d'erreur ou probabilité d'erreur (Re).

La précision de classification est utilisé pour évaluer le nombre de bouffées d'activités EMG correctement détectées. Cette précision est défini par :

$$Acc = \frac{N - D - S - I}{N} \quad (2.32)$$

N représente le nombre total d'étiquettes de segments dans les transcriptions de référence des signaux EMG, D est le nombre d'étiquettes supprimées, S est le nombre d'étiquettes substituées et I est le nombre d'étiquettes insérées.

Le critère de performance Re est utilisé pour évaluer en premier lieu la techniques ALED avec ses versions. Et en deuxième lieu pour évaluer la détection fine du début (onset) et de la fin (offset) de chaque bouffée d'activité EMG pour l'approche HMM. Afin d'évaluer le critère Re , nous avons utilisé une représentation binaire de notre signal EMGs selon :

$$b(t) = \begin{cases} 0 & \text{Si la décision du } t\text{-eme échantillon est non active} \\ 1 & \text{Si la décision du } t\text{-eme est active} \end{cases}$$

$$R_e = Prob(b(t) \neq b_{ex}(t)) \quad (2.33)$$

où $b_{ex}(t)$ fait référence à la valeur exacte de notre représentation de signal binaire donnée par l'expert.

Dans cette partie de la thèse, nous avons également réalisé l'analyse des performances en calculant les valeurs moyenne et écart type (en anglais standard deviation STD) des valeurs de durée de bouffées d'activité EMG ainsi que l'erreur de latence absolue correspondante (en anglais absolute latence error ALE) entre la moyenne de la durée expérimentale et la moyenne de la durée de référence faite par un expert, comme indiquée dans l'équation

suivante.

$$\text{ALE} = |\text{La moyenne des durées réelles des bouffées} - \text{La moyenne des durées estimées des bouffées}| \quad (2.34)$$

2.6.2 Paramètres des simulations des méthodes dans l'état de l'art

Nous avons considéré les cinq méthodes présentées dans le paragraphe 2.3 et nous avons choisi les paramètres de ces méthodes en fonction des recommandations de leurs auteurs.

Pour la méthode à double seuil, nous avons utilisé $m = 5$, $r = 1$ et $P_{fa} = 0,05$ pour le signal synthétique. Pour les signaux réels, nous avons varié les valeurs de P_{fa} et r (en utilisant une recherche dans une grille) de manière à obtenir les meilleurs résultats de la méthode pour chacun des signaux considérés.

Pour la méthode basée sur les ondelettes, nous avons utilisé une ondelette mère gaussienne et le paramètre défini $\text{gamma} = 1.2$. Le paramètre T_{noise} est choisi égale à la taille exacte de la région de bruit initiale définie par la segmentation de l'expert. En effet, nous avons utilisé la région de bruit exacte pour l'estimation de la variance de bruit pour les trois méthodes.

Pour la méthode TKEO, nous avons choisi le paramètre $JJ = 3$ pour les signaux synthétiques, tandis que pour les enregistrements réels, il a été modifié de manière à obtenir la meilleure performance de détection pour chaque signal considéré.

Pour la méthode SampEn, nous avons segmenté le signal EMG en trames d'analyse chevauchées avec une longueur de trame de 32 ms et un incrément de 4 ms. Nous avons aussi utilisé la dimension $m = 2$, r étant égale à 0,25 fois l'écart type (SD) du signal traité et le seuil $th = 0,5$.

Pour la méthode basée sur la RMS, nous avons utilisé la trame d'analyse composée de 15 échantillons. Le seuil a été choisi comme 45% de la valeur moyenne des RMS de tout le signal EMGs.

De même, pour évaluer les limites potentielles de la méthode proposée, nous avons réglé les paramètres L (taille de trame) et v (taille de la mémoire tampon) pour ALED, M-ALED et FM-ALED de manière à obtenir les meilleures détections et performances pour chaque signal considéré. D'autre part, pour être proche d'une situation de surveillance automatique pratique, nous avons fixé la taille de trame $L = 256$, la valeur de quantile $q = 70\%$ et le paramètre de seuil $\lambda = 2$ pour le paramètre OM et FOM-ALED, sans l'optimisation (réglage)

considérée précédemment.

Les paramètres du CFAR sont $m = 32$ échantillons et un Probabilité de fausse alarme de l'ordre 10^{-2} .

2.6.3 Performances des techniques ALED

Nous avons évalué les performances des techniques proposées pour trois types de signaux, à savoir les signaux EMGs simulés (synthétiques), les signaux EMGs réels de sujets sains et les signaux EMG réels de sujets parkinsoniens, respectivement. En particulier, outre les cas relativement bien contrôlés, par exemple ceux présentés dans la Fig.2.10.a, nous avons considéré dans la procédure d'évaluation des scénarios défavorables correspondant à des enregistrements de signaux sans référence initiale comme dans la Fig.2.10.b, des signaux mal enregistrés (trop bruités) comme dans la Fig.2.10.c, où des signaux avec un grand nombre de bouffées d'activités EMG comme présentés dans la Fig.2.10.d. Pour toutes les méthodes considérées, la mesure de performance est le taux d'erreur présentée dans l'équation (2.33).




FIGURE 2.10 – Segmentation automatique du signal EMG réel des muscles : (a) Left Vastus (avec bruit = 3 trames et la taille de trame = 280 échantillons) pour $R_e = 8.16$, (b) Right Soleus (avec bruit = 1 trame et la taille de trame = 78 échantillons) pour $R_e = 2.628$, (c) Left Gastroc (avec bruit = 4 trames et la taille de trame = 256 échantillons) pour $R_e = 11.056$. (d) Right Soleus (avec bruit = 3 trames et la taille de trame = 432 échantillons) pour $R_e = 7.762$.

a.). Signal EMGs synthétique

Nous avons considérons dans cette simulation numérique un signal EMGs synthétique et simulé avec deux bouffées d'activités EMG. Ce signal est noyé dans un bruit

gaussien i.i.d et additif. A travers, cette simulation, nous cherchons à analyser l'impact de la taille de la trame d'analyse et de la puissance de bruit initiale sur les performances de la méthode proposée. Il est bien entendu évident que lorsque la taille de la trame de bruit est faible ou sa puissance est assez importante les performances de détection se dégradent fortement. Cela étant, le signal considéré contient 28672 échantillons où chaque bouffée d'activité EMG contient 8192 échantillons. Ce signal est simulé avec une excitation de rampe, générée à une fréquence d'échantillonnage de 1024 Hz à l'aide du simulateur décrit dans [162]. La vitesse de conduction moyenne est fixée à 4 ms^{-1} avec un taux de décharge égal à 8Hz et le taux de recrutement maximum est de 79 %. Chaque bouffée d'activité EMG est composée de 500 TPAUM synthétiques. Le signal EMGs simulé est généré avec un $SNR = 20 \text{ dB}$ et un $SNR = 10 \text{ dB}$ respectivement.

Dans la Fig.2.11, nous présentons, pour un $SNR = 20\text{dB}$, le taux d'erreur R_e pour différentes valeurs de la taille de la trame du bruit. Le taux en question est calculé en utilisant 10^4 réalisations indépendantes de Monte Carlo. Les résultats obtenus montrent le choix optimal des deux paramètres considérés dépend essentiellement du signal.




FIGURE 2.11 – Probabilité d'erreur d'un signal EMGs synthétique pour un $SNR = 20 \text{ dB}$ pour différentes valeurs des tailles de bruits ν .

La Fig.2.12 présente un exemple illustratif dans lequel le signal EMGs synthétique est segmenté en utilisant une longueur de trame d'analyse ajustée égale à 1380 échantillons et une taille de bruit égale à 3 trames pour un taux d'erreur égale à 2.23. Dans cet exemple le SNR considéré est égal à 20 dB.

La table 2.2 présente un résultat comparatif en terme de taux d'erreur R_e pour le




FIGURE 2.12 – segmentation FOM-ALED d'un signal EMGs synthétique : SNR = 20 dB, statistique d'ordre $q = 70\%$, taille des trames d'analyse = 256 et $R_e = 1.40$.

signal EMGs synthétique considéré. Comme nous pouvons le constater, toutes les méthodes fonctionnent correctement dans ce contexte bien contrôlé.

TABLE 2.2 – Comparaison du taux d'erreur du signal EMGs synthétique.

Méthode	$R_e : SNR = 20dB$	$R_e : SNR = 10dB$
DoubleTh	5.42	12.43
Wavelet	8.60	11.12
TKEO	7.50	8.44
RMS	7.43	12.57
SampEn	8.81	9.00
ALED	1.90	4.79
FM-ALED	1.78	4.77
FOM-ALED	1.40	3.60

b.). Signal EMGs réel pour les sujets sains

La détection des bouffées d'activité EMG liées au cycle de la marche est une partie très intéressante de la surveillance de maladies neuromusculaires chroniques, telle que chez les sujets atteints de la maladie de Parkinson. Cependant, les problèmes de traitement classiques qui semblaient opérationnels chez les personnes en bonne santé conviennent moins aux sujets présentant des problèmes moteurs. En effet, dans ce dernier cas, il convient de prendre en compte les propriétés spécifiques du signal en ce qui concerne la collecte de données dynamique (activités de la marche), telles que la non-stationnarité, les modifications du rapport signal / bruit, la présence d'artefacts. Ainsi, dans la présente étude, les méthodes de détection ont été testées sur des données collectées au cours de l'activité de la marche chez des personnes atteintes de Parkinson et dans un groupe témoin (sujets sains).

Huit sujets parkinsoniens et neuf sujets en bonne santé ont été recrutés dans le cadre du projet national français de recherche ECOTECH [28]. Cette étude a été approuvée par le comité d'éthique local et les sujets ont donné leur consentement écrit avant le début.

L'activité EMG des groupes de muscles des membres inférieurs a été mesurée : soléus (Sol.), Gastrocnémien (Gas.), Tibial antérieur (TA), vastus lateralis (Vlat.) et biceps fémoral (Bfem.). Les patients ont été préparés pour le placement des électrodes en rasant la peau et en la nettoyant avec des lingettes imbibées d'alcool. Des capteurs EMG ont été placés sur le ventre du muscle parallèlement à la direction principale des fibres musculaires conformément à l'étude sur la zone d'innervation [163]. Les données ont été recueillies à l'aide d'un système embarqué de capteurs portables (bande passante de 20 à 450 Hz, 16 bits par échantillon, taux d'échantillonnage de 1926 Hz, Delsys Trigno, Natick, États-Unis). La collecte de données fournit plusieurs activités en rafale de chaque côté du membre correspondant à plusieurs cycles de marche.

Le tableau 2.3 présente les résultats de performance comparatifs des enregistrements EMG de sujets sains provenant du muscle soléaire droit. Les résultats mettent en évidence un gain en performance par rapport aux techniques proposées de type ALED et par rapport aux méthodes existantes (c'est-à-dire que le taux d'erreur a été réduit d'un facteur proche de 2). En particulier, le FOM-ALED semble être le plus approprié pour une véritable surveillance automatique de l'activité EMG car il ne repose pas sur un réglage fin des paramètres tout en offrant les meilleures performances de détection.

TABLE 2.3 – Comparaison du taux d'erreur, de la moyenne et de l'écart type (STD) de la détection des bouffées d'activité EMG du muscle **RSol** : right soleus des sujets saints

Patient (P)	DoubleTh	Wavelet	TKEO	RMS	SampEn	ALED	M-ALED	FM-ALED	FOM-ALED
P_1	12.11	15.55	14.85	19.57	14.09	11.18	11.48	10.47	9.15
P_2	19.58	23.21	14.11	13.80	9.05	4.88	6.98	4.41	6.63
P_3	20.56	17.56	13.21	26.08	11.22	14.38	8.40	6.99	12.53
P_4	18.73	20.52	14.23	19.19	11.99	14.26	8.65	7.76	14.53
P_5	34.01	34.12	31.65	30.34	20.62	10.59	7.62	7.60	9.60
P_6	22.96	14.42	10.81	8.03	7.53	5.3	5.50	4.38	6.80
P_7	18.04	17.77	12.27	11.14	8.83	6.97	5.69	5.07	7.66
P_8	19.74	20.43	15.76	15.27	23.46	12.99	8.27	7.62	6.70
P_9	22.01	22.75	15.47	18.92	9.55	9.29	7.67	7.60	8.37
Moyenne	20.86	20.70	15.82	18.11	12.92	9.99	7.81	6.88	9.11
STD	5.816	5.86	6.14	7.03	5.56	3.64	1.78	1.96	2.78

c.). **Signal EMGs réel pour les sujets Parkinsoniens**

Nous testons ici la méthode proposée pour différents signaux EMG enregistrés à partir du muscle soléaire droit de huit sujets atteints de la maladie de Parkinson. La table 2.4 fournit les résultats de performance comparatifs qui soulignent à nouveau un gain en performance des techniques de type ALED proposées. Par rapport au cas des sujets sains, nous observons une légère réduction en termes de taux d'erreur. Cependant, pour le FOM-ALED (pour lequel aucun réglage de paramètre n'est utilisé), la dégradation des performances est plus importante.

TABLE 2.4 – Comparaison du taux d'erreur, de la moyenne et de l'écart type (STD) de la détection des bouffées d'activité EMG du muscle **RSol** : right soleus des sujets Parkinsoniens.

Patient (P)	DoubleTh	Wavelet	TKEO	RMS	SampEn	ALED	M-ALED	FM-ALED	FOM-ALED
P_1	23.08	24.30	22.18	34.72	33.18	3.52	2.62	2.64	12.75
P_2	24.02	19.14	17.37	15.84	10.95	21.97	14.86	14.63	13.04
P_3	19.32	40.17	23.08	20.16	18.77	9.05	7.95	8.23	11.89
P_4	21.08	21.69	25.10	13.23	20.00	7.13	4.35	3.38	8.16
P_5	20.21	22.04	18.96	18.09	17.65	9.07	9.90	9.78	9.04
P_6	22.00	20.63	22.54	12.90	14.54	7.43	6.56	5.83	9.65
P_7	19.82	18.65	15.27	9.40	14.50	8.25	7.79	7.92	24.65
P_8	17.08	21.94	17.59	16.06	13.72	10.09	11.55	10.77	22.62
Moyenne	21.04	23.57	20.22	17.55	17.99	10.05	8.20	7.90	13.97
STD	2.30	6.94	3.46	7.68	6.83	6.26	3.91	3.95	6.22

Par ailleurs, les performances de détection de différents muscles caractérisant la marche enregistrée pour l'un des sujets parkinsoniens sont analysées. Les résultats obtenus, fournis dans le tableau 2.5 confirment le gain en performance déjà observé dans les tableaux précédents. Là encore, les résultats dégradés du FOM-ALED soulignent l'importance d'un réglage automatique des paramètres qui reste un problème ouvert complexe. Il est à noter qu'avec le réglage des paramètres, FOM-ALED se comporte de la même manière que le FM-ALED.

2.6.4 Performances de l'approche HMM

Pour l'approche HMM, la phase d'apprentissage est réalisée avec un ensemble de neuf signaux EMGs réels, composé de quatre signaux de sujets Parkinsoniens et cinq signaux de sujets sains. La phase de test et validation, quant à elle, utilise quatre signaux de sujets Parkinsoniens et quatre signaux de sujets sains.

a). Configuration Optimale du système de segmentation

Avant d'étudier les performances de la dite méthode, nous recherchons une configuration expérimentale du système de segmentation. L'évaluation des performances

TABLE 2.5 – Taux d'erreur de la détection des bouffées d'activité EMG pour les muscles : **RSol** : right soleus, **LSol** : left soleus, **RGas** : right Gastrocnemius, **LGas** : Left Gastrocnemius, **RTA** : right tibialis anterior, **LTA** : left tibialis anterior, **RVlat** : right vastus lateralis, **LVlat** : left vastus lateralis, **RBfem** : right biceps femoris, **IBfem** : left biceps femoris

Muscles	DoubleTh	Wavelet	TKEO	RMS	SampEn	ALED	M-ALED	FM-ALED	FOM-ALED
RSol	23.08	24.30	22.18	9.40	14.54	35.86	2.62	2.64	11.34
LSol	19.09	24.43	18.81	23.46	17.38	9.592	7.56	6.61	12.49
RGas	21.08	27.53	38.65	25.18	24.67	10.675	8.73	6.48	10.32
LGas	20.40	33.05	24.18	24.67	23.05	12.225	11.05	8.83	14.93
RTA	40.46	42.84	46.62	45.45	47.81	32.509	13.87	11.88	11.52
LTA	36.45	37.46	33.24	30.18	28.46	20.986	11.99	9.92	32.32
RVlat	19.03	2948	38.57	9.11	16.13	9.047	9.41	9.03	14.24
LVlat	27.33	38.41	44.76	31.46	41.19	9.913	8.16	6.34	10.32
RBfem	37.99	37.71	40.19	39.67	13.55	23.194	11.20	11.12	12.42
LBfem	33.34	28.93	79.75	21.41	17.38	23.880	16.72	15.91	17.50

est faite pour deux types de signaux, à savoir les signaux EMG réels des sujets sains et les signaux EMG réels des sujets parkinsoniens.

Plusieurs expériences sont menées pour trouver la configuration optimale qui donne les meilleures performances et ceci en étudiant : (i) les paramètres des modèles HMM (nombre d'état et le nombre de gaussiennes), (ii) les différents types de descripteurs pour l'extraction des caractéristiques (iii) la combinaison optimale de l'ondelette mère avec le niveau de décomposition. Plus précisément, les expériences suivantes sont menées :

- (1) Comparaison les performances des descripteurs LWE, DWE et WCC à celles du descripteur LPC ;
- (2) Obtention de la durée optimale de la trame d'analyse ;
- (3) Rechercher la meilleure combinaison entre l'ondelette mère et le niveau de décomposition ;
- (4) Analyse des résultats de performance de notre framework et les comparaison avec les résultats obtenus avec ceux de la première méthode proposée et les méthodes existantes.

Afin d'évaluer les performances de cette méthode, la première expérience est menée pour : différents nombres d'états HMM N_{states} , différents nombres de gaussiennes pour la modélisation GMM N_{GMM} , différents niveaux de décomposition d'ondelettes L_{decomp} et P pour la modélisation LPC. L'ondelette mère 'Sym4' est choisie avec une durée de fenêtre d'analyse égale à 66.45 ms, utilisée dans l'analyse de signaux EMG [164]. Le meilleur descripteur avec les paramètres optimaux ont été choisis pour la

deuxième expérience d'étude de la durée de la trame d'analyse. Ensuite, nous avons cherché la configuration optimale pour l'ondelette mère. Enfin, une comparaison avec les méthodes de l'état de l'art citées dans 2.3.

a.1). **Comparaison des performances de différents descripteurs**

Cette partie présente les résultats d'évaluation du descripteur DWE pour la segmentation du signal EMGs. L'analyse des performances est comparée aux descripteurs LPC, LWE et WCC. Dans cette expérience, nous cherchons la configuration optimale des paramètres qui donne les meilleurs Acc et Re . Pour chaque descripteur, nous faisons varier le nombre d'états pour chaque expérience $N_{states} = (2, 3, 4, 5, 6, 7, 8, 9, 10)$, le nombre de composants de gaussiennes dans la modélisation GMM $N_{GMM} = (1, 2, 3, 6, 12, 24, 48)$ et l'ordre $P = (2, 3, 4, 5, 6, 7, 8, 9, 10)$ du descripteur LPC. La durée de la trame d'analyse est fixée à $66 : 45 \text{ ms}$ (ce qui représente 128 échantillons) et l'ondelette mère est choisie pour 'Sym4' et le niveau de décomposition de l'ondelette $L_{decomp} = 4$. Les résultats obtenus sont donnés dans le tableau 2.6 qui montre les configurations optimales en termes de nombre de Gaussiennes N_{GMM} et de nombre d'états N_{states} pour chaque descripteur d'analyse d'ondelette DWE, LWE, WCC avec l'ordre optimal P pour le descripteur LPC. Afin d'évaluer la robustesse de chaque descripteur en faisant varier le nombre N_{GMM} et le nombre N_{states} , les valeurs moyennes et l'écart type de Re pour l'ensemble des valeurs de test. A partir des résultats obtenus, les règles suivantes peuvent être édictées afin d'identifier la meilleure configuration du système. Tout d'abord, le meilleur résultat de la précision de classification Acc doit être examiné. Ensuite, en cas d'existence de plusieurs bonnes configurations par rapport au Acc , les meilleures valeurs de Re doivent alors être également prises en compte. Les résultats présentés dans le tableau 2.6 mettent en évidence le gain en performance des descripteurs d'ondelettes qui montrent tous 100% d' Acc par rapport au descripteur LPC montrant un mauvais score de 87.34%. Enfin, le meilleur descripteur est WCC avec $Re = 4.88\%$. Cependant, le descripteur WCC nécessite plus de calcul et est plus influencé par les variations du nombre états et du nombre de gaussiennes (avec une moyenne de Re égale à 7,41 % et un écart-type de 0.51). Le descripteur LWE montre également de meilleures statistiques de Re que WCC (en particulier avec une valeur de l'écart type qui est environ 4 fois plus faible). C'est pourquoi dans les prochains paragraphes, nous choisissons le descripteur LWE avec un nombre d'états $N_{states} = 2$ et un nombre de gaus-

siennes $N_{GMM} = 3$.

descripteur	LPC*	DWE	LWE	WCC
paramètres optimaux	$N_{GMM} = 24$ $N_{states} = 2$ and $P = 2$	$N_{GMM} = 3$ $N_{states} = 3$	$N_{GMM} = 3$ $N_{states} = 2$	$N_{GMM} = 48$ $N_{states} = 2$
Acc %	87.34	100	100	100
Re %	43.48	6.16	5.37	4.88
Moyenne de Re %	49.14	6.24	6.23	7.41
STD de Re %	0.731	0.083	0.138	0.510

TABLE 2.6 – Comparaison des performance en Acc % pour les descripteurs DWE, LPC, LWE and WCC en utilisant 'Sym4' et $L_{decomp} = 4$ avec une trame d'analyse égale à 66.45 ms. L'étoile * indique que le Re est calculé uniquement pour les séquences correctement classifiées.

a.2). Influence de la durée de la fenêtre d'analyse

Après avoir choisi le descripteur LWE, nous étudions dans cette partie la durée de la trame d'analyse appropriée. Le but de cette étude est de rechercher les améliorations des performances en tenant compte des avantages de l'analyse en ondelettes appropriée pour les signaux EMG. Pour cela, nous faisons varier la durée de la trame d'analyse avec l'ondelette 'Sym4'. Les autres paramètres sont fixés comme suit : le nombre de GMM $N_{GMM} = 3$, le nombre d'états $N_{states} = 2$ et le niveau de décomposition égal à $L_{decomp} = 4$ pour le descripteur LWE. Le tableau 2.7 montre les valeurs Acc et Re pour différentes valeurs de la durée de la trame d'analyse. Les meilleures performances sont obtenues pour une durée de trame d'analyse égale à 66 : 45ms, ce qui donne des valeurs Acc et Re égales à 100% et la valeur Re la plus faible égale à 5,37%.

Durée de la trame d'analyse (ms)	16.61	33.22	49.84	66.45	83.07	99.68	116.30	132.91
Acc %	80.38	91.14	97.47	100	100	99.37	100	100
Re %	6.41	5.39	5.33	5.37	5.505	5.61	5.81	8.46

TABLE 2.7 – Comparaison des performances en Acc (%) et Re (%) pour le descripteur DWE en utilisant 'Sym4' pour différentes durées des trames d'analyse.

Dans la suite de ce paragraphe nous allons nous concentrer sur l'analyse des performances pour le choix optimal de l'ondelette mère.

a.3). Choix de l'ondelette mère

De nombreuses études sur l'analyse EMG de surface ont conclu que la famille

d'ondelettes de Daubechies (Db) est l'ondelette la plus appropriée pour l'analyse du signal EMGs [165, 166, 167]. Dans [164], les auteurs ont conclu que le 'Sym4' est le plus approprié pour la reconnaissance de formes EMG. Cette partie d'étude vise à sélectionner l'ordre optimal des ondelettes mères au sein de sa famille pour une durée de la trame d'analyse égale à $66.45ms$, un nombre de GMM $N_{GMM} = 3$, un nombre d'états $N_{states} = 2$ avec un niveau de décomposition variant entre 1 à \log_2 de nombre d'échantillons de la fenêtre d'analyse (niveau max = 7). Dans cette étude, nous considérons les familles d'ondelettes suivantes :

- la famille Daubechies avec les ordres 1 à 8 : Db1, Db2, ... , Db8 ;
- la famille Symlets avec les ordres 1 à 8 : Sym1, Sym2, ... , Sym8 ;
- la famille Coiffets avec les ordres 1 à 5 : Coif1, Coif2,..., Coif5.

Les valeurs Acc , Re et L_{decomp} sont rapportées dans les tableaux 2.8, 2.9 et 2.10 pour chacune des trois familles d'ondelettes, respectivement. Les résultats obtenus mettent en évidence la robustesse des performances de l'approche proposée en termes de valeur Acc où l'on remarque que toutes les valeurs moyennes de Acc sont supérieures à 97,47% et du taux d'erreur Re est inférieur à 5,70%. En particulier, nous remarquons également que l'ondelette 'Coif5' pour un niveau de décomposition égal à $L_{decomp} = 4$ conduit au minimum de $Re = 4,68\%$ et au maximum de $Acc = 100\%$. Ce dernier résultat montre une amélioration des performances en termes de taux d'erreur par rapport aux performances du WCC comme indiqué dans le tableau 2.6. Cette amélioration des résultats est obtenue à travers les différentes expériences décrites auparavant sans aucun calcul empirique exhaustif (ce dernier résultat sera utilisé dans l'étude comparative présentée dans le paragraphe 2.6.4). Nous pouvons remarquer que le niveau de décomposition optimal diminue en augmentant l'ordre de la famille d'ondelettes de Daubechies (ceci est également vrai pour les autres familles). Cela peut s'expliquer par le fait que la longueur du filtre augmente avec l'ordre de la famille d'ondelettes de Daubechies. Aux premiers ordres de Daubechies, les longueurs de filtre sont assez petites, ce qui est toujours efficace pour filtrer les données avec un petit nombre d'échantillons aux niveaux de décomposition les plus profonds. Par contre quand l'ordre augmente, la longueur du filtre augmente et nécessite des données avec un plus grand nombre d'échantillons pour un filtrage plus correct, limitant ainsi les valeurs optimales du niveau de décomposition à 4.

b). Statistiques de l'estimation de la durée des bouffées d'activité EMG

Daubechies		Db1	Db2	Db3	Db4	Db5	Db6	Db7	Db8	Mean	STD
66.45 ms	L_{decomp}	7	5	5	5	4	4	4	4	//	//
	Acc %	97.47	100	100	100	100	100	100	100	//	//
	Re %	5.20	5.08	5.28	5.47	5.53	4.98	5.23	5.02	5.22	0.199

TABLE 2.8 – Les performances en termes de Acc (%), Re (%) et L_{decomp} optimal pour des caractéristiques pour LWE en utilisant la familles des ondelettes **Daubechies**.

Symlets		Sym1	Sym2	Sym3	Sym4	Sym5	Sym6	Sym7	Sym8	Mean	STD
66.45 ms	L_{decomp}	7	5	5	5	4	4	4	4	//	//
	Acc %	100	100	100	100	100	100	100	100	//	//
	Re %	5.20	5.08	5.28	5.21	5.18	5.70	5.20	5.30	5.268	0.186

TABLE 2.9 – Les performances en termes de Acc (%), Re (%) et L_{decomp} optimal pour des caractéristiques pour LWE en utilisant la familles des ondelettes **Symlets**.

Coiflets		Coif1	Coif2	Coif3	Coif4	Coif5	Mean	STD
66.45 ms	L_{decomp}	6	4	4	4	4	//	//
	Acc %	100	100	100	100	100	//	//
	Re %	4.91	4.99	5.26	5.23	4.68	5.014	0.2399

TABLE 2.10 – Les performances en termes de Acc (%), Re (%) et L_{decomp} optimal pour des caractéristiques pour LWE en utilisant la familles des ondelettes **Coiflets**.

Dans cette partie, nous faisons une analyse des performances de segmentation en analysant les durées des bouffées d'activité EMG (moyenne, écart type et ALE). Les résultats sont obtenus avec une durée de la trame d'analyse égale à 66.45ms, un nombre de GMM $N_{GMM} = 3$, un nombre d'états $N_{states} = 2$ et un niveau de décomposition égale à $L_{decomp} = 4$ avec l'ondelette mère 'Coif5'.

La table 2.11 présente la moyenne et l'écart type des valeurs estimées de la durée des bouffées d'activité EMG, le nombre estimé de nombre de bouffées d'activité EMG et ALE pour les sujets sains et parkinsoniens à partir des enregistrements EMGs du muscle *soléaire* droit. La table 2.11 montre que le nombre estimé de bouffées d'activité EMG est conforme aux nombres estimés par un expert. Les résultats obtenus montrent également de faibles valeurs de ALE (moins de 46 ms pour tous les sujets) sauf pour un sujet Parkinson (affichant 80 ms).

La Fig.2.13 (respectivement 2.14) montre un exemple illustratif d'un signal EMGs réel pour le muscle *soléaire* droit d'un sujet sain (respectivement un sujet parkinsonien). Le signal est segmenté en région AC et NAC en utilisant la méthode HMM pour $N_{GMM} = 3$, $N_{states} = 2$, $L_{decomp} = 4$, par ailleurs une ondelette mère 'Coif5' est

Subject		<i>Control</i> ₆	<i>Control</i> ₇	<i>Control</i> ₈	<i>Control</i> ₉	<i>Park</i> ₅	<i>Park</i> ₆	<i>Park</i> ₇	<i>Park</i> ₈
Real burst duration	Mean(ms)	1031.7000	1013.3000	898.0833	969.2308	766.2000	990.5556	773.8000	652.2000
	STD (ms)	73.5192	321.9687	48.5264	104.8490	53.1012	55.1750	157.9421	80.6021
	Number	6	6	12	26	10	9	5	5
Estimated burst duration	Mean (ms)	1003.7020	1044.0991	925.2054	1003.3472	719.77	959.2504	693.7117	616.0029
	STD (ms)	57.2459	350.6888	48.3647	121.5427	125.0333	49.9449	124.7589	72.9712
	Number	6	6	12	26	10	9	5	5
Performance	ALE (ms)	27.95	31.09	27.12	34.11	46.43	31.30	80.0883	36.1971

TABLE 2.11 – La moyenne, l'écart type (STD) et la valeur absolue de erreur de latence (ALE) des durées de bouffées d'activités pour le muscle **RSol** right *soleus* pour des sujets sains et parkinsoniens.

utilisée et une longueur de trame d'analyse égale à 66.45 ms est adoptée Le taux d'erreur Re ainsi obtenu est égal à 2.71% pour le sujet sain ou de contrôle (respectivement 6.06% pour le sujet parkinsonien).




FIGURE 2.13 – Segmentation automatique d'un signal EMGs réel d'un sujet sain (*Control*₆) avec l'approche HMM pour le muscle *Right Soleus* avec $Re = 2.71\%$ ($N_{GMM} = 3$, $N_{states} = 2$, $L_{decomp} = 4$, ondelette = *Coif5* et une trame de durée = 66.45ms).

2.6.5 Comparaison des performances avec quelques méthodes de segmentation

Afin de comparer les méthodes proposées avec celles présentées dans le paragraphe 2.3. La table 2.12 présente les valeurs de Re pour les sujets sains et Parkinsoniens des enregistrements EMGs du muscle *soléaire* droit. Les résultats mettent en évidence un gain en performance de l'approche HMM proposée par rapport aux autres méthodes. En particulier, la méthode HMM semble être la plus appropriée pour une surveillance automatique




FIGURE 2.14 – Segmentation automatique d'un signal EMGs réel d'un sujet Parkinsonien ($Park_5$) avec l'approche HMM pour le muscle *Right Soleus* avec *Right Soleus* muscle with $Re = 6.06\%$ ($N_{GMM} = 3$, $N_{states} = 2$, $L_{decomp} = 4$, ondelette = *Coif5* and et une trame de durée = $66.45ms$).

de l'activité EMG (voir table 2.12).

Sujet	DoubleTh	Wavelet	TKEO	RMS	SampEn	FM-ALED	HMM
$Park_5$	20.11	22.04	18.96	18.09	17.65	9.78	6.06
$Park_6$	22.00	20.63	22.54	12.90	14.54	5.83	3.16
$Park_7$	19.82	18.65	15.27	9.40	14.50	7.92	10.35
$Park_8$	17.08	21.94	17.59	16.06	13.72	10.77	5.55
$Control_6$	22.96	14.42	10.81	8.03	7.53	4.38	2.71
$Control_7$	18.04	17.77	12.27	11.14	8.83	5.07	3.07
$Control_8$	19.74	20.43	15.76	15.27	23.46	7.62	3.02
$Control_9$	17.08	22.75	15.47	18.92	9.55	7.60	3.52

TABLE 2.12 – Comparaison de taux d'erreur Re pour le muscle **RSol** soléaire droite pour les sujets sains et Parkinsoniens.

La table 2.13 présente, pour des enregistrements des signaux EMGs du muscle *soléaire* droit, une étude comparative en termes d'ALE et du nombre estimé des bouffées d'activité EMG pour les sujets $Control_6$ et $Park_5$. Les résultats obtenus mettent en évidence un gain en performances de l'approche HMM proposée par rapport aux autres méthodes, en particulier sur l'estimation du nombre de bouffées d'activité EMG. Pour les sujets parkinsonien, les méthodes proposées nouvellement dans cette thèse ont réussi à estimer correctement le nombre de bouffées contrairement aux méthodes existantes qui ont malheureusement échoué dans l'estimation de ce nombre. En outre, parmi les méthodes proposées la mé-

thode HMM s'avère plus performante puisque les valeurs d'ALE obtenues sont toujours les plus petites.

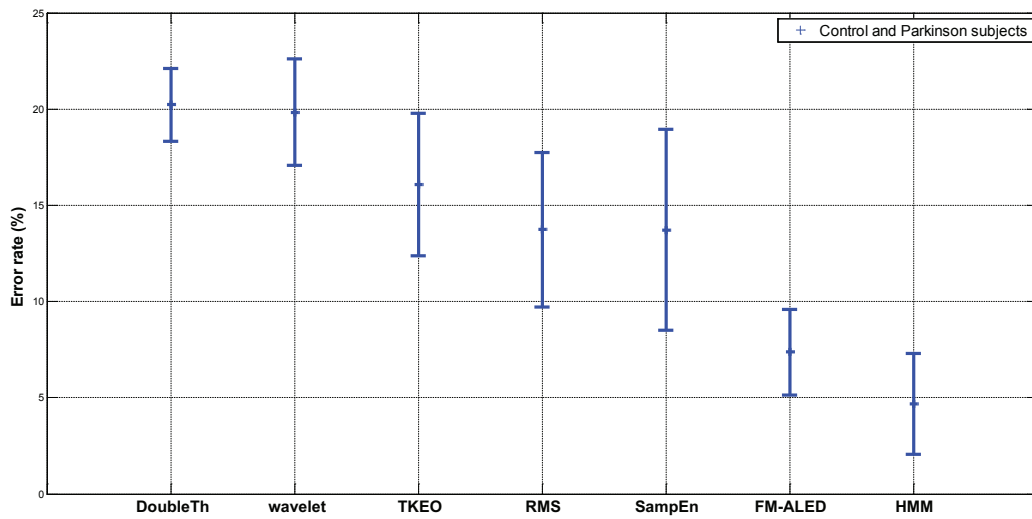


FIGURE 2.15 – Comparaison de taux d'erreur Re moyen et l'écart type pour le muscle **RSol soléaire** droite pour les sujets sains et Parkinsoniens.

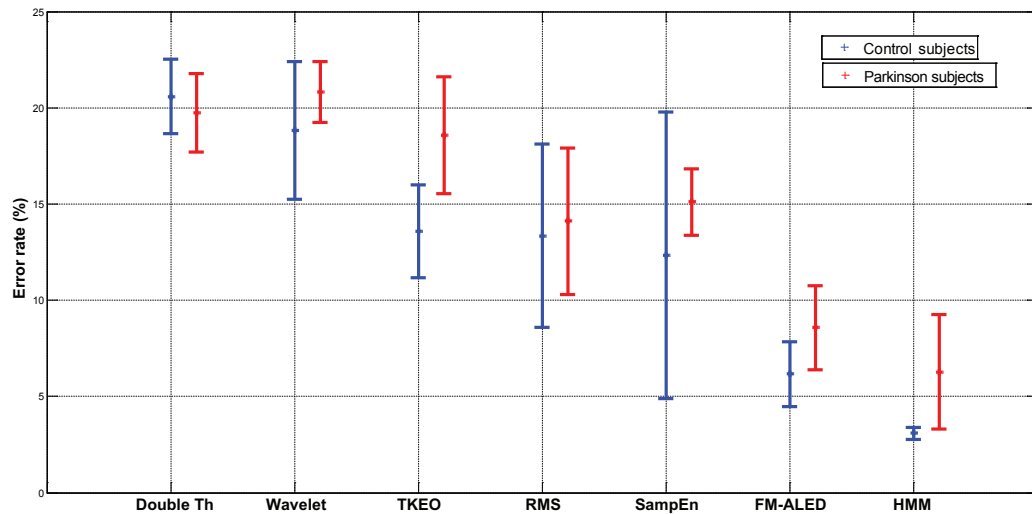


FIGURE 2.16 – Comparaison de taux d'erreur Re avec la moyenne et l'écart type pour le muscle **RSol soléaire** droite pour les sujets sains et Parkinsoniens.

Subject		Durée réelle de bouffées	DoubleTh	Wavelet	TKEO	RMS	SampEn	FM-ALED	HMM
Durée estimée de bouffées pour le sujet <i>Control₆</i>	Moyenne (ms)	1031.70	209.47	604.67	549.00	904.29	891.00	986.47	1003.70
	STD (ms)	73.52	157.85	434.41	604.15	394.28	520.51	128.60	57.24
	Nombre	6	19	9	14	7	8	6	6
Performance pour le sujet <i>Control₆</i>	ALE (ms)	//	822.22	427.03	482.70	127.41	140.07	45.18	27.95
	Moyenne (ms)	766.20	281.18	327.46	284.20	300.88	327.55	667.56	719.77
Durée estimée de bouffées pour le sujet <i>Park₅</i>	STD (ms)	53.10	201.96	180.38	177.59	281.33	105.15	16.33	125.03
	Nombre	10	17	13	15	34	11	9	10
	ALE (ms)	//	485.02	438.73	482.00	465.31	438.65	98.64	46.43

TABLE 2.13 – Comparaison : moyenne, écart type (STD) et erreur absolue de latence (ALE) de durées de bouffées d'activités EMG pour le muscle **RSol soléaire** droite de sujets *Control₆* et *Park₅*.

2.7 Discussion

dans ce paragraphe, nous abordons une phase qui constitue une nouvelle étape vers le développement d'une solution de segmentation automatique efficace. Cette dernière est une tâche importante dans le traitement et l'exploitation de données brutes des signaux EMGs, qui sont nécessaires au développement de systèmes d'aide au diagnostic de la maladie de Parkinson. Les approches proposées constituent une nette amélioration de la détection d'activité EMG puisque réalisées sur l'ensemble des données réelles du projet ECOTECH. Nous résumons et discutons ici les principales améliorations apportées et soulignons certaines perspectives pour ce travail :

- Pour la méthode ALED, nous avons utilisé des signaux EMGs synthétiques. Nous avons d'abord montré la faisabilité de la méthode dans le cadre d'une segmentation efficace du signal EMG. Enfin, nous avons mis en évidence son potentiel par rapport aux méthodes existantes dans la littérature.
- Les méthodes de type ALED ont été appliquées sur de signaux EMG des surface de sujets saints. Les performances de détection obtenues en termes de taux d'erreur sont supérieures à celles des méthodes existantes dans la littérature.
- Nous avons appliqué les méthodes proposées pour la segmentation du signal EMG chez les sujets parkinsoniens. Nous avons alors obtenu un gain en performance significatif, ainsi qu'une robustesse des méthodes dans un scénario totalement défavorable.
- La méthode FM-ALED est recommandée lorsqu'une première estimation fiable du niveau de bruit est disponible. Dans le cas contraire, l'utilisation de la méthode FOM-ALED est recommandée.
- Les valeurs du paramètre d'adaptation P utilisées sont obtenues des travaux menés sur des signaux de parole. Il serait alors souhaitable d'adapter ces valeurs aux si-

gnaux EMG afin d'améliorer davantage les performances

- Pour l'approche HMM, plusieurs expériences ont été menées pour trouver la configuration optimale du système de segmentation qui donne les meilleures performances en termes de précision (*Acc*) et de taux d'erreur (*Re*). Les résultats ont montré de nettes améliorations des performances du système.
- L'analyse DWT présente de meilleurs par rapport à l'analyse LPC quelque soit le type de descripteur d'ondelettes (DWE, LWE et WCC). Cette analyse donne une précision de 100%. En particulier, le descripteur LWE s'avère plus approprié pour cette tâche. Ces résultats sont obtenus en prenant la meilleure configuration des modèles HMM à : 2 états associés chacun à un modèle GMM de 3 composantes gaussiennes, une fenêtre d'analyse de 66.45 ms et un taux d'erreur d'environ 5% et ce quelque soit la famille de l'ondelette mère. Par ailleurs, il faut souligner que le niveau de décomposition optimal diminue en augmentant l'ordre de la famille d'ondelettes de Daubechies (également vrai pour les autres familles). Cela peut être expliqué par le fait que la longueur du filtre associée augmente avec l'ordre de Daubechies. En effet, pour les premiers ordres de Daubechies, les longueurs de filtre sont assez petite restant, tout de même, applicable au filtrage avec un petit nombre d'échantillons de données de niveaux de décomposition les plus profonds. Inversement, lorsque l'ordre augmente, la longueur du filtre augmente nécessitant ainsi des données avec un plus grand nombre d'échantillons limitant ainsi les valeurs du niveau de décomposition à 4. Les résultats expérimentaux montrent que la fonction ondelette de Coiflet avec décomposition de niveau 4 présente le meilleur taux d'erreur de 4,68%. Les Sym 2 et Db 6 donnent également de bonnes performances.
- Les performances de segmentation obtenues en termes de taux d'erreur, d'erreur de latence absolue et de nombre de bouffées d'activité EMG sont beaucoup plus intéressante que celles des méthodes existantes. Il résulte des nombreuses expériences menées la capacité de la méthode proposée à estimer correctement le nombre de bouffées EMG quelque soit le sujet étudié
- La technique HMM proposée est la plus appropriée pour la segmentation du signal EMG de sujets sains.
- Dans cette étude, nous avons utilisé la transformée en ondelettes discrète comme descripteur de caractéristiques car cette décomposition est plus adaptée que la décomposition de Fourier pour extraire les informations impulsives des potentiels d'action des unités motrices (à condition que l'ondelette mère soit bien sélectionnée).

- La méthode HMM proposée est robuste quand au choix du type d'ondelettes mères (un taux d'erreur proche de 5% et une précision de classification proche de 98% pour toutes les familles d'ondelettes testées).

2.8 Conclusion

La détection de bouffées d'activité électromyographique du muscle squelettique humain a d'importantes applications cliniques. Le présent chapitre décrit deux nouvelles approches pour résoudre le problème de la détection de l'activité musculaire. La première technique proposée (FM-ALED) offre de bonnes performances de calcul et de détection adaptées aux applications cliniques (pour différents scénarios défavorables) par rapport aux méthodes de l'état de l'art. La deuxième approche supervisée, est basé les modèles de Markov cachés combinés à une analyse DWT. Différents descripteurs extraits de cette analyse ont été utilisés et les résultats ont montré que les modèles HMM combinés avec le descripteur LWE extrait en utilisant le Coiflet 5 avec le niveau de décomposition 4 donnent les meilleures performances en termes de précision Acc et de taux d'erreur (Re). Une étude comparative avec FM-ALED et d'autre méthodes de l'état de l'art confirment la supériorité de l'approche HMM. L'approche HMM proposée offre une bonne performance de détection adaptée aux applications cliniques. Elle peut être un outil utile pour analyser les signaux EMG enregistrés lors de l'évaluation de l'ajustement postural des patients souffrant de la maladie de Parkinson. Une fois nous avons pu estimer les durées de bouffées d'activité électromyographique, nous allons introduire dans le prochain chapitre la notion de classification des ces bouffées détectés.

CHAPITRE 3

DIAGNOSTIC DE LA MALADIE DE PARKINSON BASÉ SUR LE SIGNAL EMG DE SURFACE

Contents

3.1	Introduction	79
3.2	Diagnostic de la MP en utilisant les bouffées d'activité EMG	81
3.2.1	Méthodologie de classification	81
3.2.2	Mesures de la précision de classification et la règle de vote majoritaire	94
3.2.3	Résultats et discussion	96
3.3	Diagnostic de la MP par les modèles HMM	103
3.3.1	Méthodologie de diagnostic et de classification	104
3.4	Résultats et discussion	106
3.5	Conclusion	109

3.1 Introduction

La maladie de Parkinson (MP) est une maladie neurodégénérative due à la dégénérescence dopaminergique. Cette maladie est définie cliniquement par des troubles moteurs, des troubles de mouvements et de la perte de contrôle postural. Elle est caractérisée par plusieurs symptômes : freezing, instabilité postural et trouble de la marche, tremblement de repos, rigidité, Akinésie et Bradykinésie.

Le diagnostic de la MP n'est pas toujours facile à établir. Ce dernier repose généralement sur l'examen neurologique fait par le médecin et les symptômes décrits par le patient. Plusieurs travaux de recherche sont effectués pour l'analyse, l'évaluation et l'identification de la MP en utilisant plusieurs approches telles que : l'écriture manuscrite (en anglais Hand writing) [16], l'analyse et l'évaluation de la marche à travers l'enregistrement des intervalles de foulées [17, 18, 19, 20], l'analyse de la voix (en anglais voice analysis) [21], l'imagerie médicale [22, 23], l'analyse des signaux d'électrovestibulographie (EVestG) qui sont en fait la réponse vestibulaire modulée par des signaux cérébraux corticaux [24] et enfin l'analyse de la marche en utilisant les signaux EMG de surface qui font l'objet de la présente thèse [25, 26, 27].

Dans cette thèse, les enregistrements des signaux EMGs des muscles des membres inférieurs sont considérés comme un moyen de caractérisation de la marche des patients. Ces signaux EMGs sont utilisés pour analyser et diagnostiquer la MP. Les signaux EMG sont toujours utilisés dans l'évaluation et le diagnostic du dysfonctionnement neuromusculaire.

La problématique de classification et le diagnostic des maladies neurodégénérative y compris la MP, est fortement liée aux techniques d'extraction des caractéristiques et à celles de classification, principalement développées dans le cadre de l'analyse de la marche [168, 169, 170, 171]. Dans [172], Il a été présenté que les fluctuations de l'intervalle de foulée sont augmentées dans la MP et sont corrélées au degré de gravité de la maladie. Dans [173], les auteurs ont montré que la variabilité du signal EMG enregistré à partir du muscle astrocnémien est plus élevé chez les patients Parkinsoniens. Dans [174], les auteurs ont proposé une classification multiclasse, pour indiquer le niveau de gravité de la MP (légère, modérée, sévère) à la fois la transformation empirique en ondelettes (EWT) et la transformation empirique de paquets en ondelettes (EWPT) sur des signaux de mouvements et les signaux audio. Dans [175], les auteurs ont proposé la classification de la MP par la combinaison des enregistrements de la voix et des signaux EMG en utilisant un système d'inférence neuro-floue adaptatif (en anglais Adaptive Neuro-Fuzzy Inference System : ANFIS) et les

réseaux de neurones artificiels (en anglais Artificial Neural Network : ANN). Dans [176], les auteurs ont utilisé le signal EEG en combinant les spectres d'ordre supérieur (HOS) avec quelques techniques de classification k-plus proches voisins floue (en anglais fuzzy K-nearest neighbor :FKNN), k plus proches voisins (en anglais K-nearest neighbor :KNN) et l'approche naïve bayes (en anglais NB). Dans [25], l'ANN est combiné avec les coefficients de prédiction linéaire (LPC) pour classer les troubles neuromusculaires (myopathique et neuropathiques).

Le présent chapitre présente deux systèmes d'aide au diagnostic. Le premier concerne un système de diagnostic de la MP basé sur les bouffées d'activité EMG, détectées et extraites par les méthodes de segmentation développées dans le deuxième chapitre¹. Le second système est basé sur l'utilisation de la technique HMM, dans le cadre de la segmentation et le diagnostic à la fois. Pour rappel, les HMM ont déjà été utilisés dans le deuxième chapitre dans le cadre de la détection de l'activité EMG. Dans le premier système de diagnostic, nous allons évaluer les performances de quelques méthodes de diagnostic et de classification existantes dans la littérature à savoir KNN, l'analyse discriminante linéaire (en anglais Linear Discriminant Analysis : LDA), les ANN, la méthode des machines à vecteurs de support (en anglais support vector machine :SVM) et le modèle de mélange de gaussiennes (en anglais Gaussian Mixture Model : GMM). Le deuxième système proposé d'utiliser les HMM pour distinguer les signaux EMG de sujets sains (normaux) à des signaux EMG anormaux (Parkinson).

Les deux systèmes proposés utilisent les caractéristiques ou attributs" (en anglais features) extraites à partir des signaux EMGs enregistrés dans le cadre du projet ECOTECH [28]. Les techniques d'extractions utilisées dans ce chapitre sont les coefficients LP, les coefficients de prédiction linéaire fractionnaire (en anglais fractional linear prediction FLP) (Voir Annexe D pour plus de détails, la DWT, le LWE et le WCC calculé à partir de la transformée en cosinus discrète (DCT) de LWE. A cet effet, notre tâche principale consiste à rechercher les paramètres optimaux de chaque système pour obtenir les meilleures performances de classification. Les méthodes proposées sont réalisées en deux phases, à savoir : la phase d'apprentissage et la phase d'évaluation et de test. La première phase consiste à modéliser les modèles des différentes classes, alors que la phase de test consiste à évaluer les performances du système de diagnostic. Les deux phases exigent une étape d'extraction de paramètres utiles, non redondants pour la tâche de classification.

Cela étant, le présent chapitre s'inscrit dans le cadre de diagnostic et de la classification

1. La méthodes ALED avec ses versions et l'approche HMM.

de la MP basés sur les signaux EMG de surface. Aussi afin de mieux cerner cette problématique, nous articulons le présent chapitre autour de deux parties suivantes :

- La section 3.2 présente le premier système de diagnostic de la MP basé sur les bouffées d'activité dans lequel nous utilisons quelques techniques de classification combinées avec des techniques d'extraction, existantes dans la littérature. Pour cela nous allons présenter la méthodologie de classification adoptée et la construction de la base de données des signaux EMG de surface. Ensuite, nous décrivons la phase de pré-traitement, qui consiste en l'extraction des bouffées d'activité EMG en utilisant les méthodes de segmentation développées dans le deuxième chapitre. Ensuite, nous allons présenter un aperçu sur les différents attributs utilisés dans l'analyse de signaux EMG et nous abordons très brièvement quelques méthodes de classification existantes dans la littérature. Enfin, nous présentons l'outil d'évaluation de performances et la règle de vote majoritaire et nous discutons les résultats obtenus.
- La section 3.3 est réservée au deuxième système proposé, qui est basé sur les modèles HMM. La méthodologie de diagnostic adoptée dans ce système y est présentée et une analyse des performances de diagnostic et de classification du système y est présentée.
- La section 3.5 est réservée aux remarques finales.

3.2 Diagnostic de la MP en utilisant les bouffées d'activité EMG

Dans ce paragraphe, nous allons présenter le système de diagnostic de la MP basé sur l'utilisation des bouffées d'activité EMG, extraites dans le chapitre 1. Dans ce système, nous utilisons quelques techniques de classification existantes dans la littérature. Celles-ci sont combinées avec des méthodes d'extraction des attributs.

3.2.1 Méthodologie de classification

Tout signal EMG de surface contient des segments inactifs (région de bruit) et des segments actifs (bouffées d'activité EMG) qui sont principalement composés du PAUM. Il existe principalement trois types de paramètres qui caractérisent la forme d'onde de PAUM tels que : l'amplitude, la durée et la stabilité. Ces paramètres fournissent des informations sur certaines caractéristiques spatiales et temporelles de l'activité des FM et des UM. Dans des

conditions normales, les PAUM montrent des amplitudes moyennes crête à crête d'environ 0,5 mV et une durée de 8 à 14 ms, selon la taille des UM. Dans les troubles neurogènes, l'amplitude est augmentée pour atteindre 5 à 10 fois la normale et la durée est également augmentée [177]. La taille et la forme des PAUM sont déterminées par certains aspects structurels et fonctionnels des MUs [178]. Dans ce paragraphe, les bouffées d'activité EMG (segments actifs) sont détectées et sélectionnées pour utilisation dans le diagnostic de la MP. Ces segments sont extraits à l'aide des techniques ALED (avec ses versions) et HMM. La méthodologie de diagnostic adoptée dans cette thèse est présentée dans la Fig.3.1. Nous trouvons principalement les étapes suivantes :

- (1) Construction d'une base de données pour la préparation d'une base de données d'apprentissage et une base de données de test.
- (2) Pré-traitement du signal (segmentation et détection des bouffées d'activité EMG) ;
- (3) Extraction des caractéristiques ;
- (4) Apprentissage des modèles ;
- (5) Classification et diagnostic.

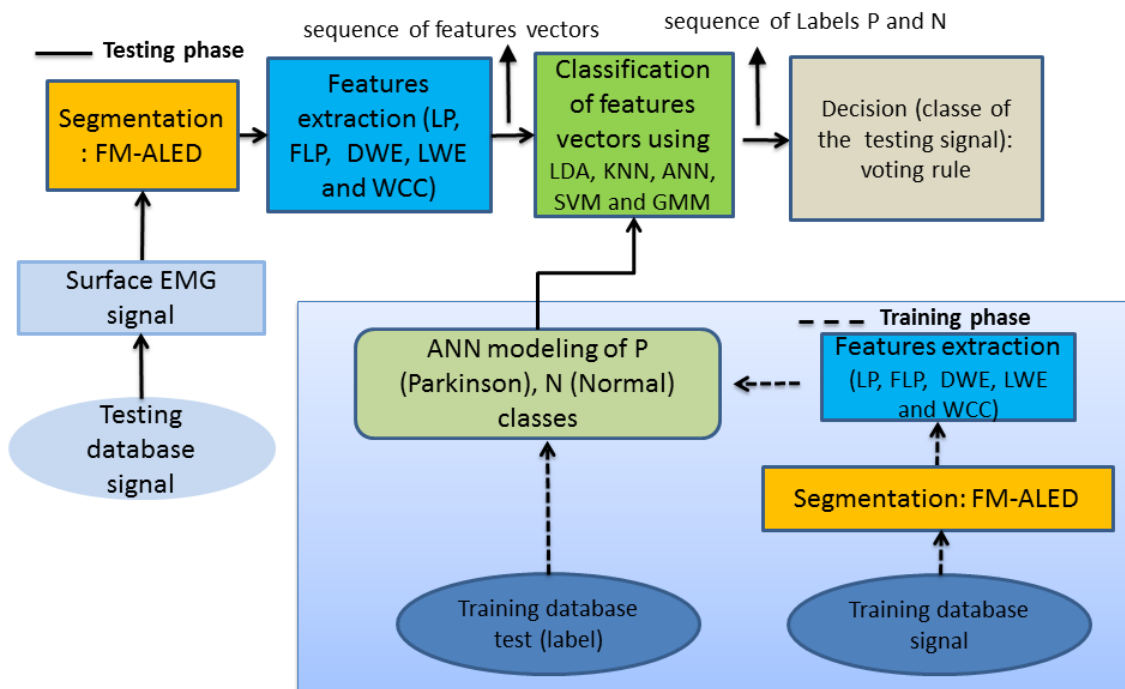


FIGURE 3.1 – Méthodologie adoptée de diagnostic et d'analyse de performances.

a). **Construction d’une base de données :**

Une des tâches essentielles de la classification est la réalisation d’une base de données assez riche et assez large. Dans cette thèse, nous utilisons la base de données réalisée dans le cadre du projet ECOTECH [28]. Celle-ci est composée de sujets sains et de patients parkinsoniens. Le détail de cette base de données est décrite dans l’annexe A. Pour la construction de cette base, des capteurs EMG sont placés sur le ventre musculaire parallèlement à la direction principale des FM conformément à l’étude sur la zone d’innervation [163]. Les données sont collectées à l’aide d’un système embarqué de capteurs portables (bande passante de 20 à 450 Hz, 16 bits par échantillon, fréquence d’échantillonnage de 1926 Hz). La collecte de données fournit plusieurs bouffées d’activités EMG du muscle soléaire droit correspondant à plusieurs cycles de marche.

Cela étant dans tout travail de classification, une partie de cette base de données est consacrée à la phase d’apprentissage tandis que la deuxième partie est utilisée pour effectuer les tests et mesurer les performances, telles qu’indiquées dans les tables 3.1 et 3.2.

Subjects		Nombre de bouffées d’activité EMG	Durée du signal (seconde)
Base de données pour phase d’apprentissage	<i>Control</i> ₁	22	26.0685
	<i>Control</i> ₂	10	11.2128
	<i>Control</i> ₃	11	14.3998
	<i>Control</i> ₄	11	14.7441
Base de données pour phase de test	<i>Control</i> ₅	11	11.1635
	<i>Control</i> ₆	6	7.7121
	<i>Control</i> ₇	6	6.5298
	<i>Control</i> ₈	12	14.3458
	<i>Control</i> ₉	26	28.5702

TABLE 3.1 – Description des signaux EMGs pour les sujets de contrôle.

Subjects		Nombre de bouffées d’activité EMG	Durée du signal (seconde)
Base de données pour phase d’apprentissage	<i>Park</i> ₁	10	28.5702
	<i>Park</i> ₂	10	9.1317
	<i>Park</i> ₃	5	4.8657
	<i>Park</i> ₄	37	39.6152
Base de données pour phase de test	<i>Park</i> ₅	10	11.2876
	<i>Park</i> ₆	9	8.9152
	<i>Park</i> ₇	5	4.4742
	<i>Park</i> ₈	5	4.6487

TABLE 3.2 – Description des signaux EMGs pour les sujets Parkinsoniens.

b). **Pré-traitement des signaux EMGs :**

Plusieurs techniques peuvent être utilisées pour le prétraitement des données avant

l'étape d'extraction des caractéristiques. Nous pouvons citer : la segmentation du signal, le filtrage et la rectification des données. Dans le présent chapitre, nous utilisons la segmentation et la détection des zones d'activité (bouffées d'activité) EMG de signaux EMG de surface comme étape de pré-traitement. Celle-ci est mise en œuvre grâce aux méthodes ALED (et ses différentes versions) et les HMM. Chaque bouffée d'activité EMG est convertie en une séquence de vecteurs des caractéristiques en utilisant une des méthodes d'extraction. Ensuite l'ensemble des séquences extraites correspondant à un signal d'entrée sont concaténées pour procéder à l'étape de classification du signal. Cette dernière étape consiste à classifier chaque vecteur des caractéristiques pour obtenir la séquence d'indices de classes correspondant au signal d'entrée, ensuite la règle de vote majoritaire est appliquée pour obtenir l'indice de classes dominant, considéré comme la classe finale du signal.

c). **Extraction d'attributs discriminants et la modélisation du signal EMG**

L'extraction des attributs joue un rôle essentiel pour obtenir un système de classification robuste. Ce processus transforme le signal EMG de surface brut en un vecteur ou une séquence de vecteurs des caractéristiques, obtenue par un calcul simple ou complexe. Généralement, les caractéristiques utilisées dans l'analyse des signaux EMG peuvent être catégorisées en :

- **Attributs temporels** : parmi ces attributs, nous pouvons citer : les coefficients LPC [53], l'erreur quadratique moyenne (en anglais Mean Square MS)[57, 58, 55, 59], Le taux de passage par zéro (en anglais Zero Crossing Rate ZCR)[55, 61, 53], le Kurtosis [54], la valeur absolue moyenne (en anglais Mean Absolute Value MAV) [57, 55, 61, 59, 53], l'histogramme [53], les coefficients cepstraux [55, 55], la variance [53], l'amplitude maximale MAX [57], l'écart type (en anglais Standard deviation SD) [57, 61, 59];
- **Attributs fréquentiels** : parmi ces attributs, nous pouvons citer : la fréquence moyenne (en anglais Mean frequency MNF) [55, 179], la fréquence médiane (en anglais Median frequency MDF) [55, 179];
- **Attributs temps-fréquence** : parmi ces attributs, nous pouvons citer : la DWT [63], la CWT [180], la décomposition en mode empirique (en anglais Empirical Mode Decomposition EMD) [180], la transformation de paquets d'ondelettes (en anglais Wavelet Packet Transform WPT) [63, 63], la transformation de Fourier à court terme (en anglais Short Time Fourier transform STFT) [62], les énergies des coefficients d'ondelettes normalisées (DWE) de la DWT, le LWE et le WCC [8].

Remarque : Il existe aussi un autre type d'attribut, appelé attribut spatial, qui est le périodogramme expérimental (en anglais experimental periodogram) [181].

Dans le présent chapitre, nous avons utilisé les descripteurs LPC, FLP, DWE, LWE et WCC. La Fig.3.2 illustre la procédure d'extraction des attributs. En outre, dans le

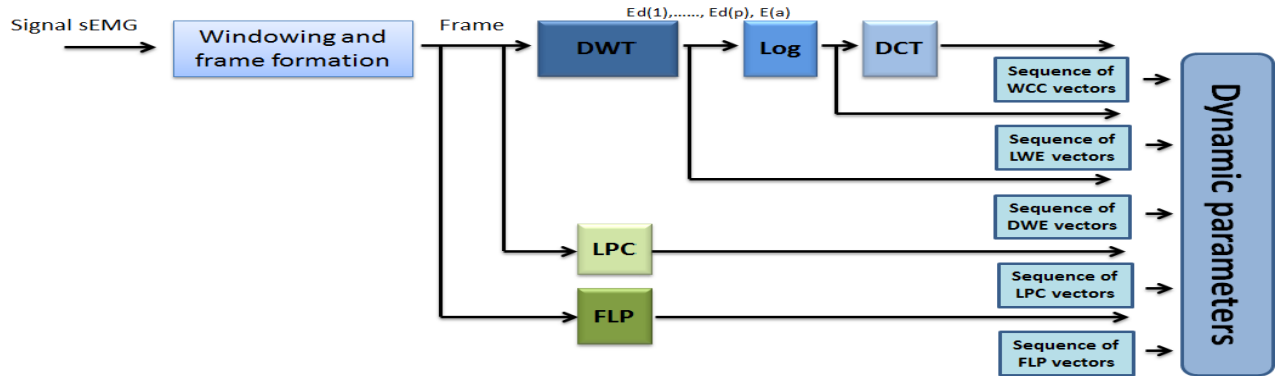


FIGURE 3.2 – Processus d'extraction des attributs

présent chapitre, nous intégrons les paramètres dynamiques qui sont les coefficients différentiels de premier ordre (appelés aussi delta Δ) et de deuxième ordre (appelés delta-delta $\Delta\Delta$), issus des coefficients initialement calculés LPC, FLP, DWE, LWE et WCC. Ces derniers sont considérés comme des paramètres statiques, ils contiennent seulement l'information sur une trame donnée. Afin d'améliorer la représentation de la trame, il est souvent proposé d'introduire de nouveaux paramètres dans le vecteur des paramètres, généralement les paramètres dynamiques. Dans [182] et [183], l'auteur propose l'utilisation des paramètres dynamiques qui présentent l'information de transition spectrale dans le signal.

Soit $C_k(t)$ l'attribut d'indice k de la trame t , alors le coefficient différentiel ΔC_k correspondant est calculé sur $2\eta_\Delta$ trames d'analyse par l'estimation de la pente de la régression linéaire du coefficient C_k à l'instant t [184] :

$$\Delta C_k(t) = \frac{\sum_{i=-\eta_\Delta}^{i=+\eta_\Delta} i \cdot C_k(t+i)}{2 \cdot \sum_{i=-\eta_\Delta}^{i=+\eta_\Delta} i^2} \quad (3.1)$$

Le coefficient delta de l'énergie Δ est calculé de la même façon. Les coefficients différentiels du second ordre $\Delta\Delta$ (delta-delta ou d'accélération) sont calculés de la même manière à partir des coefficients du premier ordre.

d). **Classification et construction de modèles :**

D'une manière générale, les modèles de classification automatique sont des systèmes qui consistent à prévoir un état, généralement, décrit par une variable discrète, au moyen d'une analyse et d'un traitement de données stockées. Ces dernières font l'objet d'une base de données élaborée au cours de longues périodes d'exploitation. Ces données sont utilisées par des techniques d'apprentissage pour extraire des informations et des connaissances appropriées très précieuses. L'apprentissage utilisant des modèles de classification est un type d'intelligence artificielle qui peut jouer un rôle essentiel dans l'exploration des données. Il utilise des informations extraites ayant des entrées et des sorties, pour apprendre et créer une fonction automatique qui déduit les sorties à partir des entrées. La fonction créée peut être appliquée sur de nouvelles données, afin de spécifier leur sortie. Dans la littérature, il existe plusieurs modèles de classification qui dépendent de l'application à traiter. Dans la suite, nous allons introduire certains méthodes de classification utilisés dans ce chapitre.

d.1). **Analyse discriminante linéaire (LDA) :** la LDA est une technique de transformation linéaire qui est couramment utilisée pour la réduction de la dimension dans l'étape de prétraitement pour la classification des modèles et les applications d'apprentissage par machine [185]. L'objectif est de projeter un ensemble de données sur un espace de dimension inférieure avec une bonne séparabilité de classe afin de réduire les coûts de calcul. L'analyse discriminante linéaire a été décrite initialement par Ronald A. Fisher en 1936 [186] pour un problème de 2 classes, puis elle a ensuite été généralisée comme LDA multi-classe par C. R. Rao en 1948 [187]. Les 5 étapes caractérisant LDA se résument comme suit :

1. Estimer les moyennes d -dimensionnelles pour les différentes classes à partir de l'ensemble de données ;
2. Calculer les matrices de dispersion intra-classes et inter-classes ;
3. Calculer les vecteurs propres (e_1, e_2, \dots, e_d) et les valeurs propres correspondantes ($\lambda_1, \lambda_2, \dots, \lambda_d$) pour les matrices de dispersion ;
4. Trier les vecteurs propres par ordre de valeurs propres décroissantes et choisir les k premiers vecteurs propres correspondants pour construire une matrice W de dimension $d \times k$;
5. Utiliser cette matrice de vecteurs propres pour transformer les échantillons sur le nouveau sous-espace. Ceci peut être résumé par la multiplication matricielle : $Y = X \times W$ (où X est une matrice $n \times d$ représentant les n observations,

et Y est l'échantillon de taille $n \times k$ transformés dans le nouveau sous-espace). En utilisant la fonction de distribution gaussienne et en simplifiant, nous finissons avec l'équation ci-dessous. C'est ce que nous appelons une fonction discriminante dont la valeur maximale détermine la classe de sortie (Y) :

$$D_k(x) = x' \left(\sum \mu_k \right)^{-1} - \frac{1}{2} \mu_k' \left(\sum \mu_k \right)^{-1} + \ln \pi_k \quad (3.2)$$

$D_k(x)$ est la fonction de discrimination pour la classe k étant donnée x , μ_k , $(\sum)^{-1}$ et π_k sont tous estimés à partir des données.

d.2). **Machines à vecteurs de support (SVM)** : les SVM sont des modèles d'apprentissage supervisés. A l'origine, les SVM sont conçus pour résoudre un problème de classification binaire et permettent de construire un classifieur linéaire non probabiliste. Un SVM effectue la classification en construisant un hyperplan N -dimensionnel qui sépare de manière optimale les données en deux catégories [188].

Exemple : cas bidimensionnel. Supposons que nous souhaitons effectuer une classification et nos données ont une variable cible catégorielle avec deux catégories. Supposons également qu'il existe deux variables prédictives (attributs) avec des valeurs continues. Si nous traçons les points de données en utilisant la valeur d'un prédicteur sur l'axe des X et l'autre sur l'axe des Y , nous pourrions finir avec une image telle qu'illustrée ci-dessous. Une catégorie de la variable cible est représentée par des rectangles tandis que l'autre catégorie est représentée par des ovals. Dans cet exemple idéal, les points d'une catégorie sont dans le




FIGURE 3.3 – hyperplan 1-dimensionnel qui sépare les cas en fonction de leurs catégories

coin inférieur gauche et les points de l'autre catégorie sont dans le coin supérieur droit ; Les points sont complètement séparés. L'analyse SVM tente de trouver un

hyperplan 1-dimensionnel (c'est-à-dire une ligne) qui sépare les points en fonction de leurs catégories cibles. Il existe un nombre infini de droites possibles, deux droites candidates sont indiquées ci-dessus. La question est de savoir quelle droite est la meilleure et comment définir la droite *optimale*. Les lignes pointillées dessinées parallèlement à la droite de séparation marquent la distance entre la droite de séparation et les vecteurs les plus proches de cette droite. La distance entre les lignes pointillées s'appelle la marge. Les vecteurs (points) qui limitent la largeur de la marge sont les vecteurs supports. Ceci est illustré par la Fig.3.4. Une analyse SVM trouve la droite (ou, en général, l'hyperplan) orientée de sorte




FIGURE 3.4 – marge optimisée entre les vecteurs supports

que la marge entre les vecteurs supports soit optimisée. Dans la Fig.3.4, la marge du panneau droit est supérieure à la marge dans le panneau de gauche. Malheureusement, toutes les analyses ne se composent pas de variables cibles à deux catégories avec deux variables prédictives, et le groupe de points pourrait être divisé par une autre courbe qu'une droite. Donc un SVM doit traiter :

- Plus de deux variables prédictives ;
- Séparer les points par des courbes non linéaires ;
- Traiter les cas où les grappes ne peuvent pas être complètement séparées ;
- Gérer les classifications avec plus de deux catégories.

Si nous avons trois variables prédictives, nous pouvons tracer les points dans un cube tridimensionnel. Les points sur un plan bidimensionnel peuvent être séparés par une ligne. De même, les points d'un cube tridimensionnel peuvent être séparés par un plan bidimensionnel. Lorsque nous ajoutons des variables prédictives supplémentaires (attributs), les points de données peuvent être représentés dans l'espace N-dimensionnel, et un hyperplan numérique (N-1) peut les séparer. Le moyen le plus simple de diviser deux groupes est celui d'une ligne droite,

d'un plan plat ou d'un hyper-plan N-dimensionnel. Mais que faire si les points sont séparés par une région non linéaire telle qu'indiquée ci-dessous? Dans ce




FIGURE 3.5 – Points séparés par une région non linéaire.

cas, nous avons besoin d'une ligne de division non linéaire. Plutôt que d'ajuster les courbes non linéaires aux données, les SVM gèrent cela en utilisant une fonction noyau "Kernel" pour distribuer les données dans un espace différent où un hyperplan peut être utilisé pour effectuer la séparation.

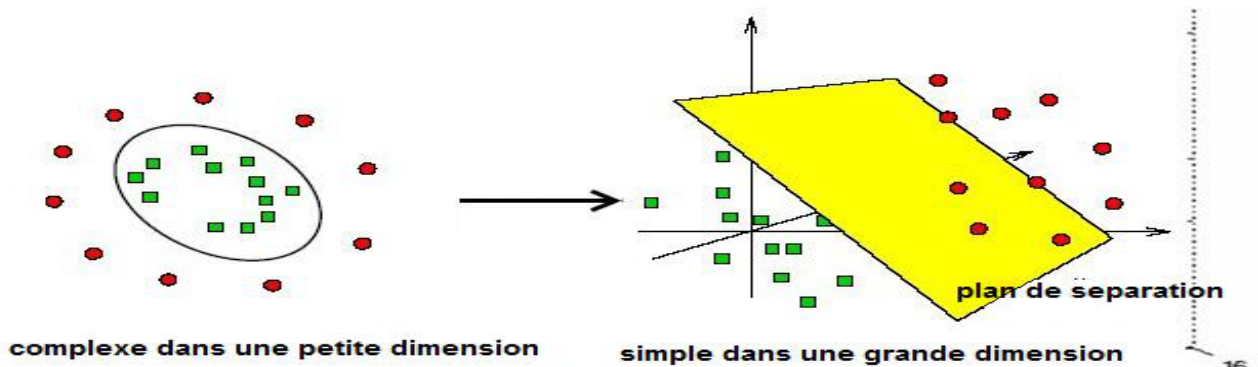


FIGURE 3.6 – Séparations avec des limites très complexes.

Le concept d'une fonction de Kernel map est très puissant. Il permet aux modèles SVM d'effectuer des séparations même avec des limites très complexes telles que celles ci-dessus.

d.3). **Méthode de k plus proches voisins (KNN)** : l'algorithme des KNN appartient à la famille des algorithmes d'apprentissage automatique. La méthode des k-NN [189] se base sur une idée fondatrice simple, qui consiste en une comparaison directe entre le vecteur caractéristique de l'instance (nouvelle observation) à classer et les vecteurs des instances de la base d'apprentissage. La comparaison consiste en un calcul de distances entre ces instances. Puis, l'instance à classer est assignée la classe majoritaire parmi les classes des k instances les plus proches. Il

existe plusieurs distances employées par l'algorithme k-NN pour comparer deux instances, parmi ces métriques nous pouvons citer :

- Distance Euclidienne : $D(X_p, X_q) = \sqrt{\sum_{i=1}^n (x_{p_i} - x_{q_i})^2}$;
- Distance de Manhattan : $D(X_p, X_q) = \sum_{i=1}^n |x_{p_i} - x_{q_i}|$;
- Distance de Minkowski : $D(X_p, X_q) = \left(\sum_{i=1}^n (x_{p_i} - x_{q_i})^r \right)^{\frac{1}{r}}$;
- Distance de Tchebychev : $D(X_p, X_q) = \max_i |x_{p_i} - x_{q_i}|$ for $i = 1 : n$.

où $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$ le vecteur caractéristique de l'instance i , avec n le nombre de variables et par p et q deux instances à comparer.

Les principaux inconvénients de cette méthode sont le nombre d'opérations nécessaires pour classer une instance dans le cas d'une grande base d'apprentissage ainsi que sa sensibilité au bruit.




FIGURE 3.7 – K-plus proche voisin.

- d.4). **Modèle de mélange de gaussiennes (GMM)** : le modèle GMM a été introduit par Reynolds [190] et largement utilisé dans la reconnaissance de locuteur [191]. Puis, cette méthode a été exploitée pour classer la position de la main [192] et également utilisée dans la détection de l'activité musculaire EMG [51]. Un GMM est une fonction de densité de probabilité paramétrique qui peut être représentée comme une somme pondérée des densités des composants gaussiens. Les paramètres GMM sont estimés à l'aide de l'algorithme itératif d'expectation-maximisation (EM) ou de l'estimation maximale a posteriori (MAP)
- Dans la suite, nous donnons une vue d'ensemble sur la méthode en question qui est bien connue dans la littérature. Un modèle de mélange gaussien de M com-

posantes gaussiennes, est donné par l'équation suivante :

$$p(x/\Omega_q) = \sum_{m=1}^M w_{m,q} b_{m,q}(x) \quad (3.3)$$

où x est le vecteur d'attributs, Ω_q est la q^{eme} classe, $w_{m,q}$ sont des pondérations scalaires positives satisfaisant la relation $\sum_{m=1}^M w_{m,q} = 1$. Les $b_{m,q}$ sont les composantes gaussiennes de mélange. Ces composantes s'écrivent par l'équation :

$$b_{m,q}(x) = \frac{1}{(2\pi)^{\frac{1}{2}} |\Sigma_{m,q}|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} (x - \mu_{m,q})^T (\Sigma_{m,q})^{-1} (x - \mu_{m,q}) \right\} \quad (3.4)$$

où $\mu_{m,q}$ et $\Sigma_{m,q}$ sont, respectivement, le vecteur de moyennes et la matrice de covariance associées à $b_{m,q}(x)$. Les paramètres $\left\{ w_{m,q}, \mu_{m,q}, \Sigma_{m,q} \right\}_{m=1 \dots M}$ de chaque classe Ω_q sont estimés en utilisant l'algorithme *EM* (Expectation Maximization) [193]. Pour les GMM, nous calculons la densité de probabilité de chaque classe sous forme d'un GMM comme indiqué dans l'équation (3.3). Par conséquent, nous divisons la base de données en deux parties. Une partie est réservée à la phase d'apprentissage et l'autre partie est utilisée pour la phase de test. La phase d'apprentissage consiste en l'exécution de l'algorithme EM pour chaque classe Ω_q afin d'avoir les paramètres $\left\{ w_{m,q}, \mu_{m,q}, \Sigma_{m,q} / m = 1, \dots, M \right\}$. Une fois ces paramètres sont estimés, la classification devient une tâche simple. Pour un vecteur d'attributs x , maximisant la k^{eme} densité de probabilité donnée dans l'équation (3.3), nous lui associons la k^{eme} classe Ω_k (par fois, on calcule $-10 \log(p(x/\Omega_k))$ pour prendre le minimum). La plupart du temps, les signaux traités sont non stationnaires. Ainsi, le vecteur d'attributs x devient une matrice d'attributs X . Dans ce cas, la classification se fait par le maximum de vraisemblance (MV). Ce dernier considère les colonnes de la matrice d'attributs X indépendantes. Donc, la densité de probabilité associée à la matrice d'attributs est le produit des densités associées à chacune de ses colonnes la constituant. Cette densité est la suivante :

$$p(X/\Omega_i) = \prod_{l=1}^N p(x_l/\Omega_i) \quad (3.5)$$

où x_l est la l^{eme} colonne de la matrice d'attributs X . Par conséquent, la matrice d'attributs X , maximisant la q^{eme} densité de probabilité donnée dans l'équation

(3.5), est associée à la q^{eme} classe Ω_q .

d.5). **Réseau de neurones artificiel (ANN)** : l'idée d'un ANN est inspirée du système cérébral et son fonctionnement en établissant des bonnes connexions, pour construire un ANN. Le cerveau humain est composé d'environ 100 milliards de cellules nerveuses appelées neurones [194]. Ils sont connectés à d'autres milliers de cellules par les axones. Les entrées des organes sensoriels provenant de l'environnement externe sont acceptées par les dendrites. Ces entrées créent des impulsions électriques, qui traversent rapidement le réseau neuronal. Un neurone peut alors envoyer le message à un autre neurone et ainsi de suite. De la même façon, les ANN sont composés de plusieurs nœuds appelés neurones qui imitent les neurones biologiques. Les neurones sont connectés par des liens et ils interagissent les uns avec les autres en leur associant des poids. Ils peuvent prendre des données d'entrée, effectuer des opérations simples puis transmettre le résultat à d'autres neurones. La sortie de chaque neurone est appelée sa valeur d'activation [195]. Les ANN sont capables d'apprendre, ce qui se produit en modifiant les valeurs de poids. La Fig.3.8 montre une illustration d'un ANN de type multicouches. Les nœuds d'entrées prennent des informations, sous la forme de




FIGURE 3.8 – Réseau de neurones artificiel simple

valeurs d'activation, où chaque nœud reçoit une valeur. Cette information est ensuite transmise dans tout le réseau. En fonction des forces de connexion (poids) et des fonctions de transfert, les valeurs d'activation sont propagées d'un nœud à un autre. Chacun des nœuds calcule un état interne qui dépend des valeurs d'activation reçues en entrée et des pondérations associées, puis transforme alors la valeur en appliquant la fonction de transfert. L'activation s'écoule à travers le

réseau, à travers des couches cachées, jusqu'à ce qu'elle atteigne les nœuds de sortie. Une distance entre la valeur de sortie prédite et la valeur réelle attendue, appelée erreur, est évaluée puis propagée en arrière sous la forme d'un gradient permettant de modifier les poids de chaque nœud en fonction de la quantité d'erreur dont le nœud est responsable. Il existe différents types de ANN, mais

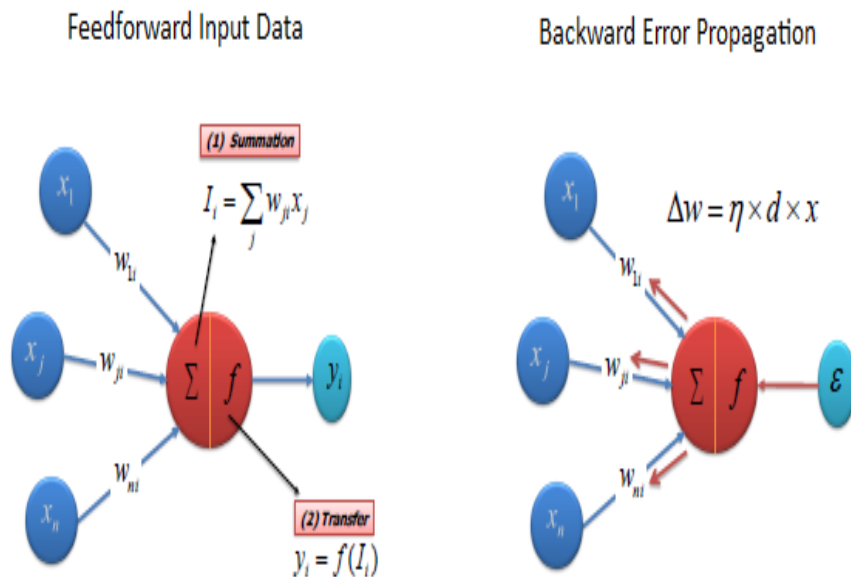


FIGURE 3.9 – Algorithme de calcul de la fonction de transfert

ils sont généralement classés dans les réseaux 'feed-forward' et 'feed-back' (voir Fig.3.9). Un réseau 'feed-forward' est un réseau non récurrent qui contient des entrées, des sorties et des couches cachées ; Les signaux ne peuvent circuler que dans une direction. Les données d'entrée sont transmises sur une couche d'éléments de traitement où elle effectue des calculs. Chaque élément de traitement fait son calcul basé sur une somme pondérée de ses entrées. Les nouvelles valeurs calculées deviennent alors les nouvelles valeurs d'entrée qui alimentent la couche suivante. Ce processus se poursuit jusqu'à ce qu'il ait parcouru toutes les couches et détermine la sortie. Une fonction de transfert de seuil est utilisée pour quantifier la sortie d'un neurone dans la couche de sortie. Les réseaux 'Feed-forward' contiennent les réseaux de base de type Perceptron (linéaire et non linéaire). Les réseaux avancés sont souvent utilisés dans l'exploration de données. Un réseau de type feed-back comporte des arcs qui peuvent transmettre des signaux dans les deux sens en utilisant des boucles. Toutes les connexions possibles entre les neu-

rones sont autorisées. Comme les boucles sont présentes dans ce type de réseau, ils deviennent un système dynamique non linéaire qui évolue continuellement jusqu'à atteindre un état d'équilibre, s'il existe. Les réseaux feed-back sont souvent utilisés dans des mémoires associatives et des problèmes d'optimisation où le réseau recherche le meilleur arrangement de facteurs interconnectés. La fonction de transfert traduit les signaux d'entrée en signaux de sortie. Quatre types de fonctions de transfert sont couramment utilisés : fonction seuil, sigmoïde, gaussien et linéaire.

Dans ce chapitre, les ANN sont utilisés avec une propagation de retour d'erreur qui est utilisée comme procédure d'apprentissage pour un réseau neuronal multi-couche à action directe. Grâce à ce processus, le réseau peut apprendre à mapper un ensemble d'entrées sur un ensemble de sorties. Dans ce chapitre, nous utilisons le vecteur des caractéristiques de taille réduite comme vecteur d'entrée. La meilleure configuration de couche cachée est obtenue à partir d'une série de tests de : 5, 10 et 20 neurones. La topologie du réseau est constituée d'une couche d'entrée contenant des neurones selon le nombre des caractéristiques, une couche cachée avec 5, 10 ou 20 neurones et un neurone de sortie correspondant aux patients parkinsoniens ou à des sujets sains (voir Fig.3.10). La fonction d'activation utilisée est la sigmoïde et l'algorithme Levenberg-Marquardt comme méthode d'apprentissage développer sur l'environnement Matlab.

3.2.2 Mesures de la précision de classification et la règle de vote majoritaire

Rappelant que chaque signal étiqueté est composé d'une séquence de régions d'activité EMG (préalablement segmentées manuellement ou automatiquement à partir des données brutes). Chaque région d'activité EMG est ensuite transformée en une séquence de vecteurs de caractéristiques (LPC, FLP, DME, LWE ou WCC) calculés à partir des trames d'analyse successives chevauchantes dont la durée temporelle peut varier. Dans ce chapitre, nous étudions l'ensemble de durées de trames d'analyse suivant 16.61, 20.00, 30.00, 33.22, 40.00, 50.00, 60.00, 66.45, 70.00, 80.00, 90.00, 100.00, 110.00, 120.00, 130.00, 132.91, 140.00, 150.00 exprimé en *ms*. Chaque valeur de durée est testée et le meilleur résultat de performance est conservé.

Les résultats de performance des méthodes de classification des signaux EMGs sont me-




FIGURE 3.10 – Exemple d’une topologie ANN.

surés en utilisant le taux de classification CR , qui peut être calculé différemment. Fondamentalement, chaque vecteur de caractéristiques est présenté comme entrée dans le classifieur ANN, KNN, SVM, LDA et GMM². La sortie du système prend une décision correcte ou non, en fonction de l’étiquette connue du signal. À partir de ces décisions individuelles, nous pouvons calculer les taux de classifications. Dans ce premier système de diagnostic, nous proposons d’évaluer les performances du système en tenant compte une mesure globale et une mesure détaillée, présentées comme suit :

- Pour la première mesure, nous calculons le taux de classification des vecteurs (CRV) (statiques ou dynamiques) de toute la base de données. Ce taux nous permet d’obtenir une mesure globale des performances de classification. Ce taux est calculé comme suit :

$$CRV = NvC/NvT \quad (3.6)$$

où NvC est le nombre des vecteurs des caractéristiques correctement classifiés et NvT est le nombre total des vecteurs des caractéristiques de la base de données.

- La méthode de règle de vote (en anglais voting rule) attribue la décision à l’étiquette de classe pour laquelle le nombre de décisions suit la règle de la majorité parmi

2. Nous avons fait varier le nombre de GMM de 2 à 10.

toutes les décisions ; les décisions peuvent être prises à partir de vecteurs de caractéristiques, de régions d'activité ou du signal entier en tant que concaténation de régions d'activité. Dans ce chapitre, la règle de vote pour les régions d'activité EMG est appliquée deux fois : d'abord pour caractériser des vecteurs pour chaque région d'activité EMG et ensuite pour les régions d'activité pour chaque signal ; la précision est le nombre de décisions correctes prises pour les signaux par le nombre total de signaux. Ce taux de classification nous permet d'obtenir une mesure détaillée des performances de diagnostic, ce taux est calculé comme suit :

$$CRS = N_{sC}/N_{sT} \quad (3.7)$$

où CRS est le taux de classification des signaux, N_{sC} est le nombre des signaux correctement classifiés et N_{sT} est le nombre total des signaux.

- La règle de vote majoritaire pour le signal EMGs est appliquée aux vecteurs de caractéristiques pour chaque signal ; le taux de classification est le nombre de décisions correctes prises pour les signaux par le nombre total de signaux. Ce taux de classification également nous permet d'obtenir une mesure détaillée en tenant compte la formule 3.7.

3.2.3 Résultats et discussion

Dans ce paragraphe, nous allons évaluer les performances de quelques méthodes existantes dans la littérature, présentées dans la section 3.2.1, sur la base de données ECHO-TECH étiquetée par un expert et deux bases de données segmentées par les méthodes de segmentation développées et présentées dans le chapitre 2. Dans un premier temps, nous allons évaluer les performances en combinant les dites méthodes de classification avec les différentes techniques d'extraction des caractéristiques adoptées dans ce chapitre. Plusieurs expériences sont menées pour trouver la configuration optimale qui donne les meilleures performances en suivant la méthodologie suivante :

- (1) Évaluation des performances des différentes méthodes de classification avec les différentes techniques d'extraction des caractéristiques sur la base de données ECHO-TECH préalablement étiquetée ;
- (2) Comparaison des performances des descripteurs LPC, FLP, DWE, DWE et WCC pour chaque technique de classification et recherche de la durée optimale de la trame d'analyse appropriée ;

- (3) Analyse des performances en tenant compte des paramètres dynamiques et la règle de vote majoritaire ;
- (4) Recherche de la meilleure combinaison entre l'ondelette mère et le niveau de décomposition ;
- (5) Étude de l'effet de la taille de base de données destinée à la phase d'apprentissage et à la phase de test ;
- (6) Analyse de l'effet de segmentation sur le diagnostic en étudiant les résultats de performance sur la base de données segmentée par les approches développées dans le deuxième chapitre.

a). **Comparaison des performances de différents descripteurs et classificateurs**

Dans ce paragraphe, nous allons étudier les performances des méthodes de classification et les différents descripteurs en termes de taux de classification CR et la durée de la trame d'analyse optimale. Pour chaque expérience, nous évaluons chaque méthode de classification pour chaque descripteur sans et avec les paramètres dynamiques, sans et avec l'application de la règle de vote majoritaire sur les bouffées d'activité EMG et sur le signal EMG entier.

- Pour les attributs FLP, nous faisons les tests de performances pour 11 coefficients FLP. Le choix de 11 coefficients est basé sur l'étude de performances de modélisation du signal EMGs par la modélisation FLP, illustrée dans l'annexe D.
- Pour les descripteurs DWE, LWE et WCC, nous considérons l'ondelette mère $Coif5$ pour un niveau de décomposition $L_{decomp} = 4$ comme des paramètres de références³.
- Pour le descripteur LPC, nous faisons varier l'ordre de modèle p de 3 à 10.

Les valeurs de CR et la durée de la trame d'analyse sont rapportés dans les tableaux 3.3, 3.4, 3.5, 3.6 et 3.7 pour chaque méthode de classification et chaque descripteur respectivement. Nous pouvons remarquer que les paramètres dynamiques donnent de meilleurs résultats par rapport à l'utilisation des descripteurs simples, et ce pour toutes les méthodes considérées dans cette étude. Les performances de CR sont aussi améliorées grâce à :

- l'application de la règle de vote majoritaire, notamment celles obtenues de la méthode ANN combinée avec le descripteur WCC pour une durée de trame d'analyse égale à 132.91ms ;

3. Ces paramètres sont trouvés comme des paramètres optimaux dans la partie segmentation de signal EMG de surface, présentés dans l'approche HMM du chapitre 2

- l'application de la règle de vote majoritaire sur le tout le signal EMG, avec une valeur de *CR* égale à 100%.

Dans la suite, cette durée de la trame d'analyse, la méthode de classification *ANN* et la technique d'extraction des attributs *WCC* sont utilisées dans l'analyse des performances pour le choix optimal de l'ondelette mère.

ANN		CR %	la durée de la trame d'analyse
FLP	coefficients FLP	67.25	12
	FLPc avec les paramètres dynamiques	67.63	70
	vote majoritaire sur les bouffées d'activité EMG	87.5	50
	vote majoritaire sur le signal EMG	75	80
LP pour p = 6	coefficients LP	68.67	150
	coefficients LP avec les paramètres dynamiques	69.70	110
	vote majoritaire sur les bouffées d'activité EMG	75	30
	vote majoritaire sur le signal EMG	75	30
DWE	coefficients DWE	54.07	110
	coefficients DWE avec les paramètres dynamiques	59.54	140
	vote majoritaire sur les bouffées d'activité EMG	75	66.45
	vote majoritaire sur le signal EMG	75	80
LWE	coefficients LWE	53.08	110
	coefficients LWE avec les paramètres dynamiques	64.45	130
	vote majoritaire sur les bouffées d'activité EMG	75	16.61
	vote majoritaire sur le signal EMG	87.5	110
WCC	coefficients WCC	53.75	60
	coefficients WCC avec les paramètres dynamiques	63.41	130
	vote majoritaire sur les bouffées d'activité EMG	75	100
	vote majoritaire sur le signal EMG	100	132.91

TABLE 3.3 – Les performances en termes de *CR* (%) et la durée de trame d'analyse pour la méthode *ANN* pour les différents caractéristiques.

SVM		CR %	la durée de la trame d'analyse
FLP	coefficients FLP	67.13	80
	FLPc avec les paramètres dynamiques	67.63	70
	vote majoritaire sur les bouffées d'activité EMG	62.5	80
	vote majoritaire sur le signal EMG	62.5	130
LP	coefficients LP	69.22	120
	coefficients LP avec les paramètres dynamiques	69.18	140
	vote majoritaire sur les bouffées d'activité EMG	75	30
	vote majoritaire sur le signal EMG	75	30
DWE	coefficients DWE	54.25	140
	coefficients DWE avec les paramètres dynamiques	59.75	140
	vote majoritaire sur les bouffées d'activité EMG	75	60
	vote majoritaire sur le signal EMG	75	40
LWE	coefficients LWE	53.83	130
	coefficients LWE avec les paramètres dynamiques	59.93	130
	vote majoritaire sur les bouffées d'activité EMG	87.5	80
	vote majoritaire sur le signal EMG	75	80
WCC	coefficients WCC	56.22	150
	coefficients WCC avec les paramètres dynamiques	60.62	130
	vote majoritaire sur les bouffées d'activité EMG	87.5	130
	vote majoritaire sur le signal EMG	75	130

TABLE 3.4 – Les performances en termes de CR (%) et la durée de trame d'analyse pour la méthode SVM pour les différents caractéristiques.

KNN		CR %	la durée de la trame d'analyse
FLP	coefficients FLP	67.13	80
	FLPc avec les paramètres dynamiques	55	140
	vote majoritaire sur les bouffées d'activité EMG	75	80
	vote majoritaire sur le signal EMG	62.5	30
LP	coefficients LP pour $p = 6$	67.48	140
	coefficients LP avec les paramètres dynamiques	66.29	140
	vote majoritaire sur les bouffées d'activité EMG	87.5	120
	vote majoritaire sur le signal EMG	75	16.61
DWE	coefficients DWE	52.74	140
	coefficients DWE avec les paramètres dynamiques	62.75	130
	vote majoritaire sur les bouffées d'activité EMG	62.5	110
	vote majoritaire sur le signal EMG	62	100
LWE	coefficients LWE	52.74	140
	coefficients LWE avec les paramètres dynamiques	57.01	61.32
	vote majoritaire sur les bouffées d'activité EMG	75	60
	vote majoritaire sur le signal EMG	75	110
WCC	coefficients WCC	52.74	140
	coefficients WCC avec les paramètres dynamiques	57.01	132.91
	vote majoritaire sur les bouffées d'activité EMG	75	60
	vote majoritaire sur le signal EMG	75	132.91

TABLE 3.5 – Les performances en termes de CR (%) et la durée de trame d'analyse pour la méthode KNN pour les différents caractéristiques.

LDA		CR %	la durée de la trame d'analyse
FLP	coefficients FLP	67.13	80
	FLPc avec les paramètres dynamiques	58.63	150
	vote majoritaire sur les bouffées d'activité EMG	75	140
	vote majoritaire sur le signal EMG	75	140
LP pour $p=6$	coefficients LP	58.73	100
	coefficients LP avec les paramètres dynamiques	64.24	100
	vote majoritaire sur les bouffées d'activité EMG	87.50	60
	vote majoritaire sur le signal EMG	87.50	50
DWE	coefficients DWE	52.23	110
	coefficients DWE avec les paramètres dynamiques	54.26	110
	vote majoritaire sur les bouffées d'activité EMG	62.5	100
	vote majoritaire sur le signal EMG	50	50
LWE	coefficients LWE	52.61	130
	coefficients LWE avec les paramètres dynamiques	56.96	130
	vote majoritaire sur les bouffées d'activité EMG	75	16.61
	vote majoritaire sur le signal EMG	62.5	110
WCC	coefficients WCC	52.61	130
	coefficients WCC avec les paramètres dynamiques	56.96	130
	vote majoritaire sur les bouffées d'activité EMG	75	16.61
	vote majoritaire sur le signal EMG	62.5	110

TABLE 3.6 – Les performances en termes de CR (%) et la durée de trame d'analyse pour la méthode LDA pour les différents caractéristiques.

GMM		CR %	la durée de la trame d'analyse
FLP	coefficients FLP	67.25	12
	FLPc avec les paramètres dynamiques	67.63	70
	vote majoritaire sur les bouffées d'activité EMG	87.5	50
	Vote majoritaire sur le signal EMG	75	80
LP	coefficients LP pour $N_{GMM} = 2$	60.23	70
	coefficients LP avec les paramètres dynamiques pour $N_{GMM} = 4$	67.44	140
	vote majoritaire sur les bouffées d'activité EMG	69.65	130
	vote majoritaire sur le signal EMG	75	110
DWE	coefficients DWE pour $N_{GMM} = 4$	52.65	80
	coefficients DWE avec les paramètres dynamiques	59.54	140
	vote majoritaire sur les bouffées d'activité EMG	67.45	120
	vote majoritaire sur le signal EMG	70.25	110
LWE	coefficients LWE	48.64	50
	coefficients LWE avec les paramètres dynamiques	64.45	130
	vote majoritaire sur les bouffées d'activité EMG	69.25	140
	vote majoritaire sur le signal EMG	75	130
WCC	coefficients WCC	48.90	50
	coefficients WCC avec les paramètres dynamiques	63.41	130
	vote majoritaire sur les bouffées d'activité EMG	70.26	120
	vote majoritaire sur le signal EMG	75	110

TABLE 3.7 – Les performances en termes de CR (%) et la durée de trame d'analyse pour la méthode GMM pour les différents caractéristiques.

b). **Choix de l'ondelette mère et niveau de décomposition**

Dans ce paragraphe, nous allons étudier l'influence du choix de l'ondelette mère et son niveau de décomposition L_{decomp} . Nous considérons le niveau de décomposition variant entre 1 et $\log_2(N)$ (où N est le nombre d'échantillons de la fenêtre d'analyse (niveau max = 7)). Dans cette étude, nous considérons les familles d'ondelettes suivantes :

- La famille Daubechies avec les ordres 1 à 10 : Db1, Db2, ... , Db10 ;
- La famille Symlets avec les ordres 1 à 8 : Sym1, Sym2, ... , Sym8 ;
- La famille Coiffets avec les ordres 1 à 5 : Coif1, Coif2,..., Coif5.

Les valeurs de CR et L_{decomp} sont rapportées dans les tableaux 3.8, 3.9 et 3.10 pour chacune des trois familles d'ondelettes, respectivement et pour l'application de la règle vote majoritaire sur tout le signal. Les résultats sont résumés comme suit :

- Pour la famille Daubechies, le CR moyenne est supérieur à 82 % et CR = 100 pour Db6 et $L_{decomp} = 6$;
- Pour la famille Symlets, le CR moyenne supérieur à 75 % et CR = 87.5 pour Sym7 et $L_{decomp} = 4$;
- Pour la famille Symlets, le CR moyenne supérieur à 82 % et CR = 100 pour Coif5 et $L_{decomp} = 4$.

Nous pouvons noter que pour les trois familles d'ondelette le CR moyenne est supérieur à 75 % et $CR = 100$ pour deux ondelettes mères *Coif5* et *Db6*. Ce résultat sera utilisé dans la suite (le paragraphe (c)).

Daubechies		<i>Db1</i>	<i>Db2</i>	<i>Db3</i>	<i>Db4</i>	<i>Db5</i>	<i>Db6</i>	<i>Db7</i>	<i>Db8</i>	<i>Db9</i>	<i>Db10</i>	moyenne
132.91 ms	L_{decomp}	6	5	3	2	2	6	2	2	6	2	//
	CR %	62.50	75	75	87.5	87.5	100	87.5	87.5	87.5	75	82.50

TABLE 3.8 – Les performances en termes de CR (%) et L_{decomp} optimal pour WCC et ANN en utilisant la familles des ondelettes **Daubechies**.

Symlets		<i>Sym1</i>	<i>Sym2</i>	<i>Sym3</i>	<i>Sym4</i>	<i>Sym5</i>	<i>Sym6</i>	<i>Sym7</i>	<i>Sym8</i>	moyenne
132.91 ms	L_{decomp}	6	6	3	2	2	3	4	2	//
	CR %	62.5	75	75	75	75	75	87.5	75	75

TABLE 3.9 – Les performances en termes de CR (%) et L_{decomp} optimal pour WCC et ANN en utilisant la familles des ondelettes **Symlets** .

Coiflets		<i>Coif1</i>	<i>Coif2</i>	<i>Coif3</i>	<i>Coif4</i>	<i>Coif5</i>	moyenne
132.91 ms	L_{decomp}	3	3	2	7	4	//
	CR %	75	87.5	75	87.5	100	82.14

TABLE 3.10 – Les performances en termes de CR (%) et L_{decomp} optimal pour WCC et ANN en utilisant la familles des ondelettes **Coiflets**.

c). **Influence de la taille de la base de données et de l'étape de segmentation**

Dans ce paragraphe, nous allons étudier l'impact de la segmentation et la répartition de la base de données pour la phase d'apprentissage et la phase de test. Trois bases de données sont testées, la première est labellisée par expert qui a fait l'objet des toutes les simulations et les deux autres sont segmentées par les deux méthodes FM-ALED et à double seuillage. Dans ce contexte, nous utilisons la configuration optimale composée du descripteur WCC, ondelette mère *Coif5*, niveau de décomposition $L_{decomp} = 4$ pour une durée de trame d'analyse égale à 132.91 ms en utilisant la base de données étiquetée ⁴, composée de neuf (09) signaux (5 contrôle et 4 Parkinsoniens) utilisés dans la phase d'apprentissage et de huit (08) signaux (4 contrôle et 4 Parkinsoniens) pour la phase de test. Plusieurs configuration de la base de données sont considérées dans les prochaines simulations. Les résultats obtenus sont

4. Rappelons que La base de données utilisée ECOTECH est composée de neuf sujets de contrôle et huit malades Parkinsoniens.

rapportés dans le tableau .3.11. Ce dernier montre que les mêmes résultats de CR sont obtenus par les deux bases de données (étiquetées et segmentées) pour la méthode FM-ALED contrairement à la méthode à double seuillage, dont les résultats sont moins bons. Ces résultats montrent encore une fois l'intérêt de segmentation du signal EMG dans la diagnostic de la MP. Nous pouvons ainsi exploiter les bouffées d'activité EMG pour le diagnostic de cette pathologie en utilisant l'approche ANN combinée à l'efficacité de la technique FM-ALED dans la phase de la segmentation.

base de donnée des signaux (S) EMG pour apprentissage (app) et pour test		app (5 S) et test (12 S)	app (8 S) et test (9 S)	app (12 S) et test (5 S)
base de données labellisée (CR %)	coefficients WCC	53.55	53.55	53.55
	WCC avec les paramètres dynamiques	61.38	61.38	61.38
	vote majoritaire sur les bouffées d'activité EMG	75	75	50
	vote majoritaire sur le signal EMG	100	100	100
base de données segmentée avec FM-ALED CR %	coefficients WCC	53.55	53.55	//
	WCC avec les paramètres dynamiques	61.93	61.93	61.93
	vote majoritaire sur les bouffées d'activité EMG	75	75	75
	vote majoritaire sur le signal EMG	100	100	100
base de données segmentée avec Double-TH (CR %)	WCC sans les paramètres dynamiques features	53.96	53.55	53.55
	WCC avec les paramètres dynamiques	53.55	58.73	53.55
	vote majoritaire sur les bouffées d'activité EMG	62.50	61.93	61.93
	vote majoritaire sur le signal EMG	50	75	75

TABLE 3.11 – Performances en termes de CR (%) pour une base de données labellisée et segmentée en utilisant WCC, ANN, $Coif5$, $L_{decomp} = 4$ et la durée de la trame d'analyse = 132.91 ms.

Le tableau .3.11 montre également qu'une erreur de segmentation élevée (de 7% pour FM-ALED à 21% pour Double-TH) endommage considérablement les performances de classification du signal (le meilleur résultat de précision est divisé par 2). Au contraire, l'erreur de segmentation produite par la méthode FM-ALED a très peu d'influence sur les statistiques de classification des signaux.

3.3 Diagnostic de la MP par les modèles HMM

Dans cette partie, nous allons présenter le deuxième système de diagnostic de la MP basé sur les modèles HMM. Ces derniers ont déjà été utilisés et testés comme étant une technique de segmentation du signal EMG, dans le chapitre 2. Toutefois, dans ce chapitre, nous allons utiliser cette méthode pour une tâche de diagnostic et classification de la MP. Dans ce système, nous avons utilisé les HMM pour la segmentation et classification de la MP. La segmentation consiste à transcrire le signal EMG d'un sujet de contrôle en une séquence de zones d'activités, suivie chacune par une zone de non-activité. Les deux types de zones appelés ACN et NAN sont modélisés chacun par un modèle HMM. Dans le cas de sujet Parkinsonien, ces zones sont appelées respectivement ACP et NAP. Ainsi, 4 classes sont considérées pour la modélisation HMM, mais chaque signal de test sera segmentée en

une séquence de zones ACP, NAP ou une séquence de zones ACN, NAN. Cette segmentation nous permet ainsi de classer un signal soit en classe P (parkinsonien) ou en classe N (contrôle) selon le type de la séquence des zones ACP, NAP ou ACN, NAN. Ainsi ce système permet de segmenter le signal en zones d'activités et zones de non-activités, et également d'effectuer la tâche de diagnostic de la maladie de Parkinson. Dans la suite, nous allons présenter la méthodologie de diagnostic et de classification de la MP adoptée dans ce présent système.

3.3.1 Méthodologie de diagnostic et de classification

Une chaîne de Markov d'ordre 1 [196] permet de modéliser des événements qui ne dépendent que de l'état précédent. Elle est employée dans de nombreux domaines tels que la reconnaissance de la parole, de textes manuscrits ou le traitement d'image. Dans ce système, nous allons utiliser les modèles HMM pour classer des signaux EMG de surface en considérant que le signal peut être modélisé comme une chaîne d'événements en utilisant une variable aléatoire. Cette variable peut prendre un état (une valeur) parmi plusieurs états cachés. Ces derniers sont ainsi dénommés cachés car ils ont seulement une signification mathématique et ne représentent pas un état observable au cours du processus physique. Les HMM ont été utilisées pour reconnaître 5 types de mouvements, simulant les commandes d'un joystick (haut, bas, gauche, droit, repos) à partir de signaux EMG [197].

La Fig.3.11 illustre le diagramme de notre système proposé de segmentation et de classification. Dans ce dernier, les quatre classes suivantes sont considérées :

- (1) ACN : classe d'activité EMG pour un sujet de contrôle (saint) ;
- (2) NAN : classe de non-activité (zone bruit) pour un sujet de contrôle (saint) ;
- (3) ACP : classe d'activité EMG pour un patient Parkinsonien ;
- (4) NAP : classe de non-activité (zone bruit) pour un patient Parkinsonien.

Dans la phase d'apprentissage, chaque classe (ACN, NAN, ACP, NAP) de région est modélisée par un modèle HMM de N_{states} états, chacun étant représenté par un modèle GMM de N_{GMM} gaussiennes avec une matrice de covariance diagonale. Les paramètres des modèles HMM et GMM sont estimés à l'aide de la commande HEREST de l'outil HTK, appliquée sur la séquence de vecteurs de caractéristiques extraits des signaux EMG de la base de données du projet ECOTECH [28]. De plus, cette estimation nécessite la transcription du texte de référence qui contient la séquence de classe de chaque signal. Les séquences de vecteurs de caractéristiques sont extraites en utilisant les descripteurs LPC, FLP, DWE, LWE et WCC,

appliqués sur chaque signal EMG de surface.

Dans la phase de segmentation et de classification, la commande HVITE de l'outil HTK utilise les modèles HMM formés et le modèle de contraintes (modèle de langage) pour transcrire chaque séquence de vecteurs de caractéristiques d'entrée en séquence de classes (ACN, NAN ACP NAP) et détecter les limites de leurs segments [157, 160]. Le problème des contraintes consiste à accepter seule la séquence des classes dans laquelle chaque étiquette ACN (classe) est suivie par l'étiquette NAN pour le signal EMG de surface du sujet contrôle et chaque étiquette ACP (classe) est suivie par l'étiquette NAP pour le signal EMG de surface pour le patient Parkinsonien. Enfin, l'évaluation des performances peut être effectuée

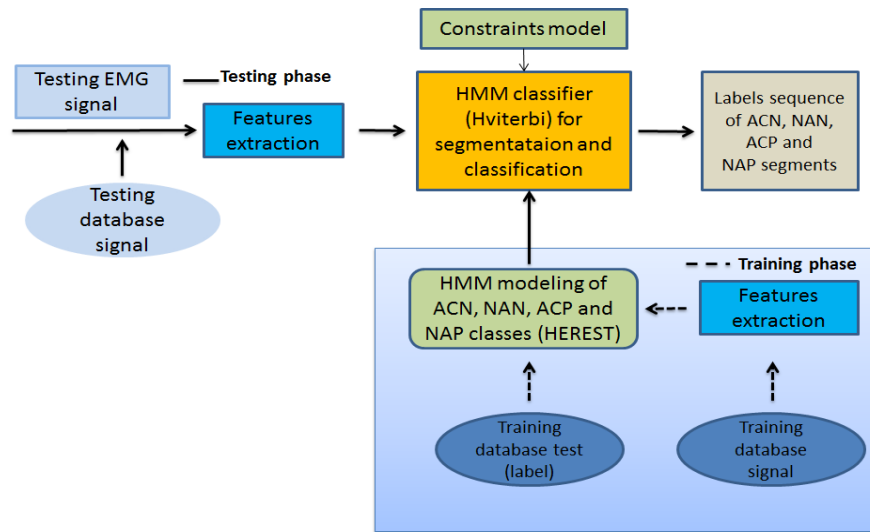


FIGURE 3.11 – Segmentation et classification du signal EMG basées sur les modèles HMM.

à l'aide de la commande HRESULTS de l'outil HTK qui compare chaque transcription de test d'un signal EMG à sa transcription de référence correspondante [157]. Le résultat de l'identification et de classification des segments est évalué en utilisant la précision Acc définie dans l'équation (2.32).

Contrairement au premier système, le deuxième système de classification est composé de trois étapes suivantes :

- (1) Extraction des caractéristiques suivant la méthodologie adoptée dans le premier système de diagnostic (voir Fig. 3.2) ;
- (2) Apprentissage et construction des modèles HMM ;
- (3) Classification de la MP, test et évaluation des performances de diagnostic.

Pour l'étape de test et d'évaluation des performances, nous adoptons les indicateurs de performances suivant : la précision de classification (Acc) et le taux de classification des signaux (CRS), définies dans l'équation (2.32) (défini dans le chapitre 2) et l'équation (3.7)

respectivement.

La précision nous permet d'avoir une mesure globale calculée à partir de classification de la totalité des zones de la base de test (ACN, NAN ACP NAP) indépendamment des signaux. Cependant, la tâche de diagnostic consiste à classifier les signaux, cette tâche diagnostic utilise le résultats de segmentation qui permet de classifier le signal en classe Parkinson (P) ou en classe control (N) selon le type de la séquence des zones (ACN, NAN ACP NAP). Le taux de classification est calculé selon la formule 3.7.

3.4 Résultats et discussion

Dans ce paragraphe, nous allons évaluer les performances de l'approche proposée HMM avec les différentes techniques d'extraction des caractéristiques. Comme tout système de classification, nous avons deux phases, la première est la phase d'apprentissage et la deuxième est la phase de test. La première phase est réalisée avec un ensemble de neuf signaux EMGs réels, composé de quatre signaux de sujets Parkinsoniens et cinq signaux de sujets saints. Dans la deuxième phase, nous prenons quatre signaux de sujets Parkinsoniens et quatre signaux de sujets saints, comme indiqué dans les tableaux 3.1 et 3.2.

Plusieurs expériences sont menées pour trouver la configuration optimale qui donne les meilleures performances en étudiant : (i) Les paramètres des modèles HMM (nombre d'état et le nombre de gaussiennes), (ii) L'étude de différents types de descripteurs pour l'extraction des caractéristiques (iii) La combinaison optimale de l'ondelette mère avec le niveau de décomposition. Les trois expériences sont traitées dans cet ordre :

- (1) Comparaison les performances des descripteurs LPC, FLP, DWE, DWE et WCC ;
- (2) Recherche la durée optimale de la trame d'analyse ;
- (3) Recherche de la meilleure combinaison entre l'ondelette mère et le niveau de décomposition ;

Pour la première expérience, nous faisons varier le nombres d'états HMM N_{states} , le nombres de gaussiennes pour la modélisation GMM N_{GMM} et le niveau de décomposition d'ondelettes L_{decomp} pour l'analyse par ondelettes⁵, l'ordre P pour la modélisation LPC et L pour la modélisation FLP. Le meilleur descripteur avec les paramètres optimaux trouvés sont utilisés pour la deuxième expérience d'étude de la durée de la trame d'analyse. Ensuite, nous cherchons la configuration optimale pour l'ondelette mère.

5. L'ondelette mère 'Coif5' a été choisie avec une durée de fenêtre d'analyse égale à 66.45 ms et un niveau de décomposition de l'ondelette $L_{decomp} = 4$, trouvés comme paramètres optimaux dans la partie segmentation par HMM du chapitre 2.

a). **Comparaison des performances de différents descripteurs**

Cette partie présente les résultats d'évaluation de performances du cinq descripteurs à savoir LPC , FLP, DWE, LWE et WCC pour le diagnostic de la MP. Dans cette expérience, nous cherchons la configuration optimale qui donne les meilleurs performances en termes de *Acc* et de *CRS*. Pour chaque descripteur, nous varions le nombre d'états pour chaque expérience $N_{states} = (2, 3, 4, 5, 6, 7, 8, 9, 10)$, le nombre de composants de gaussiennes dans la modélisation GMM $N_{GMM} = (1, 2, 3, 6, 12, 24, 48)$, l'ordre $P = (2, 3, 4, 5, 6, 7, 8, 9, 10)$ du descripteur LPC et l'ordre L du descripteur FLP . Les résultats obtenus, présentés dans le tableau 3.12 montrent les configurations optimales en termes de nombre de Gaussiennes N_{GMM} et de nombre d'états N_{states} pour chaque descripteur d'analyse d'ondelette DWE, LWE et WCC avec l'ordre optimal P pour le descripteur LPC et l'ordre optimal L pour le descripteur FLP. Ces résultats mettent en évidence le gain en performance des descripteurs d'analyse par ondelettes qui montrent une *Acc* supérieure à 88% et un *CRS* supérieure à 87 % par rapport aux descripteurs LPC et FLP. Notamment, le descripteur LWE avec *Acc* = 98.11% et *CRS* = 100% pour $N_{GMM} = 6$ et $N_{states} = 2$.

Descriptors	LPC	FLP	DWE	LWE	WCC
Paramètres optimaux	$N_{GMM} = 24$ $N_{states} = 3$ and $P = 3$	$N_{GMM} = 6$ $N_{states} = 3$ et $L = 5$	$N_{GMM} = 3$ $N_{states} = 3$	$N_{GMM} = 6$ $N_{states} = 2$	$N_{GMM} = 12$ $N_{states} = 3$
<i>Acc</i> %	66.97	83.65	88.05	98.11	91.82
<i>CRS</i> %	75	75	87.5	100	87.5

TABLE 3.12 – Comparaison des performance en *Acc* % et *CRS* % pour les descripteurs DWE, LPC, LWE et WCC en utilisant 'Coif5' et $L_{decomp} = 4$ avec une trame d'analyse égale à 66.45 ms.

b). **Influence de la durée de la fenêtre d'analyse**

Après avoir choisi le descripteur LWE, nous étudierons dans ce paragraphe la durée de la trame d'analyse appropriée en tenant compte des avantages de l'analyse par ondelettes, qui est appropriée à la non stationnarité des signaux EMG. Nous varions la durée de la trame d'analyse pour l'ondelette mère 'Coif5', le nombre de GMM $N_{GMM} = 6$, le nombre d'états $N_{states} = 2$ et le niveau de décomposition égal à $L_{decomp} = 4$ pour le descripteur LWE. Le tableau 3.13 montre les valeurs de *Acc* pour chaque valeur de la durée de la trame d'analyse. Les meilleures performances sont obtenues pour une durée de trame d'analyse égale à 80 ms, qui correspond aux valeurs de *Acc* égale à 99.37% et *CRS* égale à 100 %. Cette durée de trame d'analyse est utilisée dans l'analyse des performances pour le choix optimal de l'ondelette mère.

Durée de la trame d'analyse (ms)	16.61	20	30	33.22	40	50	60	66.45	70	80	90	100	110	120	130	132.91	140	150
Acc %	61,01	53,46	51,57	67,92	72,96	79,25	69,18	44,03	68,55	99,37	68,55	83,02	72,33	84,91	46,54	47,80	69,18	32,08
CRS %	75.00	62.50	75.00	75.00	75.00	87.50	75.00	62.50	75.00	100	75.00	87.50	75.00	87.50	62.50	62.50	75.00	50.00

TABLE 3.13 – Comparaison des performances en Acc % et CRS % pour le descripteur LWE en utilisant 'Coif5' pour différentes durées des trames d'analyse.

c). **Choix de l'ondelette mère**

De nombreuses études sur l'analyse EMG de surface ont conclu que la famille d'ondelettes de Daubechies (Db) est l'ondelette la plus appropriée pour l'analyse du signal EMGs [165, 166, 167]. Dans [164], les auteurs ont conclu que la 'Sym4' est le plus appropriée pour la reconnaissance de formes EMG. Dans le deuxième chapitre, nous avons trouvé que Coif5 est la plus appropriée pour la segmentation du signal EMG de surface. Cette partie d'étude vise à sélectionner l'ordre optimal des ondelettes mères au sein de sa famille pour une durée de la trame d'analyse égale à 80 ms, un nombre de GMM $N_{GMM} = 6$, un nombre d'états $N_{states} = 2$ avec un niveau de décomposition variant entre 1 à $\log_2(N)$ (N est le nombre d'échantillons de la fenêtre d'analyse (niveau max = 7)). Dans cette étude, nous considérons les familles d'ondelettes suivantes :

- la famille Daubechies avec les ordres 1 à 10 : Db1, Db2, ... , Db10 ;
- la famille Symlets avec les ordres 1 à 8 : Sym1, Sym2, ... , Sym8 ;
- la famille Coiffets avec les ordres 1 à 5 : Coif1, Coif2,..., Coif5.

Les valeurs de Acc et L_{decomp} sont rapportées dans les tableaux 3.14, 3.15 et 3.16 pour chacune des trois familles d'ondelettes, respectivement, plus précisément.

- Pour la familles des ondelettes **Daubechies** (voir le tableau 3.14) , nous remarquons que la moyenne de la précision de classification Acc est supérieure à 87% et la moyenne de taux de classification CRS est supérieure à 87%. Nous remarquons également que pour Db7, Db8 et Db9 avec $L_{decomp} = 4$, nous avons une Acc = 99.37 et un CRS = 100%.
- Pour la familles des ondelettes **Symlets** (voir le tableau 3.15), nous remarquons que la moyenne des taux de classification Acc est supérieure à 87% et la moyenne de taux de classification CRS est supérieure à 89 %. Nous remarquons également que pour Sym4 et $L_{decomp} = 2$ nous avons une Acc = 97.48 et un CRS = 100%.
- Pour la familles des ondelettes **Coiffets** (voir le tableau 3.16), nous remarquons que la moyenne des taux de classification Acc est supérieure à 96% et la moyenne de taux de classification CRS est supérieure à 97%. Nous remarquons également

que pour $Coif5$ et $L_{decomp} = 4$ conduit à une $Acc = 99.37$ et un $CRS = 100\%$.

Les résultats obtenus mettent en évidence la robustesse des performances de l'approche proposée en termes de valeur de Acc et de CRS où nous remarquons que toutes les valeurs moyennes de Acc et CRS sont supérieures à 87%. En particulier, nous remarquons que la famille d'ondelette 'Coiflets' donne une Acc moyenne supérieure à 96% et un CRS moyen 97%. Les ondelettes mères $Db7$, $Db8$, $Db9$ et $Coif5$ avec $L_{decomp} = 4$ donnent les mêmes valeurs d' $Acc = 99.37$ et de $CRS = 100\%$. Cette amélioration des résultats est obtenue à travers les différentes expériences décrites auparavant sans aucun calcul empirique exhaustif.

Daubechies		$Db1$	$Db2$	$Db3$	$Db4$	$Db5$	$Db6$	$Db7$	$Db8$	$Db9$	$Db10$	moyenne
80 ms	L_{decomp}	2	5	3	2	5	2	4	4	4	2	//
	Acc %	80.50	86.16	82.39	74.21	79.87	91.82	99.37	99.37	99.37	83.02	87.60
	CRS %	87.5	75	87.5	75	75	87.5	100	100	100	87.5	87.5

TABLE 3.14 – Les performances en termes de Acc %, CRS % et L_{decomp} optimal pour LWE en utilisant la familles des ondelettes **Daubechies**.

Symlets		$Sym1$	$Sym2$	$Sym3$	$Sym4$	$Sym5$	$Sym6$	$Sym7$	$Sym8$	moyenne
80 ms	L_{decomp}	2	5	3	2	4	4	4	2	//
	Acc %	80.50	86.16	82.39	97.48	86.16	83.65	83.65	96.23	87.02
	CRS %	87.5	75	87.5	100	87.5	87.5	87.5	100	89.06

TABLE 3.15 – Les performances en termes de Acc %, CRS % et L_{decomp} optimal pour LWE en utilisant la familles des ondelettes **Symlets**.

Coiflets		$Coif1$	$Coif2$	$Coif3$	$Coif4$	$Coif5$	moyenne
80 ms	L_{decomp}	1	4	2	2	4	//
	Acc %	91.19	97.48	97.48	97.48	99.37	96.60
	CRS %	87.5	100	100	100	100	97.50

TABLE 3.16 – Les performances en termes de Acc %, CRS % et L_{decomp} optimal pour LWE en utilisant la familles des ondelettes **Coiflets**.

3.5 Conclusion

La classification et le diagnostic des maladies a une importante application clinique. Le présent chapitre décrit deux nouveaux systèmes de diagnostic pour traiter le problème de

classification de la maladie de Parkinson. Le premier système est basé sur l'utilisation de quelques techniques de classification existantes dans la littérature, appliquées sur les bouffées d'activité EMG. Le deuxième système est basé sur la modélisation HMM. Pour les deux systèmes, nous avons exploité les avantages de l'analyse par ondelette, qui est la plus appropriée aux signaux non stationnaires, notamment les signaux EMG de surface. Les résultats montrent que le système WCC-ANN et le système HMM ont atteint une bonne précision de classification et un bon taux de classification adaptés aux applications cliniques. L'évaluation des performances du diagnostic est réalisée en effectuant diverses expériences sur les signaux EMG de surface. Les deux systèmes proposés donnent de meilleurs résultats, le premier système proposée conduit à un CRS de 100% pour WCC-ANN et le deuxième conduit à une Acc de 99.37% et un CRS de 100%. Par conséquent, ces deux approches proposées représente une solution appropriée pour l'analyse des signaux EMGs et son utilisation à des fins de diagnostic, notamment la maladie de Parkinson. Nous avons également vu l'efficacité de la méthode utilisée pour la segmentation EMG de surface, nommée FM-ALED et l'intérêt de la règle de vote majoritaire sur les performances présentées dans le premier système. Nous avons aussi relevé l'efficacité de la méthode HMM, présenté dans le deuxième système, dans le domaine de segmentation et la classification de la MP.

CHAPITRE 4

DÉCOMPOSITION DU SIGNAL EMG DE SURFACE EN TPAUM PAR LA SÉPARATION DE SOURCES

Contents

4.1	Introduction	112
4.2	Formulation de problème	114
4.3	Modélisation mathématique	114
4.3.1	Parcimonie et estimation des TPAUM	117
4.3.2	Décorrélation des TPAUM estimés	120
4.4	Simulations, résultats et discussion	124
4.4.1	Paramètres de simulation	124
4.4.2	Résultats et discussion	124
4.5	Conclusion	127

4.1 Introduction

La complexité du signal EMG est définie par le système neuromusculaire qui produit ce signal. En effet, il est composé d'un mélange ou d'une superpositions des TPAUM issus des unités motrices (UM). L'étude de ces dernières ouvre une fenêtre sur les mécanismes de contrôle neuronal du mouvement chez l'être humain. Les TPAUM représentent des signaux élémentaires, considérés comme des signaux sources, qui sont répartis dans le volume musculaire. Ces signaux élémentaires ont des caractéristiques différentes en fonction des propriétés physiologiques et anatomiques des sources émettrices (UMs), de leur positionnement au sein du muscle ainsi que de leur activation. Ceci définit des caractéristiques de forme d'onde, de fréquence de décharge, de vitesse de conduction différentes en fonction de ces sources et de leurs états. Il est donc important d'améliorer la connaissance de ces paramètres au niveau élémentaire. Ceci est fait grâce au développement de différentes méthodes de décomposition du signal EMGs. Cette tâche est connue par l'estimation des UMs actives à partir du signal EMG de surface.

Nombreuses approches existent dans le domaine de la décomposition du signal EMGs. Les premières méthodes, dites historiques, font la classification de potentiels d'action nerveux (PAN), effectuée sur le nerf. Ces techniques sont semi-automatiques, réalisées par une inspection visuelle. Parfois, elles sont de nature itérative et permettent de déterminer les caractéristiques indépendantes de chaque fibre nerveuse (axone) [198, 199, 200]. D'autres techniques sont basées sur la classifications automatiques des PAUM détectés à ceux de références [201, 202, 203, 204]. Dans [201], les auteurs ont proposé de détecter des PAUM par seuillage de l'amplitude. Dans [205], les auteurs proposent un algorithme de décomposition entièrement automatisé où la classification est basée sur un détecteur de type maximum a posteriori modifié, qui tient en compte des variations de l'amplitude du PAUM d'une décharge à une autre. Dans [202], les auteurs proposent une méthode itérative permettant la résolution des superpositions de plusieurs PAUM. Par la suite, les mêmes auteurs proposent un logiciel complet et ergonomique, dénommé EMGLab [206], développé sous l'environnement Matlab et permet la décomposition automatique ou manuelle de PAUM à partir de signaux intramusculaires mono ou multi-capteurs.

Une autre approche récente pour la décomposition du signal EMG est la séparation de sources en aveugle (en anglais Blind Source Separation : BSS), s'appuyant généralement sur des mesures multi-capteurs. Dans les travaux de cette thèse, nous nous intéressons aux méthodes de séparation de sources pour la décomposition de signaux EMG de surface. Ré-

nement, des amplificateurs multi-canaux et des grilles d'électrodes de surface à haute densité sont introduites pour résoudre partiellement le problème susmentionné. Les méthodes de séparation de sources permettent de retrouver les signaux sources à partir de données multi-capteurs. Beaucoup de travaux de recherche sont orientés à la séparation de sources des signaux électromyographiques de surface. Au niveau macroscopique, dans [207, 208, 209, 210, 211], les auteurs ont tenté de séparer l'activité de différents muscles, en considérant généralement un mélange linéaire instantané. Dans [212], les autres se sont intéressés à la séparation du signal électrocardiographique (ECG) et du signal EMG. Au niveau microscopique, la séparation de sources peut être utilisée pour la décomposition du signal EMG de surface en TPAUM. Cette dernière problématique constitue l'essentiel des travaux présentés dans ce chapitre.

Toute méthode de séparation de sources appliquée dans l'analyse du signal EMG prend en compte le modèle du signal EMG. Ce dernier modèle a été déjà introduit dans le premier chapitre. Il existe celles qui utilisent le modèle de mixture convolutif [213, 214]. D'autres techniques utilisent le modèle instantané, trouvé à partir d'une simplification du modèle convolutif [215, 204]. Une autre catégorie de méthode exploite la nature parcimonieuse (en anglais sparse) du signal EMG, notamment les TPAUM [216, 213, 215, 214]. Dans les travaux de cette thèse, nous avons pris le modèle convolutif en exploitant la parcimonie du signal EMG de surface. Cet aspect est connu par la séparation de source en aveugle convolutif via une représentation parcimonieuse (en anglais Convolutional Blind Source Separation via Sparse Representation : CBSS) [213].

La CBSS est un sujet bien connu dans le traitement du signal. Il trouve de nombreuses applications dans les télécommunications, le traitement d'images et le traitement du signal biomédical [217, 214]. La BSS est la séparation d'un mélange de signaux sources où les sources et le processus de mélange sont inconnus et seuls les enregistrements ou les observations des mélanges sont disponibles. Dans les applications réelles, notamment dans les applications biomédicales, les mélanges sont pondérés et retardés, et chaque source contribue à la somme avec de multiples retards correspondant aux multiples chemins par lesquels un signal biomédical se propage vers le capteur. Certaines méthodes CBSS traitent directement les données dans le domaine temporel [218], car la représentation temporelle des données a des caractéristiques spécifiques qui facilitent la séparation. Ces dernières années ont vu un regain d'intérêt et d'importants progrès de la recherche dans le domaine des représentations parcimonieuses (en anglais Sparse Representation : SR). Dans les méthodes SR, les sources sont estimées en fonction de la parcimonie des signaux source dans un do-

maine spécifique (dans le domaine temporel ou dans le domaine spectrale) [219, 220]. La représentation parcimonieuse améliore les performances des méthodes de séparation des sources en aveugle lorsque le nombre de sources est égal ou supérieur au nombre de capteurs [221]. Dans le présent chapitre, nous proposons un algorithme itératif qui tient en compte le modèle convolutif et la parcimonie du signal EMGs. L'algorithme proposé utilise deux critères : de parcimonie et de décorrélation. Aussi afin de mieux cerner cette problématique, nous articulons le présent chapitre autour des quatre points suivants :

- La section 4.2 est dédiée à la formulation de problème ;
- La section 4.3 est réservée à la modélisation mathématique ;
- La section 4.4 traite la présentation des résultats et discussion ;
- La section 4.5 soulève les remarques et conclusions.

4.2 Formulation de problème

Dans ce paragraphe, on donne un bref rappel sur la génération du signal EMGs (pour plus de détails voir chapitre 1). L'UM est la plus petite unité fonctionnelle du muscle, elle est considérée comme l'élément de base du système neuromusculaire. Une UM est constituée d'un motoneurone (MN) et des fibres musculaires qu'il innerve. Les muscles sont constitués d'un nombre différent d'UM. Le signal EMGs peut être modélisé comme un mélange convolutif des signaux de l'unité motrice (UM). La Fig.4.1 montre la génération du signal EMGs en tant que somme des trains PAUM. La décomposition de l'EMGs est le processus inverse qui consiste en l'identification des trains individuels des PAUM du signal d'interférence. La décomposition des signaux EMG est d'une importance capitale pour détecter les anomalies physiologiques, analyser les biomécanique du mouvement musculaire et étudier l'ordre et les modèles de recrutement des UM. Les caractéristiques spécifiques des PAUM nous aident dans la décomposition du signal EMG.

Le problème de décomposition du signal EMG peut aussi être représenté par la Fig.4.2. Cette représentation est utilisée dans le paragraphe 4.3.

4.3 Modélisation mathématique

Dans ce paragraphe, nous allons modéliser notre problème de séparation de sources en tenant compte du modèle du signal EMGs introduit dans le premier chapitre et illustré dans les figures 4.1 et 4.2. Le signal EMG peut alors être décrit comme étant la somme de




FIGURE 4.1 – Génération du signal EMG.

tous les trains d’impulsions générés par chaque UM [5] :

$$x_i(t) = \sum_j TPAUM_{i,j}(t) + n_i(t) \quad (4.1)$$

où : $x_i(t)$ est le signal EMG mesuré par la i^{eme} électrode, $n_i(t)$ représente le bruit contaminant le capteur de mesure. Le TPAUM peut être modélisé à son tour par la somme d’impulsions arrivant à différents instants [5] :

$$TPAUM_{i,j}(t) = \sum_{k \in \mathbb{Z}} h_{i,j}(t - I_{k,j}) \quad (4.2)$$

où j est l’indice de l’UM considérée, $I_{k,j}$ représente l’instant d’arrivée du k^{me} PAUM de l’UM j , et $h_{i,j}$ est le PAUM de l’UM j mesuré par le capteur i . Enfin, le PAUM possède une distribution spatiale et par conséquent la mesure dépend naturellement de la localisation de l’électrode.

Ainsi, l’équation (4.2) peut être réécrite autrement en introduisant la notion de train

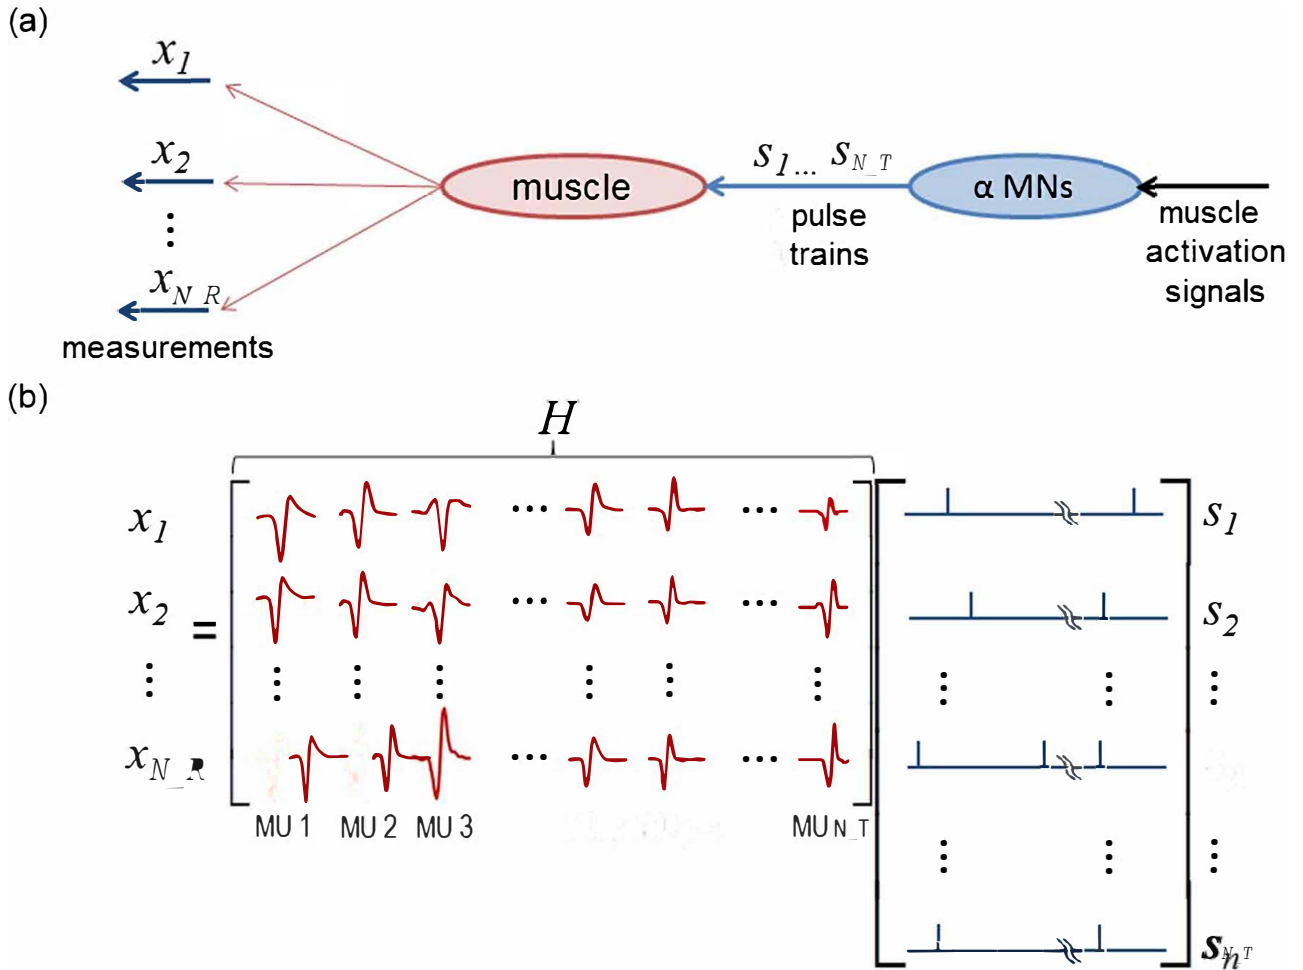


FIGURE 4.2 – Modèle de données convolutif des signaux EMG de surface. (a) Les motoneurons (MNs) conduisent l’activité électrique des fibres musculaires et des unités motrices dispersées spatialement et amplifient les informations sur la commande neurale. (b) L’activité des alpha motoneurons est modélisée par une série de fonctions delta discrètes, représentant les temps de décharge s_i . Les unités motrices convoluent ces séries de deltas avec des PAUM. Le volume de conduction agit comme un filtre passe-bas, ainsi les PAUM sont mesurés par les différents capteurs.

d’impulsion nerveux (TIN) noté $s_j(t)$ [5, 135] :

$$TPAUM_{i,j} = h_{i,j}(t) \otimes s_j(t) \quad (4.3)$$

où le symbole \otimes est l’opérateur de convolution et le TIN est défini par :

$$s_j(t) = \sum_{k \in \mathbb{Z}} \delta(t - I_{k,j}) \quad (4.4)$$

Nous soulignons au passage que le TIN est indépendant du point de mesure. Il correspond aux impulsions brutes, modélisées par des impulsions de Dirac, générées par le MN. Par

ailleurs, en injectant les équations (4.4) et (4.3) dans l'équation (4.15), nous obtenons :

$$x_i(t) = \sum_j (h_{i,j}(t) \otimes s_j(t)) + n_i(t) \quad (4.5)$$

Nous avons considéré un système MIMO (Multi-inputs multi-outputs), le mélange convolutif $x(t)_{t=1:N}$ de N_T sources émettrices $\mathbf{s}(t)$ reçues via un réseau de N_R capteurs, qui peut être modélisé comme suit :

$$\mathbf{x}(t) = \sum_{l=0}^{L-1} \mathbf{H}_l \mathbf{s}(t-l) + \mathbf{n}(t) \stackrel{def}{=} [\mathbf{H}(z)] \mathbf{s}(t) + \mathbf{n}(t) \quad (4.6)$$

où $\mathbf{x}(t) = [x_1(t) : x_{N_R}(t)]^T$, $\mathbf{s}(t) = [s_1(t) : s_{N_T}(t)]^T$ sont respectivement le vecteur d'observation et le vecteur source qui est considéré de nature parcimonieuse dans le domaine temporel. $\mathbf{n}(t) = [n_1(t) : n_{N_R}(t)]^T$ est un bruit additif blanc indépendant du signal $s(t)$ avec une matrice de covariance $\sigma^2 I_{N_R}$ et le filtre $\mathbf{H}(z) = \sum_{l=0}^{L-1} \mathbf{H}_l z^{-l}$ est une matrice de mélange de taille $N_R \times N_T$, considérée de rang de colonne plein pour tous z .

La séparation des sources en aveugle a pour but d'estimer les sources inconnues à partir des mélanges observés, en se basant uniquement sur certaines hypothèses et sur les propriétés statistiques ou structurelles des sources originales. Ceci équivaut à trouver un filtre matriciel de séparation $\mathbf{G}(z) = \sum_{l=0}^{M-1} \mathbf{G}_l z^{-l}$ de taille $N_T \times N_R$ dont la sortie est le vecteur source estimé :

$$\mathbf{z}(t) = \widehat{\mathbf{s}}(t) = [\mathbf{G}(z)] \mathbf{x}(t) = \sum_{l=0}^{M-1} \mathbf{G}_l \mathbf{x}(t-l) \quad (4.7)$$

où $M > (N_T \times L) / (N_R - N_T)$.

4.3.1 Parcimonie et estimation des TPAUM

Dans les travaux de ce chapitre, nous avons considéré la nature parcimonieuse du signal EMG (voir par exemple Fig 4.2). Cette nature parcimonieuse stipule l'existence de plusieurs parties nuls dans le signal en question. Ainsi, pour séparer les signaux source à base de leur parcimonie, nous avons opté pour la norme ' p ' avec $p \leq 1$, un critère déjà considéré dans des problématiques similaires, e.g.[222]. Toutefois, il est à rappeler que l'objectif est de réaliser la séparation des TPAUM pour un mélange convolutif. Pour ce faire, le critère doit contenir deux parties. la première partie est celle qui assure la nature parcimonieuse des sources à extraire, et la seconde partie est celle qui assure la décorrélation entre ces sources obtenues

et ce pour ne pas extraire une même source à des retards différents, en supposant que les sources sont mutuellement décorréées. Le critère globale peut être donné par :

$$C_{global} = C_{parcimonie} + \lambda C_{decorr} \quad (4.8)$$

où λ est un facteur de pondération entre les deux critères.

En premier lieu, nous traitons la minimisation du critère $C_{parcimonie}$ d'une manière itérative. Le filtre de séparation donné en équation (4.7) est mise à jours de manière itérative. La mis à jour itérative est donnée par :

$$\mathbf{G}^{(n)}(l) = \mathbf{G}^{(n-1)}(l) + \boldsymbol{\xi}^{(n)}(l) \quad (4.9)$$

Pour chaque itération ' n ', nous estimons une nouvelle matrice $\boldsymbol{\xi}^{(n)}$. Cette estimation peut se faire en minimisant la norme ' p ' des sources estimées $\mathbf{z}^{(n)}$. En conséquence, le critère à minimiser (dit de parcimonie) est le suivant :

$$C_{parcimonie}^{(n)} = \sum_{i=1}^{N_T} \sum_{t=1}^N \left| z_i^{(n)}(t) \right|^P \quad (4.10)$$

où N est le nombre des échantillons.

où $\mathbf{z}^{(n)}$ est le signal source estimé à la n -ème itération donné par :

$$\begin{aligned} \mathbf{z}^{(n)}(t) &= \sum_{l=0}^{M-1} \mathbf{G}^{(n)}(l) \mathbf{x}(t-l) \\ &= \sum_{l=0}^{M-1} \mathbf{G}^{(n-1)}(l) \mathbf{x}(t-l) + \boldsymbol{\xi}^{(n)}(l) \mathbf{x}(t-l) \\ &= \mathbf{z}^{(n-1)}(t) + \sum_{l=0}^{M-1} \boldsymbol{\xi}^{(n)}(l) \mathbf{x}(t-l) \end{aligned} \quad (4.11)$$

Pour le i -ème TPAUM estimé, nous avons :

$$\begin{aligned} z_i^{(n)}(t) &= z_i^{(n-1)}(t) + \sum_{l=0}^{M-1} \sum_{j=1}^{N_R} \xi_{i,j}^{(n)}(l) x_j(t-l) \\ &= z_i^{(n-1)}(t) + v_i^{(n)}(t) \end{aligned} \quad (4.12)$$

Ainsi, la nouvelle source à l'itération ' n ' est la somme de l'ancienne à l'itération ' $n-1$ ' avec une innovation notée ' $v_i^{(n)}$ '. Le critère donné dans l'équation (4.10) fait intervenir la

norme ' p '. Nous considérons l'approximation suivante :

$$|a + \varepsilon|^p = |a|^p \left(1 + \frac{\varepsilon}{a}\right)^p \quad (4.13)$$

avec :

$$|a| \gg |\varepsilon| \quad (4.14)$$

Le développement limité au premier ordre de l'équation (4.13) donne :

$$\Rightarrow |a|^p \left(1 + p \frac{\varepsilon}{a} + o(\varepsilon)\right) = |a|^p + p a^{p-1} \text{sgn}(a) \cdot \varepsilon \quad (4.15)$$

En considérant les sources données en (4.12), le critère de parcimonie, défini dans l'équation (4.10), devient :

$$\begin{aligned} C^{(n)} &= \sum_{i=1}^{N_T} \sum_{t=1}^N \left| z_i^{(n)}(t) \right|^p \\ &= \sum_{i=1}^{N_T} \sum_{t=1}^N \left| z_i^{(n-1)}(t) + v_i^{(n)}(t) \right|^p \\ &= \sum_{i=1}^{N_T} \sum_{t=1}^N \left| z_i^{(n-1)}(t) \right|^p + p \left| z_i^{(n-1)}(t) \right|^{p-1} \text{sgn}(z_i^{(n-1)}(t)) v_i^{(n)}(t) \\ &= C^{(n-1)} + \sum_{i=1}^{N_T} \sum_{t=1}^N \sum_{l=0}^{M-1} \sum_{j=1}^{N_R} p \left| z_i^{(n-1)}(t) \right|^{p-1} \text{sgn}(z_i^{(n-1)}(t)) \sum_{l=0}^{M-1} \sum_{j=1}^{N_R} \xi_{i,j}^{(n)}(l) x_j(t-l) \\ &= C^{(n-1)} + \sum_{l=0}^{M-1} \text{Tr}(\mathbf{M}_l^{(n-1)T} \boldsymbol{\xi}^{(n)}(l)) \end{aligned} \quad (4.16)$$

où Tr définit la trace d'une matrice. \mathbf{M}_l est comme suit :

$$\mathbf{M}_l^{(n-1)} = p \sum_{t=1}^N \bar{\mathbf{z}}^{(n-1)}(t) \mathbf{x}(t-l)^T \quad (4.17)$$

où

$$\bar{\mathbf{z}}^{(n-1)}(t) = \begin{bmatrix} \left| z_1^{(n-1)}(t) \right|^{p-1} \text{sgn}(z_1^{(n-1)}(t)) \\ \left| z_2^{(n-1)}(t) \right|^{p-1} \text{sgn}(z_2^{(n-1)}(t)) \\ \vdots \\ \left| z_{N_T}^{(n-1)}(t) \right|^{p-1} \text{sgn}(z_{N_T}^{(n-1)}(t)) \end{bmatrix} \quad (4.18)$$

Finalemment, en utilisant une technique de gradient, la mise à jour est choisie sous la forme :

$$\xi^{(n)}(l) = \frac{-\mu}{\|\mathbf{M}_l^{(n-1)}\|} \mathbf{M}_l^{(n-1)} \quad (4.19)$$

En combinant les équations (4.19) et (4.16), nous obtenons le critère :

$$C_{\text{parcimonie}}^{(n)} = C_{\text{parcimonie}}^{(n-1)} - \mu \sum_{l=0}^{M-1} \|\mathbf{M}_l^{(n-1)}\| \quad (4.20)$$

Il est à noter que le critère est décroissant sous réserve que le pas $\mu > 0$ est 'suffisamment petit' pour que l'approximation en (4.15) soit valide.

4.3.2 Décorrélation des TPAUM estimés

Dans ce paragraphe, nous traitons la partie décorrélation des TPAUM estimés, et ce pour ne pas extraire un même signal plusieurs fois à différents retards comme montré dans l'équation (4.21). Ainsi, nous développons le critère de décorrélation puis nous minimisons le critère global donné en (4.8). A cet effet, nous définissons la fonction d'auto-corrélation¹ présentée dans l'équation (4.22) :

$$[s_1(t) : s_{N_T}(t), \dots, s_1(t-L-M-1) : s_{N_T}(t-L-M-1)]^T \quad (4.21)$$

$$r_{z_i z_j}(\tau) = \frac{1}{N} \sum_{t=1}^{N-\tau} z_i(t+\tau) z_j^*(t) \quad (4.22)$$

Pour décorrélérer les TPAUM estimés retrouvées dans le paragraphe 4.3.1, nous devons minimiser la fonction suivante :

$$C_{\text{decorr}} = \sum_{1 \leq i \neq j \leq N_T} \sum_{\tau=-(M+L)}^{M+L} \left| r_{z_i z_j}(\tau) \right|^2 \quad (4.23)$$

Comme nous faisons la minimisation d'une manière itérative, la fonction d'auto-corrélation peut s'exprimer par :

$$r_{z_i z_j}^{(n)}(\tau) = \frac{1}{N} \sum_{t=1}^{N-\tau} z_i^{(n)}(t+\tau) z_j^{(n)*}(t) \quad (4.24)$$

1. On peut ignorer la conjugaison complexe dans (4.22), vu que nos signaux sont à valeurs réelles.

Le critère de décorrélation est alors :

$$C_{decorr} = \sum_{i \neq j} \sum_{\tau=-(M+L)}^{M+L} |r_{z_i z_j}(\tau)|^2 = \sum_{\tau=-(M+L)}^{M+L} \sum_{i \neq j} |r_{z_i z_j}(\tau)|^2 \quad (4.25)$$

$$C_{decorr} = \sum_{\tau=-(M+L)}^{M+L} \left(\|\mathbf{R}_{zz}(\tau)\|^2 - \sum_{i=1}^{N_T} r_{z_i z_j}^2(\tau) \right) \quad (4.26)$$

$$C_{decorr} = \sum_{\tau=-(M+L)}^{M+L} \|\mathbf{R}_{zz}(\tau)\|^2 - \|\text{diag}(\mathbf{R}_{zz}(\tau))\|^2 \quad (4.27)$$

Le signe *diag* signifie la diagonale d'une matrice et $\mathbf{R}_{zz}(\tau)$ est la matrice définie par :

$$\mathbf{R}_{zz}^{(n)}(\tau) = \frac{1}{N} \sum_{t=1}^{N-\tau} \mathbf{z}^{(n)}(t+\tau) \mathbf{z}^{(n)}(t)^T \quad (4.28)$$

Ainsi, chaque i -ème TPAUM estimé est donné par :

$$z_i^{(n)}(t) = z_i^{(n-1)}(t) + \sum_{l=0}^{M-1} \sum_{k=1}^{N_R} \xi_{i,k}^{(n)}(l) x_k(t-l) \quad (4.29)$$

Pour une écriture plus compacte, on a :

$$\mathbf{z}^{(n)}(t) = \mathbf{z}^{(n-1)}(t) + \sum_{l=0}^{M-1} \boldsymbol{\xi}^{(n)}(l) \mathbf{x}_k(t-l) \quad (4.30)$$

En combinant les équations (4.28) et (4.30), on aura :

$$\begin{aligned} r_{z_i z_j}^{(n)}(\tau) &= r_{z_i z_j}^{(n-1)}(\tau) + \frac{1}{N} \sum_{t=1}^{N-\tau} \left(\sum_{l=0}^{M-1} \sum_{k_1=1}^{N_R} \xi_{j,k_1}^{(n)}(l) x_{k_1}(t-l) \right) z_i^{(n-1)}(t+\tau) \\ &+ \frac{1}{N} \sum_{t=1}^{N-\tau} \left(\sum_{l=0}^{M-1} \sum_{k_2=1}^{N_R} \xi_{i,k_2}^{(n)}(l) x_{k_2}(t+\tau-l) \right) z_j^{(n-1)}(t) + o(\xi) \end{aligned} \quad (4.31)$$

d'une autre manière :

$$r_{z_i z_j}^{(n)}(\tau) = r_{z_i z_j}^{(n-1)}(\tau) + \sum_{i=0}^{M-1} [\boldsymbol{\xi}^{(n)}(l) \mathbf{M}_{1,l}(\tau)]_{i,j}^T + \sum_{i=0}^{M-1} [\boldsymbol{\xi}^{(n)}(l) \mathbf{M}_{2,l}(\tau)]_{i,j} \quad (4.32)$$

Avec :

$$\mathbf{M}_{1,l}(\tau) = \frac{1}{N} \sum_{t=1}^{N-\tau} \mathbf{x}(t-l)\mathbf{z}^{(n-1)}(t+\tau)^T \quad (4.33)$$

$$\mathbf{M}_{2,l}(\tau) = \frac{1}{N} \sum_{t=1}^{N-\tau} \mathbf{x}(t+\tau-l)\mathbf{z}^{(n-1)}(t)^T \simeq \mathbf{M}_{1,l}(-\tau) \quad (4.34)$$

Le critère de décorrélation à l'itération n devient :

$$C_{decorr}^{(n)} = \sum_{\tau=-(M+L)}^{M+L} \left\| \mathbf{R}_{zz}^{(n)}(\tau) \right\|^2 - \left\| \text{diag}(\mathbf{R}_{zz}^{(n)}(\tau)) \right\|^2 = A^{(n)} - B^{(n)} \quad (4.35)$$

Pour simplifier le développement du critère de décorrélation donné en (4.35), nous l'avons décomposé en deux terme A et B .

Le premier terme A est défini par :

$$A^{(n)} = \sum_{\tau=-(M+L)}^{M+L} \left\| \mathbf{R}_{zz}(\tau) \right\|^2 = \sum_{\tau=-(M+L)}^{M+L} \text{Tr}(\mathbf{R}_{zz}^{(n)}(\tau)^T \mathbf{R}_{zz}^{(n)}(\tau)) \quad (4.36)$$

$$A^{(n)} = \sum_{\tau=-(M+L)}^{M+L} \text{Tr} \left[\left(\mathbf{R}_{zz}^{(n-1)}(\tau) + \sum_{l=0}^{M-1} [\boldsymbol{\xi}^{(n)}(l)\mathbf{M}_{1,l}(\tau)]^T + \sum_{l=0}^{M-1} [\boldsymbol{\xi}^{(n)}(l)\mathbf{M}_{1,l}(-\tau)] \right)^T \left(\mathbf{R}_{zz}^{(n-1)}(\tau) + \sum_{l=0}^{M-1} [\boldsymbol{\xi}^{(n)}(l)\mathbf{M}_{1,l}(\tau)]^T + \sum_{l=0}^{M-1} [\boldsymbol{\xi}^{(n)}(l)\mathbf{M}_{1,l}(-\tau)] \right) \right] \quad (4.37)$$

Pour une approximation au premier ordre, nous avons :

$$A^{(n)} = A^{(n-1)} + 2\text{Tr} \left(\sum_{l=0}^{M-1} \boldsymbol{\xi}^{(n)}(l)\mathbf{M}_{1,l}(\tau)\mathbf{R}_{zz}^{(n-1)} \right) + 2\text{Tr} \left(\sum_{l=0}^{M-1} \boldsymbol{\xi}^{(n)}(l)\mathbf{M}_{1,l}(-\tau)\mathbf{R}_{zz}^{(n-1)T} \right) + o(\xi) \quad (4.38)$$

Le second terme B est défini comme suit :

$$B^{(n)} = \sum_{\tau=-(M+L)}^{M+L} \sum_{i=1}^{N_T} \left| r_{z_i z_j}^{(n)}(\tau) \right|^2 = \sum_{\tau=-(M+L)}^{M+L} \sum_{i=1}^{N_T} \left(r_{z_i z_j}^{(n-1)}(\tau) + \sum_{l=0}^{M-1} \mathbf{e}_i^T \boldsymbol{\xi}^{(n)}(l) [\mathbf{M}_{1,l}(\tau) + \mathbf{M}_{1,l}(-\tau)] \mathbf{e}_i \right)^2 \quad (4.39)$$

\mathbf{e}_i étant le i -ème vecteur colonne de la matrice identité.

$$B^{(n)} = B^{(n-1)} + 2 \sum_{\tau=-(M+L)}^{M+L} \sum_{l=0}^{M-1} \text{Tr} \left(\boldsymbol{\xi}^{(n)}(l) [\mathbf{M}_{1,l}(\tau) + \mathbf{M}_{1,l}(-\tau)] \mathbf{R}_d^{(n-1)}(\tau) \right) \quad (4.40)$$

tel que : $\mathbf{R}_d^{(n-1)}(\tau) = \text{diag}(\mathbf{R}_{zz}^{(n-1)}(\tau))$

$$B^{(n)} = B^{(n-1)} + 2 \sum_{l=0}^{M-1} \text{Tr}((\boldsymbol{\xi}^{(n)}(l)\mathbf{M}_{3,l})) \quad (4.41)$$

avec :

$$\mathbf{M}_{3,l} = \sum_{\tau=-(M+L)}^{M+L} (\mathbf{M}_{1,l}(\tau) + \mathbf{M}_{1,l}(-\tau)) \mathbf{R}_d^{(n-1)}(\tau) \quad (4.42)$$

En exploitant les équations (4.20) et (4.35), le critère global devient à l'itération n :

$$C_{global}^{(n)} = C_{parcimonie}^{(n)} + \lambda C_{decorr}^{(n)} \quad (4.43)$$

λ représente un facteur de pondération entre les deux critères de parcimonie et de décorrélation.

$$C_{global}^{(n)} = C_{global}^{(n-1)} + 2 \sum_{l=0}^{M-1} \text{Tr}(\boldsymbol{\xi}^{(n)}(l)^T \mathbf{M}_{T,l}) \quad (4.44)$$

avec :

$$\boldsymbol{\xi}^{(n)}(l) = -\mu \left(\mathbf{M}_l + 2\lambda \sum_{\tau=-(M+L)}^{M+L} \left[\mathbf{R}_{zz}^{(n-1)}(\tau)^T \mathbf{M}_{1,l}(\tau)^T + \mathbf{R}_{zz}^{(n-1)}(\tau) \mathbf{M}_{1,l}(-\tau)^T \right] + 2\lambda \mathbf{M}_{3,l} \right) \quad (4.45)$$

et :

$$\mathbf{M}_{T,l} = \mathbf{M}_l + 2\lambda \left(\sum_{\tau=-(M+L)}^{M+L} \left[\mathbf{R}_{zz}^{(n-1)}(\tau)^T \mathbf{M}_{1,l}(\tau)^T + \mathbf{R}_{zz}^{(n-1)}(\tau) \mathbf{M}_{1,l}(-\tau)^T \right] + \mathbf{M}_{3,l} \right) \quad (4.46)$$

$$\boldsymbol{\xi}^{(n)}(l) = \frac{-\mu}{\|\mathbf{M}_{T,l}\|} \mathbf{M}_{T,l} \quad (4.47)$$

Ainsi, l'algorithme proposé est résumé dans le tableau qui suit. Les données sont les signaux EMGs notés $\mathbf{x}(t)$. De ces signaux, nous constituons leurs versions retardées $\mathbf{x}(t-l)$. Nous initialisons les matrices \mathbf{G}_l à des matrices aléatoirement.

Algorithm 1 *Minimisation du critère global*

Initialisation :

1: initialisation des matrices \mathbf{G}_l ;

Traitement :

2: Pour chaque itération n

3: Calcul de $\mathbf{M}_{T,l}$ par (4.46);

4: Calcul de $\xi^{(n)}(l)$ par (4.47);

5: Mise à jour de la matrice de séparation $\mathbf{G}^{(n)}(l)$ par (4.9);

6: Mise à jour des sources $\mathbf{z}^{(n)}(t)$ par (4.11);

7: Fin d'itération;

4.4 Simulations, résultats et discussion

Pour évaluer la technique proposée, nous avons pris des signaux EMGs synthétiques, en suivant le modèle réaliste présenté dans le premier chapitre. La techniques proposée est ensuite appliquée pour la décomposition automatique du signal EMGs.

4.4.1 Paramètres de simulation

Dans ce chapitre, nous avons juste testé la méthode proposée sur le signal EMG synthétiques. Dans le premier scénario de simulation, nous avons pris trois (03) valeurs de $\lambda = (0.2, 0.5, 0.8)$ pour le cas de cinq (05) capteurs et trois (03) sources avec les fréquences de décharges suivantes $FR = (2, 4, 8)$. Le signal EMGs est un mélange des signaux sources où chaque signal source est composé par 3000 échantillons et est généré avec une fréquence d'échantillonnage $Fs = 500Hz$ et la taille de filtre est de l'ordre de six (06). Dans le deuxième scénario, nous avons pris sept (07) capteurs et quatre (04) sources avec les fréquences de décharges suivantes $FR = 1, 4, 7, 12^2$. Les autres paramètres sont inchangés.

4.4.2 Résultats et discussion

Dans ce paragraphe, nous allons présenter les résultats obtenus pour chaque scénarios de simulation. Les figures 4.4 et 4.5 présentent l'estimation des trois sources et le critère de convergence pour $\lambda = (0.2, 0.5, 0.8)$ et les fréquences de décharges $FR = (2, 4, 8)$, respectivement. le mélange de ces trois sources est présenté dans la Fig.4.3. Les résultats obtenus montrent l'efficacité de la méthode proposée où nous remarquons que pour les trois valeurs de λ , la convergence du critère de parcimonie est à partir de la 30^{eme} itération. Toutefois,

2. Le choix des faibles fréquences de décharges est fait pour donner plus de visibilité aux résultats de simulations obtenus.

plus la valeur de λ est grande, plus la convergence du critère de parcimonie est rapide. Les




FIGURE 4.3 – Mélange de trois sources générées avec les fréquences de décharges $FR = (2, 4, 8)$, observées par cinq capteurs.

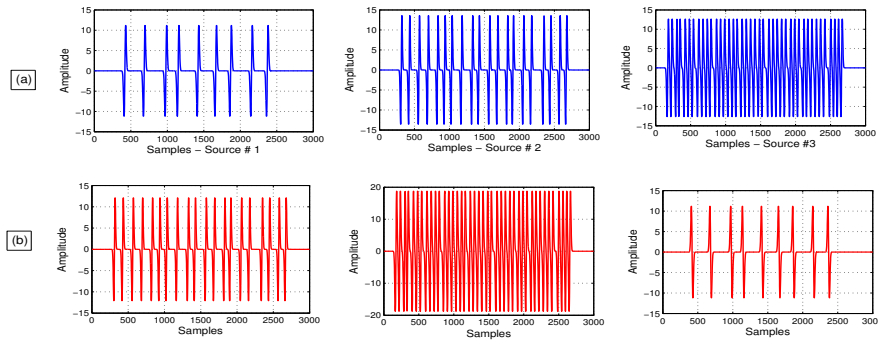


FIGURE 4.4 – Décomposition du signal EMGs(a) trois (03) sources générées (b) trois (03) sources estimées.




FIGURE 4.5 – Convergence de critère de parcimonie pour trois (03) sources et $\lambda = (0.2, 0.5, 0.8)$.

figures 4.6 et 4.7 présentent l'estimation des quatre (04) sources et le critère de convergence

pour $\lambda = (0.2, 0.5, 0.8)$ et les fréquences de décharges $FR = 1, 4, 7, 12$, respectivement. Nous remarquons que la convergence pour les trois valeurs de λ est à partir de la 27^{ème} itération.

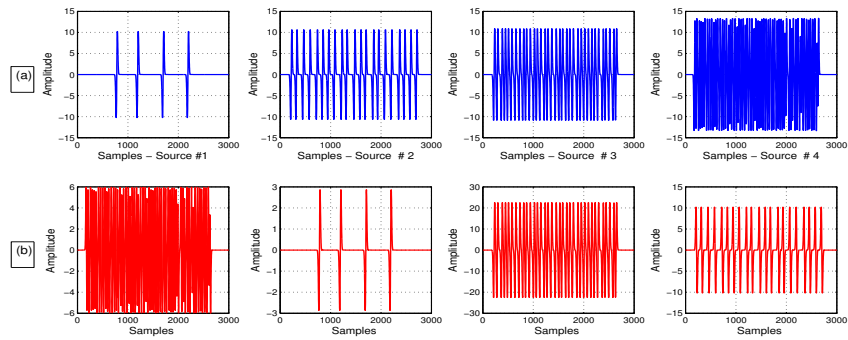


FIGURE 4.6 – Décomposition du signal EMGs (a) quatre (04) sources générées (b) quatre (04) sources estimées.




FIGURE 4.7 – Convergence de critère de parcimonie pour quatre (04) sources et $\lambda = (0.2, 0.5, 0.8)$.

4.5 Conclusion

Le présent chapitre a traité la problématique de la décomposition du signal EMGs en plusieurs TPAUM. Cette problématique est d'un intérêt certain pour le diagnostic des maladies neuromusculaires notamment la maladie de Parkinson. La solution proposée pour cette problématique rentre dans le domaine de la séparation aveugle de sources en utilisant la propriété de parcimonie. La méthode proposée a montré des performances acceptables dans les différents cas de simulations sur les signaux EMGs synthétiques. Toutefois, une validation sur les signaux réels est nécessaires et fera l'objet de travaux futurs.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

Conclusion générale

La présente thèse entre dans le cadre de l'analyse des signaux biomédicaux, en particulier les signaux neurophysiologiques. Cette analyse représente une tâche très importante pour l'évaluation et le diagnostic de différentes pathologies, notamment la maladie de Parkinson. Le travail réalisé dans la présente thèse concerne l'analyse de signaux EMG de surface et son application dans l'étude de la maladie de Parkinson. Dans une première étape, il était question de segmenter ces signaux et en extraire les bouffées d'activité EMG avant d'aborder la tâche de diagnostic et la classification avec ses différentes étapes.

Le premier chapitre a été réservé à la présentation des connaissances de base sur : la maladie de Parkinson, la physiologie des muscles et l'électromyographie (EMG) en particulier le signal EMG de surface, ses modèles mathématiques et les différents bruits qui l'affectent. Nous avons vu aussi l'intérêt du signal EMG comme un moyen utile dans l'analyse et le diagnostic des problèmes neurophysiologiques.

La détection de bouffées d'activité électromyographique du muscle squelettique humain a d'importantes applications cliniques. Deux approches de segmentation du signal EMG de surface ont fait l'objet du deuxième chapitre. Ces deux nouvelles approches servent à résoudre le problème de la détection de l'activité musculaire. La première méthode proposée est une technique nommée ALED avec ses versions, inspirées des méthodes de détection existantes dans le traitement du signal radar et audio. Dans un premier temps, nous avons exploré la première méthode qui est basée sur le détecteur d'énergie linéaire adaptatif (*ou en anglais Adaptive Linear Energy Detector ALED*), largement utilisé dans la détection d'activité vocale. Nous avons proposé également une version de la dite méthode qui est ALED modifiée (nommée M-ALED) en introduisant deux principales modifications à savoir : le pré conditionnement du signal EMG en utilisant l'opérateur Teager-Kaiser et les statistiques d'ordre. Nous avons proposé à nouveau d'exploiter les statistiques d'ordre pour l'estimation initiale de la ligne de base du signal. La seconde méthode est basée sur le taux de probabilité de fausse alarme constant (*ou en anglais Constant False Alarm Rate CFAR*) qui est largement utilisé dans la détection de cibles radar. Enfin, comme la M-ALED détecte l'activité EMG du signal EMG au niveau de la trame, nous avons proposé dans un deuxième temps d'affiner cette détection au niveau échantillon en utilisant l'approche CFAR, qui permet une détection plus affinée à travers la version Fine M-ALED (FM-ALED). Les performances de FM-ALED sont évaluées via des enregistrements de signaux EMG réels et synthétiques, et les résultats obtenus mettent en évidence son efficacité par rapport aux quelques méthodes

de références (pour différents scénarios défavorables). Elle a permis de réduire le taux d'erreur moyen d'un facteur supérieur à 2.

Pour la deuxième approche du deuxième chapitre, nous avons proposé une méthode supervisée qui est basée sur une modélisation par une chaîne de Markov cachée (ou en anglais Hidden Markov models HMM) combinée avec la transformée discrète en ondelettes (DWT). L'approche proposée est réalisée en deux phases principales. La première phase est une phase d'apprentissage, qui a servi à la formation des classes (région d'activité EMG et région de non activité EMG), en modélisant les signaux EMGs par des modèles HMM en utilisant la base de données des signaux EMG de surface étiquetés. La deuxième phase concerne le test et la validation et a pour rôle d'évaluer les performances du système à l'aide de la base de données de test du projet ECOTECH. Les deux phases nécessitent l'étape d'extraction des caractéristiques sous forme de descripteurs. Différents descripteurs ont été utilisés et les résultats ont montré que les modèles HMM combinés avec le descripteur LWE en utilisant la famille d'ondelette, notamment Coiflet 5 avec le niveau de décomposition 4 donnent les meilleures performances en termes de précision *Acc* et de taux d'erreur (*Re*). Les performances de l'approche HMM sont évaluées via des enregistrements de signaux EMG de surface réels. Une étude comparative avec FM-ALED et d'autres méthodes de l'état de l'art confirment la supériorité de l'approche HMM (elle a permis de réduire le taux d'erreur moyen d'un facteur supérieur à 1.3). L'approche HMM proposée offre une bonne performance de détection des bouffées d'activité EMG, adaptée aux applications cliniques. Elle peut être un outil utile pour analyser les signaux EMG enregistrés lors de l'évaluation de l'ajustement postural des patients souffrant de la maladie de Parkinson.

Une fois que nous avons pu détecter et identifier les bouffées d'activité EMG, nous avons exploité ces dernières dans le diagnostic et la classification de la maladie de Parkinson. Cette tâche a fait l'objet du troisième chapitre. Deux nouveaux systèmes de diagnostic ont été décrits pour traiter le problème de classification de la MP. Le premier système est basé sur l'utilisation de quelques techniques de classification existantes dans la littérature, appliquées sur les bouffées d'activité EMG. Le deuxième système est basé sur la modélisation HMM. Pour les deux systèmes, nous avons exploité les avantages de l'analyse par ondelette, qui est plus appropriée aux signaux non stationnaires, notamment les signaux EMG de surface. A cet effet, notre tâche principale consiste à rechercher les paramètres optimaux de chaque système pour obtenir les meilleures performances de classification. Les méthodes proposées sont réalisées en deux phases, à savoir : la phase d'apprentissage et la phase d'évaluation et de test. La première phase consiste à caractériser les modèles des

différentes classes, alors que la phase de test consiste à évaluer les performances du système de diagnostic. Les deux phases exigent une étape d'extraction de paramètres (ou attributs) utiles, non redondants pour la classification. L'évaluation des performances est réalisée en effectuant diverses expériences sur les signaux EMG de surface en utilisant le taux de classification CR . Pour le premier système, nous avons fait une étude de performances en exploitant l'analyse par ondelette combinée avec quelques techniques de classification existantes dans la littérature, nous avons trouvé un $CR = 100\%$ pour WCC-ANN (Wavelet Cepstral Coefficient -les réseaux de neurones artificiels).

Dans le deuxième système, nous avons exploité à nouveau les HMM pour distinguer les signaux EMG de sujets sains (normaux) des signaux EMG anormaux (Parkinson). Les HMM sont déjà utilisés et testés comme étant une technique de segmentation du signal EMG de surface, présentée dans le deuxième chapitre. Tandis que dans les travaux du troisième chapitre, elle a été utilisée pour une tâche de diagnostic et de classification de la MP. Elle a conduit à une Acc de 99.37% un CR de 100%. Par conséquent, ces deux approches proposées représentent une solution appropriée pour l'analyse des signaux EMGs et son utilisation à des fins de diagnostic, notamment celui de la maladie de Parkinson.

Finalement, une méthode itérative est proposée au chapitre 4 pour résoudre le problème de décomposition du signal EMG de surface en TPAUM. Cette méthode est basée sur la séparation de sources en exploitant la parcimonie du signal EMG. La technique proposée a montré son efficacité sur les signaux EMG synthétiques.

Perspectives et travaux futurs

Comme perspectives à notre travail, nous proposons :

- Elargir la base de données de signaux EMG de surface, en incluant tous les canaux enregistrements pour tous les muscles afin de valider les résultats obtenus de différentes techniques proposées et éventuelle application réelle ;
- Elargir la base de données de signaux EMGs pour les différents stade et évolution de la maladie de Parkinson ;
- Etudier et évaluer les enregistrements des autres muscles caractérisant la marche, étant donnée que durant ce travail, nous avons exploité seulement les signaux enregistrés du muscle Solaire droit ;
- Etudier la faisabilité de diagnostic de la MP indépendamment de type de muscle : *classification en mode indépendant* ;

- La méthode FM-ALED dépend de la table du paramètre P qui est faite sur les signaux audio, nous proposons de la paramétrer sur les signaux EMG de surface ;
- Application et analyse de performances de ces techniques sur d'autres types de maladies neurodégénératives, par exemple Huntington et SLA (sclérose latérale amyotrophique) ;
- Exploration et analyse d'autres techniques d'extraction des caractéristiques pour l'approche HMM ;
- Analyse de performance des régions de non activité EMG, qui comportent théoriquement des activités EMG *involontaires* ;
- Généraliser et tester la méthode de décomposition proposée sur les signaux EMG réels.

ANNEXE A

DESCRIPTION DE NOTRE BASE DE DONNÉES

Dans les travaux de cette thèse, nous avons utilisé une base de données de signaux EMG de surface, enregistrés dans le cadre de projet French National Project ECOTECH [28]. Ces signaux EMG de surface sont composés de plusieurs bouffées d'activité EMG et sont enregistrés de différents muscles des membres inférieures caractérisant la marche. Cette base de données comporte deux groupes de sujets (patient), le premier groupe est composé de neuf (9) sujets sains et le deuxième groupe est composé de huit (8) patients atteints du maladie de Parkinson.

Les patients ont été préparés pour le placement des électrodes en rasant la peau et en la nettoyant avec des lingettes alcoolisées. Des capteurs EMG ont été placés sur le ventre musculaire parallèlement à la direction principale des fibres musculaire conformément à l'étude sur la zone d'innervation [163]. Les données ont été collectées à l'aide d'un système embarqué de capteurs portables (bande passante, 16 bits par échantillon, taux d'échantillonnage de 1926 Hz, Delsys Trigno, Natick, USA). La collecte de données fournit plusieurs activités EMG du muscle soléaire droit (*RSol*) correspondant à plusieurs cycles de la marche. La description de la base de données est présentée dans les tableaux A.1 et A.2.

Table A1. Description of sEMG signals for healthy subjects

Sujets	Nombre de bouffées d'activité EMG	Moyenne de durées de bouffées d'activité EMG (ms)	STD de durées réelles de bouffées d'activité EMG (ms)	Longueur du Signal (échantillons)	Durée du Signal (second)
<i>Control</i> ₁	22	1037.7000	98.5539	50206	26.0685
<i>Control</i> ₂	10	1059.7000	288.3023	21595	11.2128
<i>Control</i> ₃	11	1068.1000	85.4207	27733	14.3998
<i>Control</i> ₄	11	1069.3000	103.7267	28396	14.7441
<i>Control</i> ₅	11	809.9091	33.3090	21500	11.1635
<i>Control</i> ₆	6	1031.7000	73.5193	14853	7.7121
<i>Control</i> ₇	6	1013.3000	321.9687	12576	6.5298
<i>Control</i> ₈	12	898.0833	48.5264	27629	14.3458
<i>Control</i> ₉	26	969.2308	104.8490	55024	28.5702

Table A2. Description of sEMG signals for Parkinsonian subjects

ANNEXE B

DÉRIVATION DE PROBABILITÉ DE FAUSSE ALARME ET DE DÉTECTION DU CA-CFAR À GAUCHE

B.1 Calcul de probabilité de fausse alarme et de détection

Pour le calcul de la P_{fa} , on définit d'abord les expressions suivantes :

$$P_{fa} = \int_0^{+\infty} f_Z(z)P(U < \frac{z}{T})dz = \int_0^{+\infty} f_Z(z)F_Z(\frac{z}{T})dz \quad (\text{B.1})$$

où $F_s(x)$ est la fonction cumulative présentée dans [223], et définit par :

$$F_U(\frac{z}{T}) = 1 - \exp(-\frac{z}{2T\sigma_w^2}) \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{z}{2T\sigma_w^2}\right)^k, z \geq 0 \quad (\text{B.2})$$

En injectant l'équation (B.2) dans l'équation (B.1), on obtient :

$$P_{fa} = \int_0^{+\infty} f_Z(z)F_Z(\frac{z}{T})dz = \int_0^{+\infty} f_Z(z) \left(1 - \exp(-\frac{z}{2T\sigma_w^2}) \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{z}{2T\sigma_w^2}\right)^k\right) dz \quad (\text{B.3})$$

$$= \int_0^{+\infty} f_Z(z)dz - \int_0^{+\infty} f_Z(z) \cdot \exp(-\frac{z}{2T\sigma_w^2}) \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{z}{2T\sigma_w^2}\right)^k dz \quad (\text{B.4})$$

$$= 1 - \int_0^{+\infty} f_Z(z) \exp(-\frac{z}{2T\sigma_w^2}) \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{z}{2T\sigma_w^2}\right)^k dz \quad (\text{B.5})$$

$f_Z(z)$ est une distribution chi deux centrée de premier ordre, donnée par :

$$f_Z(z) = \frac{1}{\sqrt{2\pi\sigma_w^2}} z^{-\frac{1}{2}} \exp\left(\frac{-z}{2\sigma_w^2}\right) \quad (\text{B.6})$$

En remplaçant l'équation (B.5) dans (B.6), on obtient :

$$P_{fa} = 1 - \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{z}{2T\sigma_w^2}\right)^k \int_0^{+\infty} \frac{1}{\sqrt{2\pi\sigma_w^2}} z^{-\frac{1}{2}} \exp\left(\frac{-z}{2\sigma_w^2}\right) \exp\left(-\frac{z}{2T\sigma_w^2}\right) dz \quad (\text{B.7})$$

$$= 1 - \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{1}{T}\right)^k \int_0^{+\infty} \frac{1}{\sqrt{\pi}2\sigma_w^2} \left(\frac{z}{2\sigma_w^2}\right)^{k-\frac{1}{2}} \exp\left(\frac{-z}{2\sigma_w^2}\right) \exp\left(-\frac{z}{2T\sigma_w^2}\right) dz \quad (\text{B.8})$$

$$= 1 - \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{1}{T}\right)^k \frac{\Gamma(k+\frac{1}{2})}{\sqrt{\pi}} \int_0^{+\infty} \frac{1}{2\sigma_w^2\Gamma(k+\frac{1}{2})} \left(\frac{z}{2\sigma_w^2}\right)^{k-\frac{1}{2}} \exp\left(\frac{-z}{2\sigma_w^2}\right) \exp\left(-\frac{z}{2T\sigma_w^2}\right) dz \quad (\text{B.9})$$

où $\Gamma(\cdot)$ est la fonction gamma. Pour des raisons de simplification des expressions précédentes, on définit la fonction de densité de probabilité de chi-deux centrée de degré de liberté de $2k+1$, présenté dans [223] comme suit :

$$PDF_{\chi_2(2k+1,\sigma_w^2)} = \frac{1}{2\sigma_w^2\Gamma(k+\frac{1}{2})} \left(\frac{z}{2\sigma_w^2}\right)^{k-\frac{1}{2}} \exp\left(\frac{-z}{2\sigma_w^2}\right) \quad (\text{B.10})$$

De la, si on injecte l'équation (B.10) dans l'équation (B.9), on obtient :


$$P_{fa} = 1 - \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{1}{T}\right)^k \frac{\Gamma(k+\frac{1}{2})}{\sqrt{\pi}} \int_0^{+\infty} PDF_{\chi_2(2k+1,\sigma_w^2)} \exp\left(-\frac{z}{2T\sigma_w^2}\right) dz \quad (\text{B.11})$$

Utilisant la définition de la fonction du moment $\Psi_z(y)$ présentée dans [223] pour une chi deux centré de degré de liberté $2k+1$, définit comme suit :

$$\Psi_z(y) = \int_0^{+\infty} PDF_{\chi_2(2k+1,\sigma_w^2)} \exp\left(-\frac{z}{2T\sigma_w^2}\right) dz = \left[\frac{1}{1-2jy\sigma_w^2} \right]^{k+\frac{1}{2}} \quad (\text{B.12})$$

Pour $y = \frac{j}{2T\sigma_w^2}$ on obtient :

$$\Psi_z(y) = \left[\frac{T}{T+1} \right]^{k+\frac{1}{2}} \quad (\text{B.13})$$



(a) Probabilité de fausse alarme.

(b) Probabilité d'oubli.

Ce qui induit à

$$P_{fa} = 1 - \sum_{k=1}^{m-1} \frac{1}{k!} \left(\frac{1}{T}\right)^k \frac{\Gamma(k + \frac{1}{2})}{\sqrt{\pi}} \left[\frac{T}{T+1}\right]^{k+\frac{1}{2}} \quad (\text{B.14})$$

Finalement, on obtient :

$$P_{fa} = 1 - \sum_{k=1}^{m-1} \frac{1}{k!} \frac{\Gamma(k + \frac{1}{2})}{\sqrt{\pi}} \frac{\sqrt{T}}{(T+1)^{k+\frac{1}{2}}} \quad (\text{B.15})$$

Pour le calcul de la probabilité de détection P_d , même dérivation nous conduit à :

$$P_d = 1 - \sum_{k=1}^{m-1} \frac{1}{k!} \frac{\Gamma(k + 1/2)}{\sqrt{\pi}} (1 + SNR)^k \frac{\sqrt{T}}{(T + SNR + 1)^{k+1/2}} \quad (\text{B.16})$$

où $SNR = \frac{\sigma_s^2}{\sigma_w^2}$ est le rapport signal sur bruit. Nous pouvons aussi définir la probabilité d'erreur, comme suit :

$$P_e = P(H_0)P(H_0/H_1) + P(H_1)P(H_1/H_0) \quad (\text{B.17})$$

$$P_e = P(H_0)P_{miss} + P(H_1)P_{fa} \quad (\text{B.18})$$

Dans notre simulation nous avons pris : $P(H_0) = P(H_1) = 1/2$.

B.2 Simulation numériques

Les formules de P_{fa} , P_{miss} et P_e sont présentées dans les équations (2.24), (2.27) et (B.18), respectivement sont calculé et simulé numériquement. Les résultats de simulation numériques sont reportés dans les figures B.1a, B.1b et B.2, respectivement.




FIGURE B.2 – Probabilité d’erreur pour ($m = 10$, $m = 20$) et $\text{SNR} = 20$ dB avec $P(H_0) = P(H_1) = 0.5$.

Comme nous pouvons le voir sur la Fig.B.1a, le facteur d’échelle diminue lorsque la probabilité de fausse alarme augmente. De plus, plus il y a de cellules de référence, plus la probabilité de fausse alarme doit être faible.

D’autre part, plus le facteur d’échelle augmente, la probabilité d’oubli augmente, comme le montre la Fig.B.1b.

De toute évidence, il existe un choix optimal de ces paramètres pour arbitrer entre les probabilités d’oubli et de fausse alarme. Pour obtenir le facteur d’échelle optimal, la probabilité d’erreur doit être prise en compte.

Sur la Fig.B.2, des courbes de probabilité d’erreur en fonction du facteur d’échelle, pour chaque nombre de cellules de référence considérées $M = 2m$, sont dessinées. Pour chaque valeur de m , un facteur d’échelle optimal T apparaît pour un minimum de probabilité d’erreur.

B.3 Résultats de simulation

Dans ce paragraphe, nous présentons dans les tableaux B.1 et B.2 les résultats de simulation de la technique CA-CFAR sur les sujets sains et Parkinsoniens. L’évaluation est faite en utilisant le latence, calculé entre l’onset réel et estimé, donné par cette relation :

TABLE B.1 – Latence entre onset réel et estime de l’activité EMG pour le muscle Soléaire droit pour les sujets Parkinsoniens

Sujet (P)	Facteur d’échelle (T)	Cellule de Référence	Latence (échantillons)
P_1	0.5	968	973
P_2	0.1	0	2
P_3	2.3	793	974
P_4	1.2	189	219
P_5	1.4	410	553
P_6	0.01	3	2
P_7	0.01	0	3
P_8	2.04	840	824
P_9	1.67	1220	1137

TABLE B.2 – Latence entre onset réel et estime de l’activité EMG pour le muscle Soléaire droit pour les sujets sains

Sujet (P)	Facteur d’échelle (T)	Cellule de Référence	Latence (échantillons)
P_1	0.2	40	4
P_2	0.31	160	0
P_3	0.28	65	4
P_4	0.01	150	14
P_5	0.41	35	7
P_6	0.27	155	3
P_7	0.3	145	0
P_8	0.14	160	16

ANNEXE C

DIFFÉRENTS TYPES D'ATTRIBUTS

Valeur absolue moyenne (MAV)	$MAV = \frac{1}{N} \sum_{i=1}^N X_i $
Erreur quadratique moyenne (EQM)	$EQM = \sqrt{\frac{1}{N} \sum_{n=1}^N [x(n)]^2}$
integrated EMG	$IEMG = \sum_{i=1}^N X_i $
taux de passage par zéro	$ZCR = 4$
Kurtosis	$Kurtosis = \int_{-X}^{+X} \frac{(X-\bar{X})^4}{\sigma^4} P(x).dX$
Histogramme	HEMG divides elements in the EMG signal into equally spaced segments and returns number of signal elements for each segment.
coefficients cepstraux	$c_n = -a_n - \sum_{k=1}^n (1 - \frac{k}{n}) a_k \cdot c_{n-k}, c_1 = -a_1, c_n =$ <i>nthcepstrumcoefficient, a_i = ARcoefficient</i>
coefficients autoregressifs	$x_n = \sum_{i=1}^P a_{i,n} x_{n-i}, P =$ <i>modelorder, a_{i,n} =</i> <i>theithcoefficientat timeinstantn</i>
variance	$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2$

TABLE C.1 – Attributs temporels.

Mean frequency	Median frequency
$MNF = \frac{\sum_{j=1}^M f_j \cdot P_j}{\sum_{j=1}^M P_j}$	$MDF \sum_{j=1} P_j = \sum_{j=MDF}^M P_j = \frac{1}{2} \sum_{j=1}^M P_j$

TABLE C.2 – Attributs fréquentiels.

Root Mean Square (RMS)	$\sqrt{\frac{1}{N} \sum_{n=1}^N [x(n)]^2}$
Crest factor (Cf)	$\frac{\sup x(n) }{\sqrt{\frac{1}{N} \sum_{n=1}^N [X(n)]^2}}$
Peak	$\sup x(n) $
K factor	$\sup x(n) \cdot \sqrt{\frac{1}{N} \sum_{n=1}^N [x(n)]^2}$
Kurtosis	$\int_{-X}^{+X} \frac{(X-\bar{X})^4}{\sigma^4} P(x) \cdot dX$
Shape factor	$\frac{RMS}{\frac{1}{N} \sum_{n=1}^N a_n }$
Impulse factor	$\frac{Peak}{\frac{1}{N} \sum_{n=1}^N a_n }$

TABLE C.3 – Attributs statistiques.

Spatial domain features :Experimental periodogram : $\gamma(h) = \frac{1}{2n(h)} \sum_{i=1}^{n(h)} [x(z_i) - x(z_i + h)]^2$;
h = distance vector, $x(z_i)$ = measurement at location z_i . **n(h)** = number of pairs h units apart in the direction of the vector h

Short time Fourier transform	$STFT(k, m) = \sum_{r=1}^{N-1} x(r).g(r - k).e^{-j.2.\pi.m.i/N}$.
Continuous wavelet transform	$WT_x(\cdot, a) = \frac{1}{\sqrt{a}} \int x(t)\Psi(\frac{t-\tau}{a})dt$; τ =translation parameter ; a = scale parameter ; Ψ = mother wavelet function.
Discrete wavelet transform	DWT splits the signal into an approximation and detail coefficients by passing it through complementary low- and high-pass filters. The approximation coefficients are further split into a second-level approximation and detail coefficients. By repeating the process, one signal is broken down into many lower resolution components.
Wavelet packet transform	WPT is a generalized version of DWT that is applied to both low-pass results (approximations) and high-pass results (details).

TABLE C.4 – Attributs temps-fréquence.

MODÉLISATION DU SIGNAL EMG PAR LA PRÉDICTION LINÉAIRE FRACTIONNELLE : FLP

D.1 Modèle mathématique des coefficients FLP

Dans les travaux de cette thèse, nous nous intéressons aussi aux attributs FLP, qui sont largement utilisés dans la modélisation du signal de la parole [224], les signaux EEG [225] et pour distinguer l'arythmie de contraction ventriculaire prématurée (PVC) des battements normaux sur la base du signal d'électrocardiogramme (ECG) [226]. Ils sont utilisés aussi pour étudier la variabilité du signal EMG [60]. Dans ce travail ; la taille de la trame d'analyse et l'ordre du modèle FLP ont été analysés pour obtenir des résultats de classification optimaux. Premièrement, le signal EMG a été divisé en trames d'analyse sans chevauchement afin d'avoir plus d'observation. .

En effet, le modèle autorégressif fractionnel (FLP) a été introduit comme une extension du fameux modèle autorégressif (AR). Les coefficients AR ont également été utilisés comme attributs pour classer les signaux EMG enregistrés chez des sujets normaux, de neuropathie et de myopathie [52]. Dans le modèle AR, chaque échantillon de trame d'analyse du signal EMG est décrit comme une combinaison linéaire d'échantillons précédents plus un terme d'erreur $e(n)$ qui est indépendant des échantillons précédents [227] :

$$\hat{x}(n) = - \sum_{k=1}^p a_k x(n-k) + e(n) \quad (\text{D.1})$$

Où a_k sont les coefficients AR et p est l'ordre du modèle et $e(n)$ est un bruit blanc moyen

nul avec la variance σ^2 . Pour étendre ce modèle, plusieurs techniques peuvent être utilisées pour calculer l'ordre fractionnaire intégration/dérivation. Les différentiels fractionnaires de la fonction continue $g(t)$ selon la définition de Grunwald-Letnikov sont données par [228] :

$${}_a D_t^\alpha g(t) = \lim_{h \rightarrow 0} \frac{1}{h^\alpha} \sum_{j=0}^{\lfloor (t-a)/h \rfloor} (-1)^j \binom{\alpha}{j} g(t-jh) \quad (D.2)$$

où α ($0 < \alpha < 1$) est une valeur réelle, $[\cdot]$ représente l'entier le plus proche de la valeur entre les crochets, h est la période d'échantillonnage et $\binom{\alpha}{j}$ est la combinatoire. ${}_a D_t^\alpha g(t)$ désigne l'ordre fractionnaire appliqué sur la fonction continue $g(t)$. Lorsqu'elle est appliquée à la fonction discrète $g(n)$, une formule simplifiée de l'opérateur d'ordre différentiel fractionnaire utilisant l'approximation inverse du premier ordre et la troncature de la série MacLaurin peut être écrite comme [229] :

$$D^\alpha g(n) = \sum_{j=0}^n (-1)^j \binom{\alpha}{j} g(n-j) \quad (D.3)$$

De même que la modélisation de prédiction linéaire (LP), la prédiction linéaire fractionnaire peut être exprimée comme la prédiction $\hat{x}(n)$ de $x(n)$ lorsqu'elle est développée comme une combinaison linéaire de ses intégrales ou dérivées fractionnaires [225]. En termes fractionnaires dérivés, l'expression d'estimation est la suivante :

$$\hat{x}(n) = - \sum_{k=1}^L \alpha_k D^{p_k} x(n) \quad (D.4)$$

où α_k sont les coefficients FLP du modèle, p_k sont des nombres positifs réels représentant l'ordre de dérivé L. Dans l'opérateur intégral fractionnaire, les coefficients FLP sont nommés $\beta_k < 0$ qui sont donnés dans l'équation de prédiction suivante :

$$\hat{x}(n) = - \sum_{k=1}^L \beta_k D^{p_k} x(n) \quad (D.5)$$

le $\beta = [\beta_1, \beta_2, \dots, \beta_L]^T$ peut être estimé en minimisant l'erreur d'énergie de prédiction $e(n)^2 = (\hat{x}(n) - x(n))^2$ en utilisant la méthode des moindres carrés. L'énergie totale de l'erreur peut

être exprimée comme suit :

$$E = \sum_{n=1}^N e(n)^2 \quad (\text{D.6})$$

où N représente la taille de la trame d'analyse $\mathbf{x} = [x(1), x(2), \dots, x(N)]$. Sur lequel l'opérateur intégral d'ordre p_k peut être appliqué L fois comme $\rho_{p_k} = D^{p_k} x$ produisant une matrice $H = [\rho_{p_1}, \rho_{p_2}, \dots, \rho_{p_L}]$. Les erreurs de prédiction peuvent également être mises dans un vecteur $\mathbf{e} = [e(1), e(2), \dots, e(N)]$. Enfin, le problème est réduit à l'équation $x = H\beta + e$, qui est résolue par la procédure d'estimation des moindres carrés donnant les coefficients FLP estimés $\hat{\beta}$ comme :

$$\hat{\beta} = (H^T H)^{-1} H^T x \quad (\text{D.7})$$

Ce processus est fait pour chaque trame d'analyse. Les paramètres obtenus $\hat{\beta}$ sont concaténés dans une matrice \mathbf{B} .

D.2 Performance de modélisation FLP pour le signal EMG

Dans la première partie, nous avons divisé après avoir fait l'étape de prétraitement le signal EMGs brut en trame d'analyse de durée 20, 50, 100, 200, 300 et 400 ms. Ensuite, nous avons calculé le gain de prédiction pour chaque trame et chaque ordre L sur la base du rapport signal / erreur (RSB) (voir équation D.8) et de l'erreur quadratique moyenne (EQM). Nous avons testé au hasard trois nombres d'ordre α avec $0 < \alpha < 1$. Les résultats obtenus ont été rapportés dans les tableaux D.1 et D.2 où le premier représente le gain moyen de prédiction pour les sujets normaux tandis que le second représente le gain de prédiction pour les patients Parkinsoniens. Comme nous pouvons le voir, les résultats mettent en évidence le gain de prédiction de performances sur la modélisation FLP pour le signal EMGs. En particulier, l'ordre $L = 11$ coefficients FLP semble être le plus approprié pour la modélisation de prédiction linéaire fractionnaire (FLP).

$$SER = 10 \log \frac{\sum_{i=1}^N [x(i)]^2}{\sum_{i=1}^N [x(i) - \hat{x}(i)]^2} \quad (\text{D.8})$$

Où N est la taille de la trame d'analyse, x et \hat{x} sont respectivement les signaux d'origine et les signaux simulés.

TABLE D.1 – Performance de modélisation du signal EMGs pour les sujets sains

Nombre de coefficients	gain de prédiction (dB)	Erreur quadratique moyenne (MSE)
03 coeff	10.85	0.1728
06 coeff	12.79	0.1290
11 coeff	13.25	0.0481

TABLE D.2 – Performance de modélisation du signal EMGs pour les sujets Parkinsoniens

Nombre de coefficients	gain de prédiction (dB)	Erreur quadratique moyenne (MSE)
03 coeff	8.57	0.3971
06 coeff	10.99	0.3855
11 coeff	12.21	0.3617

- [1] E Viel. Biomécanique des articulations sacro-iliaques. *Ann Kinesither*, 16 :423–430, 1989.
- [2] George Zouridakis. *Biomedical technology and devices handbook*. CRC press, 2003.
- [3] Kamel Mebarkia. *Paramétrisation des potentiels d'action d'une unité motrice détectés non-invasivement*. PhD thesis, 2018.
- [4] JV Basmajian and CJ DeLuca. *Muscles alive*. baltimore. Md. : *Williams & Wilkins*, 1985.
- [5] Julien Roussel. *Modélisation cyclostationnaire et séparation de sources des signaux électromyographiques*. PhD thesis, 2014.
- [6] Leif Sörnmo and Pablo Laguna. *Bioelectrical signal processing in cardiac and neurological applications*, volume 8. Academic Press, 2005.
- [7] Abdenour Hacine-Gharbi. *Sélection de paramètres acoustiques pertinents pour la reconnaissance de la parole*. PhD thesis, 2018.
- [8] Abdenour Hacine-Gharbi and Philippe Ravier. Wavelet cepstral coefficients for electrical appliances identification using hidden markov models. In *ICPRAM*, pages 541–549, 2018.
- [9] William W Campbell. *Essentials of electrodiagnostic medicine*. Demos Medical Publishing, 2013.

- [10] R Artois. La sclérose latérale amyotrophique, affection terrible et méconnue. *Le Monde*, 30, 2002.
- [11] EC Hayden. Rewired nerves control robotic leg. *Nature News*, 2013.
- [12] Tommaso Proietti. *Characterizing the reciprocal adaptation in physical human-robot interaction to address the inter-joint coordination in neurorehabilitation*. PhD thesis, 2017.
- [13] A Ferreira, RL Silva, WC Celeste, TF Bastos Filho, and M Sarcinelli Filho. Human-machine interface based on muscular and brain signals applied to a robotic wheelchair. In *Journal of Physics : Conference Series*, volume 90, page 012094. IOP Publishing, 2007.
- [14] Kevin R Wheeler. Device control using gestures sensed from emg. In *Proceedings of the 2003 IEEE International Workshop on Soft Computing in Industrial Applications, 2003. SMCia/03.*, pages 21–26. IEEE, 2003.
- [15] F Filloux. Quoi de neuf chez microsoft ? *Le Monde*, 16, 2010.
- [16] Sara Rosenblum, Margalit Samuel, Sharon Zlotnik, Ilana Erikh, and Ilana Schlesinger. Handwriting as an objective tool for parkinson’s disease diagnosis. *Journal of neurology*, 260(9) :2357–2361, 2013.
- [17] Beth Wendling. Gait analysis of left and right stride intervals in neurodegenerative diseases. *This is available online at < web. cecs. pdx. edu/~ edam/Reports/2004/Wendling.pdf*, 2008.
- [18] Akash Kumar Bhoi. Classification and clustering of parkinson’s and healthy control gait dynamics using lda and k-means. *International Journal Bioautomation*, 21(1), 2017.
- [19] Enas Abdulhay, N Arunkumar, Kumaravelu Narasimhan, Elamaran Vellaiappan, and V Venkatraman. Gait and tremor investigation using machine learning techniques for the diagnosis of parkinson disease. *Future Generation Computer Systems*, 83 :366–373, 2018.
- [20] Patrick Kugler, Christian Jaremenko, Johannes Schlachetzki, Juergen Winkler, Jochen Klucken, and Bjoern Eskofier. Automatic recognition of parkinson’s disease using

- surface electromyography during standardized gait tests. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 5781–5784. IEEE, 2013.
- [21] Akash P Manwatkar, SR Salwe, AP Bagade, and Ranjan Raut. A review on detection of parkinson’s disease.
- [22] Jingjing Xu and Minming Zhang. Use of magnetic resonance imaging and artificial intelligence in studies of diagnosis of parkinson’s disease. *ACS chemical neuroscience*, 10(6) :2658–2667, 2019.
- [23] Eleanor Porter, Andreas-Antonios Roussakis, Nicholas P Lao-Kaim, and Paola Piccini. Multimodal dopamine transporter (dat) imaging and magnetic resonance imaging (mri) to characterise early parkinson’s disease. *Parkinsonism & Related Disorders*, 2020.
- [24] Zeinab A Dastgheib, Brian Lithgow, and Zahra Moussavi. Diagnosis of parkinson’s disease using electrovestibulography. *Medical & biological engineering & computing*, 50(5) :483–491, 2012.
- [25] I Elamvazuthi, NHX Duy, Zulfiqar Ali, SW Su, MKA Ahamed Khan, and S Parasuraman. Electromyography (EMG) based classification of neuromuscular disorders using multi-layer perceptron. *Procedia Computer Science*, 76 :223–228, 2015.
- [26] Rhutuja K Raut and Ajay A Gurjar. Bio-medical (emg) signal feature extraction using wavelet transform for design of prosthetic leg. *International Journal of Electronics, Communication and Soft Computing Science & Engineering (IJECSCE)*, 4 :81, 2015.
- [27] Nurhazimah Nazmi, Mohd Azizi Abdul Rahman, Shin-Ichiroh Yamamoto, Siti Anom Ahmad, Hairi Zamzuri, and Saiful Amri Mazlan. A review of classification techniques of EMG signals during isotonic and isometric contractions. *Sensors*, 16(8) :1304, 2016.
- [28] Olivier Buttelli. Agence nationale de la recherche. <http://www.agence-nationale-recherche.fr/Projet-ANR-12-TECS-0020>, 2012.
- [29] Richard P Di Fabio. Reliability of computerized surface electromyography for determining the onset of muscle activity. *Physical Therapy*, 67(1) :43–48, 1987.

- [30] Silvestro Micera, Angelo M Sabatini, and Paolo Dario. An algorithm for detecting the onset of muscle contraction by EMG signal processing. *Medical Eng. & Physics*, 20(3) :211–215, 1998.
- [31] Lev Vaisman, José Zariffa, and Milos R Popovic. Application of singular spectrum-based change-point analysis to EMG-onset detection. *Journal of Electromyography and Kinesiology*, 20(4) :750–760, 2010.
- [32] Stanisław Solnik, Paul DeVita, Patrick Rider, Benjamin Long, and Tibor Hortobágyi. Teager–Kaiser operator improves the accuracy of EMG onset detection independent of signal-to-noise ratio. *Acta of bioengineering and biomechanics/Wroclaw University of Technology*, 10(2) :65, 2008.
- [33] Stanislaw Solnik, Patrick Rider, Ken Steinweg, Paul DeVita, and Tibor Hortobágyi. Teager–Kaiser energy operator signal conditioning improves EMG onset detection. *European Journal of Applied Physiology*, 110(3) :489–498, 2010.
- [34] Mateusz Magda. EMG onset detection development and comparison of algorithms. *Faculty of Computing Blekinge Institute of Technology Karlskrona Sweden*, 2015.
- [35] Paolo Bonato, Tommaso D’Alessio, and Marco Knaflitz. A statistical method for the measurement of muscle activation intervals from surface myoelectric signal during gait. *IEEE Transactions on Biomedical Engineering*, 45(3) :287–299, 1998.
- [36] Xiaoyan Li and Alexander S Aruin. Muscle activity onset time detection using Teager–Kaiser energy operator. *27th Annual International Conference of the Engineering in Medicine and Biology Society*, pages 7549–7552, 2005.
- [37] Andrea Merlo, Dario Farina, and Roberto Merletti. A fast and reliable technique for muscle activity detection from surface EMG signals. *IEEE Transactions on Biomedical Engineering*, 50(3) :316–323, 2003.
- [38] Kerem Tuncay Özgünen, Umut Çelik, and Sanlı Sadi Kurdak. Determination of an optimal threshold value for muscle activity detection in emg analysis. *Journal of sports science & medicine*, 9(4) :620, 2010.
- [39] Natalia M López, Eugenio Orosco, and Fernando di Sciascio. Surface Electromyographic onset detection based on statistics and information content. *Journal of Physics : Conference Series*, 332(1), 2011.

- [40] Xu Zhang and Ping Zhou. Sample entropy analysis of surface emg for improved muscle activity onset detection against spurious background spikes. *Journal of Electromyography and Kinesiology*, 22(6) :901–907, 2012.
- [41] Qi Xu, Yazhi Quan, Lei Yang, and Jiping He. An adaptive algorithm for the determination of the onset and offset of muscle contraction by EMG signal processing. *IEEE Trans on Neural Systems and Rehabilitation Engineering*, 21(1) :65–73, 2013.
- [42] Eugenio Orosco, Pablo Diez, Eric Laciari, Vicente Mut, Carlos Soria, and Fernando Di Sciascio. On the use of high-order cumulant and bispectrum for muscular-activity detection. *Biomedical Signal Processing and Control*, 18 :325–333, 2015.
- [43] Jie Liu, Dongwen Ying, and William Zev Rymer. EMG burst presence probability : A joint time–frequency representation of muscle activity and its application to onset detection. *Journal of Biomechanics*, 48(6) :1193–1197, 2015.
- [44] Gerhard H Staude, Werner M Wolf, Ulrich Appel, and Reinhard Dengler. Methods for onset detection of voluntary motor responses in tremor patients. *IEEE Transactions on Biomedical Engineering*, 43(2) :177–188, 1996.
- [45] Qi Xu, Yazhi Quan, Lei Yang, and Jiping He. An adaptive algorithm for the determination of the onset and offset of muscle contraction by EMG signal processing. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 21(1) :65–73, 2012.
- [46] Usman Rashid, Imran Khan Niazi, Nada Signal, Dario Farina, and Denise Taylor. Optimal automatic detection of muscle activation intervals. *Journal of Electromyography and Kinesiology*, 48 :103–111, 2019.
- [47] Xiaoyan Li, Ping Zhou, and Alexander S Aruin. Teager–kaiser energy operation of surface emg improves muscle activity onset detection. *Annals of biomedical engineering*, 35(9) :1532–1538, 2007.
- [48] Richard T Lauer and Laura A Prosser. Use of the teager-kaiser energy operator for muscle activity detection in children. *Annals of biomedical engineering*, 37(8) :1584–1593, 2009.
- [49] Hsiu-Jen Liu, Kuu-Young Young, et al. An adaptive upper-arm emg-based robot control system. *International Journal of Fuzzy Systems*, 12(3) :181–189, 2010.

- [50] Paolo Soda, Stefano Mazzoleni, Giuseppe Cavallo, Eugenio Guglielmelli, and Giulio Iannello. Human movement onset detection from isometric force and torque measurements : A supervised pattern recognition approach. *Artificial intelligence in medicine*, 50(1) :55–61, 2010.
- [51] Amal Naseem, Meryem Jabloun, Olivier Buttelli, and Phillippe Ravier. Detection of semg muscle activation intervals using gaussian mixture model and ant colony classifier. In *Signal Processing Conference (EUSIPCO), 2016 24th European*, pages 1713–1717. IEEE, 2016.
- [52] Sabri Koçer. Classification of EMG signals using neuro-fuzzy system and diagnosis of neuromuscular diseases. *Journal of Medical Systems*, 34(3) :321–329, 2010.
- [53] Dennis Tkach, He Huang, and Todd A Kuiken. Study of stability of time-domain features for electromyographic pattern recognition. *Journal of neuroengineering and rehabilitation*, 7(1) :21, 2010.
- [54] Kianoush Nazarpour, Ali H Al-Timemy, Guido Bugmann, and Andrew Jackson. A note on the probability distribution function of the surface electromyogram signal. *Brain research bulletin*, 90 :88–91, 2013.
- [55] Angkoon Phinyomark, Pornchai Phukpattaranont, and Chusak Limsakul. Feature reduction and selection for emg signal classification. *Expert systems with applications*, 39(8) :7420–7431, 2012.
- [56] Rami N Khushaba, Ahmed Al-Ani, and Adel Al-Jumaily. Orthogonal fuzzy neighborhood discriminant analysis for multifunction myoelectric hand control. *IEEE Transactions on Biomedical Engineering*, 57(6) :1410–1419, 2010.
- [57] Wan Mohd Bukhari Wan Daud, Abu Bakar Yahya, Chong Shin Horng, Mohamad Fani Sulaima, and Rubita Sudirman. Features extraction of electromyography signals in time domain on biceps brachii muscle. *International Journal of Modeling and Optimization*, 3(6) :515, 2013.
- [58] Alexandre Balbinot and Gabriela Favieiro. A neuro-fuzzy system for characterization of arm movements. *Sensors*, 13(2) :2613–2630, 2013.

- [59] Md R Ahsan, MI Ibrahimy, and OO Khalifa. Neural network classifier for hand motion detection from emg signal. In *5th Kuala Lumpur International Conference on Biomedical Engineering 2011*, pages 536–541. Springer, 2011.
- [60] Philippe Ravier, Meryem Jabloun, Mohamed Lamine Talbi, Ross Parry, Elodie Lalo, and Olivier Buttelli. Characterizing parkinson’s disease using emg fractional linear prediction. In *2016 24th European Signal Processing Conference (EUSIPCO)*, pages 1723–1727. IEEE, 2016.
- [61] Haitham M Al-Angari, Gunter Kanitz, Sergio Tarantino, and Christian Cipriani. Distance and mutual information methods for emg feature and channel subset selection for classification of hand movements. *Biomedical Signal Processing and Control*, 27 :24–31, 2016.
- [62] An-Chih Tsai, Jer-Junn Luh, and Ta-Te Lin. A novel stft-ranking feature of multi-channel emg for motion pattern recognition. *Expert Systems with Applications*, 42(7) :3327–3341, 2015.
- [63] Kevin Englehart, Bernard Hudgins, Philip A Parker, and Maryhelen Stevenson. Classification of the myoelectric signal using time-frequency based representations. *Medical Engineering and Physics*, 21(6) :431–438, 1999.
- [64] Rubana H Chowdhury, Mamun BI Reaz, Mohd Alauddin Bin Mohd Ali, Ashrif AA Bakar, Kalaivani Chellappan, and Tae G Chang. Surface electromyography signal processing and classification techniques. *Sensors*, 13(9) :12431–12466, 2013.
- [65] Saara Rissanen, Markku Kankaanpää, Mika P Tarvainen, Juho Nuutinen, Ina M Tarkka, Olavi Airaksinen, and Pasi A Karjalainen. Analysis of surface emg signal morphology in parkinson’s disease. *Physiological measurement*, 28(12) :1507, 2007.
- [66] Nooshin Haji Ghassemi, Franz Marxreiter, Cristian F Pasluosta, Patrick Kugler, Johannes Schlachetzki, Axel Schramm, Bjoern M Eskofier, and Jochen Klucken. Combined accelerometer and emg analysis to differentiate essential tremor from parkinson’s disease. In *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 672–675. IEEE, 2016.
- [67] Deepak Joshi, Aayushi Khajuria, and Pradeep Joshi. An automatic non-invasive method for parkinson’s disease classification. *Computer methods and programs in biomedicine*, 145 :135–145, 2017.

- [68] D Flament, DE Vaillancourt, T Kempf, K Shannon, and DM Corcos. Emg remains fractionated in parkinson's disease, despite practice-related improvements in performance. *Clinical neurophysiology*, 114(12) :2385–2396, 2003.
- [69] Julie A Robichaud, Kerstin D Pfann, Cynthia L Comella, Melanie Brandabur, and Daniel M Corcos. Greater impairment of extension movements as compared to flexion movements in parkinson's disease. *Experimental Brain Research*, 156(2) :240–254, 2004.
- [70] Masaru Okamoto, Yukihiro Matsubara, Keisuke Shima, and Toshio Tsuji. EMG pattern classification using hierarchical network based on boosting approach. *International Journal of innovative computing, information and control*, 5(12) :4935–4943, 2009.
- [71] Decho Surangsrirat, Chusak Thanawattano, Ronachai Pongthornseri, Songphon Dumnin, Chanawat Anan, and Roongroj Bhidayasiri. Support vector machine classification of parkinson's disease and essential tremor subjects based on temporal fluctuation. In *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 6389–6392. IEEE, 2016.
- [72] Donald B Lindsley. Electrical activity of human motor units during voluntary contraction. *American Journal of Physiology-Legacy Content*, 114(1) :90–99, 1935.
- [73] John Burdon-Sanderson. *Memoirs on the Physiology of Nerve, of Muscle and of the Electrical Organ*, volume 1. Clarendon Press, 1887.
- [74] Jean Martin Charcot. *Lectures on the diseases of the nervous system : Delivered at La Salpetriere*, volume 1. New Sydenham Society, 1877.
- [75] DR Wilkie. The relation between force and velocity in human muscle. *The Journal of physiology*, 110(3-4) :249, 1949.
- [76] James G Golseth. Diagnostic contributions of the electromyogram. *California medicine*, 73(4) :355, 1950.
- [77] Machiel J Zwarts, Gea Drost, and Dick F Stegeman. Recent progress in the diagnostic use of surface emg for neurological diseases. *Journal of Electromyography and Kinesiology*, 10(5) :287–291, 2000.

- [78] Yunfen Wu, María Ángeles Martínez Martínez, and Pedro Orizaola Balaguer. Overview of the application of emg recording in the diagnosis and approach of neurological disorders. In *Electrodiagnosis in New Frontiers of Clinical Research*, pages 1–24. IntechOpen, 2013.
- [79] JV Bashamajian and CJ De Luca. *Muscles alive baltimore*. MD Williams & Wilkins, 1985.
- [80] CI Sarmiento, D San-Juan, and VBS Prasath. Letter to the editor : Brief history of transcranial direct current stimulation (tdcs) : from electric fishes to microcontrollers. *Psychological medicine*, 46(15) :3259–3261, 2016.
- [81] Luigi Galvani. *Commentary on the effects of electricity on muscular motion*. Number 10. Burndy Library, 1953.
- [82] Haruo Uesugi, Masahiro Sonoo, Erik Stålberg, Kohji Matsumoto, Mana Higashihara, Hideharu Murashima, Yoshikazu Ugawa, Yu Nagashima, Teruo Shimizu, Hisatoshi Saito, et al. “clustering index method” : A new technique for differentiation between neurogenic and myopathic changes using surface emg. *Clinical Neurophysiology*, 122(5) :1032–1041, 2011.
- [83] Jean-Yves Hogrel. Clinical applications of surface electromyography in neuromuscular disorders. *Neurophysiologie Clinique/Clinical Neurophysiology*, 35(2-3) :59–71, 2005.
- [84] B Dubois, C Malapani, M Verin, P Rogelet, and B Deweer. Fonctions cognitives et noyaux gris centraux : le modèle de la maladie de parkinson. *Revue neurologique (Paris)*, 150(11) :763–770, 1994.
- [85] Enrico Finazzi-Agro, Antonella Peppe, ANDREA D’AMICO, Filomena Petta, Paolo Mazzone, Paolo Stanzione, Francesco Micali, and Carlo Caltagirone. Effects of sub-thalamic nucleus stimulation on urodynamic findings in patients with parkinson’s disease. *The Journal of urology*, 169(4) :1388–1391, 2003.
- [86] G Deuschl. Long-latency reflexes following stretch and nerve stimulation. In *Handbook of clinical neurophysiology*, volume 1, pages 285–294. Elsevier, 2003.
- [87] Sina Askari, Mo Zhang, and Deborah S Won. An emg-based system for continuous monitoring of clinical efficacy of parkinson’s disease treatments. In *2010 Annual*

- International Conference of the IEEE Engineering in Medicine and Biology*, pages 98–101. IEEE, 2010.
- [88] J Chaco and E Wolf. Impairment of postural reflexes in parkinson’s disease. *European neurology*, 4(6) :332–336, 1970.
- [89] N Accornero, A Berardelli, G Bini, G Cruccu, and M Manfredi. Corneal reflex elicited by electrical stimulation of the human cornea. *Neurology*, 30(7) :782–782, 1980.
- [90] EP Lukhanina, MT Kapoustina, and IN Karaban. A quantitative surface electromyogram analysis for diagnosis and therapy control in parkinson’s disease. *Parkinsonism & Related Disorders*, 6(2) :77–86, 2000.
- [91] Jie Zhang, Yan Xing, Xiuli Ma, and Liqun Feng. Differential diagnosis of parkinson disease, essential tremor, and enhanced physiological tremor with the tremor analysis of emg. *Parkinson’s Disease*, 2017, 2017.
- [92] G Alves, T Wentzel-Larsen, and Jan Petter Larsen. Is fatigue an independent and persistent symptom in patients with parkinson disease? *Neurology*, 63(10) :1908–1911, 2004.
- [93] Meg E Morris. Locomotor training in people with parkinson disease. *Physical Therapy*, 86(10) :1426–1435, 2006.
- [94] Roberto Merletti and Philip J Parker. *Electromyography : physiology, engineering, and non-invasive applications*, volume 11. John Wiley & Sons, 2004.
- [95] GERALD Stern. Did parkinsonism occur before 1817? *Journal of neurology, neurosurgery, and psychiatry*, 52(Suppl) :11, 1989.
- [96] BR Bloem. Postural instability in parkinson’s disease. *Clinical neurology and neurosurgery*, 94 :41–45, 1992.
- [97] Stewart A Factor, N Kyle Steenland, Donald S Higgins, Eric S Molho, Denise M Kay, Jennifer Montimurro, Ami R Rosen, Cyrus P Zabetian, and Haydeh Payami. Postural instability/gait disturbance in parkinson’s disease has distinct subtypes : an exploratory analysis. *Journal of Neurology, Neurosurgery & Psychiatry*, 82(5) :564–568, 2011.
- [98] Joseph Jankovic and Asha S Kapadia. Functional decline in parkinson disease. *Archives of neurology*, 58(10) :1611–1615, 2001.

- [99] Allan L Adkin, James S Frank, and Mandar S Jog. Fear of falling and postural control in parkinson's disease. *Movement disorders*, 18(5) :496–502, 2003.
- [100] L Beaudet, C Beauvais, S Chouinard, M Desjardins, M Panisset, E Pourcher, and V Soland. Chapitre 1 : La maladie de parkinson et ses traitements (p. 13-32), in la société du parkinson du québec (ed.), le guide infoparkinson. en ligne, 2002.
- [101] Jin Xu, Shyan-Yuan Kao, Frank JS Lee, Weihong Song, Lee-Way Jin, and Bruce A Yankner. Dopamine-dependent neurotoxicity of α -synuclein : a mechanism for selective neurodegeneration in parkinson disease. *Nature medicine*, 8(6) :600–606, 2002.
- [102] Daniel Weintraub, Andrew D Siderowf, Marc N Potenza, Joseph Goveas, Knashawn H Morales, John E Duda, Paul J Moberg, and Matthew B Stern. Association of dopamine agonist use with impulse control disorders in parkinson disease. *Archives of neurology*, 63(7) :969–973, 2006.
- [103] Atilla Ünlü, Rüdiger Brause, and Karsten Krakow. Handwriting analysis for diagnosis and prognosis of parkinson's disease. In *International Symposium on Biological and Medical Data Analysis*, pages 441–450. Springer, 2006.
- [104] Lisa M Shulman, Ann L Gruber-Baldini, Karen E Anderson, Christopher G Vaughan, Stephen G Reich, Paul S Fishman, and William J Weiner. The evolution of disability in parkinson disease. *Movement disorders*, 23(6) :790–796, 2008.
- [105] Margaret M Hoehn and Melvin D Yahr. Parkinsonism : onset, progression, and mortality. *Neurology*, 17(5) :427–427, 1967.
- [106] Resul Das. A comparison of multiple classification methods for diagnosis of parkinson disease. *Expert Systems with Applications*, 37(2) :1568–1572, 2010.
- [107] C Okan Sakar, Gorkem Serbes, Aysegul Gunduz, Hunkar C Tunc, Hatice Nizam, Betül Erdogan Sakar, Melih Tutuncu, Tarkan Aydin, M Erdem Isenkul, and Hulya Apaydin. A comparative analysis of speech signal processing algorithms for parkinson's disease classification and the use of the tunable q-factor wavelet transform. *Applied Soft Computing*, 74 :255–263, 2019.
- [108] K Guelton. Contribution à l'évaluation objective de la posture des sujets scoliotiques, 2000.

- [109] Maëva Le Goïc. *Etude du contrôle postural chez l'homme : analyse des facteurs neuro-physiologiques, biomécaniques et cognitifs, impliqués dans les 500 premières millisecondes d'une chute*. PhD thesis, Paris 5, 2013.
- [110] Yves Lajoie, Normand Teasdale, Chantal Bard, and Michelle Fleury. Attentional demands for static and dynamic equilibrium. *Experimental brain research*, 97(1) :139–144, 1993.
- [111] Keith C Hayes. Biomechanics of postural control. *Exercise and sport sciences reviews*, 10(1) :363, 1982.
- [112] Simon Bouisset and Jean-Luc Duchêne. Is body balance more perturbed by respiration in seating than in standing posture? *Neuroreport*, 5(8) :957–960, 1994.
- [113] T Okada, T Fujita, M Kubota, S Masaki, N Mataga, R Ide, Y Sakata, and S Misumi. Intramolecular electron donor-acceptor interactions in the excited state of (anthracene)-(ch₂)_n-(n, n-dimethylaniline) systems. *Chemical Physics Letters*, 14(5) :563–568, 1972.
- [114] SVEN CARLSÖÖ. The static muscle load in different work positions : an electromyographic study. *Ergonomics*, 4(3) :193–211, 1961.
- [115] Fay B Horak. Postural orientation and equilibrium : what do we need to know about neural control of balance to prevent falls? *Age and ageing*, 35(suppl_2) :ii7–ii11, 2006.
- [116] David A Winter. Human balance and posture control during standing and walking. *Gait & posture*, 3(4) :193–214, 1995.
- [117] Yvon Brenière. Why we walk the way we do. *Journal of motor behavior*, 28(4) :291–298, 1996.
- [118] Elaine Nicpon Marieb and Katja Hoehn. *Human anatomy & physiology*. Pearson education, 2007.
- [119] Gerard J Tortora and Bryan Derrickson. *Anatomie et physiologie*. De Boeck supérieur, 2018.
- [120] Jacques Paillard et al. Le codage nerveux des commandes motrices. *Rev EEG Neurophysiol*, 6(4) :453–72, 1976.

- [121] Sue Bodine-Fowler, Alan Garfinkel, Roland R Roy, and V Reggie Edgerton. Spatial distribution of muscle fibers within the territory of a motor unit. *Muscle & Nerve : Official Journal of the American Association of Electrodiagnostic Medicine*, 13(12) :1133–1145, 1990.
- [122] Edgar D Adrian and Detlev W Bronk. The discharge of impulses in motor nerve fibres : Part ii. the frequency of discharge in reflex and voluntary contractions. *The Journal of physiology*, 67(2) :9–151, 1929.
- [123] Alan L Hodgkin, Andrew F Huxley, and Bernard Katz. Measurement of current-voltage relations in the membrane of the giant axon of loligo. *The Journal of physiology*, 116(4) :424–448, 1952.
- [124] Edward George Tandy Liddell and Charles Scott Sherrington. Recruitment and some other features of reflex inhibition. *Proceedings of the Royal Society of London. Series B, Containing Papers of a Biological Character*, 97(686) :488–518, 1925.
- [125] Matt S Stock, Travis W Beck, and Jason M Defreitas. Effects of fatigue on motor unit firing rate versus recruitment threshold relationships. *Muscle & nerve*, 45(1) :100–109, 2012.
- [126] CARLO J De Luca, ANDREW M Roy, and ZEYNEP Erim. Synchronization of motor-unit firings in several human muscles. *Journal of neurophysiology*, 70(5) :2010–2023, 1993.
- [127] Steen Andreassen and Annelise Rosenfalck. Regulation of the firing pattern of single motor units. *Journal of Neurology, Neurosurgery & Psychiatry*, 43(10) :897–906, 1980.
- [128] Steen Andreassen and Lars Arendt-Nielsen. Muscle fibre conduction velocity in motor units of the human anterior tibial muscle : a new size principle parameter. *The Journal of Physiology*, 391(1) :561–571, 1987.
- [129] H Peter Clamann. Statistical analysis of motor unit firing patterns in a human skeletal muscle. *Biophysical journal*, 9(10) :1233–1251, 1969.
- [130] William H Calvin and CHARLES F Stevens. Synaptic noise and other sources of randomness in motoneuron interspike intervals. *Journal of neurophysiology*, 31(4) :574–587, 1968.

- [131] Elwood Henneman. Relation between size of neurons and their susceptibility to discharge. *Science*, 126(3287) :1345–1347, 1957.
- [132] Lorne M Mendell. The size principle : a rule describing the recruitment of motoneurons. *Journal of Neurophysiology*, 93(6) :3024–3026, 2005.
- [133] Elwood Henneman, George Somjen, and David O Carpenter. Functional significance of cell size in spinal motoneurons. *Journal of neurophysiology*, 28(3) :560–580, 1965.
- [134] Mamun Bin Ibne Reaz, MS Hussain, and Faisal Mohd-Yasin. Techniques of EMG signal analysis : detection, processing, classification and applications. *Biological procedures online*, 8(1) :11, 2006.
- [135] Roberto Merletti, Dario Farina, and Aleš Holobar. Surface electromyography (semg). *Wiley encyclopedia of electrical and electronics engineering*, pages 1–22, 1999.
- [136] François Hug and Kylie Tucker. Surface electromyography to study muscle coordination. 2018.
- [137] Edward Shwedyk, R Balasubramanian, and RN Scott. A nonstationary model for the electromyogram. *IEEE Transactions on Biomedical Engineering*, (5) :417–424, 1977.
- [138] Ralph D Hippenstiel. *Detection theory : applications and digital signal processing*. CRC Press, 2017.
- [139] Bassem R Mahafza. *Radar systems analysis and design using MATLAB*. CRC press, 2002.
- [140] Petr Pollak, Pavel Sovka, and Jan Uhlir. Noise suppression system for a car. *Third European Conference on Speech Communication and Technology*, 93 :1073–1076, 1993.
- [141] R Venkatesha Prasad, Abhijeet Sangwan, HS Jamadagni, MC Chiranth, Rahul Sah, and Vishal Gaurav. Comparison of voice activity detection algorithms for VoIP. *Seventh International Symposium on Computers and Communications*, pages 530–535, 2002.
- [142] Abhijeet Sangwan, MC Chiranth, HS Jamadagni, Rahul Sah, R Venkatesha Prasad, and Vishal Gaurav. VAD techniques for real-time speech transmission on the internet. *5th IEEE International Conference on High Speed Networks and Multimedia Communications*, pages 46–50, 2002.

- [143] Dinesh D Patil, RP Singh, Vilas M Thakare, and Avinash K Gulve. Automatic classification of ecg arrhythmia using morphological parameters with hmm and svm. *International Journal of Applied Engineering Research*, 12(20) :10376–10384, 2017.
- [144] Dihong Jiang, Ya-nan Lu, MA Yu, and WANG Yuanyuan. Robust sleep stage classification with single-channel eeg signals using multimodal decomposition and hmm-based refinement. *Expert Systems with Applications*, 121 :188–203, 2019.
- [145] Mohamed Nait-Meziane, Abdenour Hacine-Gharbi, Philippe Ravier, Guy Lamarque, Jean-Charles Le Bunetel, and Yves Raingeaud. Hmm-based transient and steady-state current signals modeling for electrical appliances identification. In *Proceedings of the 5th International Conference on Pattern Recognition Applications and Methods*, pages 670–677. SCITEPRESS-Science and Technology Publications, Lda, 2016.
- [146] Abed Khorasani and Mohammad Reza Daliri. Hmm for classification of parkinson’s disease based on the raw gait data. *Journal of medical systems*, 38(12) :147, 2014.
- [147] Matteo Rossi, Simone Benatti, Elisabetta Farella, and Luca Benini. Hybrid emg classifier based on hmm and svm for hand gesture recognition in prosthetics. In *2015 IEEE International Conference on Industrial Technology (ICIT)*, pages 1700–1705. IEEE, 2015.
- [148] Jang-Woo Kwon, Jung-Ho Kim, and Heung-Ho Choi. Classification of the emg signal using cascaded classifier. In *World Congress on Medical Physics and Biomedical Engineering 2006*, pages 1222–1225. Springer, 2007.
- [149] José Dilermando Costa Junior, José Manoel de Seixas, et al. A template subtraction method for reducing electrocardiographic artifacts in emg signals of low intensity. *Biomedical Signal Processing and Control*, 47 :380–386, 2019.
- [150] James F Kaiser. On a simple algorithm to calculate the energy of a signal. *International Conference on Acoustics, Speech, and Signal Processing*, pages 381–384, 1990.
- [151] Ping Zhou and Xu Zhang. A novel technique for muscle onset detection using surface emg signals without removal of ecg artifacts. *Physiological measurement*, 35(1) :45, 2013.

- [152] Alexandre Balbinot, Guilherme Corseti, and Amanda Balbinot. Adaptive and linear energy based detector for a virtual mouse control. *International Work-conference on Bioinformatics and Biomedical Engineering*, pages 147–154, 2013.
- [153] Verteletskaya Ekaterina Sakhnov Kirill and Simak Boris. Approach for energy-based voice detector with adaptive scaling factor. *IAENG International Journal of Computer Science*, 2009, 36(4), 2009.
- [154] Herbert Aron David and Haikady Navada Nagaraja. Order statistics. *Encyclopedia of Statistical Sciences*, 9, 2004.
- [155] JD Moore and NB Lawrence. Comparison of two CFAR methods used with square law detection of swerling I targets. *International Radar Conference*, 1 :403–409, 1980.
- [156] Hichem BENGACEMI, Karim ABED-MERAIM, Olivier BUTTELLI, Abdlaziz OUL-DALI, and Ammar MESLOUB. A new detection method for emg activity monitoring derivation of the false alarm and detection probabilities., 2018.
- [157] Steve Young, Gunnar Evermann, Mark Gales, Thomas Hain, Dan Kershaw, Xunying Liu, Gareth Moore, Julian Odell, Dave Ollason, Dan Povey, et al. The htk book. *Cambridge university engineering department*, 3 :175, 2002.
- [158] Abdenour Hacine-Gharbi and Philippe Ravier. On the optimal number estimation of selected features using joint histogram based mutual information for speech emotion recognition. *Journal of King Saud University-Computer and Information Sciences*, 2019.
- [159] Jean-Paul Haton, Christophe Cerisara, Dominique Fohr, Yves Laprie, and Kamel Smaïli. *Reconnaissance automatique de la parole : Du Signal à son Interprétation*. Dunod, 2006.
- [160] Claude C Chibelushi, Farzin Deravi, and John SD Mason. A review of speech-based bimodal recognition. *IEEE transactions on multimedia*, 4(1) :23–37, 2002.
- [161] Dario Farina, Elena Fortunato, and Roberto Merletti. Noninvasive estimation of motor unit conduction velocity distribution using linear electrode arrays. *IEEE Transactions on Biomedical Engineering*, 47(3) :380–388, 2000.
- [162] Dario Farina and Roberto Merletti. A novel approach for precise simulation of the EMG signal detected by surface electrodes. *IEEE Transactions on Biomedical Engineering*, 48(6) :637–646, 2001.

- [163] Marco Barbero, Roberto Merletti, and Alberto Rainoldi. *Atlas of muscle innervation zones : understanding surface electromyography and its applications*. Springer Science & Business Media, 2012.
- [164] Jingwei Too, AR Abdullah, Norhashimah Mohd Saad, N Mohd Ali, and H Musa. A detail study of wavelet families for EMG pattern recognition. *International Journal of Electrical and Computer Engineering (IJECE)*, 8(6) :4221–4229, 2018.
- [165] MS Hussain, Mamun Bin Ibne Reaz, Faisal Mohd-Yasin, and Muhammad I Ibrahimy. Electromyography signal analysis using wavelet transform and higher order statistics to determine muscle contraction. *Expert Systems*, 26(1) :35–48, 2009.
- [166] K Mahaphonchaikul, D Sueaseenak, C Pintavirooj, M Sangworasil, and S Tungjitkusolmun. EMG signal feature extraction based on wavelet transform. In *ECTI-CON2010 : The 2010 ECTI International Confernce on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, pages 327–331. IEEE, 2010.
- [167] Angkoon Phinyomark, Chusak Limsakul, and Pornchai Phukpattaranont. An optimal wavelet function based on wavelet denoising for multifunction myoelectric control. In *2009 6th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, volume 2, pages 1098–1101. IEEE, 2009.
- [168] Timoteo Carletti, Duccio Fanelli, and Alessio Guarino. A new route to non invasive diagnosis in neurodegenerative diseases? *Neuroscience letters*, 394(3) :252–255, 2006.
- [169] Osamu Henmi, Yoshitaka Shiba, Toyokazu Saito, Harukazu Tsuruta, Akihiro Takeuchi, Masuo Shirataka, Shuichi Obuchi, Motonaga Kojima, and Noriaki Ikeda. Spectral analysis of gait variability of stride interval time series : comparison of young, elderly and parkinson’s disease patients. *Journal of Physical Therapy Science*, 21(2) :105–111, 2009.
- [170] Jeffrey M Hausdorff, Merit E Cudkowicz, Renée Firtion, Jeanne Y Wei, and Ary L Goldberger. Gait variability and basal ganglia disorders : Stride-to-stride variations of gait cycle timing in parkinson’s disease and huntington’s disease. *Movement disorders*, 13(3) :428–437, 1998.

- [171] L Sugavaneswaran, K Umapathy, and S Krishnan. Ambiguity domain-based identification of altered gait pattern in ALS disorder. *Journal of neural engineering*, 9(4) :046004, 2012.
- [172] Jeffrey M Hausdorff, Susan L Mitchell, Renee Firtion, Chung-Kang Peng, Merit E Cudkowicz, Jeanne Y Wei, and Ary L Goldberger. Altered fractal dynamics of gait : reduced stride-interval correlations with aging and huntington’s disease. *Journal of applied physiology*, 82(1) :262–269, 1997.
- [173] Robert A Miller, Michael H Thaut, Gerald C McIntosh, and Ruth R Rice. Components of EMG symmetry and variability in parkinsonian and healthy elderly gait. *Electroencephalography and Clinical Neurophysiology/Electromyography and Motor Control*, 101(1) :1–7, 1996.
- [174] Qi Wei Oung, Hariharan Muthusamy, Shafriza Nisha Basah, Hoileong Lee, and Vikneswaran Vijean. Empirical wavelet transform based features for classification of parkinson’s disease severity. *Journal of medical systems*, 42(2) :29, 2018.
- [175] Farika T Putri, Mochammad Ariyanto, Wahyu Caesarendra, Rifky Ismail, Khairisma Agung Pambudi, and Elta Diah Pasmansari. Low cost parkinson’s disease early detection and classification based on voice and electromyography signal. In *Computational Intelligence for Pattern Recognition*, pages 397–426. Springer, 2018.
- [176] Rajamanickam Yuvaraj, U Rajendra Acharya, and Yuki Hagiwara. A novel parkinson’s disease diagnosis index using higher-order spectra features in eeg signals. *Neural Computing and Applications*, 30(4) :1225–1235, 2018.
- [177] Paul E Barkhaus. Motor unit action potential quantitation. In *An AAEM workshop. Rochester, Minn : American Association of Electrodiagnostic Medicine*, volume 2, 2001.
- [178] Ignacio Rodríguez-Carreño, Luis Gila-Useros, and Armando Malanda-Trigueros. Motor unit action potential duration : measurement and significance. In *Advances in Clinical Neurophysiology*. InTech, 2012.
- [179] Cynthia Kendell, Edward D Lemaire, Yves Losier, Adam Wilson, Adrian Chan, and Bernie Hudgins. A novel approach to surface electromyography : an exploratory study of electrode-pair selection based on signal characteristics. *Journal of neuroengineering and rehabilitation*, 9(1) :24, 2012.

- [180] Rubana Haque Chowdhury and Mamun Bin Ibne Reaz. Fatigue contraction analysis using empirical mode decomposition and wavelet transform. *Jurnal Teknologi*, 77(6), 2015.
- [181] Antonietta Stango, Francesco Negro, and Dario Farina. Spatial correlation of high density emg signals provides features robust to electrode number and shift in pattern recognition for myocontrol. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 23(2) :189–198, 2014.
- [182] Sadaoki Furui. Cepstral analysis technique for automatic speaker verification. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 29(2) :254–272, 1981.
- [183] Sadaoki Furui. Speaker-independent isolated word recognition using dynamic features of speech spectrum. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 34(1) :52–59, 1986.
- [184] Steve Young, G Evermann, M Gales, T Hain, D Kershaw, G Moore, J Odell, D Ollason, D Povey, V Valtchev, et al. The htk book (for htk version. 3.3), cambridge university engineering department, 2005. URL <http://htk.eng.cam.ac.uk/docs/docs.shtml>, 2006.
- [185] Ryan Tibshirani. Data mining : Spring 2013, 2018.
- [186] Ronald A Fisher. The use of multiple measurements in taxonomic problems. *Annals of eugenics*, 7(2) :179–188, 1936.
- [187] C Radhakrishna Rao. The utilization of multiple measurements in problems of biological classification. *Journal of the Royal Statistical Society. Series B (Methodological)*, 10(2) :159–203, 1948.
- [188] Asa Ben-Hur and Jason Weston. A user’s guide to support vector machines. In *Data mining techniques for the life sciences*, pages 223–239. Springer, 2010.
- [189] Naomi S Altman. An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 46(3) :175–185, 1992.
- [190] Douglas A Reynolds. A gaussian mixture modeling approach to text-independent speaker identification. 1993.

- [191] Douglas A Reynolds, Thomas F Quatieri, and Robert B Dunn. Speaker verification using adapted gaussian mixture models. *Digital signal processing*, 10(1-3) :19–41, 2000.
- [192] Yonghong Huang, Kevin B Englehart, Bernard Hudgins, and Adrian DC Chan. A gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses. *IEEE Transactions on Biomedical Engineering*, 52(11) :1801–1811, 2005.
- [193] Todd K Moon. The expectation-maximization algorithm. *IEEE Signal processing magazine*, 13(6) :47–60, 1996.
- [194] OLUWOLE CHARLES AKINYOKUN. Neuro-fuzzy expert system for evaluation of human resource performance first bank of nigeria plc endowment fund lecture. 2002.
- [195] Dan CireşAn, Ueli Meier, Jonathan Masci, and Jürgen Schmidhuber. Multi-column deep neural network for traffic sign classification. *Neural networks*, 32 :333–338, 2012.
- [196] Lawrence R Rabiner. A tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2) :257–286, 1989.
- [197] Charles Jorgensen, Kevin Wheeler, Slawomir Stepniewski, and Peter Norvig. Bioelectric control of a 757 class high fidelity aircraft simulation. 2000.
- [198] William Simon. The real-time sorting of neuro-electric action potentials in multiple unit studies. *Electroencephalography and clinical neurophysiology*, 18(2) :192–195, 1965.
- [199] Daniel G Keehn. An iterative spike separation technique. *IEEE Transactions on Biomedical Engineering*, (1) :19–28, 1966.
- [200] JF Vibert and J Costa. Spike separation in multiunit records : a multivariate analysis of spike descriptive parameters. *Electroencephalography and clinical neurophysiology*, 47(2) :172–182, 1979.
- [201] JM Agnier, B Rouvrais, JL Coatrieux, P-Y Arques, and R Le Bars. Presentation de methodes de reconnaissance des signaux d’électromyographie. In *8° Colloque sur le traitement du signal et des images, FRA, 1981*. GRETSI, Groupe d’Etudes du Traitement du Signal et des Images, 1981.

- [202] Kevin C McGill. Optimal resolution of superimposed action potentials. *IEEE Transactions on Biomedical Engineering*, 49(7) :640–650, 2002.
- [203] Yong Ning, Xiangjun Zhu, Shanan Zhu, and Yingchun Zhang. Surface emg decomposition based on k-means clustering and convolution kernel compensation. *IEEE journal of biomedical and health informatics*, 19(2) :471–477, 2014.
- [204] Alexander Kenneth Clarke, S Farokh Atashzar, Alessandro Del Vecchio, Deren Y Barsakcioglu, Silvia Muceli, Paul Bentley, Filip Urh, Ales Holobar, and Dario Farina. Deep learning for robust decomposition of high-density surface emg signals. *IEEE Transactions on Biomedical Engineering*, 2020.
- [205] Ronald S LeFever and Carlo J De Luca. A procedure for decomposing the myoelectric signal into its constituent action potentials-part i : technique, theory, and implementation. *IEEE transactions on biomedical engineering*, (3) :149–157, 1982.
- [206] Kevin C McGill, Zoia C Lateva, and Hamid R Marateb. Emglab : an interactive emg decomposition program. *Journal of neuroscience methods*, 149(2) :121–133, 2005.
- [207] D Farina, F Lebrun, C Fevotte, C Doncarli, and R Merletti. Blind source separation of multiplicative mixtures of non-stationary surface emg signals. In *19Colloque sur le traitement du signal et des images, FRA, 2003*. GRETSI, Groupe d’Etudes du Traitement du Signal et des Images, 2003.
- [208] Direk Sueaseenak, Theerasak Chanwimalueang, Manas Sangworasil, and Chuchart Pintavirooj. An investigation of robustness in independent component analysis emg. In *2009 6th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, volume 2, pages 1102–1105. IEEE, 2009.
- [209] Ganesh R Naik, Dinesh K Kumar, and Hans Weghorn. Ica based identification of sources in semg. In *2007 3rd International Conference on Intelligent Sensors, Sensor Networks and Information*, pages 619–624. IEEE, 2007.
- [210] Ganesh R Naik, Dinesh K Kumar, Sridhar P Arjunan, M Palaniswami, and Rezaul Begg. Limitations and applications of ica for surface electromyogram. In *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 5739–5742. IEEE, 2006.

- [211] Ganesh R Naik, Dinesh K Kumar, and Marimuthu Palaniswami. Source identification and separation using sub-band ica of semg. In *TENCON 2008-2008 IEEE Region 10 Conference*, pages 1–6. IEEE, 2008.
- [212] Satoshi Horihata, Zhong Zhang, Takeshi Enomoto, Hiroshi Toda, Takashi Imamura, Tetsuo Miyake, and Yoshifumi Yasuda. Independent component analysis using wavelet transform and its application to biological signals. In *2008 International Conference on Wavelet Analysis and Pattern Recognition*, volume 1, pages 436–441. IEEE, 2008.
- [213] Hoda Dehghan. *Convulsive Blind Sparse Source Separation with Application to EMG Decomposition*. PhD thesis, Carleton University, 2016.
- [214] Francesco Negro, Silvia Muceli, Anna Margherita Castronovo, Ales Holobar, and Dario Farina. Multi-channel intramuscular and surface emg decomposition by convulsive blind source separation. *Journal of neural engineering*, 13(2) :026027, 2016.
- [215] Abdelouahab Boudjellal, Karim Abed-Meraim, Abdeldjalil Aïssa-El-Bey, Adel Belouchrani, and Ph Ravier. Sparsity-based algorithms for blind separation of convulsive mixtures with application to emg signals. In *2014 IEEE workshop on statistical signal processing (SSP)*, pages 189–192. IEEE, 2014.
- [216] Fabian J Theis and Gonzalo A García. On the use of sparse signal decomposition in the analysis of multi-channel surface electromyograms. *Signal Processing*, 86(3) :603–623, 2006.
- [217] Zhaoshui He, Shengli Xie, Shuxue Ding, and Andrzej Cichocki. Convulsive blind source separation in the frequency domain based on sparse representation. *IEEE Transactions on Audio, Speech, and Language Processing*, 15(5) :1551–1563, 2007.
- [218] Te-Won Lee, Anthony J Bell, and Russell H Lambert. Blind separation of delayed and convolved sources. In *Advances in neural information processing systems*, pages 758–764, 1997.
- [219] Yuanqing Li, Andrzej Cichocki, and Shun-ichi Amari. Analysis of sparse representation and blind source separation. *Neural computation*, 16(6) :1193–1234, 2004.
- [220] Yuanqing Li, Shun-Ichi Amari, Andrzej Cichocki, Daniel WC Ho, and Shengli Xie. Underdetermined blind source separation based on sparse representation. *IEEE Transactions on signal processing*, 54(2) :423–437, 2006.

- [221] Te-Won Lee, Michael S Lewicki, Mark Girolami, and Terrence J Sejnowski. Blind source separation of more sources than mixtures using overcomplete representations. *IEEE signal processing letters*, 6(4) :87–90, 1999.
- [222] Mounira Maazaoui, Karim Abed-Meraim, and Yves Grenier. Blind source separation for robot audition using fixed hrtf beamforming. *EURASIP Journal on Advances in Signal Processing*, 2012(1) :1–18, 2012.
- [223] Marvin K Simon. *Probability distributions involving Gaussian random variables : A handbook for engineers and scientists*. Springer Science & Business Media, 2007.
- [224] Khaled Assaleh and Wajdi M Ahmad. Modeling of speech signals using fractional calculus. In *9th International Symposium on Signal Processing and Its Applications ISSPA.*, pages 1–4. IEEE, 2007.
- [225] Varun Joshi, Ram Bilas Pachori, and Antony Vijesh. Classification of ictal and seizure-free EEG signals using fractional linear prediction. *Biomedical Signal Processing and Control*, 9 :1–5, 2014.
- [226] Mohamed Lamine Talbi and Philippe Ravier. Detection of PVC in ECG signals using fractional linear prediction. *Biomedical Signal Processing and Control*, 23 :42–51, 2016.
- [227] Omry Paiss and Gideon F Inbar. Autoregressive modeling of surface EMG and its spectrum with application to fatigue. *Mathematical and Computer Modelling*, 10(10) :793–794, 1988.
- [228] Marius Eckert, Martin Kupper, and Sören Hohmann. Functional fractional calculus for system identification of battery cells. *at–Automatisierungstechnik*, 62(4) :272–281, 2014.
- [229] Tadeusz Kaczorek. *Selected problems of fractional systems theory*, volume 411. Springer Science & Business Media, 2011.

L'Analyse de signaux EMG et leur application au diagnostic de la maladie de Parkinson

Résumé : L'objectif de cette thèse est l'analyse des signaux EMG de surface et leur application au diagnostic de la maladie de Parkinson (MP). Trois points ont été abordés dans cette thèse à savoir la segmentation des signaux EMG de surface, la classification ou diagnostic de la MP basé sur l'apprentissage machine et la décomposition du signal EMG de surface en TPAUM.

Dans le premier point, nous avons développé, deux techniques originales. La première, ALED et ses variantes, est non supervisée alors que la seconde est supervisée et est basée sur l'utilisation des modèles HMM. Ces techniques ont été développées pour la détection des bouffées d'activités EMG et leur analyse.

Dans le second point, nous avons proposé deux systèmes de diagnostic de la MP. Le premier est basé sur l'analyse des bouffées d'activité EMG en utilisant et comparant différents descripteurs et différentes techniques de classification existantes dans la littérature. Le deuxième système est basé sur les HMM.

Dans le dernier point, une méthode de décomposition du signal EMG de surface en TPAUM est proposée, basée sur la séparation de sources via leur parcimonie temporelle.

Mots clés : Signal EMG de surface, maladie de Parkinson, activité EMG, FM-ALED, HMM, BSS.

Analysis of EMG signals and their application to the diagnosis of Parkinson's disease

Summary: The objective of this thesis is the study of surface EMG signal and its application for Parkinson's disease (PD) diagnosis. Three problems have been investigated, namely the segmentation of surface EMG signals, the classification or diagnosis of PD and the decomposition of the surface EMG signal into TPAUM.

In the first problem, two techniques have been introduced for EMG signal segmentation. The first one is an unsupervised method called ALED and the second one is a supervised one based on the use of HMM models. These techniques are developed for the detection of the bursts EMG activity and their monitoring.

To deal with the second problem, we have proposed two diagnostic systems for PD detection. The first one is based on the analysis of the burst EMG activity using (and comparing) different features and different classification techniques from the literature and the second one is based on HMMs.

For the last problem, we have developed a new technique for the EMGs signal decomposition into TPAUM based on sparse source separation.

Keywords: Surface EMG signal, Parkinson disease, EMG activity, FM-ALED, HMM, BSS.



PRISME - Laboratoire Pluridisciplinaire de Recherche en
Ingénierie des Systèmes et Mécanique Energétique.

Université d'Orléans. France

