

الجمهورية الجزائرية الديمقراطية الشعبية

**REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE**

وزارة التعليم العالي والبحث العلمي

**Ministère de l'Enseignement Supérieur et de la Recherche Scientifique**

جامعة أبي بكر بلقايد - تلمسان

Université Aboubakr Belkaïd – Tlemcen –

Faculté de TECHNOLOGIE



**THESE**

Présentée pour l'obtention du **grade de DOCTORAT 3<sup>ème</sup> Cycle**

**En** : Génie Biomédical

**Spécialité** : Instrumentation Biomédical

**Par** : Aicha MOKDAD

Analyse Temps-Fréquence du signal Electromyogramme (EMG)

Soutenue publiquement, le 19 /06 /2022, devant le jury composé de :

M Lotfi HAMZA CHERIF	Professeur	Univ. Tlemcen	Président
M Sidi Mohamed El Amine DEBBAL	Professeur	Univ. Tlemcen	Directeur de thèse
Mme Fadia MEZIANI	MCA	Univ. Tlemcen	Co- Directeur de thèse
M Mahdi SOUIER	Professeur	ESM. Tlemcen	Examineur 1
Melle Nour El Houda BAAKEK YETTOU	MCA	Univ. Tlemcen	Examineur 2

Je dédie cette thèse à :

Ma mère et mon père

Mes sœurs et frères.

L'âme de mon neveu

Aicha MOKDAD

Avril, 2022

## Remerciements

Je remercie vivement Monsieur DEBBAL. Sidi Mohamed El Amine mon directeur de thèse pour m'avoir donné l'opportunité de travailler sur le traitement et la classification des signaux électromyogrammes. Mes plus sincères remerciements vont à Mme MEZIANI Fadia, mon Co-encadrante pour ses conseils et sa confiance dans mon travail.

Je remercie sincèrement Monsieur SOUIER Mahdi, de l'école supérieure de management à Tlemcen et mademoiselle BAAKEK YETTOU Nour El Houda de l'université de Tlemcen, qui ont accepté de faire partie de mon jury, Le professeur HAMZA CHERIF Lotfi de l'université de Tlemcen qui m'a fait l'honneur de présider mon jury, Monsieur BENGACEMI Hichem de l'hôpital militaire de Ain Naaja, Monsieur Fabien DAL MASO de l'université de Montréal, Monsieur TALBI Abdelhamid. Je les remercie pour leur regard critique et pertinent ainsi que leurs conseils judicieux.

Mes derniers remerciements et non pas de moindres, à ma famille à qui je dédie ce travail. Mes remerciements seront également à mes parents pour leur soutien, leur amour, leur présence même du loin, je ne pourrai jamais les remercier assez pour ce qu'ils font pour moi et si j'en suis là maintenant c'est grâce à eux. A mes frères, mes sœurs, mes neveux et mes collègues. "Je vous dois tellement !"

## Liste de matières

Remerciements.....	ii
Liste des figures.....	vii
Listes des tableaux.....	x
Nomenclature.....	xi
Introduction Générale.....	1

### **Chapitre 1 : Le système neuromusculaire et le signal Electromyographie (EMG)**

1.1 Introduction.....	11
1.1 L'anatomie et la physiologie musculaire.....	11
1.2 Les caractéristiques du tissu musculaire .....	12
1.3 Fonctions musculaires.....	12
1.4 Les différents types des muscles .....	12
1.4.1 Anatomie du muscle squelettique.....	13
1.5 Les fibres musculaires.....	14
1.6 Les propriétés fonctionnelles de la fibre musculaire .....	15
1.6.1 Actine.....	15
1.6.2 Myosine .....	15
1.7 La contraction musculaire .....	16
1.7.1 Mécanismes cellulaires de la contraction musculaire .....	16
1.7.2 Les différents types de contraction musculaire .....	19
1.8 L'Electromyogramme .....	19
1.8.1 source de signal EMG .....	20
1.8.1.1 Potentiel d'action nerveux.....	20
1.8.1.2 Potentiel d'action d'une unité motrice .....	20
1.8.2 Détection de signal EMG .....	21
1.8.2.1 Electrodes de surface .....	22
1.8.2.2 Les électrodes Aiguilles.....	23
1.8.2.3 Stimulateurs.....	25
1.8.3 Caractéristiques des signaux EMG.....	25
1.9 Les pathologies neuromusculaires.....	30
1.9.1 La sclérose latérale amyotrophique (SLA).....	31
1.9.2 Démarche diagnostique de la SLA.....	32
1.9.2.1 L'électroneuromyogramme (ENMG) .....	32
1.9.2.2 La SLA et l'électromyogramme de détection .....	32
1.10 Conclusion .....	34

## **Chapitre 2 : Techniques de débruitage des signaux électromyogrammes EMG**

2.1 Introduction .....	35
2.2 Prétraitement du signal EMG.....	35
2.2.1 Signal EMG normalisé en amplitude et en temps .....	35
2.2.2 EMG lissé.....	37
2.2.2.1 Débruitage par un filtre linéaire.....	37
2.2.2.2 Débruitage par seuillage.....	37
2.2.2.2.1 Le seuillage dur (hard thresholding).....	38
2.2.2.2.2 Le seuillage doux (soft thresholding).....	39
2.3 La détection d'enveloppe.....	41
2.3.1 L'extraction de l'enveloppe.....	42
2.4 La rectification du signal EMG.....	43
2.5 Résultats et discussion.....	45
2.6 Conclusion.....	48

## **Chapitre 3 Analyse temporelle et fréquentielle des signaux électromyogrammes (EMGs)**

3.1 Introduction .....	49
3.2 Analyse du signal EMG dans le domaine temporel et fréquentiel.....	49
3.2.1 Quantification dans le domaine temporel.....	49
3.2.2 Quantification dans le domaine fréquentiel.....	50
3.2.3 Quantification dans le domaine bispectral.....	51
3.3 Résultats et discussions.....	52
3.4 Conclusion.....	59

## **Chapitre 4 : Classification des signaux EMGs par les méthodes d'analyse temps-fréquence**

4.1 Introduction.....	60
4.2 Méthodologie.....	60
4.3 Mesure de différents paramètres à partir de la représentation temps-fréquence (TFR).....	61
4.3.1 Par application de la T.F.C.T.....	61
4.3.1.1 Le spectrogramme.....	61
4.3.1.2 Extraction des paramètres.....	62
4.3.2 Par application de la transformé d'ondelette (T.O.C).....	63
4.3.2.1 La T.O.C.....	63
4.3.2.2 Extraction des paramètres.....	63
4.4 Classification des signaux EMGs.....	64
4.4.1 L'apprentissage automatique.....	65

4.4.1.1 La classification non supervisé .....	65
4.4.1.2 La classification supervisée.....	66
4.4.1.2.1 Les données.....	67
4.4.1.2.2 Une classe.....	67
4.4.1.2.3 Les méthodes de la classification supervisée implémentées.....	67
4.4.1.2.3.1 Les modèles transparents.....	67
4.4.1.2.3.1.1 Le K plus proche voisin.....	68
4.4.1.2.3.1.2 L'Analyse Discriminante Linéaire LDA.....	69
4.4.1.2.3.2 Interprétation des modèles boîtes noires.....	71
4.4.1.2.3.2.1 Le modèle SVM .....	71
a. SVMs à marge dure.....	72
b. SVMs à marge souple.....	73
4.6 Résultats et discussions.....	75
4.7 Conclusion.....	85
Conclusion Générale.....	86
Annexe.....	88
Bibliographie.....	89
Résumé	

## Liste des figures

### Chapitre 1 : Le système neuromusculaire et le signal Electromyographie (EMG)

1.1 : Types musculaires ; (a) : Différentes types de muscle. (b) : Muscle squelettique.....	13
1.2 : Anatomie du muscle.....	14
1.3 : la structure microscopique des fibres musculaires.....	14
1.4 : les compositions des fibres musculaires.....	16
1.5 : Théorie des filaments glissants : comportement des filaments d'actine par rapport aux filaments de myosine dans la contraction en allongement (en haut), sans modification de longueur (au milieu), et en raccourcissement (en bas). La longueur du sarcomère est exprimée en pourcentage de la longueur de repos (L.R.) .....	16
1.6 : Muscle de biceps brachial.....	17
1.7 : Le chemin anatomique du nerf musculo-cutané.....	18
1.8: Exemple d'un potentiel d'action.....	20
1.9 : Décomposition d'un signal EMG brute résulte des TPAUMs individuelles.....	21
1.10 : présentation des électrodes.....	22
1.11 : Disposition des électrodes de surfaces.....	23
1.12: Electrodes Aiguilles.....	24
1.13 : Différents types d'électrodes aiguilles utilisées en EMG. (a):Aiguilles concentriques (à fil fin), (b): Aiguilles monopolaires.....	24
1.14: Stimulateur électrique utilisé en EMG.....	25
1.15: Amplitude et Spectres de Bio-potentiels d'origines différentes.....	25
1.16 : Structure élémentaire de l'amplificateur différentiel.....	26
1.17 : Le signal EMG normal produit par les muscles.....	28
1.18 : Tracés du signal EMG normal et pathologique : le premier signal obtenu d'un patient sain, le deuxième signal d'un patient avec neuropathie et le troisième d'un cas atteint de myopathie.....	29
1.19 : Maladie de Charcot.....	31
1.20 : (a) Signal EMG normal ; (b) Signal EMG d'un patient qui a la SLA.....	32
1.21 : (a) Spectrogramme d'un patient normal ; (b) Spectrogramme dans le cas de la SLA.....	33

### Chapitre 2 : Techniques de débruitage des signaux électromyogrammes EMG

2.1 : Tracé du signal EMG non normalisé.....	35
2.2 : les procédures de normalisation du signal EMG.....	36
2.3 : Tracé du signal EMG normalisé.....	36
2.4 : Différence entre le seuillage dur et le seuillage doux.....	39
2.5 : Effet de filtrage par les deux techniques : la TOD et le filtre linéaire.....	40
2.6 : L'enveloppe détectée par la valeur absolue (abs) de la transformée d'Hilbert du signal EMG.....	41

2.7 : a. L'enveloppe du signal, b. Lissage de l'enveloppe du signal EMG.....	43
2.8 : La représentation du signal EMG rectifié.....	43
2.9 : Algorithme de l'extraction des pathologies neuromusculaire et leur classification.....	44
2.10 : Effet de filtrage par les deux techniques : Le filtre linéaire (en rouge) et la TOD (en bleu) dans le cas (a) sain et (b) pathologique.....	45
2.11 : Représentation temporelle du signal EMG dans le cas (a) : normal, (b) SLA.....	46
2.12 : L'enveloppe du signal EMG dans le cas (a) : normal, (b) SLA.....	47
2.13 : La représentation du signal EMG rectifié dans le cas (a) : normal, (b) SLA.....	48

### **Chapitre 3 : Analyse temporelle et fréquentielle des signaux électromyogrammes (EMG)**

3.1 : spectre de fréquence du signal EMG ; (a) cas normal, (b) le cas de la SLA.....	53
3.2 : L'estimation de la fréquence médiane du signal EMG ; (a) cas normal, (b) le cas de la SLA.....	54
3.3 : L'estimation de la fréquence moyenne du signal EMG ; (a) cas normal, (b) le cas de la SLA.....	54
3.4 : Histogrammes de l'analyse temporelle et fréquentielle des signaux EMGs.....	57
3.5 : bispectrum d'un : (a, b, c) signal EMG normal et (d, e, f) signal EMG neuropathique...59	

### **Chapitre 4 : Classification des signaux EMGs par les méthodes d'analyse temps-fréquence**

4.1 : L'Organigramme de la classification des troubles neuromusculaires.....	61
4.2 : L'organigramme des méthodes d'apprentissage automatique.....	65
4.2 : exemple de méthode KNN des deux classes pour k=1 (exemple 1) et k=3 (exemple 2) .....	68
4.3 : Le choix de 'k' influence la décision : pour k=5, la décision est de classer l'objet 'noir' dans la classe 'rond'. Pour k=9, la décision est de le classer en tant que 'croix'.....	69
4.4 : Frontières de décision de l'Analyse Discriminante Linéaire (LDA) sur un jeu de données en dimension 2.....	71
4.5 : Surfaces de décision existant pour séparer deux classes .....	71
4.6 : Exemple de séparation entre deux classes par les SVMs .....	73
4.7 : Hyperplans séparateur dans le cas de données non-linéairement séparables .....	73
4.8 : Spectrogramme du signal EMG, (a) sain ; (b) Spectrogramme de la SLA utilisant une taille de fenêtre de 256 ms et (c) sain ; (d) Spectrogramme ALS utilisant une taille de fenêtre 512 ms.....	76
4.9: Représentation en ondelettes continue à l'aide de db4 au niveau 6 : (a, b, c) conditions de signal EMG saines et (d, e, f) de la SLA.....	77
4.10 : Les histogrammes des paramètres extraits en utilisant le spectrogramme du signal EMG des cas sains (N) et pathologique (A) utilisant une taille de fenêtre 256 et 512 ms.....	79



4.11 : Les histogrammes des paramètres extraits par application de l'ondelette continue du signal EMG des cas sains (N) et pathologique (A) utilisant un ordre de Daubechies 4 et 7...	81
4.12 : Les courbes des classifieurs utilisés pour chaque TFR et les conditions optimales de taille de fenêtre et d'ordre de Daubechies.....	85

## Liste des tableaux

### Chapitre 3 : Analyse temporelle et fréquentielle des signaux électromyogrammes (EMG)

Tableau 3.1 : Les paramètres temporels et fréquentiels des signaux EMGs normaux et pathologiques.....56

### Chapitre 4 : Classification des signaux EMGs par les méthodes d'analyse temps- fréquence

Tableau 4. 1 : les différents paramètres extraits de la RTF.....78

Tableau 4.2 : Précision de classification des caractéristiques du spectrogramme avec deux tailles de fenêtre optimales.....83

Tableau 4.3 Précision de classification des caractéristiques du scalogramme avec deux ordres de Daubechie optimaux.....84

## Nomenclature

Symbole	Abréviation
Abs	Valeur absolue
ARI	En anglais: Adjusted Rand Index (Index Rand ajusté)
ASC	Air sous la courbe de ROC (ROC en anglais : receiver operating characteristic « caractéristique de fonctionnement du récepteur »)
COC	Coefficients d'ondelettes continues
CSP	Changement de signe de pente
CVM	Contraction volontaire maximale
D1	Détail au premier niveau
D2	Détail au deuxième niveau
DTF	Distribution temps-fréquence
DWV	Distribution de Wigner-Ville
ECG	Électrocardiogramme
EEG	Électroencéphalographie
En	Énergie
ENMG	Électroneuromyogramme
En_O	Entropie d'ondelettes
EOG	Électro-oréculographie
Ep	Entropie du signal
EQM	Erreur quadratique moyenne
ER	Entropie de Renyi
ES	Entropie de Shannon
LDA	Analyse linéaire discriminante
LMF	Longueur maximale de la fractale
LO	Longueur de la forme d'onde
LOA	Longueur d'onde améliorée
PAUMs	Potentiels d'action des unités motrices
PKF	En anglais : Peak of frequency (fréquence de crête)
PMN	Puissance moyenne
PMYO	Taux de pourcentage de Myopulse
Pr	Précision
PSO	Particle Swarm Optimisation
PTT	Puissance totale
PZ	Passage par zéro
RBF	Fonction de base radiale
RES	Rapport entre la distance euclidienne et l'écart-type
RN	Réseaux de neurones
RRMC	Rapport de réjection en mode commun
RTF	Représentation temps fréquence
sEMG	Électromyogramme de surface
SNC	Système nerveux central
Std	En anglais : Standard deviation (Écart type)
TF	La transformée de Fourier
TFR	Transformée de Fourier rapide

TFCT	Transformée de Fourier à court terme
TO	Transformée en ondelettes
TOC	En anglais : Continuous Wavelet Transform (Transformée en ondelettes continue)
TOD	Transformé en ondelette discrètes
SVM	En anglais : Support vector machine (machine à vecteur de support)
VAM	Valeur absolue Moyenne
VAR	Variance
Vrms	En anglais : root mean square voltage (Tension quadratique moyenne)

## Introduction Générale

L'appareil locomoteur, constitué de muscles, d'os et d'articulations, sont des acteurs indispensables au mouvement du corps, cet appareil nécessite une attention et un soin tout particuliers sinon raideurs, courbatures, contractures, douleurs et inflammations deviendront les compagnes d'une activité physique mal adaptée et mal préparée. Pour une évaluation progressive de l'état de fonctionnement de ce dernier, un bilan constitue principalement d'un signal d'électromyographie est notamment utile pour certains déficits musculaires.

Dans notre vie quotidienne, la nature nous montre que les deux variables en temps et en fréquence sont habituellement mises en corrélation dans les signaux, tels que la parole, la musique enregistrée ou la chanson de baleine. Un tel signal est décrit comme une variation dans le temps (ou non stationnaire) parce que leur contenu de fréquence varie avec le temps, la représentation dans le domaine temporel ne présente pas clairement quelles fréquences, et la représentation fréquentielle ne montre pas à quel temps elles sont présentes, mais la représentation de chacun des deux est garantie dans le plan temps-fréquence

Donc, le savoir du type de signal est important pour le développement d'algorithme. Nous pouvons sélectionner les caractéristiques que nous souhaitons estimer et des outils de conception appropriés pour l'analyser. Par exemple, dans le domaine biomédical, le signal c'est une collection électrique obtenu par une variation physique, qui est normalement une fonction de temps et est descriptible en termes d'amplitude et de fréquence bien déterminé, un décalage de ces valeurs de l'intervalle des valeurs normales signe d'une anomalie, un bilan dans le cas des troubles musculaires est primordial en faisant appel au signal d'électromyographie; le cas de la sclérose latérale amyotrophique (SLA) à évolution rapide qui est causé par la destruction des cellules nerveuses du cerveau et de la moelle épinière [1], entraînant une perte de contrôle nerveux des muscles volontaires, puis une dégénérescence et une atrophie des muscles. Finalement, les muscles respiratoires sont affectés, ce qui entraîne la mort par incapacité à respirer, à se déplacer lorsque les neurones meurent [2], c'est la sévérité de la SLA qui nous a poussé vers cette étude à travers un signal EMG détecté au moyen des électrodes qui doivent être convenablement disposées sur le muscle concerné, soit par une méthode invasive utilisant un capteur d'électrode à aiguille, soit par une méthode non invasive utilisant un capteur d'électrodes de surface. Plus de compétences cliniques sont nécessaires pour déployer des électrodes à aiguilles et elles sont utilisés pour enregistrer le signal EMG du muscle profond, cependant, il nécessite l'insertion d'une aiguille dans le muscle qui a besoin d'un assistant clinique et cause de la douleur au sujet [3]. Tandis que les électrodes de surface peuvent être facilement appliquées et fournissent toujours des informations importantes à utiliser dans de

nombreuses applications [4, 5]. Une fois ce signal est détecté puis affiché par une routine d'environnement MATLAB, il est décrit par son amplitude et sa fréquence, de nature complexes et non stationnaires avec des caractéristiques temporelles et fréquentielles très complexes [3]. L'amplitude du signal EMG est normalement dans la plage de 0 à 10 millivolts (crête à crête) ou de 0 à 1,5 millivolts (moyenne quadratique) et de 0 à 500 Hz de fréquence (électrodes de surface) et de 0 à 1500 Hz (électrodes à aiguille), il est noyé dans différentes sortes de bruits, il est alors nécessaire de le filtrer pour pouvoir l'exploiter. Différentes méthodes de filtrage ont été implémenté par plusieurs chercheurs parmi eux : Karthick et al, [6] ont utilisé un filtre Butterworth d'une bande fréquentielle allant de 10-400 Hz avec une fréquence d'échantillonnage de 1000 Hz [6], les travaux d'Edward et al, [7] sur l'identification de la relation EMG – couple à posture constante autour du coude à l'aide de modèles dynamiques non linéaires, de Wang et al [8] sur classification des signaux EMGs de surface à l'aide de la transformation en paquets d'ondelettes harmoniques où ils ont fait appel à un filtre passe bande de 10-2000 Hz et 10-500 Hz respectivement, ou bien d'implémenter deux filtres successifs (un filtre passe haut d'une fréquence de coupure de 2 Hz et un filtre passe bas de 10KHz) ce qui a été fait par E. Gokgoz et al, [9]. Récemment, la théorie du débruitage par ondelettes s'est avérée très efficace pour débruiter un certain nombre de signaux physiologiques [10, 11, 12, 13] et donc du signal EMG avec différentes bandes fréquentielles. Elle est préférée aux autres techniques de filtrage de signal car elle a tendance à maintenir intacte les caractéristiques du signal même tout en minimisant le bruit. M. LIMEM et al [14] ont testé l'efficacité de débruitage des signaux EMGs utérins, en utilisant différentes fonctions d'ondelettes : Daubechies (db2, db4, db5, db6 et db8), Symmlet (sym4, sym5) et orthogonal Meyer (dmey) à deux différents niveaux de décomposition (niveau 3 et niveau 4) en trouvant les valeurs du rapport signal sur bruit (RSB) des signaux débruités. Les résultats obtenus grâce à cette recherche montrent clairement que la fonction d'ondelettes db4 avec trois niveaux de décomposition peut réduire efficacement le bruit du signal EMG utérin par rapport aux autres fonctions d'ondelettes, ils ont montré aussi l'efficacité du débruitage par un filtre passe-bande de Butterworth [14].

Le signal ainsi filtré doit être analysé en vue de suivre l'évolution de la SLA en analysant spectro-temporellement le changement des paramètres du signal EMG des patients affectés par cette pathologie. Ces changements paramétriques peuvent être connus par une analyse temps-fréquence des signaux EMGs [15, 16, 17, 18, 19] qui fournit également une source d'informations importante pour le diagnostic des troubles neuromusculaires qui peuvent endommager la contraction musculaire [20] telles que : le niveau de recrutement des unités motrices, leur contenu fréquentiel, la force de la commande neurale, la quantité d'information véhiculée par le signal, leur intervalle de temps ... etc. qui nécessite un outil basé sur les

techniques de traitement du signal par l'application de plusieurs instruments de mesures parmi eux : la détection d'enveloppe [21, 22, 23], la transformée de Fourier rapide (TFR), la transformée de Fourier à court terme (TFCT) [2, 17, 24, 25], la transformée en ondelettes (TO) [17, 24] et la classification des signaux EMGs [26, 27, 28, 29]. Ce sont les différentes étapes qui doivent être réalisées pour finaliser cette thèse.

Dans ce sens, plusieurs chercheurs ont tenté d'analyser les signaux EMGs, que ce soit dans le domaine temporel, le domaine fréquentiel et le domaine temps-fréquence.

Les informations du domaine temporel sont obtenues à partir du signal brut dans la représentation temporelle. La notion d'enveloppe du signal peut être introduit, en calculant la valeur absolue du signal : C'est ce qu'on appelle la rectification pleine onde [30]. L'EMG redressé signifie qu'on considère désormais la valeur absolue du signal. Cela permet de tenir compte de toute l'information du signal [31]. L'étape de rectification est essentielle pour obtenir la forme ou « enveloppe » du signal EMG. On pourrait penser que l'enveloppe pourrait être capturée simplement en passant (ou en filtrant) bas le signal non redressé. La raison pour laquelle cela ne fonctionne pas bien en soi et que le signal EMG est naturellement proche de zéro, avec des oscillations rapides qui oscillent rapidement et plus ou moins identique de chaque côté de zéro. Si vous lissez un tel signal, vous obtenez simplement zéro qui n'est donc pas très utile. Si l'on rectifie d'abord, les oscillations négatives se transforment en oscillations positives. Le signal redressé est filtré passe-bas, dans la plage de 5 à 100 Hz et le résultat ressemble à « l'enveloppe » du signal d'origine. Une façon de filtrer le signal redressé passe-bas est d'utiliser une version discrète d'un filtre passe-bas traditionnel tel que Butterworth ou Tchebychev.

La combinaison du redressement et du filtrage passe-bas est également appelée recherche de « l'enveloppe linéaire » du signal, car l'opération de filtrage répond à la définition mathématique de la linéarité, et, comme elle est passe-bas, elle capture « l'enveloppe » du signal [30], l'enveloppe du signal redressé permet une visualisation agréable des périodes d'activation du muscle, son amplitude reflète le niveau d'activation et sa durée la durée de la réponse. Il est à signaler néanmoins que lors de l'étude de synchronisation des signaux, le passage du signal redressé à l'enveloppe via un filtre passe bas peut provoquer un petit décalage temporel [31]. D'autres techniques plus représentatives pour extraire l'enveloppe du signal EMG sont la transformée d'Hilbert [32], le critère d'erreur quadratique moyenne (EQM) [33] et la forme d'onde produite par le signal rectifié [34]. Nous nous sommes intéressés dans ce travail par la transformée d'Hilbert [21].

L'extraction de fonctionnalités est généralement rapide et facile à mettre en œuvre car elle implique des propriétés mathématiques simples et ne nécessite aucune transformation basée sur

des informations EMGs brutes dans le temps. Elle a largement été utilisée dans la recherche et les pratiques médicales et techniques en raison de leur faible complexité de calcul et de l'environnement à faible bruit, cependant, cette méthode présente l'inconvénient majeur de la non stationnarité avec des propriétés statistiques changeantes au fil du temps, mais le domaine temporel assume les données en signal stationnaire [3, 35]. Dans ce qui suit, une étude générale de quelques caractéristiques extraites du signal EMG par plusieurs chercheurs a été faite. L'extraction des paramètres temporels comme l'amplitude qui sert à refléter le niveau d'activation musculaire et elle est influencée par le recrutement des unités motrices (UMs). Cela signifie la différence entre les valeurs extrêmes de la variable [36]. La quantité d'énergie neuronale est mesurée avec l'activité EMG intégrée (iEMG), et pendant la fatigue, l'activité iEMG augmente en raison d'une défaillance de la contraction musculaire ; sa diminution implique le maintien d'une force constante d'un muscle [37, 38], ce paramètre a été réservé comme caractéristiques de la fatigue [39]. Un autre paramètre temporel : la valeur quadratique moyenne (en anglais root mean square : RMS) qui est lié à la force du contenu [39], c'est une caractéristique de la fatigue [3, 40]. La valeur absolue Moyenne (VAM) sert à fournir des informations énergétiques du signal, contrôler les membres prothétiques et le suivi de la fatigue [41]. L'objectif fixé par l'énergie (En) du signal EMG est de définir la quantité d'informations véhiculées par le signal [42]. Cependant, le domaine temporel a une limitation majeure dans la restauration du signal non stationnaire avec une amplitude et des fréquences variables [35].

Le signal brut dans le domaine temporel doit subir une transformée de Fourier pour passer du domaine temporel au fréquentiel [43]. L'analyse fréquentielle permet de caractériser le contenu spectral du signal EMG et de détecter notamment des signes de fatigue musculaire. Les diminutions du spectre de fréquences, dans les basses fréquences, traduisent une diminution de la vitesse de conduction des potentiels d'actions des unités motrices (MUAPs) [44], généralement basée sur la transformée de Fourier rapide (TFR), permettant d'analyser les raies spectrales du signal en présentant l'amplitude du signal en fonction des fréquences.

Plusieurs caractéristiques communes sont généralement utilisées : la fréquence moyenne (FMN) et la fréquence médiane (FMD) comme indices universels capables de détecter à la fois la force musculaire et la fatigue musculaire [45, 46]. Khanam F et al [47] et A. Phinyomark et al [48] ont utilisé la puissance totale (PTT) et la puissance moyenne (PMN) dans le domaine fréquentiel comme indicateur de fatigue musculaire [48]. D'autres paramètres comme la fréquence de crête (PKF) qui sert à déterminer la fréquence à laquelle la puissance maximale se produit [35]. Dans ce travail, quelques paramètres vont être implémentés pour vérifier la présence de la SLA.



Pour un suivi plus poussé de la SLA, une analyse bispectral a été implémenté, c'est une technique plus ancienne du traitement des signaux biomédicaux, elle a été effectuée sur le signal d'intérêt. Souvent, il nous permet de différencier les différents états physiologiques ou conditions pathologiques [49]. Le bispectrum est une fonction de deux fréquences contrairement au spectre de puissance qui est fonction d'une seule fréquence. La fréquence  $f$  peut être normalisée par la fréquence de Nyquist (la moitié de la fréquence d'échantillonnage) pour être comprise entre 0 et 1 [50, 51]. Les travaux de Kaplanis et al [51] ont utilisé des spectres d'ordre supérieur pour analyser le signal d'électromyogramme de surface (sEMG) [52]. Ils ont montré que le niveau de gaussianité de sEMG a changé avec la variation de la contraction volontaire maximale (CVM). Le signal est devenu moins gaussien à des CVM très bas et très élevé, mais certains étaient au milieu, sEMG est devenu plus gaussien. Le niveau de non-gaussianité de la variation du signal EMG a été utilisé pour différencier les signaux EMGs sains et pathologiques [53]. De plus, F.Meziani et al [42] ont appliqué l'analyse bispectrale pour suivre la sévérité pathologique chez 2 patients et ont comparé leurs résultats avec un patient en bonne santé, ils ont proposé le bispectrum dans la discrimination des conditions saines et pathologiques [42].

Cependant, ces techniques ont la limitation de répondre au comportement du signal EMG avec succès car elles nécessitent un signal stationnaire pour des résultats précis [35]. Les distributions temps-fréquence (DTFs) sont des techniques puissantes et précises qui représentent un signal dans une représentation conjointe temps et fréquence créée pour résoudre les problèmes posés sur la stationnarité [35]. Dans une analyse des signaux, la représentation temps fréquence (RTF) est largement utilisé dans la modification et la synthèse des signaux non stationnaires car il fournit des informations de temps et de fréquence pour les signaux. Pour cette raison, les distributions temps-fréquence (DTFs) sont appropriées pour analyser les signaux EMGs qui consistent en un signal de composantes non stationnaires et multifréquences [35]. Les DTFs sont globalement classées en deux catégories qui sont les distributions temps-fréquence linéaires et bilinéaires. La distribution temps-fréquence linéaire est une forme plus basique que les distributions temps-fréquence bilinéaires. Les techniques couramment utilisées sont le Gabor, le spectrogramme, la transformée en ondelettes (TO) et la Transformé en S [35]. Contrairement aux transformées temps-fréquence linéaires, le signal apparaît deux fois dans les transformées temps-fréquence bilinéaires, appelées transformées bilinéaires. Les distributions temps-fréquence bilinéaires pourraient fonctionner mieux que les distributions temps-fréquence linéaires en raison du fait qu'il ne souffre pas des effets de maculage causés par la fonction de fenêtrage [5]. La distribution de Wigner-Ville (DWV) et la distribution de Choi-Williams (DCW) sont quelques-unes des approches temps-fréquence du DTF bilinéaire qui ont été utilisé

pour le traitement du signal EMG [54]. Dans cette thèse, les DTFs linéaires ont été implémentées, ce sont le spectrogramme par application de la transformé de Fourier à court terme (TFCT) et la transformé en ondelette, Ces deux méthodes d'analyse temps-fréquence ont été appliquées pour la détection précoce des pathologies neuromusculaires à travers le signal EMG qui est l'une des préoccupations de plusieurs chercheurs, La SLA est l'une de ces pathologies qui devrait être mentionner lorsqu'on parle des pathologies neuropathiques à cause de sa forte progression.

La transformé de Fourier à court terme (TFCT) en tant que méthode d'analyse temps-fréquence consiste à faire coulisser une fenêtre d'analyse le long du signal étudié mais les dimensions de cette dernière doivent être fixées de façon à garantir les conditions de stationnarité. Le travail de A.B.M. Doulaht et al [2] sur la mesure et l'analyse des signaux myoélectriques du muscle de biceps brachial de 8 sujets normaux âgés de 21 à 37 ans et d'un groupe de patients atteints de la sclérose latérale amyotrophique (SLA) composé de 8 patients âgés de 35 à 67 ans de la base de données EMGLAB [2] montre que la bande fréquentielle et la localisation temporelle de potentiel d'action des unités motrices présentent des caractéristiques pertinentes estimées pour analyser le signal EMG et à identifier la présence de la SLA où les caractéristiques temporelles et fréquentielles peuvent aider le clinicien lors de son diagnostic médical [2], l'article de Jingwei Too et al [25] se base sur la sélection de la fenêtre la plus optimale par application de la TFCT, ils ont examiné trois largeurs optimales de la fenêtre Hanning (cette fenêtre est plus utilisé pour une meilleure résolution fréquentielle par rapport aux autres fenêtres [55]) de 128, 256 et 512 ms avec un chevauchement de 50 %, ils ont montré que l'information temporelle est réduite lorsque la largeur de la fenêtre augmente et l'information fréquentielle se minimise avec une fenêtre étroite. Donc, la sélection de la fenêtre la plus optimale est nécessaire pour balancer l'information dans le domaine temps-fréquence. Certes, le spectrogramme a une limitation dans le compromis de la distribution de temps et de fréquence et il a été mentionné dans la littérature [25]. La fenêtre de taille appropriée doit être sélectionnée pour optimiser le résultat du signal EMG car une fenêtre fixe facilitera l'interprétation en termes d'harmoniques et leurs effets sur la résolution temps-fréquence [56].

En gardant cette notion de fenêtrage, on fait appel à une technique qui possède une fenêtre d'analyse de dimensions souple, adaptative et qui fournit une bonne résolution temporelle (et donc une mauvaise résolution fréquentielle) aux hautes fréquences et une bonne résolution fréquentielle (donc une mauvaise résolution temporelle) aux basses fréquences [57, 58, 59] : c'est la transformée en ondelette (TO).

Le terme ondelette peut être utilisé pour décrire plusieurs sujets. Il a été introduit en premier lieu par Morlet et son équipe en décrivant la transformée en ondelettes continue (TOC) en utilisant une ondelette spécifique qui porte son nom [60].

La transformée d'ondelette a démontré sa tendance d'analyser les signaux EMGs avec plus de précision et d'exactitude que d'autres techniques [61], Elle agit comme un microscope mathématique avec lequel il est possible d'observer les différentes parties du signal, elle utilise des fonctions de base « atomes » qui peuvent être construites par dilatation ou contraction et translation d'une fonction unique appelée « ondelette mère ».

La transformée en ondelettes a été proposée dans le but d'enlever les limitations des méthodes traditionnelles temps-fréquence. Jean Morlet s'est inspiré de l'analyse de Fourier à fenêtre, proposée par Gabor [62], Elle est effectuée de la même manière que la transformée de Fourier C'est-à-dire, qu'au lieu de garder fixe la taille de la fenêtre et de faire varier le nombre d'oscillations à l'intérieur de la fenêtre, Morlet a choisi de garder constant le nombre d'oscillations à l'intérieur de la fenêtre et a fait varier sa taille, l'étirant ou la comprimant comme un accordéon en multipliant le signal par la fonction analysante et on calcule l'intégrale du produit, en remplaçant simplement les sinusoïdes par la famille des ondelettes. C'est donc une décomposition du signal sur des fonctions à support en temps et en fréquence. L'approche d'ondelettes a joué un rôle très intéressant dans le débruitage des EMGs, car cette méthode est plus efficace que les méthodes de filtrage conventionnel [42].

Plusieurs chercheurs se sont penchés sur l'extraction et la sélection des paramètres temps fréquence et l'appui d'un meilleur classifieur. Une fois les caractéristiques du signal sont calculées, celles-ci sont entrées dans un classifieur qui, grâce à un apprentissage, permet d'associer le vecteur de caractéristique généré par l'extraction des caractéristiques à des classes établies par un observateur. Encore une fois, beaucoup d'algorithmes existent pour réaliser cette opération. Toutefois, beaucoup de ceux-ci sont très consommateurs en temps de calculs, comme les réseaux de neurones (RN). Toutefois, Englehart et al [63] ont montré que l'importance du choix du classifieur est limitée et que les gains en termes de performances de classifieurs complexes tels que les RN sont négligeables par rapport aux performances d'un classifieur plus simple comme l'analyse linéaire discriminante (LDA).

Les méthodes de classification nécessitent souvent un apprentissage qui peut être supervisé ou non supervisé.

- L'apprentissage supervisé : est effectué à partir de données étiquetées

- L'apprentissage non supervisé : est effectué sur des données sur lesquelles on ne possède aucune connaissance a priori. [64]. Dans ce cas d'étude des données EMGLAB, les méthodes d'apprentissage supervisé rendent plausible.

L'une des fonctionnalités des méthodes d'apprentissages automatiques : la classification des cas normaux et anormaux, ce sont des algorithmes qui servent à classer et prédire si le cas représente une situation positive ou négative par l'extraction de plusieurs paramètres dans les domaines temps-fréquence. Il existe un algorithme de classification des K plus proches voisins (en anglais k nearest neighbors : kNN), analyse discriminante linéaire (en anglais linear discriminant analysis : LDA), Naïve Bayésienne (NB) et machine à vecteurs de support (en anglais support vector machine : SVM) ...etc. qui sont implémentés aux signaux EMGs.

Tengku Nor Shuhada Tengku Zawawi et al [65] ont appliqué l'analyse du spectrogramme dans la classification du signal EMG pour la tâche de dépistage de la santé, Ils ont mis en œuvre quatre classifieurs d'apprentissage automatique kNN, LDA, NB et SVM par l'extraction de quatre paramètres du spectrogramme (tension quadratique moyenne ( $V_{rms}$ ), fréquence moyenne (FMN), variance (VAR) et écart-type (Std)) et à la fin, ils ont qualifié SVM comme étant le classifieur le plus recommandé. En parallèle, d'autres chercheurs ont testé deux classifieurs SVM et LDA pour évaluer les performances des caractéristiques de représentation temps-fréquence (RTF) dans la classification des signaux EMGs à l'aide de nombreuses fonctionnalités [6, 25] et ils ont déterminé la meilleure taille de fenêtre dans le spectrogramme pour chaque classifieur utilisé, ils ont indiqué que le spectrogramme avec la taille de fenêtre optimisée et LDA, la plus haute précision de classification moyenne de 91,29% est obtenue, il est observé que la fenêtre de 256 ms (LDA) et la fenêtre de 512 ms (SVM) sont plus appropriées pour être utilisées dans la classification des signaux EMGs [20, 25, 66]. Elamvazuthi et al [67] ont étudié la composante détaillée des daubechies au niveau 1, 2, 5, 9 pour trois ordres de daubechies (db4, db7 et db10) en utilisant l'un des paramètres les plus réussis qui est : la valeur absolue de la moyenne (VAM). L'indice RES (le rapport entre la distance euclidienne et l'écart-type) donne une meilleure performance en utilisant le septième ordre de daubechies du signal de détail au premier et au deuxième niveau (D1 et D2) [67].

De nombreux chercheurs ont extrait des paramètres simples du domaine temps-fréquence du coefficient d'ondelettes telles que l'entropie d'ondelettes ( $En\_O$ ), la valeur absolue de la moyenne (VAM), le passage par zéro (PZ), le changement de signe de pente (CSP), le taux de pourcentage de Myopulse (PMYO) , la valeur quadratique moyenne (en anglais root mean square : RMS) [68, 69] la longueur de la forme d'onde (LO) [28, 29], longueur maximale de la fractale (LMF) [35, 69, 70] et longueur d'onde améliorée (LOA) [68], les caractéristiques

statistiques sont introduits aux quatre classifieurs qui sont la machine à vecteur de support par l'optimisation de l'essaim de particules (en anglais Particle Swarm Optimisation-support vector machine : PSO-SVM), SVM, méthode des K plus proches voisins (KNN), machine à vecteurs de support de la fonction de base radiale (RBF-SVM). PSO-SVM atteint une précision élevée de 98,8% par rapport au RBF-SVM [26], Benazouz et al [29] ont appliqués KNN et forêt aléatoire pour le diagnostic des troubles neuromusculaires, les résultats obtenus montrent que le classifieur forêt aléatoire a donné les meilleures performances avec une précision de 88,8% [29], les classifieurs LDA et KNN ont donné respectivement une précision maximale de 80,83% et 72,5% [27, 28].

Cette thèse vise à aborder l'analyse de la variation de plusieurs paramètres sous l'impact de la présence d'une sclérose latérale amyotrophique. Le résultat obtenu a permis aux professionnels du domaine de suivre l'évolution de cette pathologie selon deux principaux axes de recherche :

Une première phase est établie par la construction d'un algorithme de prétraitement pour bien comprendre le signal EMG.

Une deuxième phase de traitement qui fera appel à des techniques d'analyse temps-fréquence (Transformé de Fourier à court terme, transformée d'ondelettes, etc.) pour étudier les performances du spectrogramme et de la transformé d'ondelette continue dans la discrimination des troubles de la SLA et obtenir des caractéristiques spectro-temporelle des signaux EMGs.

Une dernière phase qui pourra utiliser les résultats spectro-temporelle obtenus pour aider à la compréhension et à la classification des signaux EMGs normaux et pathologiques par des algorithmes d'apprentissage automatique populaires à savoir RBF-SVM, LDA et KNN et de sélectionner le classifieur le plus approprié pour les caractéristiques temps-fréquence déjà extraites.

Dans ce contexte, cette thèse sera organisée de la manière suivante :

Le Chapitre 1 présente les informations indispensables pour appréhender la génération de l'activité musculaire et du signal EMG, la relation EMG-SLA ainsi que leur impact afin de cerner notre problématique.

Le Chapitre 2 décrit les méthodes de traitement du signal EMG existant. Cela nous a permis la mise au point de notre algorithme de traitement pour rendre notre signal compréhensible et d'extraire des informations pertinentes sur ce signal.

Le Chapitre 3 est dédié à l'étude de différents paramètres extrait dans le domaine temporel et fréquentiel en fonction des cas étudié (sains et pathologiques), ainsi le suivi de cette pathologie dans le domaine bispectral.

Le Chapitre 4 fait le bilan de notre travail et présente la conclusion de cette étude. Il propose finalement, un protocole pour notre modèle et faire qualifier différentes connaissances dans le domaine de la compréhension de la relation EMG-SLA dans le plan temps-fréquence, Nous proposons d'abord un organigramme accrédité des méthodes d'analyse temps-fréquence ainsi différents paramètres à extraire en vue de classer les cas sains et pathologiques selon un support de séparation. Les résultats expérimentaux sont ensuite comparés et donnent lieu à une discussion.

# **1. Le système neuromusculaire et le signal Electromyographie (EMG)**

## **1.1 Introduction**

Lorsque l'homme marche, court, nage ou lance un ballon, il accomplit des gestes (sportifs ou non) qui sont tributaires d'une action musculaire. Le corps humain comprend plus de 650 muscles individuels fixés sur le squelette, qui fournissent une force de traction qui permet le déplacement. Ces muscles constituent environ 40% du poids total du corps. En règle générale, les muscles sont fixés par de solides structures fibreuses appelées tendons. Ces fixations relient une ou plusieurs articulations et le résultat de la contraction musculaire est le mouvement de ces articulations.

Le corps est mu principalement par des groupes musculaires. Ils fournissent la puissance nécessaire à toute action, allant de l'introduction d'un fil dans le chas d'une aiguille au port de charges lourdes.

L'étude de système musculaire est très importante pour bien comprendre la naissance du signal l'électromyogramme (EMG), et déterminer les diverses pathologies qui altèrent l'intégralité de l'organisme. Dans ce chapitre et dans un premier temps, on s'intéresse à la compréhension de l'aspect anatomique et fonctionnel du muscle et du système neuromusculaire. Ensuite, nous accorderons dans un second temps le principe de formation ou l'origine de potentiel d'action musculaire et leurs caractéristiques.

Ce chapitre est finalisé par l'une des maladies du siècle les plus complexes et les plus fréquentes. La sclérose latérale amyotrophique (SLA) qui touche annuellement 1.5 à 7 personnes sur 100000 et sa prévalence est en croissance. Elle est plus fréquente chez les hommes, à savoir 1.7 homme atteint pour 1 femme. Un facteur héréditaire serait reconnu dans 5 à 10% des cas. Au Canada, présentement, de 2500 à 3000 personnes vivent avec la SLA [71]

## **1.1 L'anatomie et la physiologie musculaire**

L'appareil musculaire est constitué de l'ensemble des muscles, organes actifs du mouvement. Cet appareil fait partie, avec le squelette osseux, de l'appareil locomoteur, car il assure la motricité du corps. Les muscles sont des organes charnus dont le rôle est de par leur contraction de mouvoir activement les segments osseux sur lesquels ils s'insèrent ou les viscères auxquels ils sont affectés.

## 1.2 Les caractéristiques du tissu musculaire

Un tissu musculaire est caractérisé par :

- L'excitabilité, ou l'irritabilité : qui est la capacité de recevoir et de répondre à un stimulus.
- Contractilité : qui est la capacité de se contracter de force lorsque stimulé.
- L'extensibilité : qui est la capacité à être étiré.
- L'élasticité : qui est la capacité de reprendre la longueur initiale des cellules une fois étiré [72, 73]

## 1.3 Fonctions musculaires

Les muscles ont différentes fonctions dans le corps. En effet,

- Les muscles produisent des mouvements en agissant sur les os du squelette, en pompant du sang ou en propulsant des substances dans les systèmes d'organes creux.
- Les muscles aident à maintenir la posture en ajustant la position du corps par rapport à la gravité.
- Les muscles stabilisent les articulations en exerçant une tension autour de l'articulation.
- Les muscles produisent de la chaleur en fonction de leurs processus métaboliques cellulaires [72].

## 1.4 Les différents types des muscles

Le muscle est un tissu ou organe du corps humain (constitué principalement des cellules contractiles) qui permet les mouvements du corps. Généralement il peut avoir trois formes différentes : une forme allongée, une forme plate et une forme circulaire.

Le tissu musculaire comporte trois types présentant quelques différences : le muscle squelettique, le muscle cardiaque et le muscle lisse [73]. (Figure 1.1 (a))

- Les muscles squelettiques (muscles striés) ont pour fonction d'assurer la motricité du corps dans son environnement, en permettant de faire bouger le squelette de manière volontaire. Ils peuvent répondre de façon réflexe à une stimulation. Leurs contractions peuvent être lentes ou rapide selon leur type des fibres. Parmi les muscles striés squelettiques les plus connus, on peut citer les biceps, les quadriceps ou les abdominaux. (Figure 1.1 (b))

- Les muscles lisses, se retrouvent dans la paroi du tube digestif, de la vessie, des artères et d'autres organes internes. Innervés par le système nerveux autonome, leur action n'est pas liée à la volonté. Leurs contractions, bien que lentes, peuvent être soutenues longtemps.

- Le muscle cardiaque est un muscle différent des autres, notamment car il est soumis à l'influence des hormones, et se contracte de façon involontaire.






Figure 1.1 : Types musculaire (a): Différents types de muscle [74]. (b) : Muscle squelettique [75].

Dans l'étude du signal Electromyogramme (EMG) intramusculaire (le cas de notre thèse) on s'intéresse beaucoup plus aux muscles Squelettiques [76].

#### 1.4.1 Anatomie du muscle squelettique

L'unité de base du tissu musculaire squelettique est la fibre musculaire. Ces fibres s'apparentent à de longues formes cylindriques contenant noyaux, mitochondries, réticulum endoplasmique et myofibrilles. Les fibres sont disposées parallèlement. Elles mesurent de 10 à 100  $\mu\text{m}$  de diamètre et peuvent atteindre 30 cm de longueur. Elles sont composées de cellules appelées myocytes (Figure I.2), qui renferment dans leur cytoplasme de nombreux filaments allongés parallèlement au grand axe de la cellule. Ces filaments sont de deux types : Les uns, fins, sont faits d'actine ; les autres, épais, sont composés de myosine. C'est grâce à leur interaction que la contraction musculaire s'effectue [77].

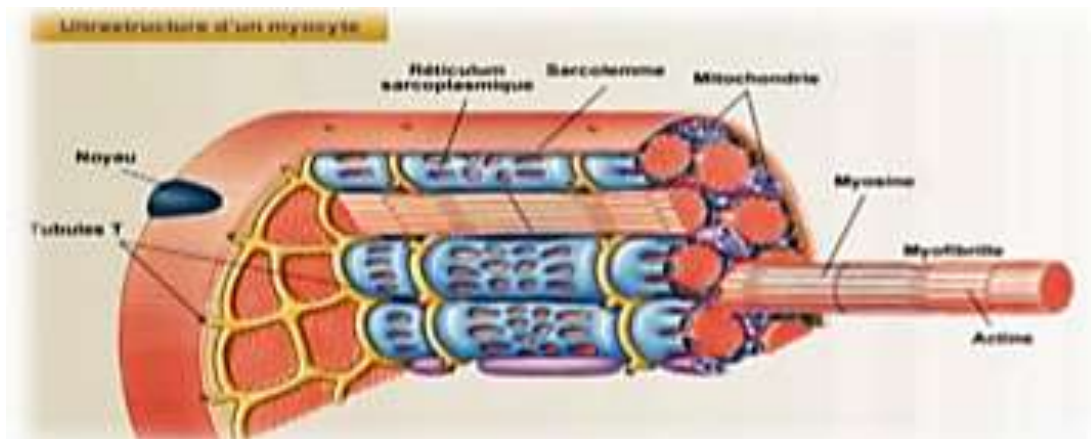


Figure 1. 2 : Anatomie du muscle [75]

### 1.5 Les fibres musculaires

La fibre musculaire (voir figure 1.3) est composée d'un ensemble de myofibrille de nature protéique. Chaque myofibrille est constituée de succession d'unités contractiles appelées sarcomères [78] (unités contractiles de base étant de  $2\mu\text{m}$ ). Elles ont des myofilaments qui se chevauchent et sont reliés à des disques Z à chaque extrémité du sarcomère [72]. Les myofilaments qui composent les myofibrilles sont constitués de filaments épais (myosine) et minces (actine) (structure hexagonale en coupe) [79]. Un disque Z est principalement composé de la protéine alpha actinine et est relié aux disques Z de myofibrilles adjacentes par des filaments intermédiaires composés de desmin.

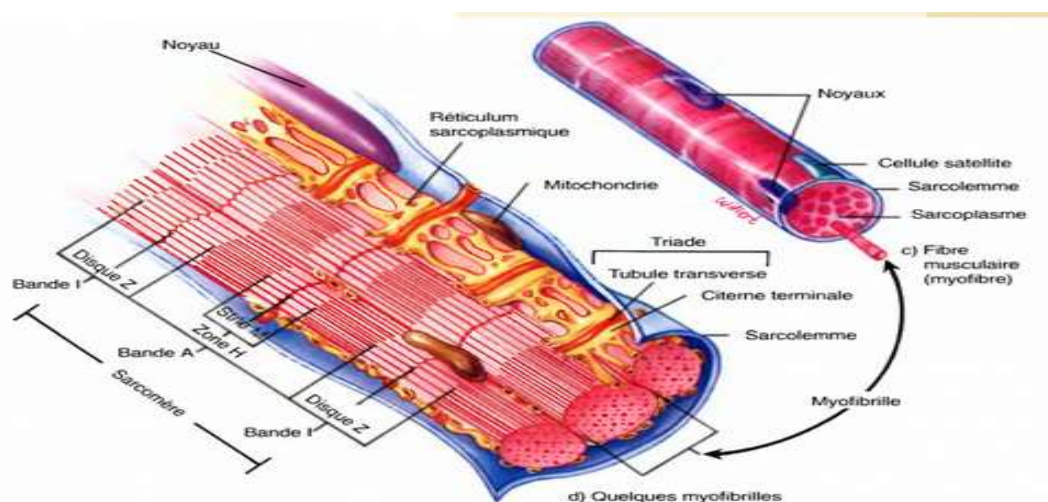


Figure 1.3 : la structure microscopique des fibres musculaires [80]

## 1.6 Les propriétés fonctionnelles de la fibre musculaire

Les myofibrilles des muscles squelettiques (voir figure 1.4) occupent le plus grand parti du volume des fibres.

Elles sont alignées selon le grand axe avec une longueur identique à celle de la fibre, de l'ordre de plusieurs centimètres, et un diamètre de 1 à 3  $\mu\text{m}$ . Les protéines myofibrillaires sont nombreuses et représentent environ 50% des protéines musculaires. Parmi ces protéines, les plus abondantes sont la myosine et l'actine [79].

### 1.6.1 Actine

C'est une protéine globulaire qui se polymérise à force ionique physiologique pour former dans les tissus musculaires un double filament hélicoïdal. En plus de son rôle structural (filaments fins des myofibrilles), elle a la propriété d'activer de 100 à 200 fois la vitesse à laquelle la myosine hydrolyse l'ATP en présence de  $\text{Mg}^{+2}$ , cependant, celui-ci régule in situ la contraction musculaire par le système Troponine-Tropomyosine lié au filament d'actine [79]. La Troponine est une protéine qui est en étroite association avec la tropomyosine - une longue fibre-comme la protéine qui s'enroule autour de l'actine et bloque activement ses « sites actifs » [78].

### 1.6.2 Myosine

La Myosine est un filament épais ayant des têtes globulaires qui peuvent former des ponts croisés avec l'actine par liaison à des sites actifs [72]. La molécule de myosine est constituée principalement de deux longues chaînes lourdes polypeptidiques enroulées l'une autour de l'autre sur une longueur de 1400 Å : cette région fibrillaire forme la « queue » de la molécule. Ces chaînes lourdes se séparent à une extrémité pour se combiner chacune à deux chaînes légères chimiquement distinctes formant ainsi deux régions globulaires d'un diamètre de 100 Å. Chacune des têtes de la myosine contient : outre la partie terminale globulaire de la chaîne lourde, deux chaînes légères : une phosphorable, l'autre alcaline [81].

La myosine saisit et tire l'actine, ce qui provoque le glissement des myofilaments l'un contre l'autre pendant une contraction musculaire. [72].




Figure I.4 : les compositions des fibres musculaires. [80]

## 1.7 La contraction musculaire

### 1.7.1 Mécanismes cellulaires de la contraction musculaire

La théorie qui prévaut actuellement pour expliquer comment les muscles créent des tensions internes (forces) est celle dite "des filaments glissants" développée par Huxley et basée sur le modèle de Hanson et Huxley. Elle stipule que, lors de la contraction musculaire, les filaments d'actine se glissent entre les filaments de myosine (voir Figure 1.5).




Figure 1.5 : Théorie des filaments glissants : comportement des filaments d'actine par rapport aux filaments de myosine dans la contraction en allongement (en haut), sans modification de longueur (au milieu), et en raccourcissement (en bas). La longueur du sarcomère est exprimée en pourcentage de la longueur de repos (L.R.) [77].

Lorsqu'une tête de myosine s'attache à un filament d'actine, formant un pont d'actine-myosine, et bouge, les deux filaments glissent l'un sur l'autre. Les têtes de myosine et les ponts ainsi formés subissent un changement de configuration spatiale, dès l'instant où les têtes de myosine s'attachent sur les sites actifs des filaments d'actine.

Le bras du pont ainsi établi et la tête de myosine exercent une attraction moléculaire très forte qui amène la tête de myosine à basculer vers le centre du sarcomère, entraînant ainsi le filament d'actine. Cette bascule est à l'origine de la génération de puissance par le muscle [77].

La tétine de filament élastique fixe les filaments épais en disques Z et s'étend dans les filaments épais jusqu'à la ligne M (correspondant au milieu du sarcomère) (voir figure 1.4).

Le glissement des filaments fin par rapport au filament épais entraîne le raccourcissement du sarcomère et donc du muscle [78].

Dans cette étude du signal Electromyogramme (EMG) intramusculaire (le cas de notre thèse) nous nous intéressons aux muscles du biceps brachiale de la base de données EMGLAB, du latin biceps, provenant de bis, signifiant deux, et de caput, signifiant tête, est un muscle situé dans la partie antérieure du bras, région du membre supérieur localisée entre l'épaule et le coude. [82] Il agit sur trois articulations et est capable de générer des mouvements dans les articulations glénohumérales, du coude et radio-ulnaire [83]. Le biceps brachial est un gros muscle épais sur la partie ventrale de la partie supérieure du bras.



Figure 1.6 : Muscle de biceps brachial [83].

Ce sont des muscles squelettiques, c'est-à-dire muscles sous contrôle volontaire du système nerveux central. Le biceps brachial est innervé par le nerf musculocutané en provenance des vertèbres cervicales C5 et C6 [84]. Ils ont deux origines : la longue tête du tubercule supraglénoïde de l'omoplate et la tête courte du processus coracoïde de l'omoplate localisée sur son bord supérieur. Il s'insère sur la tubérosité radiale et est le supinateur primaire et le fléchisseur important de l'avant-bras [85]. Les deux têtes évoluent de manière distale et deviennent un ventre musculaire confluent avant de se rétrécir sur la face antérieure du coude, [86, 87]. Le biceps brachial est impliqué dans différents mouvements du membre supérieur : la supination de l'avant-bras, la flexion du coude et dans une moindre mesure, le fléchissement

du bras vers l'épaule. Biomécaniquement, la longue tête a un rôle controversé dans la stabilité dynamique de l'articulation de l'épaule. Il a été démontré, principalement dans des études biomécaniques basées sur des cadavres et des modèles animaux, que le tendon joue au moins un rôle stabilisateur passif dans l'épaule. Neer [88] a proposé dans les années 1970 que le rôle stabilisateur des têtes longues du biceps brachial variait en fonction de la position du coude. Plusieurs études ultérieures ont réfuté la théorie selon laquelle la longue tête du biceps brachial jouait un effet stabilisateur actif de l'épaule [89]. Jobe et Perry ont évalué l'activation du biceps lors du mouvement de lancer chez les athlètes. Les auteurs ont rapporté que le pic de stimulation musculaire s'est produit en relation avec la flexion du coude et la décélération de l'avant-bras, avec très peu d'activité du biceps proximal pendant les premières phases du lancer [88].

Le nerf musculo-cutané est la branche terminale du cordon latéral du plexus brachial (C5, C6 et C7) et émerge au bord inférieur du muscle petit pectoral. [90]

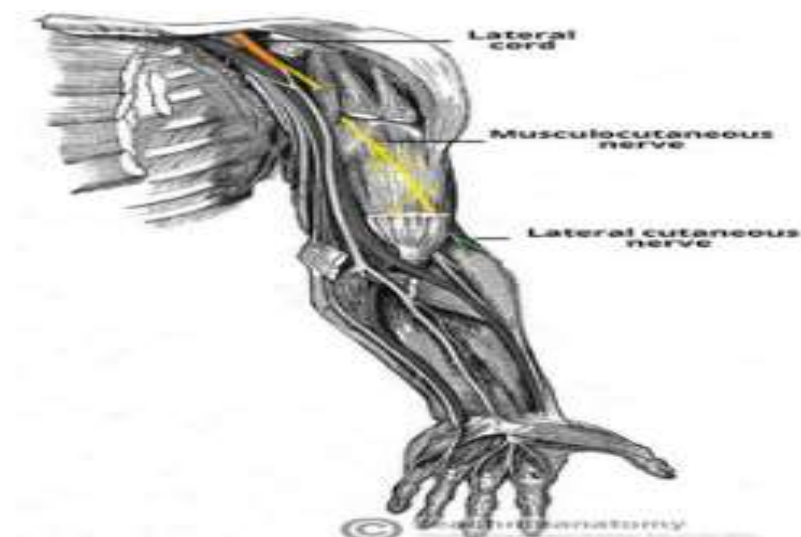


Figure 1.7 : Le chemin anatomique du nerf musculo-cutané [90].

Ce muscle nécessite une attention bien particulière et si des douleurs au niveau du bras sont fréquemment ressenties. Les causes de ces douleurs sont variées et peuvent être associées à différents muscles tel que le biceps brachial. Un examen d'électromyogramme peut résoudre le conflit.

### **1.7.2 Les différents types de contraction musculaire**

Il y a deux types fondamentaux de contraction tout dépend de la longueur du muscle qui change au cours de celle-ci ou pas. Dans la contraction isotonique, la force reste constante quelque soit le changement de la longueur du muscle. Dans la contraction isométrique, le raccourcissement du muscle est empêché de sorte que la force est produite à longueur constante. Les mêmes événements ont lieu dans le muscle au cours des deux types de contractions : l'excitation du muscle déclenche le processus contractile ; l'activité cyclique des ponts d'union a lieu ; le glissement des filaments raccourcit les sarcomères ce qui étire l'élément élastique en série, qui génère alors une force sur les pièces squelettiques à l'insertion des tendons.

Il y a en réalité deux types de contraction isotonique, concentrique et excentrique. Dans les deux cas, la longueur du muscle change à force constante. Dans une contraction concentrique, le muscle se raccourcit, tandis qu'il s'allonge au cours d'une contraction excentrique car il est étiré par une force externe pendant la contraction. En pareil cas, l'activité contractile s'oppose à l'étirement [77].

En fait, chaque fois que nous avons besoin pour accomplir une tâche, le système nerveux central (SNC) envoie des signaux à la partie du corps respectifs pour effectuer cette activité. Par exemple, supposons que nous avons besoin de tirer un objet lourd, à ce moment-là le SNC continuera à envoyer des signaux aux muscles des bras pour produire la quantité requise de force pour tirer cet objet. Si la force n'est pas suffisante, alors plus de nombre de muscles se joindront pour augmenter la force. Quand un muscle est utilisé pour effectuer une tâche, les « unités motrices » sont excitées.

L'excitation de ces unités motrices (UMs) sont à l'origine d'un signal électrophysiologique : L'électromyogramme (EMG) qui traduisant cette activité musculaire.

### **1.8 L'Electromyogramme**

L'Electromyogramme (EMG) désigne le signal électrique collectif des muscles, qui est contrôlé par le système nerveux et est produit lors de la contraction musculaire [91]. Il est constitué de la somme de tous les potentiels d'action produits par les unités motrices des fibres musculaires sous le volume des électrodes. La qualité du signal EMG et ses propriétés intrinsèques sont cependant influencées par une multitude de facteurs. Les caractéristiques globales de l'EMG sont l'amplitude et le spectre de fréquences. Ces variables dépendent de l'état physiologique du muscle et des caractéristiques des potentiels d'action des unités motrices (PAUMs) [92].

On rencontre deux types de signaux EMGs dépendant de la manière avec laquelle ils sont détectés : L'EMG de surface et intramusculaire. L'EMG de surface est détecté de manière non-invasive avec des électrodes disposées sur la peau cependant l'EMG intramusculaire est détecté de manière invasive avec des électrodes implantées dans le muscle. Dans ce travail on s'intéresse à l'EMG intramusculaire.

### 1.8.1 Source de signal EMG

Comme expliqué ci-dessus, l'EMG résulte de la somme de tous les potentiels d'action produits par les unités motrices des fibres musculaires suite à une innervation.

#### 1.8.1.1 Potentiel d'action nerveux

Le potentiel d'action ou influx nerveux, correspond à une inversion transitoire, locale, brève de la membrane plasmique, sa durée est entre 1 et 2 ms, et son amplitude absolue atteint 100mV. Si un certain niveau de seuil est dépassé dans le flux des ions de  $\text{Na}^+$  (ion de sodium), la dépolarisation de la membrane provoque un potentiel d'action qui change rapidement de -70 mV à +30 mV. Il s'agit d'un éclatement électrique monopolaire qui est immédiatement rétablie par la phase de repolarisation et suivie d'une période d'hyperpolarisation de la membrane (voir Figure 1.8).

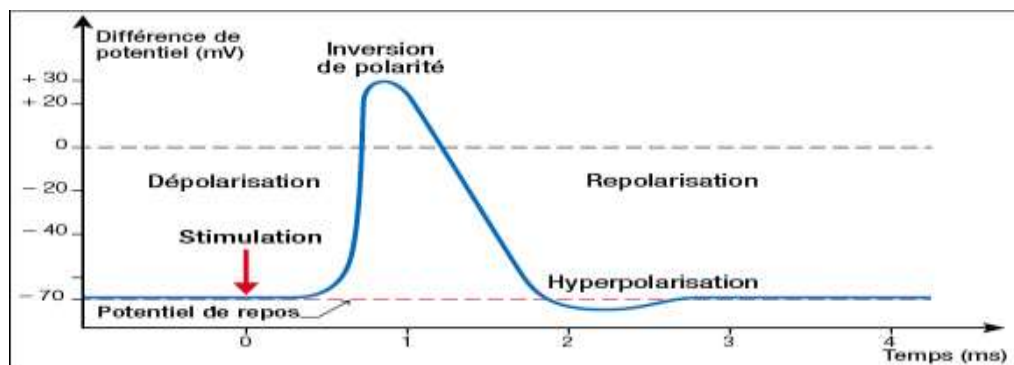


Figure 1.8: exemple d'un potentiel d'action. [77]

La contraction des fibres musculaires se produit lorsque des potentiels d'action sont générés dans le neurone moteur qui les fournit. Lorsque le potentiel d'action atteint le neurone moteur et l'axone terminale dépasse le seuil de dépolarisation dans la membrane post synaptique de la jonction neuromusculaire, il devient un potentiel d'action musculaire.

#### 1.8.1.2 Potentiel d'action d'une unité motrice

Quand une unité motrice est activée via le neurone moteur à partir de la moelle épinière vers la jonction neuromusculaire (plaque motrice), les fibres appartenant à ces unités motrices sont toutes excitées et se contractent ensemble [93]. La somme des potentiels de fibre musculaire créée par la dépolarisation et la repolarisation spatialement et temporellement dispersées de



toutes les fibres excitées d'une seule unité motrice (UM) est appelée potentiel d'action de l'unité motrice (PAUM) [94].

Afin de maintenir une contraction musculaire, les unités motrices doivent être activées de manière répétitive et chaque unité motrice génère des PAUMs multiples. La collection de tous les PAUMs génère un train de potentiels d'une unité motrice (TPAUM). La superposition des TPAUMs de toutes les unités motrices recrutées constitue un signal EMG [92] (Figure 1.9).

Par conséquent, l'analyse des PAUMs créés par les UMs d'un muscle se contractant peut aider à identifier son état de santé [94].




Figure 1.9 : Décomposition d'un signal EMG brute résulte des TPAUMs individuels. [95]

En raison de la nature du tissu musculaire qui est considéré comme un volume conducteur, le potentiel d'action résultant, se propageant dans les deux directions de la fibre et atteignant les tendons, crée un courant dans le voisinage de la fibre. Ce dernier crée un champ électrique dans tout le volume conducteur, qui est à l'origine des signaux EMGs détectés par des électrodes [93].

### 1.8.2 Détection de signal EMG

Les électrodes jouent un rôle majeur dans la détection des signaux EMGs qui ont une très faible amplitude ainsi que la durée, donc si les électrodes n'ont pas une bonne conductivité alors elles affecteront la qualité des signaux. Il existe principalement deux types d'électrodes l'une est « électrode insérée » (cas de la détection de l'EMG intramusculaire) et l'autre est « électrode de surface ou électrode de peau » (cas de l'EMG de surface). Pour vérifier le fonctionnement de l'électromyogramme, la force qui sera développée par le muscle devrait être proportionnelle à l'amplitude du signal. Dans chacune des catégories, il existe un nombre impressionnant de types d'électrode différents (voir figure 1.10) [96].



Figure 1.10 : présentation des électrodes [97].

1. Electrode aiguille
2. Electrode jetable Ag/AgCl
3. Electrode réutilisable Ag/AgCl
4. Electrodes Laplaciennes
5. Matrice d'électrodes sèches
6. Electrodes barre

Toutefois pour garantir une bonne détection du signal EMG de surface, il faut qu'avant l'application des électrodes EMG de surface, une bonne préparation de la peau est primordiale.

### 1.8.2.1 Electrodes de surface

Ceux sont des électrodes techniquement non invasives qui enregistrent la somme des activités de nombreuses unités motrices et même l'activité des muscles adjacents [94] lors de la mesure et la détection du signal EMG. Pour cela, les électrodes de surface nécessitent :

- Un gel abrasif est recommandé pour réduire la couche sèche de la peau.
- retirer complètement les cheveux de l'endroit où les électrodes doivent être placées.
- Il ne devrait pas y avoir d'humidité ou de sueur sur la peau. Dans le cas contraire la peau doit être nettoyée avec de l'alcool [98].

L'EMG de surface est la méthode la plus utilisée dans le milieu médical sportif, puisque sa technique de détection est non-invasive et peut être conduite par le personnel autre que les médecins, avec un risque minimal pour le sujet. La mesure de l'EMG de surface dépend d'un certain nombre de facteurs qu'on peut résumer par :

- La synchronisation et l'intensité de la contraction musculaire
- La distance de l'électrode du secteur actif du muscle
- Les propriétés du tissu (par exemple épaisseur de la peau)

- Les propriétés des électrodes et amplificateurs
- La qualité de la surface de contact entre l'électrode et la peau.

En outre, la mesure du signal EMG dépend des propriétés des électrodes et de leur interaction avec la peau. [99]. Il y a plusieurs configurations des électrodes dans la détection du signal EMG de surface : monopolaire, bipolaire, double différentielle et Laplacienne. La géométrie des électrodes et la configuration à l'enregistrement influencent étroitement le recueil du signal.

Ainsi, à titre d'exemple la figure 1.11 ci-dessous illustre la disposition des électrodes de surface pour la détection de différents EMGs dépendant de la position de ces électrodes (l'EMG est la différence de potentiel entre deux électrodes). En fait, entre l'insertion tendineuse et l'unité motrice du muscle, les électrodes EMG de surface doivent être placées le long de la ligne médiane longitudinale du muscle. Entre le centre des électrodes ou les surfaces de détection, la distance doit être de 1 à 2 cm seulement.

L'axe longitudinal des électrodes doit être parallèle à la longueur des fibres musculaires [98].




Figure 1.11 : Disposition des électrodes de surfaces [100]

### 1.8.2.2 Les électrodes Aiguilles

Les électrodes aiguilles sont largement utilisées dans des procédures cliniques dans les évaluations neuromusculaires [100] (pour la détection des EMGs intramusculaires).

Elles permettent l'enregistrement des potentiels individuels de l'unité motrice et fournissent beaucoup d'informations sur les muscles profonds. Pour des applications de diagnostic, on souhaite obtenir des informations temporelles et spatiales détaillées sur les fibres musculaires d'une UM [94]. La pointe de l'aiguille électrode est nue et utilisée en tant que surface de détection. Elle contient un fil isolé dans la canule. Les électrodes aiguilles ont deux principaux avantages.

Le premier est que la superficie relativement restreinte de contact permet à l'électrode de détecter les PAUMs individuels pendant les contractions de force relativement faibles. L'autre est que les électrodes peuvent être facilement repositionnées dans le muscle (après insertion) de sorte que de nouveaux territoires tissulaires peuvent être explorés (figure 1.12) [100].




Figure 1.12: Electrodes Aiguilles. [100]

Trois types principaux d'électrodes à aiguilles utilisées en électromyographie courante :

Électrode d'aiguille concentrique, qui consiste en une aiguille d'acier creuse dans laquelle passe un fil d'acier, d'argent ou de platine, totalement isolé excepté à son extrémité. La différence de potentiel est mesurée entre la canule qui sert d'électrode de référence et l'extrémité du fil, qui sert d'électrode active. Une électrode séparée est reliée à la terre. Ce type d'électrode est celui le plus souvent utilisé par les électromyographistes, d'autant plus qu'il existe des modèles à usage unique.

Électrode d'aiguille monopolaire, qui est une aiguille solide, en acier, totalement isolée sauf à son extrémité. Elle sert ainsi d'électrode active. L'électrode de référence est généralement une électrode de surface posée à distance du point d'insertion.

Un troisième type d'électrode est l'électrode d'aiguille bipolaire qui contient deux fils ou, plus de platine isolé sauf à leur extrémité, qui font office d'électrodes active et de référence, la canule étant reliée à la terre [101, 102].



Figure 1.13 : Différents types d'électrodes aiguilles utilisées en EMG. (a):Aiguilles concentriques (à fil fin), (b): Aiguilles monopolaires [101, 102].

### 1.8.2.3 Stimulateurs

On utilise des appareils délivrant des chocs électriques carrés (figure ci-dessous) de latence, de durée et de fréquence réglables. Leur amplitude peut être accrue progressivement et est donnée soit en volts (cas le plus fréquent), soit en ampères [103].



Figure I.14: Stimulateur électrique utilisé en EMG [104].

### 1.8.3 Caractéristiques des signaux EMGs

La figure 1.15 présente les caractéristiques principales du signal de chacun des appareils ci-dessus. On voit que chacun des signaux possède ces propres caractéristiques ce qui permet de déterminer qu'elles sont les critères que l'on doit avoir pour bien filtrer notre signal. Si l'on observe le signal EMG, leurs gammes de fréquences varient jusqu'au 3 KHz [96] dépendant de l'effort et de l'activité. Avec cette gamme de fréquences, une partie de l'ECG (électrocardiogramme) et de l'EEG (électroencéphalographie) est également incluse, de sorte que nous choisissons la plage de fréquence dominante des signaux EMG qui est de 20 Hz à 1500 Hz. Son amplitude varie de (-70mv) à environ (40mv) [105] en fonction du potentiel d'action de l'unité motrice (PAUM) [106].




Figure 1.15: Amplitude et spectres de bio-potentiels d'origines différentes. [96]

Comme décrit ci-dessus, le signal EMG détecté au niveau des électrodes est de très faible amplitude et noyé dans différentes sources de bruits. En plus le signal est très souvent détecté aux bornes de deux électrodes (tension différentielle entre deux conducteurs) ce qui va entraîner la présence d'une tension en mode commun. Il est alors indispensable de l'amplifier tout en minimisant l'effet de ces bruits. En instrumentation cette condition est retrouvée dans les amplificateurs d'instrumentation. Pour mieux comprendre ce type d'amplificateur (qui en fait, est une configuration d'au moins trois amplificateurs différentiels [107]) et particulièrement sa caractéristique fondamentale qui est le rapport de réjection en mode commun (RRMC) élevé, il est important de clarifier cette notion.

L'utilisation d'un amplificateur différentiel (voir figure 1.16 ci-dessous) est souvent rendue nécessaire lors de la présence d'une tension de mode commun. Son rôle est de fournir en sortie, une tension proportionnelle à la différence des deux tensions d'entrée.




Figure 1.16 : Structure élémentaire de l'amplificateur différentiel.

On dispose de deux entrées : l'Entrée inverseuse de gain ( $-A_1$ ) et l'entrée non-inverseuse de gain ( $A_2$ )

La tension de sortie  $V_s$  est obtenue à travers un sommateur ( $\Sigma$ ).

Ainsi la tension de sortie s'écrit :

$$V_s = A_2 V_A - A_1 V_B \quad (1.1)$$

$$V_{mc} = \frac{V_A + V_B}{2} \quad (1.2)$$

Et 
$$V_d = V_A - V_B \quad (1.3)$$

On peut réécrire  $V_s$  sous la forme :

$$V_s = A_d \cdot V_d + A_{mc} \cdot V_{mc} \quad (1.4)$$

Où  $A_d$  est le gain différentiel et  $A_{mc}$  le gain de mode commun

Avec :

$$A_d = A_2 - A_1 \quad (1.5)$$

Et 
$$A_{mc} = \frac{A_1 + A_2}{2} \quad (1.6)$$

Dans un amplificateur différentiel on cherche évidemment à obtenir  $A_{mc}V_{mc} \ll A_dV_d$ .

Pour qualifier un amplificateur quant à son aptitude à rejeter la tension en mode commun, on introduit une grandeur appelée le rapport de réjection en mode commun [107].

$$RRMC = \frac{A_d}{A_{mc}} \quad (1.7)$$

Le RRMC est défini en (dB) par :

$$\tau = 20 \log \frac{A_d}{A_{mc}} \quad (1.8)$$

Ainsi l'expression de la tension de sortie d'un amplificateur différentiel s'écrit :

$$V_s = A_d \left( V_d + \frac{1}{RRMC} V_{mc} \right) \quad (1.9)$$

Une fois le signal EMG est détecté à travers les électrodes puis amplifié et en vue de son traitement numérique et affichage sur un PC, un circuit d'acquisition est nécessaire. Différentes structures de circuits peuvent être développées dépendant de la nature du port d'entrée utilisé sur le PC (parallèle, série ou encore USB), de la vitesse de transmission du signal numérisé vers le PC, et de la manière avec laquelle le signal va être numérisé (utilisation du convertisseur analogique digital). Bref, ce circuit d'interface peut être réalisé de manière discrète en utilisant un convertisseur analogique digital, un circuit d'horloge pour générer la fréquence d'échantillonnage, et des buffers pour l'interface et la synchronisation de transmission des données via le port d'entrée/sortie du PC (en mode série ou parallèle). Plusieurs cartes d'acquisition disponible sur le marché à un prix très compétitif, et très facile dans sa manipulation et programmation sont utilisées.

L'électromyographie permet de détecter l'activité musculaire spontanément, au repos ou au moment de l'activité du muscle, ou bien lorsque l'on procède à la stimulation électrique musculaire nerveuse dans le cadre d'une épreuve ou d'un examen neurologique. Elle permet également d'affirmer si une lésion est de nature organique « réelle » ou non de nature physiologique.

Cet examen complémentaire permet également de localiser, au sein du système nerveux central ou du muscle, la lésion suspectée. Cette lésion concerne l'axone du neurone lui-même, la myéline ou la jonction neuromusculaire. Le tracé obtenu est appelé électromyogramme.

La figure 1.17 illustre un exemple de signal EMG normal produit par les muscles. [105]

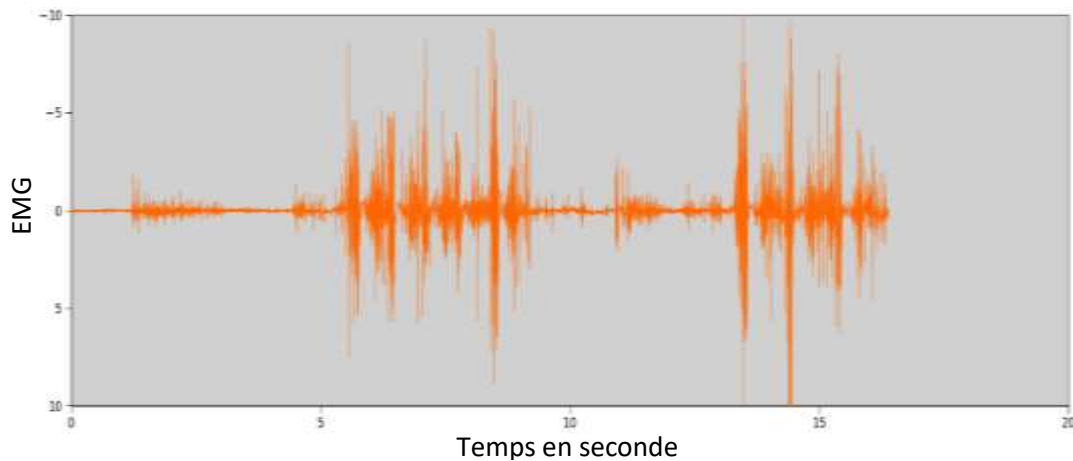


Figure 1.17 : Le signal EMG normal produit par les muscles. [31]

Les potentiels d'action (PAs) d'un muscle normal enregistré lors de la contraction volontaire présentent les caractéristiques suivantes :

➤ La morphologie normale (forme de PAUM) : elle est mono-bi ou triphasique et peut être polyphasique (Il est admis qu'il existe environ 10 % de potentiels polyphasiques dans un électromyogramme normal). La forme des potentiels varie également en fonction du muscle et de l'âge (les potentiels sont plus fréquemment polyphasiques chez le nourrisson et chez le sujet âgé).

➤ Durée normale : elle est de l'ordre de 3 à 5ms, varie en fonction du muscle exploité (plus brève dans les muscles qui sont constitués de petites et nombreuses UMs).

➤ Amplitude normale de PAUM : est également conditionnée par la taille des unités motrices. Elle varie entre 200 microvolts à 1mV [108], peut atteindre 2 mV [103, 109].

➤ Richesse des tracés [109] :

Au repos : Il n'existe aucune activité électrique. C'est ce qu'on appelle le « silence électrique ». Le tracé normal de repos se limite à la ligne de base.

Contraction volontaire : Au cours d'une contraction volontaire de force croissante, on voit le tracé électromyographique se « compliquer » de plus en plus. On peut distinguer trois stades :

1. contraction faible : On obtient ce qu'on appelle un « tracé simple ». Il est formé d'un seul potentiel bien individualisé correspondant à une seule UM en activité. Ce potentiel se répète identique à lui-même. Son enregistrement permet l'étude précise de sa forme, de son amplitude, de sa durée, de sa fréquence.

2. Contraction modérée : On obtient ce qu'on appelle un « tracé intermédiaire ». Il devient de plus en plus difficile de reconnaître chaque PAUM. En effet, l'activité électromyographique, à



ce stade, correspond à deux phénomènes : le recrutement de nouvelles unités motrices (sommation spatiale) ; et l'accélération de la fréquence de décharge des unités motrices (sommation temporelle).

3. Contraction maximale : L'amplitude augmente et peut atteindre 10 mV. On obtient ainsi un tracé de type « interférentiel » comparable à un tracé d'électromyographie globale (de surface); et la décomposition des PAUMs à partir du signal EMG obtenue devienne plus difficile.

Remarque : si le potentiel d'action d'unité motrice (PAUM) a un aspect polyphasique, avec une durée réduite et une faible amplitude on peut dire que le patient souffre d'une myopathie, et si les potentiels obtenus sont d'amplitudes anormalement grandes et anormalement longues (longues durée) on confirme alors la présence d'une neuropathie [103, 109, 110]. Cela est bien illustré sur la figure 1.18.




Figure 1.18 : Tracés du signal EMG normal et pathologique : le premier signal obtenu d'un patient sain, le deuxième signal d'un patient avec neuropathie et le troisième d'un cas atteint de myopathie [111].

## **1.9 Les pathologies neuromusculaires**

Le fonctionnement normal d'un muscle peut être perturbé à la suite des atteintes physiologiques. Ainsi, lorsque le corps cellulaire ou l'axone d'un motoneurone est endommagé, le muscle innervé ne peut plus être mis en activité et cette situation est appelée neuropathie. Si d'autre part le motoneurone est intact mais que les fibres musculaires ne sont pas en état de se contracter, on parle alors de myopathie. Et si la jonction neuromusculaire (plaque motrice) est touchée, l'unité motrice fonctionne mal et le muscle ne peut pas se contracter normalement (ici il s'agit des pathologies neuromusculaires).

Ce travail est basé sur l'une des pathologies que jusqu'à présent aucun traitement efficace n'est malheureusement connu, on parle de la sclérose latérale amyotrophique (SLA), elle se traduit par une perte des mouvements musculaires volontaires et de la coordination et avec le temps, les muscles s'affaiblissent et l'individu se retrouve peu à peu paralysé. Les personnes atteintes par cette maladie ne parviennent plus à faire leurs activités quotidiennes : il ne peut ni marcher ou se lever d'une chaise. Lorsque la paralysie s'étend, la personne est confrontée à des difficultés pour avaler, parler et même respirer car elle touche les motoneurons à la fois supérieurs et inférieurs.

Plus le nombre de motoneurons touché est grand, plus il est difficile pour l'individu de transmettre un signal vers ses muscles [112].

### **1.9.1 La sclérose latérale amyotrophique (SLA)**

La sclérose latérale amyotrophique est une maladie neurodégénérative évolutive menant à la dégradation (sclérose) des voies motrices spinales (cordons latéraux) et à l'atrophie musculaire (amyotrophie) consécutive à l'atteinte des neurones moteurs, La SLA constitue la troisième maladie neurodégénérative de l'adulte la plus fréquente après les maladies d'Alzheimer et de Parkinson [113, 114].

La SLA est définie par la dégénérescence progressive des motoneurons centraux, situés dans le cortex moteur et donnant naissance au faisceau pyramidal et des motoneurons périphériques, localisés dans la moelle épinière et le tronc cérébral trophique [115], encore appelée « maladie de Charcot » ou « Lou Gehrig's disease », est une dégénérescence progressive du faisceau pyramidal. Cette maladie est fatale. Elle apparaît typiquement chez des sujets âgés entre 40 et 65 ans et affecte aussi bien les hommes que les femmes. [116]

La motricité volontaire se réduit progressivement et finalement disparaît, tandis que les muscles involontaires ne sont généralement pas affectés par la maladie. Après la déclaration de la maladie, l'espérance de vie est située entre 3 et 5 ans. Les sujets atteints ne décèdent pas de

la SLA en tant que telle, mais d'une paralysie des muscles respiratoires ou d'une infection des poumons. Cette maladie concerne environ 2 cas sur 100 000 personnes [116].




Figure 1.19 : Maladie de Charcot [117]

La SLA peut se présenter sous deux formes principales : la forme "spinale" (qui débute par l'atteinte d'un membre), et la forme "bulbaire" (qui débute par l'atteinte des muscles de la bouche). La personne atteinte peut présenter des symptômes divers d'évolution progressive qui s'étendent au fur et à mesure :

- Des crampes musculaires
- Des difficultés à la mobilisation, évoluant vers la paralysie,
- Une diminution de la masse musculaire, appelée amyotrophie
- Un ralentissement des mouvements
- Des contractions involontaires de certains faisceaux musculaires sous la forme de fasciculations
- Des troubles de la déglutition,
- Des difficultés alimentaires,
- Des troubles de la parole.

### 1.9.1 Démarche diagnostique de la SLA

Le diagnostic de SLA est essentiellement clinique et électrophysiologique. Néanmoins, il est indispensable de pratiquer un certain nombre d'examens qui permettent, en dehors du diagnostic, de juger du profil évolutif et de suivre les effets thérapeutiques. Ainsi, en complément de la recherche des symptômes de la SLA. L'électroneuromyogramme est l'une de ces examens qui permet de suivre l'évolution de la SLA.

#### 1.9.1.1 L'électroneuromyogramme (ENMG)

L'ENMG est l'examen de référence à condition qu'il soit réalisé selon un protocole standardisé (Il comporte un électromyogramme de détection à l'électrode aiguille, l'étude de la conduction motrice, l'étude des ondes F, la recherche des blocs de conduction moteurs, la stimulation répétitive et l'étude de la conduction sensitive périphérique), et effectué par un neurologue. Il confirme l'atteinte du motoneurone périphérique, montre l'extension à des zones cliniquement préservées et permet d'écarter certains diagnostics différentiels [118].

##### 1.9.1.1.1 La SLA et l'électromyogramme de détection

Lors de la contraction volontaire, il objective la diminution du nombre de potentiels d'unités motrices recrutées traduisant la perte en neurone moteur. Le caractère pathologique des potentiels reflète les phénomènes de dénervation/réinnervation au sein des unités motrices, les modifications du rythme de fréquence des potentiels d'unités motrices lors de la contraction volontaire sont inconstantes dans cette pathologie associant une atteinte périphérique et centrale [118].

Les deux signaux EMGs du groupe de contrôle normal et de la personne atteinte de la SLA sont représentés sur la figure suivante :




Figure 1.20 : (a) Signal EMG normal ; (b) Signal EMG d'un patient qui a la SLA [2]

La figure précédente est une représentation de ces deux signaux EMGs en fonction de nombre des échantillons. Elle donne une vue générale de l'amplitude du signal et sa limite maximale à l'état normal, sinon il est considéré comme anormal et d'après cette figure, une augmentation progressive de l'amplitude d'un patient sain à celle qui a de la neuropathie (où elle a dépassé les 500 mV) est bien remarquée, ces des PUM d'amplitude et de durée augmentées qui se traduit par l'ancienne réinnervation. Aussi, le tracé de la SLA est appauvri à cause d'une perte d'UM.

La SLA a été ensuite représenté sur le plan temps-fréquence par application de transformé de Fourier à court terme (TFCT) dans les muscles biceps brachial, ce qui implique une fonction décrivant les changements dans le paramètre du signal EMG en temps et en fréquence illustré par la figure suivante.

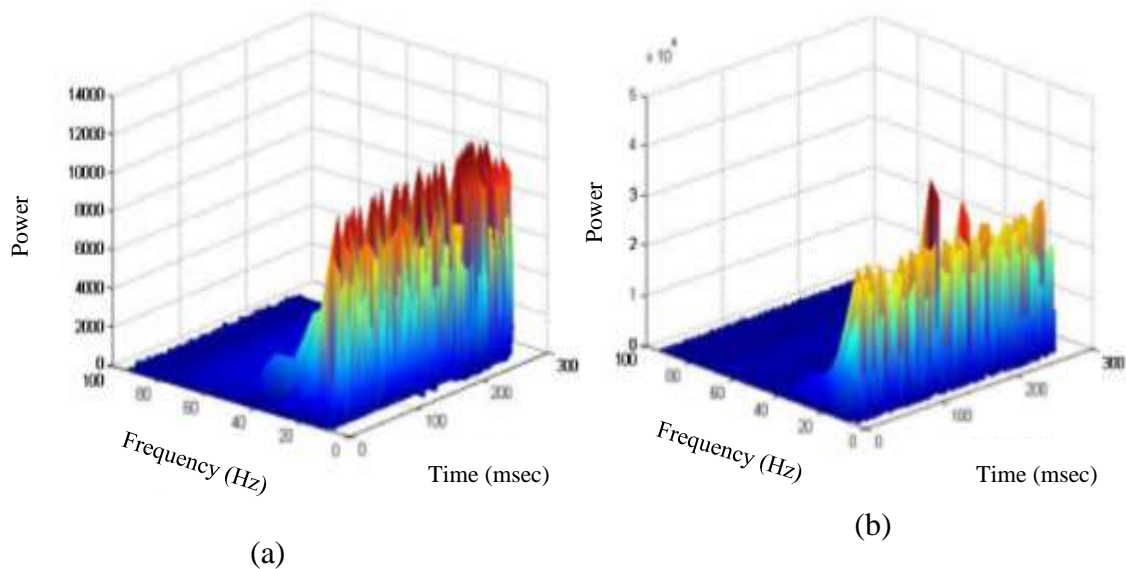


Figure 1.21 : (a) Spectrogramme d'un patient sain ; (b) Spectrogramme dans le cas de la SLA [2]

L'effet de la SLA est observable dans la représentation du spectrogramme du signal EMG. Dans cette méthode analytique, il est évident que le niveau de puissance du spectrogramme des patients qui souffrent de la SLA est significativement plus élevé que celui du groupe normal.

Les résultats analytiques montrent que les signaux EMGs affectés par la SLA ont un niveau de puissance supérieur à 11 000 unités, tandis que les signaux EMGs normaux ont un niveau de puissance inférieur à 11 000 unités. En plus de ça, on voit que la SLA provoque un déplacement du spectre de puissance EMG vers une fréquence plus élevée. Aussi, le nombre de pics dans le spectre de puissance du patient SLA est inférieur à celui du groupe normal, ce qui est attendu de la nature de cette maladie. La méthode TFCT a été utilisée pour l'extraction des

caractéristiques du signal EMG. Les caractéristiques extraites ont été utilisées pour détecter et vérifier la présence de la SLA. Les caractéristiques distinctives sont le niveau de puissance du spectre, le décalage de fréquence vers une région supérieure et le nombre de pics d'apparition.

### **1.10 Conclusion**

Dans ce chapitre, des connaissances de base sur l'électromyographie et la sclérose latérale amyotrophique (SLA) ont été présentées, enrichie par quelques notions de base anatomique et physiologique concernant le muscle et son fonctionnement (anatomie et contraction musculaire, génération des potentiels d'action des unités motrices (PAUMs), la génération du signal EMG). L'état de fonctionnement du muscle a poussé plusieurs chercheurs et surtout lorsque la pathologie est incurable comme la SLA.

L'analyse et l'exploration de ce signal électrophysiologique nécessite des méthodes de traitement de signal et des outils plus performants dans le domaine temporel et fréquentiel pour vérifier l'existence ou pas d'une sclérose latérale amyotrophique qui affecte les muscles ; ce que nous allons définir dans le chapitre suivant.

## **2. Les Techniques de débruitage des signaux électromyogrammes EMGs**

### **2.1 Introduction**

L'état de fonctionnement des muscles peut être étudiée à travers l'utilisation du signal électromyogramme (voir chapitre 1) qui va servir à comprendre les phénomènes physiologiques qui se passent au niveau de nos muscles. Comme la plupart des signaux électrophysiologiques, il est caractérisé à sa détection au niveau des électrodes par des différentes natures des bruits. Ainsi, la réalisation d'une routine permettant son analyse nécessite des précautions et des choix appropriés des fonctions et des méthodes d'analyse pour garantir la visualisation et le suivi correct de l'activité musculaire à travers ce signal et d'apprécier et de contrôler la réaction musculaire. Le traitement du signal numérique généré par le groupe musculaire peut nous amener à extraire plusieurs informations pour l'étude de l'activité neuromusculaire à travers l'électromyogramme (EMG).

### **2.2 Prétraitement du signal EMG**

Le matériel consiste en un groupe témoin sain et un groupe de patients atteints de SLA. Le groupe témoin était composé de 10 sujets normaux âgés de 2 à 37 ans, 4 femmes et 6 hommes. 6 sur 10 étaient en très bonne forme physique, et les autres sauf un étaient en bonne forme générale. Aucun dans le groupe témoin n'avait de signes ou d'antécédents de troubles neuromusculaires. Le groupe SLA était composé de 8 patients ; 4 femmes et 4 hommes âgés de 35 à 67 ans. Outre les signes cliniques et électrophysiologiques compatibles avec la SLA, 5 d'entre eux sont décédés quelques années après le début de la maladie, ce qui appuie le diagnostic de SLA. Les muscles du biceps brachial ont été utilisés dans cette étude car ils étaient les plus fréquemment investigués dans les deux groupes de patients. Les signaux EMG ont été enregistrés à partir du muscle biceps brachial par une électrode à aiguille concentrique et amplifiés par un amplificateur d'instrumentation DISA15C01 avec un gain de 500. Un filtre passe-bande analogique avec des fréquences de coupure de 2 Hz à 10 kHz a été utilisé. Ces signaux analogiques ont été numérisés par Motorola DSP56ADC16 avec une résolution de 16 bits et échantillonnés à une fréquence de 23438 Hz.

#### **2.2.1 Signal EMG normalisé en amplitude et en temps**

L'amplitude du signal EMG varie en fonction du placement de l'électrode et de la conductivité de la peau (électrodes de surface), variable d'un sujet à un autre et le gain utilisé lors de l'amplification. Pour pouvoir comparer l'activité de l'EMG de différents sujets dans différentes conditions de recueil, on normalise généralement l'EMG, par exemple en le divisant

par l'amplitude maximale obtenue lors de contraction maximale volontaire. On obtient ainsi un EMG normalisé en amplitude.

Le tracé sur la figure ci-dessous (Figure 2.1) décrit le signal EMG recueilli sur le muscle concerné lors d'une contraction volontaire. C'est un signal tracé directement en exploitant les échantillons acquis à travers la carte d'acquisition (après circuit d'offset) à la fréquence d'échantillonnage. Il est considéré comme signal EMG non normalisé. Pour une représentation plus compréhensible, ce signal est normalisé à travers la routine décrite ci-dessous.

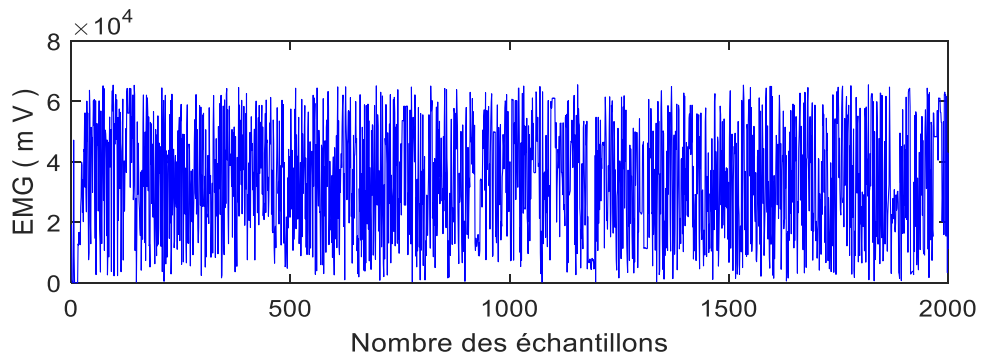


Figure 2.1 : Tracé du signal EMG non normalisé.

Pour normaliser notre signal il faut passer par trois opérations (voir organigramme sur la figure 2.2) :

- Diviser les amplitudes du signal par le gain introduit au niveau du circuit lors de la détection. Dans le cas de cette base de données, il est de 500
- Diviser la longueur de signal par la fréquence d'échantillonnage ( $f_s$ ) ce qui permet d'adapter l'axe d'abscisse en fonction du temps,  $f_s=23438$  Hz.
- Pour éliminer la composante continue de signal, on soustrait la valeur moyenne du signal de toutes les valeurs successives.



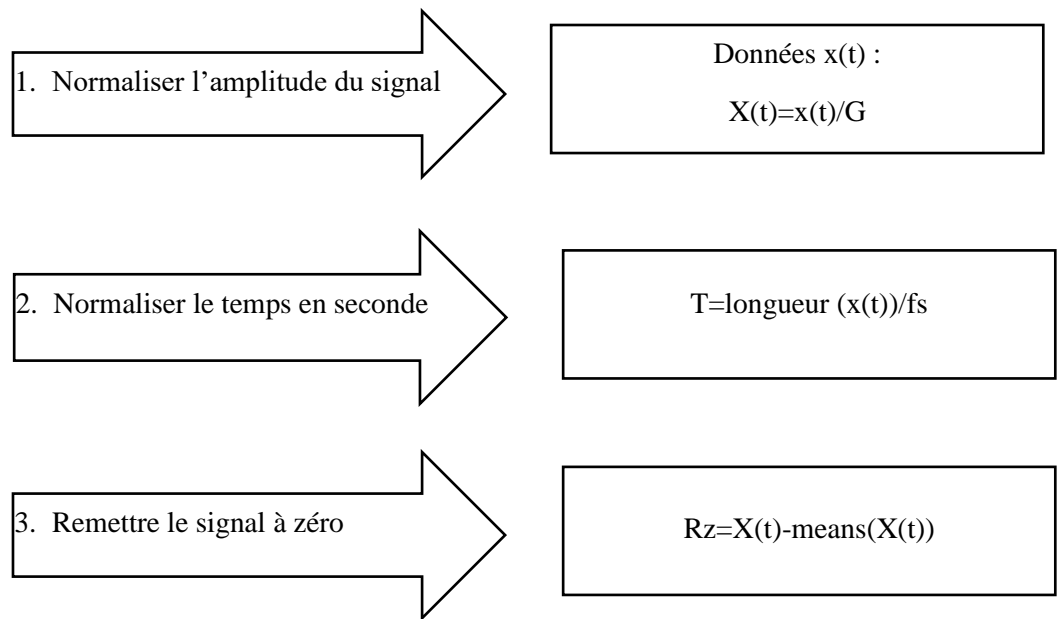


Figure 2.2 : les procédures de normalisation du signal EMG.

Après l'application de ces opérations, notre signal est normalisé. Le signal EMG normalisé est illustré sur la figure ci-dessous.




Figure 2.3 : Tracé du signal EMG normalisé.

## 2.2.2 EMG lissé

Le modèle proposé consiste à séparer le signal électromyogramme (EMG) du bruit en utilisant la transformé en ondelette discrètes (TOD). La méthode appliquée est décrite en détail par la suite mais avant d'entamer la description, quelques généralités sur ce type de débruitage sont résumées dans cette section.

### 2.2.2.1 Débruitage par utilisation d'un filtre linéaire

Un filtre numérique de type passe bande « Butterworth » est utilisé, ce filtrage sert à minimiser les basses et les hautes fréquences du signal. La fréquence de coupure basse du filtre passe bande supprime la dérive de la ligne de base parfois associée au mouvement, à la transpiration, etc., et supprime tout décalage DC. Les valeurs typiques de la coupure basse

fréquence sont de 5 à 20 Hz. Si la valeur moyenne du signal n'est pas nulle avant le filtrage passe-haut ou passe-bande, elle le sera après, car ces filtres suppriment les composantes basses fréquences d'un signal, et donc ils forcent la valeur moyenne à être nulle ou presque nulle. La coupure haute fréquence du filtre passe-bande supprime le bruit haute fréquence et empêche le crénelage de se produire dans le signal échantillonné. La coupure haute fréquence doit être assez élevée. Les valeurs typiques sont de 200 Hz à 1 kHz.

- Recommandations Seniam pour l'EMG de surface : passe-haut avec coupure 10-20 Hz, coupure passe-bas « près de 500 Hz », dans la plupart des cas.
- Recommandations ISEK pour l'EMG de surface : passe-haut avec coupure à 5 Hz, passe-bas avec coupure à 500 Hz.
- Recommandations ISEK pour l'EMG intramusculaire et à l'aiguille : passe-bas avec coupure de 1500 Hz ou plus ; passe-haut non spécifié [30].

Certains auteurs appliquent un passe-haut numérique au signal pour supprimer les mouvements et autres artefacts. Solnik et al ont appliqué un filtre passe-haut de 6ème ordre à 20-500 Hz, pour l'EMG de surface de vastus lateralis [119, 120].

### 2.2.2.2 Débruitage par seuillage

Le modèle considéré pour ce débruitage est classique, le signal mesuré  $x$  est un mélange additif d'un signal informatif  $s$  et d'un bruit de mesure  $r$  :

$$X(t)=s(t)+r(t) \quad (2.1)$$

Le débruitage par seuillage des coefficients d'ondelettes, tel qu'il est défini en [14], revient à « l'extraction d'une structure cohérente » du signal mesuré.

L'hypothèse de départ porte sur le bruit  $r$ , qui est considéré comme non cohérent par rapport à une base de formes d'onde prédéfinie, c'est-à-dire non corrélé avec ces formes d'ondes.

La transformation en ondelette discrète (TOD) est issue de la version continue (TOC), sauf que la TOD utilise un facteur d'échelle et une transformation discrétisé  $a=2^j$  et  $b = n2^j$

$$W(i, m) = 2^{-\frac{i}{2}} \sum_{n \in \mathbb{Z}} x(n) \psi\left(\frac{n}{2^j} - m\right) \quad (2.2)$$

De nombreuses familles d'ondelette peuvent être implémenté en Matlab y compris les Morlet, chapeau mexicain, Meyer, Haar, Daubechies, Symplets, Coifets et autre. La famille des ondelettes de Daubechies se compose de 45 types. Dans cette étude, seule l'ondelette orthogonale db4 est examiné car elle est recommandée par plusieurs chercheurs qui ont prouvé

son efficacité quand l'analyse du signal EMG grâce à sa morphologie similaire à ce signal [14, 121, 122, 123].

La décomposition est faite en appliquant successivement une série de filtres passe-haut et passe-bas (filtre miroirs en quadrature) et en effectuant un sous échantillonnage pour conserver le nombre initial de point de données. Cette procédure se traduit par des détails, qui sont à petite échelle, les éléments de haute fréquence du signal et des approximations, qui sont à grande échelle, les composantes basses fréquences du signal.

Cette décomposition est effectuée sur plusieurs niveaux, le processus de décomposition étant itéré pour des approximations successives [124]. Lors du débruitage, tous les coefficients en dessous d'une certaine valeur sont libérés avec un seuil spécifique. Certains paramètres de seuil doivent être choisis. Les deux méthodes courantes de seuillage d'un signal sont le seuillage doux et dur qui est utilisé dans la boîte à outils d'ondelettes de Matlab.

Les deux méthodes peuvent être définies comme ci-dessous où  $T$  représente le seuil et  $x$  désigne le facteur d'échelle. LIMEM et al ont utilisé cette approche dans le débruitage du signal électromyogramme (EMG). Dans la littérature, on trouve deux types de seuillage : Le seuillage dur (hard thresholding) et le seuillage doux (soft thresholding) [13, 125, 126, 127].

#### 2.2.2.2.1 Le seuillage dur (hard thresholding)

Ce seuillage propose l'annulation de toutes les valeurs en dessous d'un seuil  $T$ , les valeurs supérieures restant inchangées ( $w_{j,k}$  Les coefficients de la décomposition du signal  $x$ ).

$$w_{j,k} = \begin{cases} w_{j,k} & \text{si } |w_{j,k}| > T \\ 0 & \text{si } |w_{j,k}| \leq T \end{cases} \quad (2.3)$$

#### 2.2.2.2.2 Le seuillage doux (soft thresholding)

Opère, en plus de l'annulation, une soustraction du seuil  $T$  aux valeurs restantes, supérieures au seuil, afin de réduire le nombre de discontinuités dans le signal débruité.

$$w_{j,k} = \begin{cases} \text{sign}(w_{j,k})(|w_{j,k}| - T) & \text{si } |w_{j,k}| > T \\ 0 & \text{si } |w_{j,k}| \leq T \end{cases} \quad (2.4)$$

Il est connu que le seuillage doux fournit des résultats plus lisses en comparaison avec la technique de seuillage dur. [13, 126, 127]. Selon [128], la méthode de seuillage dur est utilisée lorsque le signal et le bruit sont aléatoires.

Bien que le seuillage dur soit la méthode la plus simple, le seuillage doux peut fournir de meilleurs résultats que le seuillage dur. En effet, le seuillage dur peut provoquer des

discontinuités au niveau du seuil T du fait que ces valeurs inférieures au seuil soient mises à zéro.

Pour montrer cet effet voici l'exemple suivant :

Soit  $y$  un signal tel que :

$y = \text{linspace}(-1,1,100)$ ; Voici le signal résultant d'un seuillage dur et doux par un seuil de 0.4

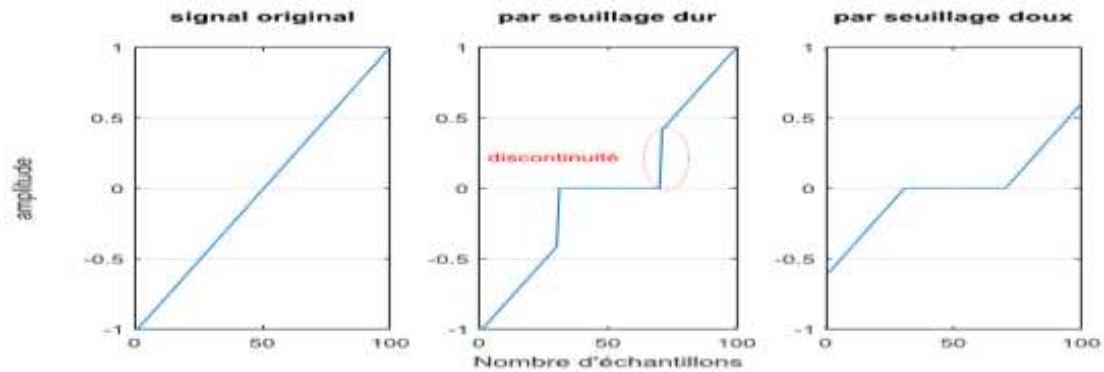


Figure 2.4 : Différence entre le seuillage dur et le seuillage doux

Le seuil  $S$  peut être calculé de différentes manières. La méthode développée par Donoho et Johnstone [129], connue par le seuillage universel. Cette dernière propose un seuil déterminé à partir de l'énergie estimée du bruit, elle utilise l'hypothèse d'un bruit blanc gaussien superposé au signal. Le seuil  $S$  est égal à  $\delta\sqrt{2 \log N}$ , où  $N$  désigne le nombre de points du signal et  $\delta^2$  la variance du bruit, elle peut être estimée par

$$\delta = \frac{M_{w_{1,k}}}{0.6745} \quad (2.5)$$

Où  $M_{w_{1,k}}$  : est la médiane du bruit.

Mallat a montré que l'amplitude du bruit a une très forte probabilité d'être juste en dessous de  $S$ . cette méthode a été améliorée par le principe d'estimation du risque non-biaisé de Stein (Stein Unbiased Risk Estimator : SURE), afin de réduire le risque de non-détection.

Avant d'appliquer un débruitage par ondelettes, on doit prendre en considération certains paramètres, comme le type d'ondelette utilisé, le niveau de décomposition choisi et le type de seuillage. Nityanand Thakur et al ont sélectionné (db2, 4ème niveau) pour le débruitage du signal EMG avec un seuillage universel doux [130] alors que LIMEM et al ont examinées différentes fonctions d'ondelettes pour optimiser la procédure de débruitage : Daubechies (db2, db4, db5, db6 et db8) y compris Symmlet (sym4, sym5) et orthogonal Meyer (dmey) avec trois et quatre niveaux de décomposition. La fonction d'ondelettes appropriée est choisie en raison des valeurs du rapport signal sur bruit calculées. Les résultats de ces travaux ont montré que l'ondelette Daubechies du 4<sup>ème</sup> ordre (db4) avec 3 niveaux de décomposition est la plus appropriée pour l'analyse du signal électromyogramme. De plus, ils ont prouvé que le seuillage

universel doux donne des résultats très satisfaisants [14]. Pour cela, l'ondelette Daubechies de 4<sup>ème</sup> ordre avec 3 niveaux de décomposition avec un seuillage universel doux a été implémenté dans ce travail pour le débruitage du signal EMG.

Dans cette section, nous avons implémenté aussi un filtre linéaire de type passe bande « butterworth » d'ordre 6 avec une bande fréquentielle de (20-1500) Hz. L'intérêt est de comparer ces deux méthodes de débruitage en vue de sélectionner la méthode la plus fiable qui aide à la compréhension du signal EMG.

La figure suivante (Figure 2.5) illustre le processus de filtrage résultant, il apparait clairement que le débruitage TOD est le plus efficace, car il présente une ligne de base plate que possible. En revanche, le débruitage linéaire montre une haute-fidélité du signal d'origine même s'il ne reçoit pas la même performance en tant que processus TOD.




Figure 2.5 : Effet de filtrage par les deux techniques : la TOD et le filtre linéaire

### 2.3 La détection d'enveloppe

Dans la littérature, diverses approches peuvent être trouvées pour extraire l'enveloppe  $E(t)$  [131]. Les techniques les plus représentatives utilisent la transformée d'Hilbert [32, 132], le critère d'erreur quadratique moyenne (EQM) [33] et la forme d'onde produite par le signal redressé [34]. Un algorithme précoce qui exploite l'enveloppe reflétant l'activité moyenne [133] Une de ces approches, la transformée d'Hilbert qui est fréquemment utilisée.

Un signal analytique est composé par le signal original et sa transformée d'Hilbert. Il est donné par l'équation 2.6, où  $H(t)$  est la transformée d'Hilbert (Eq.2.7)

$$S_A = S(t) + i * H_s(t) \quad (2.6)$$

$$H_s(t) = (h * S)(t) = \int_{-\infty}^{\infty} S(\tau) h(t - \tau) d\tau = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{S(\tau)}{t - \tau} d\tau \quad (2.7)$$

La transformée d'Hilbert peut être interprétée comme la convolution entre le signal et  $1/\pi t$  [134]. L'enveloppe du signal analytique,  $S_A(t)$  peut être produite fidèlement par le module de l'équation (Equation 2.8).

$$|S_A(t)| = \sqrt{|S(t)|^2 + |S_H(t)|^2} \quad (2.8)$$

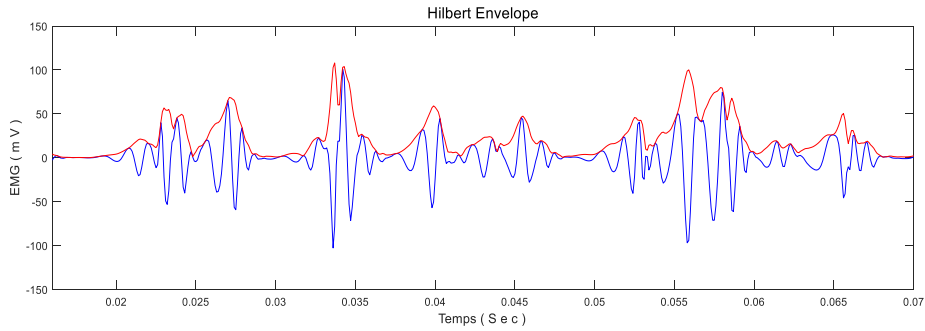


Figure 2.6 : L'enveloppe détectée par la valeur absolue (abs) de la transformée d'Hilbert du signal EMG.

Le calcul du carré du signal ou de la valeur absolue sert à extraire l'enveloppe, voir l'équation (2.9) et (2.10). La valeur absolue donne le même poids à tous les échantillons sans tenir compte de leur valeur ou intensité. Par contre, l'énergie (carré) change la mesure par l'accentuation des hautes intensités par rapport aux faibles intensités. Deux autres approches peuvent être utilisées, sont l'entropie et l'énergie de Shannon [135], voir l'équation (2.11), (2.12). Ces approches donnent le plus grand poids aux intensités moyennes du signal, par conséquent, le bruit de faible intensité et les perturbations de hautes intensités seront atténués.

Energie au carrée :

$$E = S(t)^2 \quad (2.9)$$

Valeur absolue :

$$E = |S(t)| \quad (2.10)$$

Entropie de Shannon :

$$E = - |S(t)| * \log |S(t)| \quad (2.11)$$

Energie de Shannon :


$$E = - S(t)^2 * \log S(t)^2 \quad (2.12)$$

### 2.3.1 L'extraction de l'enveloppe

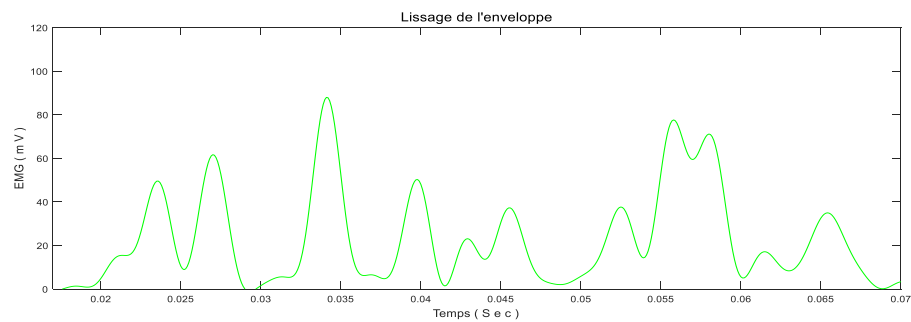
La détection d'enveloppe est essentielle pour pouvoir localiser les instants d'activation musculaire. Ceci permettra donc une séparation de l'activité actuelle et la prochaine innervation. Quelques études récentes ont montré l'intérêt de l'utilisation de la transformé d'Hilbert pour une détection efficace de l'enveloppe [32, 132].

La détection d'enveloppe dans notre travail (voir figure 2.7 (a)) est basée sur la valeur absolue et de la transformé d'Hilbert, qui est la combinaison entre l'enveloppe du signal par sa valeur absolue et la transformée d'Hilbert dont le but est d'obtenir une enveloppe couvrante le long du signal et surmonter le problème de synchronisation crée par les méthodes classiques de détection d'enveloppe par application des filtres.

Une étape de lissage supplémentaire est ajoutée pour juste améliorer l'allure du signal et réduire les transitions imprévues ce qui fera appel à un simple filtre passe bas de butterworth d'ordre 6 avec une fréquence de coupure de 6 Hz (Figure 2.7 (a)). Ce dernier servira une visualisation agréable des périodes d'activation musculaire c'est-à-dire des débuts et fins de chaque innervation musculaire.



(a)



(b)

Figure 2.7 : a. L'enveloppe du signal, b. Lissage de l'enveloppe du signal EMG.

## 2.4 La rectification du signal EMG

La rectification qui représente la valeur absolue du signal EMG ; il sert à identifier la force globale de la commande neurale sur le muscle [136], toutes les amplitudes négatives sont converties en amplitudes positives, les pics négatifs sont « remontés » à plus ou reflétés par la ligne de base [120]. La figure 2.8 représente le signal EMG rectifié.




Figure 2.8 : La représentation du signal EMG rectifié.

L'organigramme suivant (Figure 2.9) présente les différentes étapes à suivre pour finaliser cette thèse, les étapes de prétraitement sont importantes pour rendre ce signal compréhensible (Normalisation, débruitage...). Puis, l'analyse de ce signal par des méthodes temporelles et fréquentielles servent à extraire toutes les informations nécessaires pour le suivi d'une telle pathologie ; le cas de la SLA dans ce travail. En fin, la représentation temps-fréquence par application de la TFCT et la TOC ont fait l'objet de cette étude pour obtenir des hautes performances à la classification des signaux EMGs.



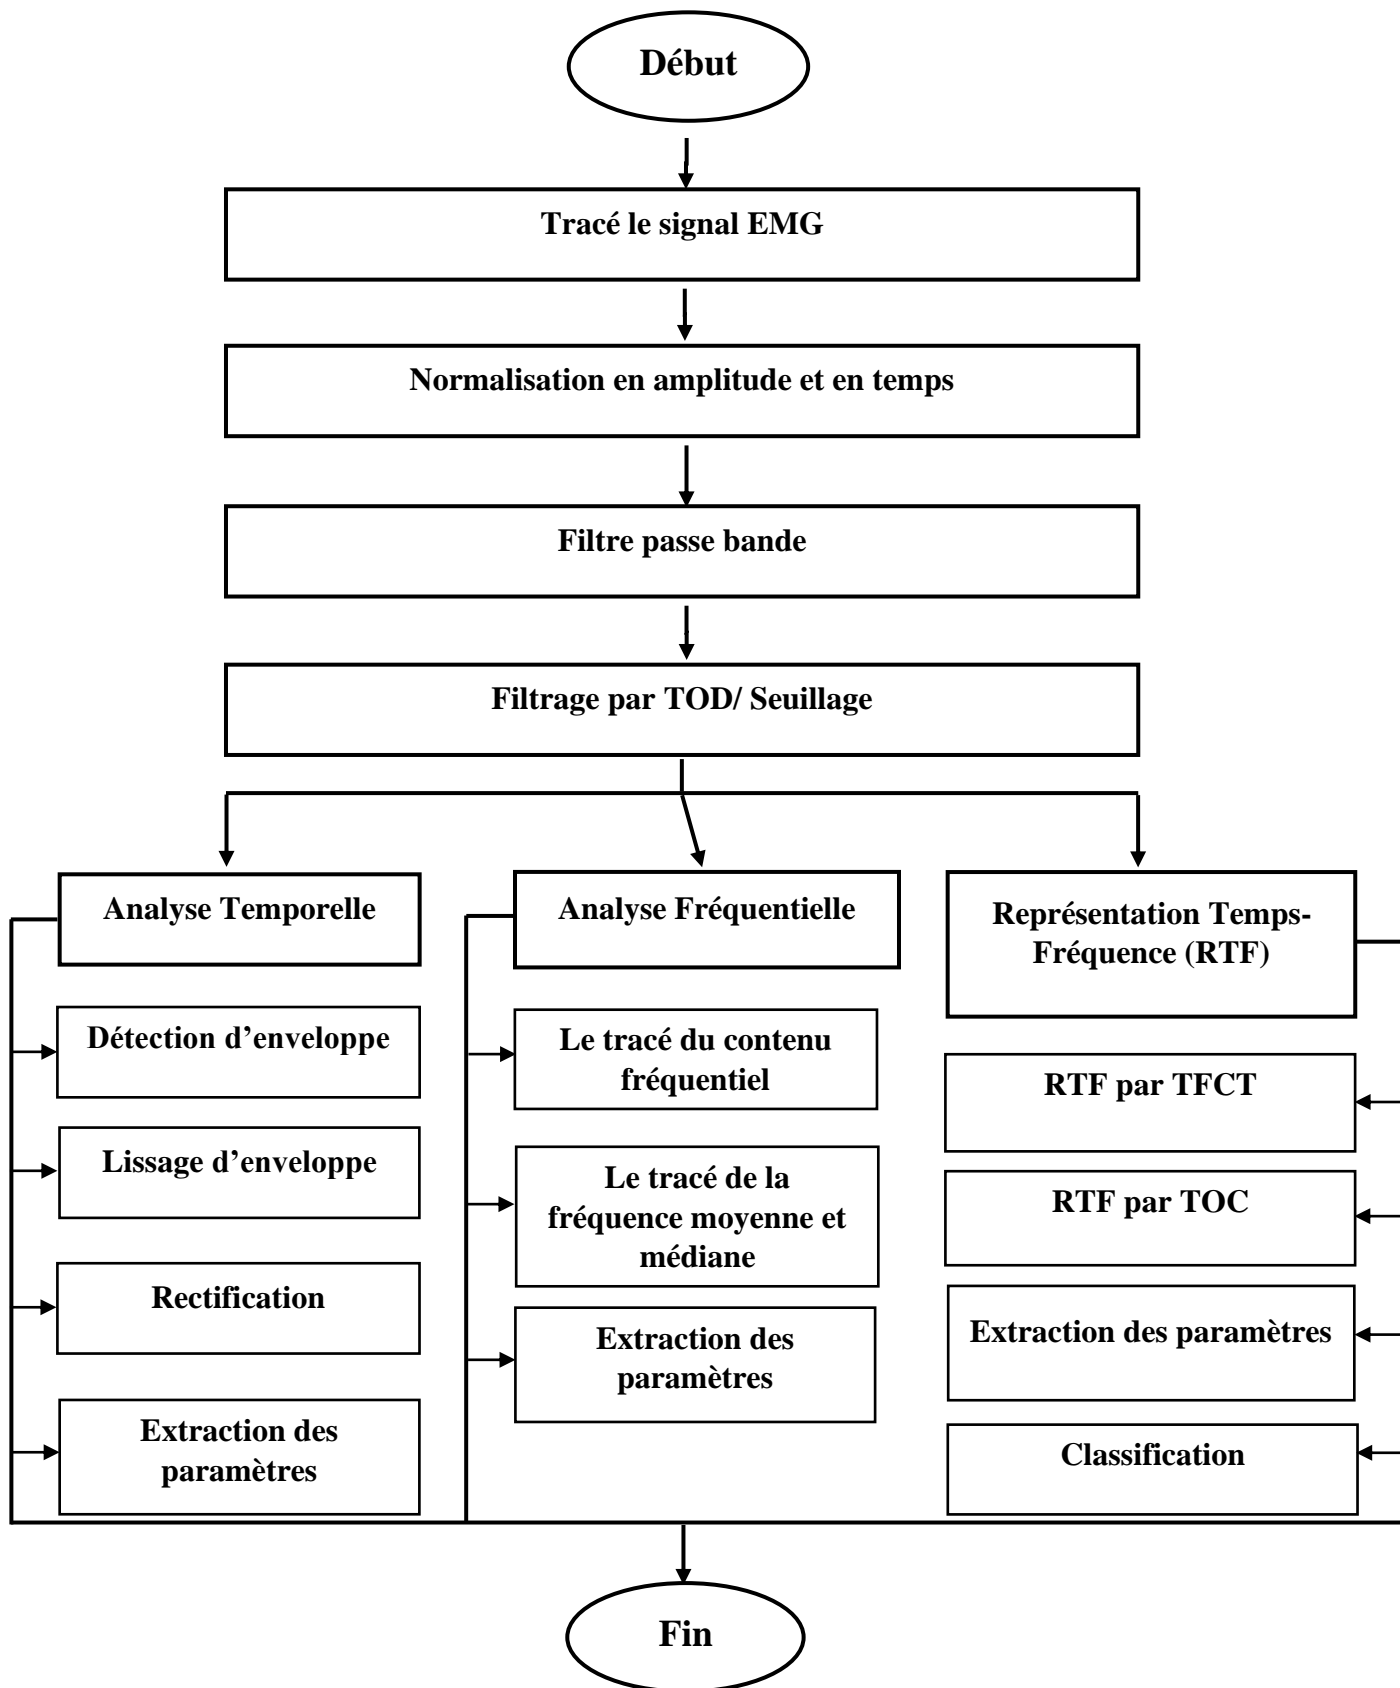




Figure 2.9 : Algorithme de l'extraction des pathologies neuromusculaire et leur classification.

## 2.5 Résultats et discussion

Les figures suivantes (Figure 2.10 (a et b)) montrent les résultats obtenus après l'application de l'algorithme basé sur le débruitage utilisés sur différents signaux EMGs dans les deux cas, en rouge est obtenu après un filtre passe bande de type butterworth de 6<sup>ème</sup> ordre, le signal n'est pas encore prêt pour les étapes de traitement. Ce qui est en bleu est le débruitage par TOD, le signal est bien net, les bruits sont minimisés ; l'étape de traitement et d'extraction des paramètres dans les cas normaux et anormaux sont les étapes suivantes.




(a)




(b)

Figure 2.10 : Effet de filtrage par les deux techniques : Le filtre linéaire (en rouge) et la TOD (en bleu) dans le cas (a) sain et (b) pathologique

La figure 2.11 suivante a montré l'effet du filtrage par application de la TOD sur les cas normaux (figure 2.11(a)) et celle qui sont pathologiques (figure 2.11 (b)).



(a)



(b)

Figure 2.11 : Représentation temporelle du signal EMG dans le cas (a) : sain, (b) pathologique.

La comparaison des cas normaux et des cas pathologiques par application de la TOD nous a permis d'extraire l'amplitude maximale, ce paramètre est très supérieure  $> 1000$  mV chez les patients qui ont la SLA par rapport aux patients sains  $< 200$  mV, cette visualisation a qualifié l'amplitude du signal EMG d'être un indicateur de la présence d'une pathologie.

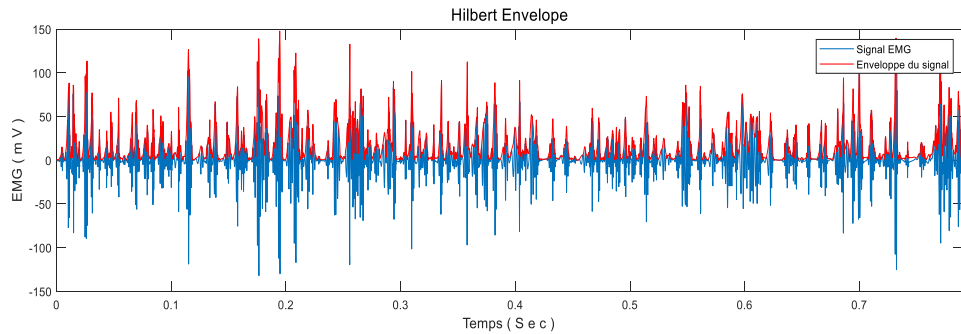
Les figures suivantes représentent une partie de l'algorithme basé sur l'analyse temporelle par détection d'enveloppe utilisés sur différents signaux EMGs, ce paramètre sert à visualiser les périodes d'activation musculaire, son amplitude traduit l'intensité lors du recrutement des unités motrices, et sa durée la durée de de l'activité avant le relâchement du muscle.

La comparaison des cas normaux et pathologiques a confirmé que


L'enveloppe du signal chez les sujets sains (figure 2.12(a)) a montré que l'amplitude de cette enveloppe ne dépasse pas 150 mV par contre, chez les sujets qui ont la SLA où leurs amplitudes seront multiplié encore, elles atteignent 2V, cette augmentation de l'amplitude se traduit par une stimulation directe du muscle du biceps brachial et donc d'une augmentation de la taille des unités motrices qui se traduit par potentiel des unités motrices (PUM) d'amplitude augmentées.

On peut conclure que :

Plus le signal a une sévérité pathologique accentuée et plus l'amplitude de l'activité est très importante ce qui implique une période d'activation musculaire très large.




(a)




(b)

Figure 2.12 : L'enveloppe du signal EMG dans le cas (a) : normal, (b) SLA.

À travers le signal rectifié on peut apprécier la force globale de la commande neurale. En effet, elle est importante chez les patients qui souffrent de la SLA (voir figure 2.13 (b)) par rapport aux patients sains (figure 2.13 (a)), ce qui a été présenté par la figure ci-dessous. C'est un indicateur de la présence d'une pathologie nerveuse car une sévérité pathologique accentuée implique une élévation de cette force. La figure suivante illustre le signal EMG après rectification dans le cas normal et pathologique, ces figures ont montré clairement que la force globale pour que la commande neurale soit reçue est très importante chez les souffrants de la SLA, environ  $300 \text{ mv}^2$  contre  $150 \text{ mv}^2$  chez les cas sains.



(a)



(b)

Figure 2.13 : La représentation du signal EMG rectifié dans le cas (a) : normal, (b) SLA.

## 2.5 Conclusion

Dans ce chapitre, nous avons d'abord présenté le processus de normalisation puis de débruitage des signaux EMGs par des filtres linéaires et par la transformée en ondelettes discrètes TOD afin de faciliter le choix pour l'utilisateur concernant la méthode la plus fiable.

Les filtres linéaires sont largement utilisés pour le débruitage des signaux. Ils ont montré une haute-fidélité au signal original, mais ils ne sont pas toujours au top lorsqu'on veut une ligne de base plate après filtrage. C'est pourquoi nous recommandons la TOD pour obtenir des bons résultats dans ce cas.

Le chapitre a été finalisé par la présentation temporelle du signal EMG, son enveloppe, EMG rectifié puis par une comparaison de ces méthodes d'analyse temporelle chez les patients sains et celle qui ont la SLA dans le but de faciliter le diagnostic de cette pathologie, le prochain chapitre se détaille hermétiquement les méthodes d'analyse temporelle et fréquentielle pour un suivi précoce de la sclérose latérale amyotrophique.

### 3. Analyse temporelle et fréquentielle des signaux électromyogrammes (EMGs)

#### 3.1 Introduction

L'électromyogramme correspond au tracé de l'activité électrique du muscle au cours du temps. L'évolution du signal en temps et en fréquence peut être quantifiée de manière visuelle (visualisation métrique) ou à l'aide de plusieurs paramètres. L'objectif de ce chapitre est de déterminer l'amplitude et/ou la fréquence des oscillations sur le tracé brut. Progressivement, l'analyse quantitative du signal EMG est devenue plus rigoureuse et a donné lieu à divers procédés d'analyse automatique. Le but dans cette partie de la thèse est d'analyser les signaux EMGs par le biais de certains paramètres obtenus à partir de l'analyse temporelle et l'analyse fréquentielle telle que : la valeur absolue moyenne (MAV), l'énergie (En), la fréquence moyenne (FMN) et la fréquence médiane (FMD), la puissance moyenne (PMN) et totale (PTT) et l'analyse bispectrale qui représente le signal d'intérêt en deux fréquences. Ces paramètres sont les plus envisageables non seulement pour la quantification du signal EMG mais aussi pour la distinction et la différenciation entre les cas normaux et pathologiques.

#### 3.2 Analyse du signal EMG dans le domaine temporel et fréquentiel

Le but de ce paragraphe c'est d'établir un certain nombre de paramètres temporels et fréquentiels, susceptibles de faire ressortir facilement et de façon très visible des informations pouvant aider à déceler toutes variations du signal EMG analysé par rapport au signal EMG normal pris comme référence.

##### 3.2.1 Quantification dans le domaine temporel

Premier paramètre d'analyse : Valeur absolue moyenne (VAM) qui fournit les informations énergétiques et calculées selon la formule suivante [24].

$$VAM = \frac{1}{N} \sum_{n=1}^N |S(n)| \quad (3.1)$$

Où  $S(t)$  est le signal EMG,  $N$  : nombre d'échantillon

Deuxième paramètre d'analyse : Énergie (En) l'objectif fixé par ce paramètre est de définir la quantité d'informations véhiculées par le signal. Il est donné par la formule suivante [42] :

$$En[S] = \int |S(t)|^2 dt \quad (3.2)$$

### 3.2.2 Quantification dans le domaine fréquentiel

#### 3.2.2.1 Transformé de Fourier Rapide (TFR)

La transformée de Fourier (TF) est un outil classique de traitement du signal. En analysant le contenu spectral du signal, cette TF permet de dévoiler et de représenter dans le domaine fréquentiel des caractéristiques (répartition de l'énergie en fonction des fréquences) que la simple représentation temporelle ne permet pas de percevoir. Son expression mathématique est la suivante :

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-2i\pi ft} dt \quad (3.3)$$

Où  $x(t)$  est le signal EMG à analyser,  $X(f)$  est sa transformée de Fourier [77].

Mais elle ne permet pas de localiser la présence ou l'évolution d'une composante fréquentielle dans le temps. De ce fait, la transformée de Fourier n'est utile que dans le cas d'un signal stationnaire parce que les propriétés statistiques d'un tel signal restent constantes par rapport au temps.

#### 3.2.2.2 Fréquence moyenne (FMN) et la fréquence médiane (FMD)

L'extraction des indicateurs fréquents comme la fréquence moyenne (FMN), la fréquence médiane (FMD) [42], la puissance totale (PTT) et la puissance moyenne (PMN) sert aussi à suivre l'évolution de certaines pathologies, les deux premiers paramètres peuvent être utilisés pour déterminer la vitesse de conduction des fibres [137].

La fréquence moyenne (FMN) est calculée comme la somme du produit du spectre de puissance EMG et de la fréquence divisée par la somme totale du spectre de puissance (donnée par l'équation 3.4) [35, 138].

$$FMN = \frac{\sum_{j=1}^L f_j p_j}{\sum_{j=1}^L p_j} \quad (3.4)$$

Où  $f_j$  est la valeur de fréquence du spectre de puissance EMG à la case de fréquence  $j$ ,  $p_j$  est le spectre de puissance EMG à la case de fréquence  $j$ , et  $L$  est la longueur de la case de fréquence. FMN a une définition similaire pour plusieurs caractéristiques, à savoir la fréquence centrale ( $f_c$ ), dans un certain nombre d'études [139, 140]. En outre, FMN est également appelé fréquence moyenne de puissance et fréquence spectrale moyenne dans plusieurs articles.

La fréquence médiane (FMD) est une fréquence à laquelle le spectre de puissance EMG est divisé en deux régions d'amplitude égale [35, 138]. FMD est également défini comme la moitié de la puissance totale (PTT).

$$\sum_{j=1}^{FMD} p_i = \sum_{j=FMD}^L p_i = \frac{1}{2} \sum_{j=1}^L p_i \quad (3.5)$$

Le comportement de FMN et FMD est toujours similaire. Cependant, les performances de FMN dans chacune des applications sont assez différentes par rapport aux performances de FMD, bien que les deux caractéristiques soient deux types de moyennes dans les statistiques. Il convient de noter que FMN est toujours légèrement plus élevé que FMD en raison de la forme asymétrique du spectre de puissance EMG [141]. Cependant, l'estimation du FMD est moins affectée par le bruit aléatoire, en particulier dans le cas du bruit situé dans la bande haute fréquence du spectre de puissance EMG, et plus affectée par la fatigue musculaire [142].

### 3.2.2.3 Puissance moyenne (PMN) et totale (PTT)

La PTT est un agrégat du spectre de puissance EMG. Son équation est exprimée comme suit :

$$PTT = \sum_{j=1}^M P_j \quad (3.6)$$

PMN est une puissance moyenne du spectre de puissance EMG. Il est défini par :

$$PMN = \frac{\sum_{j=1}^M P_j}{M} \quad (3.7)$$

Où,  $P_j$  et  $M$  sont le spectre de puissance EMG à la fréquence  $j$  et la longueur de fréquence respectivement. [48]

La PTT et le PMN sont des caractéristiques du domaine fréquentiel qui extraient les mêmes informations que les caractéristiques du domaine temporel basées sur les informations énergétiques, en raison du fait que la fatigue musculaire entraîne une augmentation de l'amplitude du signal EMG. Ainsi, la PTT et la PMN peuvent également être utilisés comme indicateurs de la fatigue musculaire notamment [48] et précisément comme indicateurs de la sévérité pathologique (ce qui a été démontrées par la suite dans ce chapitre). Malgré cela cette technique reste incapable de fournir des indications concernant l'évolution temporelle.

### 3.2.3 Quantification dans le domaine bispectral

Le bispectrum est la transformée 2D-Fourier de la troisième fonction cumulée définie comme

$$S_2^x(\omega_1, \omega_2) = \sum_{\tau_1=-\infty}^{\infty} = \sum_{\tau_2=-\infty}^{\infty} = \text{cum}_3^x(\tau_1, \tau_2) W \exp[-j\omega_1\tau_1 + \omega_2\tau_2] \quad (3.8)$$

Pour  $|\omega_1| \leq \pi$ ,  $|\omega_2| \leq \pi$ , et  $|\omega_1 + \omega_2| \leq \pi$



Où  $W(\tau_1, \tau_2)$  est la fonction de fenêtre à 2 dimensions qui diminue la variance du bispectrum. Dans cette étude, une fenêtre Hanning a été utilisée,  $\text{cum}_3^x$  est le cumulante d'ordre 3. Le cumulante d'ordre 3 d'un signal discret  $x(k)$ , qui est stationnaire et a une moyenne de 0, est défini comme

$$\begin{aligned} \text{cum}_3^x(\tau_1, \tau_2) = & \text{cum}\{x(k)x(k+\tau_1)x(k+\tau_2)\} = \\ & \langle x(k)x(k+\tau_1)x(k+\tau_2) \rangle - \langle x(k) \rangle \{ \langle x(k)x(k+\tau_1) \rangle + \langle x(k)x(k+\tau_2) \rangle + \langle x(k+\tau_1)x(k+\tau_2) \rangle \} + 2\langle x(k) \rangle^3 \end{aligned} \quad (3.9)$$

Où  $\langle \cdot \rangle$  désigne le processus attendu,  $x(k)$  signal discret

Les cumulants peuvent être exprimés en termes des moments et vice versa. On peut facilement calculer les cumulants comme certaines combinaisons non linéaires de moments.

Les cumulants du deuxième et du troisième ordre sont :

$$\text{Cum}_1^x = m_1^x \quad (3.10)$$

$$\text{Cum}_2^x(\tau) = m_2^x(\tau) - (m_1^x)^2 \quad (3.11)$$

$$\text{Cum}_3^x(\tau_1, \tau_2) = m_3^x(\tau_1, \tau_2) - m_1^x [m_2^x(\tau_1) + m_2^x(\tau_2) + m_2^x(\tau_1 - \tau_2)] + 2(m_1^x)^3 \quad (3.12)$$

L'estimation du bispectrum d'un processus aléatoire stationnaire et ergodique avec l'approche non paramétrique est donnée par :

$$B(f_1, f_2) = \langle X(\omega_1)X(\omega_2)X^*(\omega_1 + \omega_2) \rangle \quad (3.13)$$

où:  $X(f)$  est la transformée de Fourier d'un segment (ou d'une partie fenêtrée)  
\* désigne un conjugué complexe.

$\langle \cdot \rangle$  Désigne le processus attendu.

Le bispectrum est fonction de deux fréquences contrairement au spectre de puissance qui est fonction d'une variable de fréquence. La fréquence  $f$  peut être normalisée par la fréquence de Nyquist (la moitié de la fréquence d'échantillonnage) pour être comprise entre 0 et 1. Le bispectrum peut être normalisé (par des spectres de puissance aux fréquences composantes) de telle sorte qu'il ait une amplitude comprise entre 0 et 1 et indique le degré de couplage de phase entre les composantes de fréquence [50, 51].

### 3.3 Résultats et discussions

La représentation fréquentielle à l'aide de la TFR illustrée par la figure 3.1 montre que les fréquences importantes à conserver dans le signal EMG vont de 0 à 1500 Hz et permet de sélectionner les différentes fréquences excitées dans ce signal. Dans cette étude, nous avons divisé en trois bandes fréquentielles. Le résultat de cette étude est donné par la figure ci-dessous (figure 3.1) où le spectre de fréquence d'un patient sain a une amplitude maximale à

102 Hz dans la bande de fréquence qui varie de [10-150 Hz] contrairement au cas pathologique qui est de 32 Hz. Pour la bande suivante allant de [150-500 Hz], une fréquence de 310 Hz et de 272 Hz apparaît pour une amplitude maximale du cas sain et neuropathique, respectivement, l'amplitude maximale est maintenue une autre fois dans la dernière bande fréquentielle qui s'étend de [150-1500 Hz] à une fréquence de 1140 Hz et 808 Hz pour le cas sain et neuropathique. En résumé, la sclérose latérale amyotrophique présente une amplitude et une durée augmentée qui traduit deux principaux phénomènes : une réinnervation plus ancienne lors de l'influx nerveux et une vitesse de conduction faible (diminution de fréquence et une réduction en nombre des raies spectrales) ceci reflète la sévérité pathologique de la SLA, la TFR peut révéler des dissimilarités plus ou moins importantes car il sert à déterminer les différentes fréquences excitées dans le signal EMG.

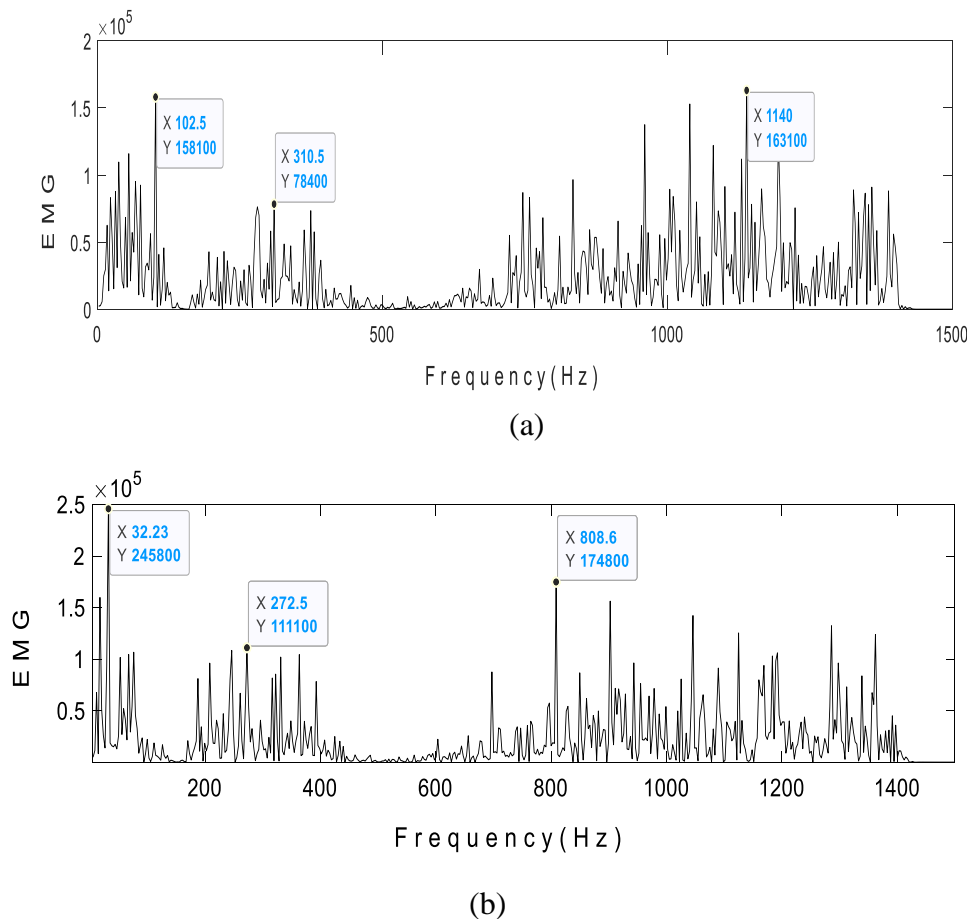





Figure 3.1 : spectre de fréquence du signal EMG ; (a) cas normal, (b) le cas de la SLA.



Les deux figures suivantes (figure 3.2 et figure 3.3) ont illustré la variation de la fréquence médiane et la fréquence moyenne pour chaque patient (a) : sain et l'autre (b) qui souffre de la SLA.




(a)



(b)

Figure 3.2 : L'estimation de la fréquence médiane du signal EMG ; (a) cas sain, (b) le cas pathologique.



(a)

(b)

Figure 3.3 : L'estimation de la fréquence moyenne du signal EMG ; (a) cas sain, (b) le cas pathologique.

L'estimation de la fréquence médiane (donnés par la figure ci-dessus (Figure 3.2)) a été largement utilisé par les kinésologues pour obtenir des informations importantes relatives à la fatigue musculaire. Cette estimation de la fréquence médiane du signal EMG revient à tracer la densité spectrale de puissance (DSP) et annoter la fréquence médiane. La différence des cas normaux et pathologiques nous a permis de suivre la SLA car elle varie avec le type d'enregistrement entre 76 Hz chez les cas normaux et 66Hz pour le cas de la neuropathie.

La fréquence moyenne (FMN) indique des valeurs plus proches de celles de la fréquence médiane. Le cas normal a une valeur qui est proche de 103 Hz, il est très supérieur à celui du cas neuropathique, qui est de 92Hz. La diminution du FMD et du FMN est attribuée à la réduction de la vitesse de conduction des potentiels d'action sur les enveloppes de la fibre musculaire, à l'augmentation de la synchronisation des unités motrices [143] et à une fréquence de décharge descendante plus anecdotique des unités motrices [144]. Cela traduit que plus le signal présente une sévérité accentuée, plus ses valeurs de fréquence sont petites. Cette constatation a également été confirmée par [36].

De cette analyse, nous pouvons conclure que ces deux fréquence FMD et FMN, présentent des indicateurs pertinents de l'évolution de la sévérité pathologique des signaux EMGs par rapport aux cas normaux.

Le signal EMG a été soumis à des traitements mathématiques destinés pour le quantifier de 16 patients sains et pathologiques, l'extraction de ces paramètres temporels et fréquentiels ont été donné par le tableau suivant :

Sujets	VAM	En	PTT	PMN
<b>Signaux de la SLA</b>				
A1	1,2349	$4,62 * 10^5$	$3,16 * 10^6$	24.0992
A2	1,2344	$4,66 * 10^5$	$2,83 * 10^6$	21.6234
A3	1,2325	$4,50 * 10^5$	$2,47 * 10^6$	18.8541
A4	1,2431	$4,64 * 10^5$	$2,84 * 10^6$	21.6594
A5	1,2325	$4,60 * 10^5$	$2,65 * 10^6$	20.2103
A6	1,2314	$4,57 * 10^5$	$2,59 * 10^6$	19.7614
A7	1,233	$4,67 * 10^5$	$2,38 * 10^6$	18.1941
A8	1,2357	$4,87 * 10^5$	$2,72 * 10^6$	20.7887
<b>Signaux normaux</b>				
N1	1,2274	$4,42 * 10^5$	$2,28 * 10^6$	17.4201
N2	1,232	$4,61 * 10^5$	$2,26 * 10^6$	17.2787
N3	1,2334	$4,59 * 10^5$	$2,36 * 10^6$	17.9875
N4	1,2099	$4,16 * 10^5$	$2,20 * 10^6$	16.7803
N5	1,2329	$4,64 * 10^5$	$2,29 * 10^6$	17.4569
N6	1,2333	$4,67 * 10^5$	$2,23 * 10^6$	18.6171
N7	1,2225	$4,33 * 10^5$	$2,42 * 10^6$	18.4372
N8	1,2138	$4,16 * 10^5$	$2,09 * 10^6$	15.9720

Tableau 3.1 : Les paramètres temporels et fréquentiels des signaux EMGs normaux et pathologiques

Un électromyogramme (EMG) est un test clinique couramment utilisé pour évaluer la fonction des muscles et des nerfs qui les contrôlent. Les études des signaux EMGs sont utilisées pour aider au diagnostic et à la gestion de troubles tels que la neuropathie. Les études de conduction nerveuse qui mesurent la qualité et la vitesse à laquelle les nerfs conduisent les impulsions sont souvent réalisées en conjonction avec des études EMGs. Pour bien comprendre

l'évolution de la pathologie en les comparant par des cas normaux : VAM et En (comme étant des paramètres d'analyse temporels), PTT et PMN (comme des paramètres fréquentiels) ont été extraits, ces paramètres présentés par le tableau ci-dessus ont permis de tracer les histogrammes ci-dessous montré par la figure 3.4 et de faire une comparaison appropriée.

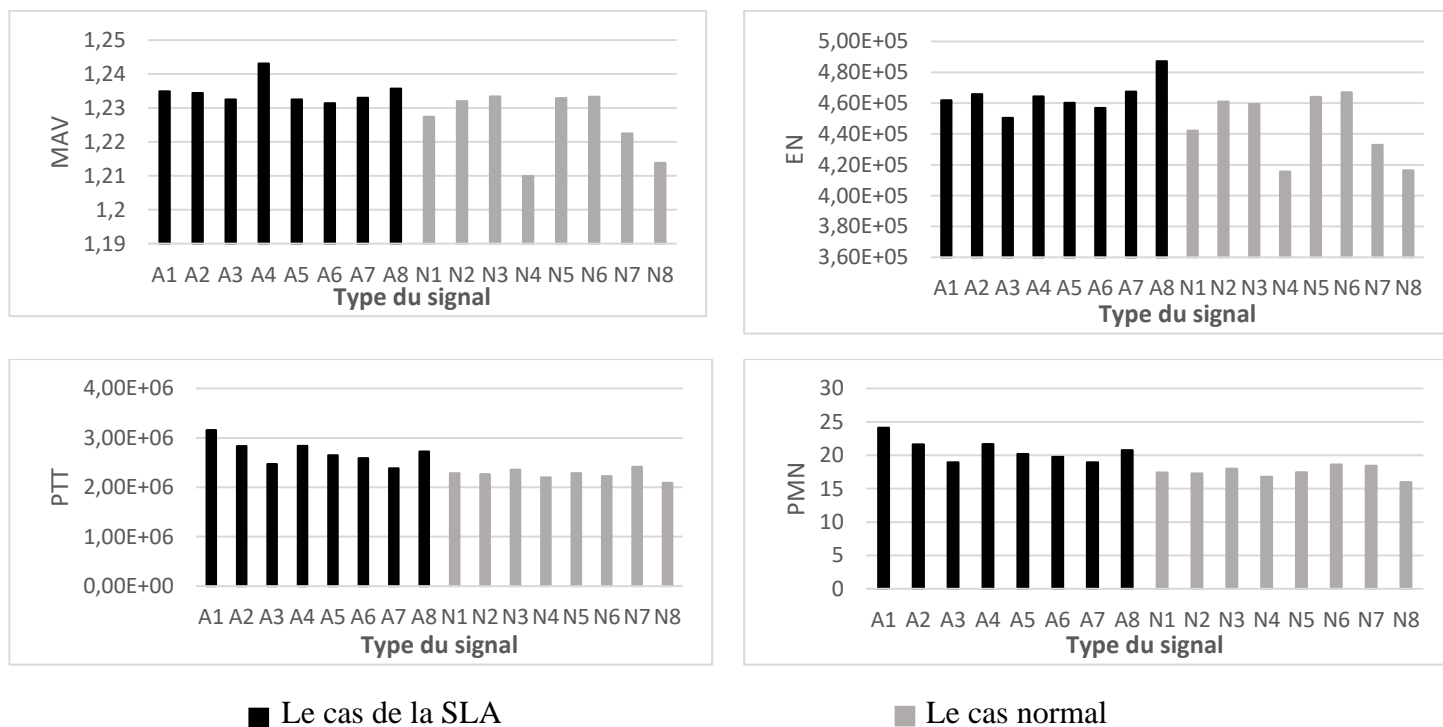


Figure 3.4 : Histogrammes de l'analyse temporelle et fréquentielle des signaux EMGs

L'histogramme de la variation de la VAM illustré par la figure 3.4 est utilisé sous deux aspects importants :

Le premier aspect pour identifier chaque enregistrement par une analyse temporelle :

Le résultat de la variation de la VAM représenté sur la figure 3.4 fait ressortir les différences qui peuvent exister entre ces signaux. La valeur de la VAM chez les cas neuropathiques, est beaucoup plus proche des cas normaux. Ces résultats, si bien confirment que la variation de la VAM sert d'être un paramètre qui suit la sévérité pathologique.

Pour les mêmes cas étudiés, La variations d'énergie représentés par la même figure (figure 3.4) montrent que le premier enregistrement (le cas normal) est le cas qui représente le moins d'énergie par rapport au cas neuropathique. Dans ce contexte, la variation d'énergie, présente un paramètre important pour compléter la différenciation de la sévérité pathologique entre les signaux EMGs : la neuropathie est le cas le plus sévère car elle présente une énergie plus

importante, cette accumulation d'énergie au niveau du muscle traduit la mauvaise consommation et gestion du potentiel nerveux.

Le deuxième aspect pour identifier chaque enregistrement par une analyse fréquentielle. La figure 3.4 représente aussi les histogrammes de la variation de la PTT et PMN en fonction de différents signaux EMGs, la variation de ses valeurs selon différents signaux EMGs ont été qualifiées comme les paramètres les plus significatifs dans l'analyse des types de ces signaux car il montre une proportionnalité relative avec la sévérité de la maladie SLA. Où : la neuropathie a des valeurs qui se rapprochent du cas normal mais elles restent inférieures. Ces résultats confirment ce qui a été trouvé par les paramètres calculés précédemment. Ainsi, la SLA est une maladie grave qui nécessite un suivi particulier et plus rigoureux, difficilement détectable. Ce qui nous a poussé vers une analyse bispectrale.

La figure 3.5 représente le bispectrum des patients : (a, b, c) sains et (d, e, f) qui souffrent de la SLA qui a montré que le niveau de gaussianité de l'EMG a changé d'un cas normal à un cas neuropathique, en général, le signal est devenu moins gaussien à des fréquences très basses et très élevées, mais certains étaient au milieu où l'EMG devenait plus gaussien. Le niveau de non-gaussianité de la variation du signal EMG nous a permis de suivre la sévérité pathologique, la non-linéarité et la concentration de non-gaussianité des cas normaux, sont bien centrées à des fréquences plus basses que les activités neuropathiques. Cela nous a permis de conclure que la neuropathie est la plus sévère en raison du niveau de non-gaussianité du signal EMG qui tend vers les hautes fréquences. Par conséquent, de qualifier le bispectrum comme une méthode d'analyse la plus appropriée qui valorise la sévérité pathologique et une visualisation agréable de la non-gaussianité vers les hautes fréquences a indiqué une sévérité pathologique plus accentuée.

Une comparaison appropriée de la neuropathie par rapport aux cas sains par une analyse bispectrale a indiqué une légère augmentation de la magnitude bispectrale dans les cas neuropathiques qui atteignaient les  $8 \cdot 10^{-8}$ . Dans des conditions saines, la valeur de la magnitude varie de  $6,5 \cdot 10^{-11}$  à  $11 \cdot 10^{-12}$ , ce qui nous a amené à suivre l'évolution de la pathologie par extraction de la magnitude bispectrale et de mettre le doigt sur l'analyse bispectrale à être fiable pour déterminer la gravité d'une pathologie tout en conservant l'intervalle du début et de la fin de sa magnitude bispectrale [145].

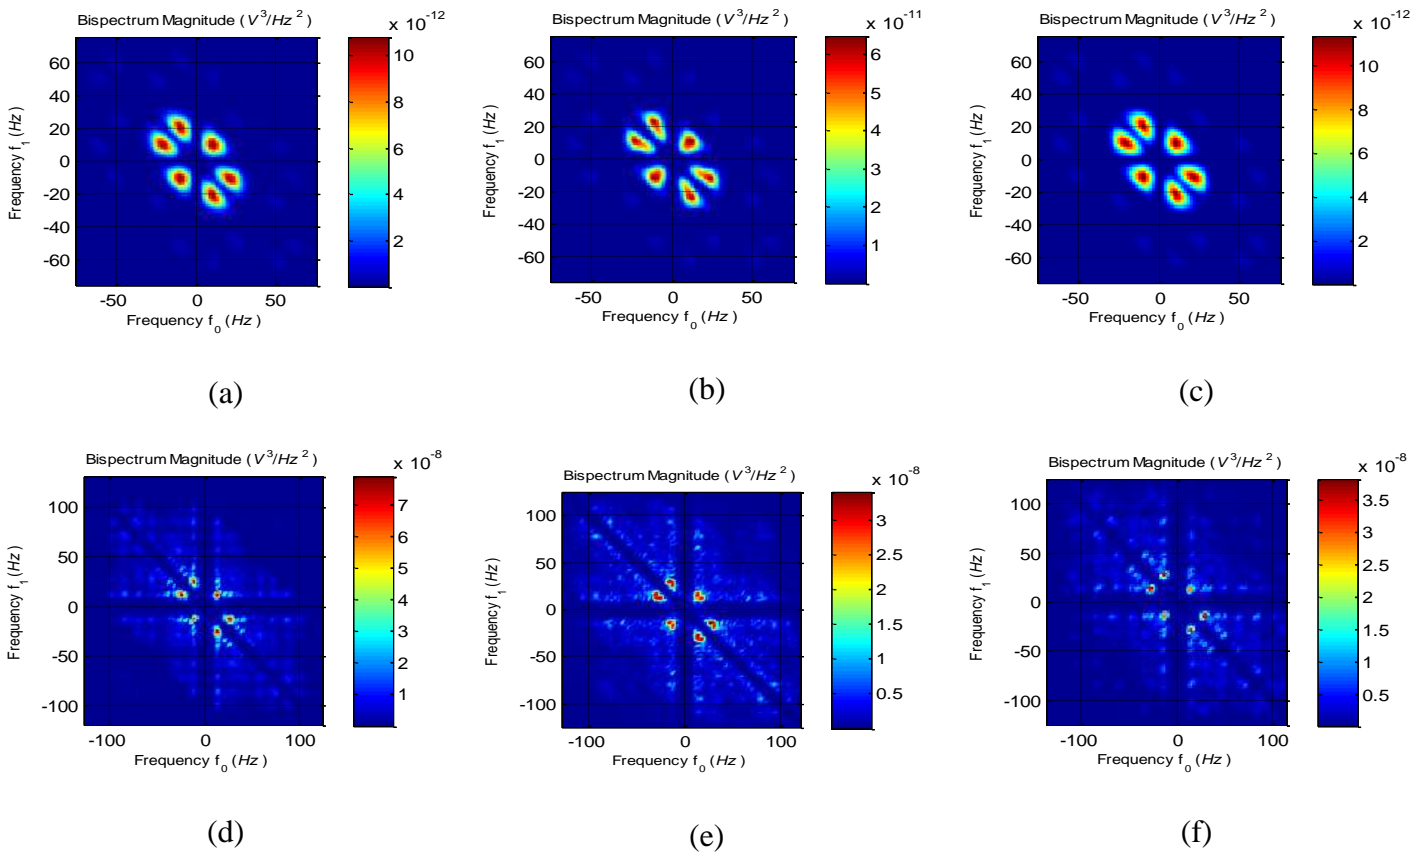


Figure 3.5 : bispectrum d'un : (a, b, c) signal EMG normal et (d, e, f) signal EMG neuropathique.

### 3.4 Conclusion

Dans ce chapitre, une analyse temporelle et fréquentielle du signal EMG a été développée en tenant compte de son état (normal et neuropathique). Tout d'abord, en appliquant la TFR, cette analyse a reflété les fréquences d'excitation dans le muscle et plus le signal a une sévérité pathologique accentuée, son contenu en fréquence a révélé des dissimilarités plus importantes. Cette étude a été renforcée par une analyse statistique du signal EMG ; la quantification est faite par extraction des paramètres pour le suivi de la SLA, ces paramètres temporels et spectraux, tel que la valeur absolue moyenne, l'énergie, la puissance totale et moyenne, la fréquence médiane et la fréquence moyenne ont été qualifiés pour vérifier la présence de la SLA. À la fin de ce chapitre, l'étude a été confirmée par une analyse bispectrale où la sclérose latérale amyotrophique a été bien détectée par une représentation bifréquentielle en la comparant avec des cas sains.



## 4. Classification des signaux EMGs par les méthodes d'analyse temps-fréquence

### 4.1 Introduction

Le signal Electromyogramme (EMG) est l'approche utilisée pour explorer l'activité musculaire et extraire de nombreuses fonctionnalités pour l'aide au diagnostic. Les personnes touchées par les problèmes neuromusculaire devraient savoir qu'il s'agit des problèmes de santé sérieux et qui nécessite des soins particuliers comme par exemple le cas de la sclérose latérale amyotrophique (SLA) car leur comportement temporel et fréquentiel montre clairement leur sévérité (voir chapitre 3). Pour en savoir plus, Ce chapitre traite l'importance de l'analyse temps-fréquence en premier lieu par application de la transformé de Fourier à court terme (TFCT) et la transformé en ondelette continue (TOC) en vue de vérifier la présence de la SLA dans un signal EMG mais une visualisation métrique reste insuffisante pour faire une décision. Donc, des paramètres temps-fréquence fiable ont été extraits en se basant sur les deux largeurs de la fenêtre Hanning pour la TFCT et deux ordres de Daubechies dans le cas de la TOC. A ce stade-là, des méthodes d'apprentissage font le bilan de cette étude pour classier les cas touchés par la sclérose latérale amyotrophique de celles qui sont normaux en qualifiant le meilleur classifieur qui donne une meilleure précision.

### 4.2 Méthodologie

La figure 4.1 illustre l'organigramme de l'architecture de classification proposé [146]. Tout d'abord, le spectrogramme est utilisé pour transformer le signal en une représentation temps-fréquence (RTF). Il est à noter que dans ce travail, deux tailles de fenêtre Hanning de 256 et 512 ms spécifiées pour chaque classifieur avec un chevauchement de 50% sont utilisées. Parallèlement, les coefficients d'ondelette continue (COC) sont obtenus à partir de la transformé d'ondelette continue (TOC) en appliquant deux ordres de daubechies 4 et 7 au niveau 6. Ensuite, quatre caractéristiques dont l'entropie de Shannon (ES), l'entropie de Renyi (ER), la fréquence moyenne (FMN) et la fréquence médiane (FMD) sont extraites du spectrogramme et quatre autres caractéristiques sont extraites du COC comme l'entropie d'ondelette (En\_O), la longueur d'onde (LO), la longueur fractale maximale (LFM), et la Longueur d'onde améliorée (LOA). Après cela, trois classifieurs largement utilisés sont implémentés en vue d'évaluer les performances du spectrogramme et les caractéristiques de la TOC dans la classification des troubles de la SLA (voir Figure 4.1).

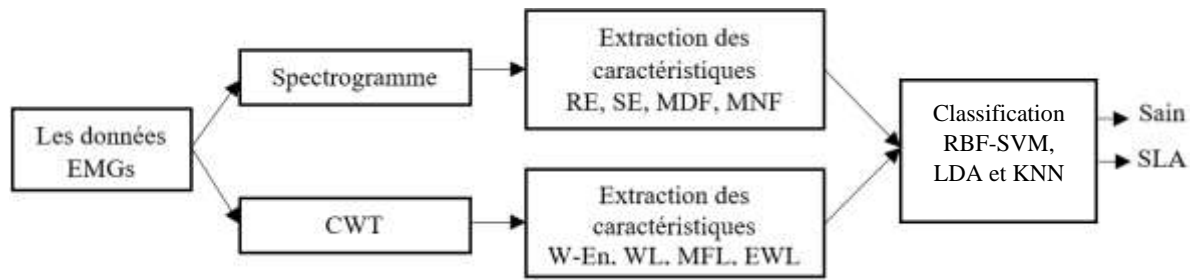


Figure 4.1 : Organigramme de la classification des troubles neuromusculaires [146].

### 4.3 Mesure de différents paramètres à partir de la représentation temps-fréquence (TFR)

#### 4.3.1 Par application de la TFCT

##### 4.3.1.1 Le spectrogramme

Le spectrogramme est le principe fondamental de la distribution temps-fréquence (DTF) dans l'analyse des signaux EMGs qui sont ensuite transférés au RTF pour fournir plus d'informations sur le comportement musculaire de différentes fibres musculaires [147].

Le spectrogramme est la grandeur carrée de la transformée de Fourier à court terme (TFCT), qui représente la distribution d'énergie du signal sur des plans temps-fréquence [148, 149] qui montre la nature non stationnaire des signaux EMGs dans l'analyse temps-fréquence [150], il est calculé comme suit :

$$S(t, f) = \left| \int_{-\infty}^{\infty} x(\tau) w(\tau - t) e^{2\pi f \tau} d\tau \right|^2 \quad (4.1)$$

Où  $x(\tau)$  est le signal EMG et  $w(\tau - t)$  est la fonction de fenêtre de Hanning.

La représentation temps-fréquence par application du spectrogramme a été obtenue sous un environnement MATLAB. Elle est basée sur le choix de la largeur de la fenêtre Hanning, ce choix est dû à la sensibilité du signal EMG au bruit, donc la fenêtre Hanning est appropriée à utiliser en raison de son utilité pour la mesure du bruit avec une meilleure résolution en fréquence que certaines autres fenêtres [55]

Des études antérieures ont indiqué qu'une taille de fenêtre plus basse affectait la précision des informations liées à la fréquence. Cependant, une plus grande taille de fenêtre entraîne une précision moindre dans les informations liées au temps [151].

### 4.3.1.2 Extraction des paramètres

À partir d'une représentation temps-fréquence par application de la TFCT, plusieurs paramètres peuvent être déterminés, susceptible de détecter toutes variations du signal EMG analysé par rapport au type de la pathologie.

**L'entropie de Renyi (ER)** : ce paramètre extrait de la distribution temps-fréquence, elle mesure la complexité des signaux. Un degré plus élevé de signaux multicomposants non stationnaires entraîne une ER plus élevée. Par exemple, un signal à plusieurs composants a donné une ER plus grand que le signal à composante unique.

L'entropie de Renyi dans le domaine temps-fréquence est donné par l'équation suivante [152] :

$$ER = \frac{1}{1-\alpha} \log_2 \sum_{n=1}^M \sum_{k=1}^L \left( \frac{S(n,k)}{\sum_n \sum_k S(n,k)} \right)^\alpha \quad (4.2)$$

Où  $\alpha$  est l'ordre de l'entropie de Renyi, S est le spectrogramme, L et N sont la longueur du points temps et fréquence, respectivement. Il convient de noter que  $\alpha$  doit être un entier impair et qu'il doit être supérieur à 2. Dans ce travail,  $\alpha$  avec une valeur de 3 est appliqué [153].

**L'entropie de Shannon (ES)** : qui est l'élément fondamental de la RTF, Ce paramètres souligne la tension moyenne et se concentre sur les faibles intensités d'énergie dans la distribution temps-fréquence [154]. ES est exprimé par la formule suivante :

$$ES = \sum_{n=1}^L \sum_{k=1}^M \frac{S(n,k)}{\sum_L \sum_M S(n,k)} \log_2 \left( \frac{S(n,k)}{\sum_L \sum_M S(n,k)} \right) \quad (4.3)$$

**La fréquence médiane (FMD)** : qui est définie comme la fréquence à laquelle la puissance totale est divisée en deux parties égales [155, 156]. Dans ce travail, la FMD est utilisée comme caractéristique temps-fréquence, définie comme :

$$\sum_{k=1}^{FMD} p(n, k) = \sum_{FMD}^M p(n, k) = \frac{1}{2} \sum_{k=1}^M p(n, k) \quad (4.4)$$

Où P est le spectre de puissance.

**La fréquence moyenne (FMN)** : qui est calculée comme la somme du produit de la puissance et sa fréquence correspondante divisée par la somme totale des parties de puissance [25, 156]. Dans ce travail, la FMN est utilisée comme caractéristique, elle est exprimée comme :

$$FMN = \frac{\sum_{k=1}^M f_k p(n, k)}{\sum_{k=1}^M p(n, k)} \quad (4.5)$$

La valeur de la fréquence  $f_k$  du spectre de puissance à la fréquence bin k.

### 4.3.2 Par application de la transformé d'ondelette (T.O.C)

#### 4.3.2.1 La TOC

La TOC représente le signal dans l'espace de l'échelle de temps, il a un large éventail d'applications dans l'analyse des signaux EMGs et la détection de la fatigue musculaire [157], la TOC est définie comme :

$$\text{T.O.C (a,}\tau\text{)} = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} s(t) W^*\left(\frac{t-\tau}{a}\right) dt, \quad a \neq 0 \quad (4.6)$$

Où  $w(t)$  est une fonction prototype appelée ondelette mère,  $\tau$  est l'indice de translation et  $a$  est le paramètre d'échelle lié au contenu fréquentiel.

Dans ce travail, des daubechies d'ondelettes mères de 4<sup>ème</sup> ordre avec 6 niveaux de décompositions (db4) a été choisi pour implémenter la transformée en ondelettes, TOC décompose un signal en plusieurs composantes multirésolutions (coefficients).

#### 4.4.2.2 Extraction des paramètres

Le plan temps-fréquence par application de la TOC nous a permis de suivre l'évolution de ces deux indices en temps réel selon le cas étudié et d'extraire plusieurs paramètres susceptibles de détecter toutes variation du signal EMG. Ces paramètres sont :

**L'entropie d'ondelettes (En-O) :**

$$\text{En-O} = \sum_{n=1}^N p_j(i)^2 \log p_j(i)^2 ; \quad p_j = \frac{\sum_{n=1}^N C_j(i)^2}{\sum_{n=1}^N S(i)^2} \quad (4.7)$$

Où  $s$  est le signal EMG,  $j$  indique le nombre de niveaux de décomposition,  $C$  sont les coefficients d'ondelettes et  $N$  est la longueur du coefficient.

**La longueur d'onde (LO) :** qui est une autre caractéristique populaire du signal EMG, et elle peut être calculée en simplifiant la longueur cumulée de la somme des formes d'onde [70, 158].

Le LO peut être défini comme :

$$\text{LO} = \sum_{n=1}^{N-1} |C_{n+1} - C_n| \quad (4.8)$$

**La longueur fractale maximale (LFM) :**

$$\text{LFM} = \log_{10} \left( \sqrt{\sum_{n=1}^{N-1} (C_{n+1} - C_n)^2} \right) \quad (4.9)$$

### La Longueur d'onde améliorée (LOA) :

$$LOA = \sum_{n=2}^N |(C_n - C_{n-1})^p| \quad (4.10)$$

$\left\{ \begin{array}{l} 0.75, \text{ if } n \geq 0.2N \ \& \ n \leq 0.8N \\ 0.50, \text{ autrement} \end{array} \right.$

Le paramètre  $p$  est utilisé pour identifier l'influence de l'échantillon dans le signal. En LOA, un plus grand nombre de  $p$  est utilisé pour 20% à 80% des régions. En effet, en renforçant le contenu de l'information dans la région centrale, des informations plus précieuses peuvent être obtenues. De cette façon, la qualité des fonctionnalités peut être améliorée. De plus, on voit que LOA est l'extension LO avec une simple modification, et donc pas beaucoup de temps de calcul supplémentaire n'est requis dans l'évaluation.

#### 4.4 Classification des signaux EMGs

La classification est un processus qui consiste à extraire de manière automatique des connaissances à partir d'un ensemble de données lors d'une phase d'apprentissage, puis à utiliser ces connaissances afin de regrouper les données (les mêmes que celles utilisées pour l'apprentissage ou d'autres) en classes homogènes dans le sens de propriétés communes lors d'une phase de prédiction. Le but de la classification de données est d'organiser et classer des données dans des classes distinctes constituant un modèle. Ce modèle peut être représenté sous plusieurs formes selon la méthode d'apprentissage utilisée (méthodes statistiques, neuronales,). La phase d'apprentissage peut être réalisée de deux manières distinctes : supervisée ou non supervisée ; L'apprentissage supervisé consiste à utiliser un ensemble d'exemples d'apprentissage (objets classés préalablement) afin de produire les descriptions des classes servant ensuite à la prédiction. L'apprentissage non supervisé quant à lui, n'utilise pas d'exemples et produit directement une classification à partir de données. [159]

Avant d'entamer les méthodes de classification utilisées pour l'EMG, il est primordial de savoir l'apprentissage automatique. L'organigramme suivant présente cette technique qui adopte au choix du bon algorithme de classification selon les données qu'on a eu.

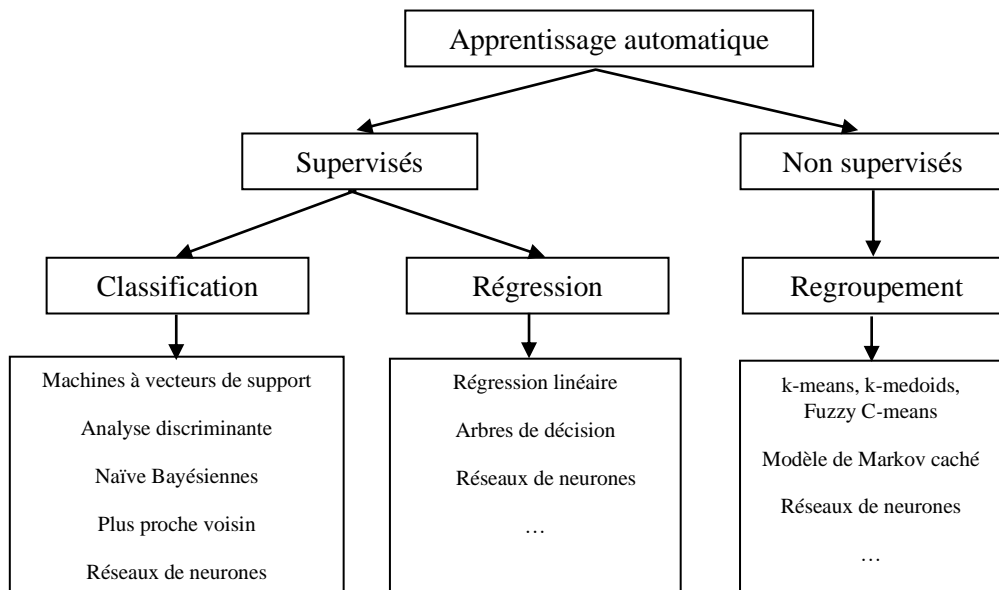


Figure 4.2 : L'organigramme des méthodes d'apprentissage automatique

#### 4.4.1 L'apprentissage automatique

Cette technique consiste à programmer la machine pour qu'elle apprenne à effectuer des tâches difficiles à travers des moyens algorithmiques. L'idée de base est de construire un modèle à partir d'un jeu de données, duquel les performances peuvent être évaluées en utilisant des méthodes de validation (e.g., la précision pour la classification supervisée et l'inertie intra\inter clusters pour le clustering).

L'apprentissage automatique se décline en plusieurs variantes en fonction de la nature des données dont on dispose (supervisé, non supervisé, etc.). On peut donc placer la classification supervisée dans le domaine de l'apprentissage supervisé et le clustering dans le domaine de l'apprentissage non supervisé [160].

##### 4.4.1.1 La classification non supervisé

On ne prend pas en compte les classes connues a priori des contractions. Dans ce cas, la méthode de classification consiste à faire un « Clustering » des nuages des points dans l'espace. Ensuite une interprétation est faite pour affecter chaque cluster à une classe physiologique. Ces méthodes sont avantageuses quand nous n'avons pas un ensemble d'apprentissage assez grand pour faire un apprentissage correct pour certaines méthodes de classification supervisées.

Le clustering consiste à trouver la distribution sous-jacente des exemples dans leur espace de description. Autrement dit, à partir d'une base de données non étiquetées, cette approche vise à former des groupes (ou clusters) homogènes en fonction d'une certaine notion de similarité et les observations qui sont considérées similaires sont associées au même groupe alors celles qui sont considérées comme différentes sont associées à des groupes différents. Plus

formellement, dans les problèmes de clustering, les données  $D = \{X_i\}_{i=1}^N$  sont composées de  $N$  observations sans étiquette (ou classe), chacune décrite par plusieurs variables. On notera  $X_i = \{X_i^1, \dots, X_i^d\}$ , l'ensemble de  $d$  variables décrivant l'observation  $i$  ( $i \in [1, N]$ ). L'objectif ici est donc de partitionner l'espace d'entrée en  $K$  clusters. Chaque cluster  $S_k$  ( $k \in \{1, \dots, K\}$ ) doit être, d'une part, différent des autres clusters et d'autre part, doit contenir des observations similaires. D'une manière générale, le processus du clustering se divise en trois étapes principales : La préparation des données, le choix de l'algorithme de clustering et la validation et l'interprétation des résultats [161].

#### 4.4.1.2 La classification supervisée

La classification supervisée, dite aussi discrimination est la tâche qui consiste à discriminer des données, de façon supervisée (c'est à dire. Avec l'aide préalable d'un expert), un ensemble d'objets ou plus largement de données, de telle manière que les objets d'un même groupe (appelé classes) sont plus proches (au sens d'un critère de dissimilarité choisi) les uns aux autres que celles des autres groupes. Généralement, on passe par une première étape dite d'apprentissage où il s'agit d'apprendre une règle de classification à partir de données annotées (étiquetées) par l'expert et donc pour lesquelles les classes sont connues, pour prédire les classes de nouvelles données, pour lesquelles (on suppose que) les données sont inconnues [152]. La classification supervisée cherche à prédire la classe des nouvelles instances en se basant sur des informations connues a priori. Elle est un processus à deux étapes : une étape d'apprentissage et une étape de classification.

Dans l'étape d'apprentissage, un modèle est construit en analysant un jeu de données dit "d'apprentissage" dans lequel la classe de chaque instance est supposée prédéfinie. Soit  $D = \{(X_i, Y_i), i \in \{1, \dots, N\}\}$  un jeu de données d'apprentissage composé de  $N$  instances. Chaque instance ( $X_i = \{X_i^1, \dots, X_i^d\}, Y_i \in \{1, \dots, J\}$ ) est représentée par un vecteur de variables de dimension  $d$  et d'une variable cible  $Y_i$  indiquant son appartenance à une des  $J$  classes. Soit  $\chi$  et  $\kappa$  respectivement l'espaces des valeurs d'entrée et de sortie. D'une manière plus formelle, l'étape d'apprentissage a pour but d'apprendre, à partir des données d'apprentissage, une fonction

$f : \chi \rightarrow \kappa$  de telle sorte que  $f(X)$  est un "bon" prédicteur de la valeur correspondante à  $Y$ . Dans l'étape de classification, le modèle construit dans la première étape est utilisé pour classer les nouvelles instances. Le modèle construit par un algorithme d'apprentissage doit en général remplir un certain nombre de critères. Citons à titre d'exemple :

— Le taux d'erreur doit être le plus bas possible. Ce point peut être mesuré en utilisant plusieurs critères d'évaluation. A titre d'exemple, la précision (Pr), l'aire sous la courbe de ROC (ASC),

(ROC de l'anglais receiver operating characteristic « caractéristique de fonctionnement du récepteur ») l'indice ARI (Adjusted Rand Index), ..., etc.

— Il doit être aussi peu sensible que possible aux fluctuations aléatoires des données d'apprentissage.

— les décisions de classification doivent autant que possible être explicites et compréhensibles [161].

Dans cette thèse, nous nous intéressons exclusivement à la classification supervisée où :

#### **4.4.1.2.1 Les données**

Les données traitées en classification peuvent être des images, signaux, textes, autres types de mesures, etc. Dans le cadre de ce projet les données seront des signaux. On pourra donc considérer que les données sont un vecteur d'une dimension (signal) de la base de données EMGLAB.

#### **4.4.1.2.2 Une classe**

En gros, une classe (ou groupe) est un ensemble de données formée par des données homogènes (qui “se ressemblent” au sens d'un critère de similarité (distance, densité de probabilité, etc.) Par exemple, une classe peut être un évènement particulier dans un signal. [162]. Dans cette thèse, nous nous intéressons aux cas normaux et amyotrophiques latérales sclérosées.

#### **4.4.1.2.3 Les méthodes de la classification supervisée implémentées**

Dans la littérature, les modèles de la classification supervisée se catégorisent en deux grandes familles : les modèles transparents et les modèles boîtes noires. Les modèles transparents désignent tous les algorithmes d'apprentissage qui fournissent des résultats facilement interprétables par l'utilisateur. Contrairement aux modèles boîtes noires (ou opaque) qui désignent les algorithmes d'apprentissage fournissant des résultats non difficilement compréhensibles par l'utilisateur.

##### **4.4.1.2.3.1 Les modèles transparents**

Dans cette section, nous présentons les facteurs principaux permettant de générer des résultats compréhensibles par l'utilisateur.



#### 4.4.1.2.3.1.1 Le K plus proche voisin


Toujours dans le but d'atteindre un degré maximal de précision et d'efficacité, nous nous intéressons à l'algorithme des K-voisins les plus proches nommé KNN, Introduit par Fix et Hodges en 1957 [163] est devenu l'un des algorithmes les plus populaires dans la catégorisation de textes. Il est robuste et placé parmi les meilleurs algorithmes. Le chercheur Sebastiani le recommandait, vu qu'il est simple et comparable à la meilleure approche SVM. En plus de ses bonnes performances, il est très facile à comprendre et à mettre en œuvre [164].

Le KNN [161] est un classifieur qui ne nécessite pas d'apprendre une fonction précise d'apprentissage pour qu'il prédise la classe des nouvelles instances. Dans le cas des jeux de données de petites dimensions, ce modèle a la capacité de fournir à l'utilisateur un certain type d'explication concernant la classification de chaque nouvelle instance. Ces explications sont obtenues à l'aide d'une analyse simple des K plus proches voisins utilisés pour classer une instance. Il est à signaler que dans le cas des jeux de données de grandes dimensions, l'algorithme des K-plus proches voisins devient un modèle boîte noire.

La règle KNN classifie X en lui attribuant le label le plus fréquemment représenté parmi les K plus proche voisin ce qui signifie qu'une décision est prise examinant les étiquettes sur le K plus proches voisins et de prendre une classification de KNN [165].

L'exemple suivant présente la règle de la méthode KNN pour  $k=1$  et  $k=3$  :

Exemple 1 :



Exemple 2 :




Figure 4.2 : exemple de méthode KNN des deux classes pour  $k=1$  (exemple 1) et  $k=3$  (exemple 2) [166]

#### a. Quelques règles sur le choix de k

La valeur de  $k$  est un des paramètres à déterminer lors de l'utilisation de ce type de méthode. La valeur que l'on choisit pour  $k$  va être plus critique, plus déterminante en rapport avec la performance du classifieur. On peut se permettre de considérer un plus grand nombre de voisins, sachant que plus ils diffèrent du document à classer, moins ils ont d'impact sur la

prise de décision. Cependant, il demeure nécessaire de limiter le nombre de voisins pour s'en tenir à un temps de calcul raisonnable.

L'emploi de k voisins, au lieu d'un seul, assure une plus grande robustesse à la prédiction. Classiquement, dans le cas où la variabilité à prédire comporte deux étiquettes, ce paramètre k doit être fixé afin d'avoir une majorité plus facilement décidable. [167]




Figure 4.3 : Le choix de 'k' influence la décision : pour k=5, la décision est de classer l'objet 'noir' dans la classe 'rond'. Pour k=9, la décision est de le classer en tant que 'croix'. [167]

Dans ce projet de thèse, le choix de la valeur k est crucial pour réduire les erreurs ainsi que pour améliorer les performances ; k est réglé à 10 [29].

#### b. Mesure de la distance

Parmi les fonctions distance types, nous nous intéressons dans ce travail à la distance euclidienne qui est définie comme suit : [168]

$$\sqrt{\sum_{i=1}^k (X_i - Y_i)^2} \quad (4.11)$$

#### c. L'algorithme KNN

L'algorithme KNN figure parmi les plus simples algorithmes d'apprentissage artificiel.

Dans un contexte de classification d'une nouvelle observation x, l'idée fondatrice simple est de faire voter les plus proches voisins de cette observation. La classe de x est déterminée en fonction de la classe majoritaire parmi les k plus proches voisins de l'observation x.

La méthode KNN est donc une méthode à base de voisinage, non-paramétrique. Ceci signifiant que l'algorithme permet de faire une classification sans faire d'hypothèse sur la fonction  $y=f(x_1, x_2, \dots, x_p)$  qui relie la variable dépendante aux variables indépendantes. [167]

#### 4.4.1.2.3.1.2 L'Analyse Discriminante Linéaire LDA

Introduite en 1936 par Fisher, LDA est probablement la méthode générative la plus ancienne et la plus populaire [169]. LDA doit également son nom au fait qu'elle réalise des séparations linéaires entre les classes, il s'agit d'un classifieur linéaire dont les coefficients définissent un hyperplan, permettant de discriminer les signaux EMGs appartenant à deux classes. La figure suivante représente, par des croix et des cercles, la position de plusieurs vecteurs de valeurs

caractéristiques par rapport à l'hyperplan. La position de ces vecteurs définit la classe estimée par le classifieur LDA.

La position et la distance du vecteur  $x \in \mathbb{R}^d$  (avec  $d$  la dimension du vecteur caractéristique) par rapport à l'hyperplan sont calculées à partir de la fonction linéaire :

$$f(x) = \omega_0 + \omega^T x \quad (4.12)$$

Où  $\omega_0 \in \mathbb{R}^1$  et  $\omega \in \mathbb{R}^d$  représentent les coefficients du classifieur. Le calcul du classifieur LDA consiste à trouver les coefficients de l'hyperplan dont la projection maximise la distance entre les moyennes de chaque classe, tout en minimisant la variance inter-classe. Ces coefficients sont calculés par la relation :

$$\omega = \Sigma^{-1}(\mu_+ - \mu_-) \quad (4.13)$$

$$\omega_0 = -\omega^T (\mu_+ - \mu_-) / 2 \quad (4.14)$$

Où  $\mu_+$  et  $\mu_- \in \mathbb{R}^d$  représentent la moyenne des vecteurs de valeurs caractéristiques pour les deux classes. Correspond à la matrice de covariance supposée identique pour les deux classes. En effet, on considère que les données des vecteurs suivent une distribution normale  $\mathcal{N}(\mu_+, \Sigma)$  et  $\mathcal{N}(\mu_-, \Sigma)$  respectivement pour la classe positive et négative.

La polarité de  $f(x)$  définit la position du vecteur  $x$  de part et d'autre de l'hyperplan. En revanche, la valeur absolue de  $f(x)$  correspond à la distance du vecteur par rapport à l'hyperplan. Cette distance peut être interprétée comme un indice de confiance, de telle sorte que plus sa valeur est importante plus le classifieur est confiant sur la classe estimée [170]

Dans le cas d'un problème multi-classes, une méthode souvent utilisée consiste à calculer plusieurs classifieurs LDA, un pour chaque classe en suivant la stratégie du 'un contre tous'. La classe du vecteur peut ensuite être définie en utilisant un simple système de vote à partir de l'indice de confiance de chaque classifieur.

Le classifieur LDA présente l'avantage d'être simple à utiliser et d'obtenir de bonnes performances de classification. De plus, il nécessite peu de temps de calcul, par conséquent il est bien adapté pour une analyse en temps réel des signaux EMGs




Figure 4.4 : Frontières de décision de l'Analyse Discriminante Linéaire (LDA) sur un jeu de données en dimension 2 [170].

#### 4.4.1.2.3.2 Interprétation des modèles boîtes noires

Dans certains cas d'étude, l'interprétation des résultats d'un classifieur reste une question secondaire. La performance prédictive du modèle est dans cette situation le point clé pour la résolution des problématiques. Les algorithmes utilisés dans ce cadre privilégient plus le critère de performance prédictive que celui de l'interprétation. Ces modèles sont connus sous le nom des modèles boîtes noires. Parmi ces méthodes, on pourra citer notamment les machines à vecteurs de support (SVM).

Les résultats fournis par les modèles boîtes noires sont incompréhensibles et ne conduisent donc pas à des interprétations informatives. Seule une étude des erreurs de prévisions permet de se faire une idée de la qualité du modèle en question. À titre d'exemple :

##### 4.4.1.2.3.2.1 Le modèle SVM

Ce modèle a pour objectif de trouver l'hyperplan optimal qui sépare au mieux les données dans l'espace d'entrée. Cependant, les seules informations fournies par ce dernier sont en général soit les vecteurs de support sans aucune autre information, soit les coefficients de l'hyperplan de séparation et éventuellement le taux de bonnes classifications. L'utilisateur trouve donc une difficulté d'expliquer ce qui fait qu'un individu est dans une classe plutôt que dans une autre.

Les machines à vecteurs de support ou séparateurs à vaste marge (en anglais support vector machine, SVM) : un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de discrimination, Les SVM sont une généralisation des classifieurs linéaires. Ils effectuent la classification en trouvant l'hyperplan qui maximise la marge entre deux classes.




Figure 4.5 : Surfaces de décision existant pour séparer deux classes

Les variables d'entrée sont des vecteurs :

$$p = (x_1, x_2, \dots, x_n) \quad (4.15)$$

Les données sont représentées comme :

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (4.16)$$

Où  $n$  : nombre des exemples,  $x_i$ : ième point et  $y_i$ : la classe correspondante,  $y_i = \{+1, -1\}$

La méthode SVM est basée sur la construction d'un hyperplan optimal séparant des données appartenant à deux classes différentes dans deux cas différents : Le cas des données linéairement séparables (marge dure) et le cas des données non -linéairement séparables (marge souple).

#### a. SVMs à marge dure

SVMs trouvent les deux points les plus proches des deux classes. Puis, il décide que le meilleur ligne de séparation est la ligne qui bissecte et est perpendiculaire à la ligne de connexion, cette ligne est définie en termes d'une interception  $b$  et un vecteur normal  $\vec{\omega}$  perpendiculaire à l'hyperplan et toutes les point  $\vec{x}$  sur l'hyperplan satisfont la règle de décision donnée par :

$$\vec{\omega} \cdot \vec{x} + b = 0 \quad (4.17)$$

Minimiser  $\frac{\|\vec{\omega}\|^2}{2}$  sous les contraintes  $y_i(\vec{\omega} \cdot \vec{x}_i + b) \geq 1$  par la méthode classique des multiplicateurs de Lagrange. Ça nous permet de définir et ensuite de minimiser Lagrange comme suivant :

$$L = \frac{\|\vec{\omega}\|^2}{2} - \sum \alpha_i [y_i(\vec{\omega} \cdot \vec{x}_i + b) - 1] \quad (4.18)$$

Avec  $\alpha_i$  : Le multiplicateurs de Lagrange.

L'hyperplan optimal est celui qui assure une marge maximale, c'est-à-dire qui rend minimale la quantité  $\|\vec{\omega}\|$ . En effet, il existe plusieurs hyperplans linéaires séparateurs, mais il y en a un seul qui maximise la marge. Cette marge est la plus petite distance entre l'hyperplan séparateur et le point positif (respectivement négatif) le plus proche [171]

SVM réduit le problème multi classe à une composition de plusieurs hyperplans bi-classe permettant de tracer les frontières de décision entre les différentes classes. Il décompose l'ensemble d'exemples en plusieurs sous-ensembles représentant chacun un problème de classification binaire. A chaque fois un hyperplan de séparation est déterminé par la méthode SVM binaire. [172]. La figure suivante présente un exemple de séparation entre deux classes par les SVMs.




Figure 4.6 : Exemple de séparation entre deux classes par les SVMs.

### b. SVMs à marge souple

La notion de marge maximale ne permet de résoudre que des problèmes de discrimination linéairement séparables. Donc une transformation d'un problème de séparation non linéaire dans l'espace de représentation en un problème de séparation linéaire dans un espace de re-description de plus grande dimension. Cette transformation non linéaire est réalisée via une fonction noyau. En pratique, quelques familles de fonctions noyau paramétrables sont connues et il revient à l'utilisateur de SVM d'effectuer des tests pour déterminer celle qui convient le mieux pour son application. On peut citer les exemples de noyaux suivants : polynomiale, gaussien, sigmoïde et laplacien [173].

Dans le cas où les données sont non-linéairement séparables (figure 4.7), l'hyperplan optimal est celui qui satisfait les conditions suivantes :

- La distance entre les vecteurs bien classés et l'hyperplan optimal doit être maximale.
- la distance entre les vecteurs mal classés et l'hyperplan optimal doit être minimale.

L'idée de la SVM dans ce cas-là est de reconsidérer le problème dans un autre espace de dimension infinie par transformation non-linéaire  $\phi$ .




Figure 4.7 : Hyperplans séparateur dans le cas de données non-linéairement séparables [173].

#### b.1. Utilisation des Noyaux

La détermination d'une telle fonction non linéaire est très difficile voire impossible. Pour cela les données sont amenées dans un espace  $\Phi$  où cette fonction devient linéaire, Plus la dimension de l'espace de description est grande, plus la probabilité de pouvoir trouver un

hyperplan séparateur entre les classes est élevée. En transformant l'espace d'entrée en un espace de re-description de très grande dimension, cette astuce permet de garder les mêmes modèles de problèmes d'optimisation, utilisant les SVMs basées essentiellement sur le principe de séparation linéaire [174].

Notons  $\Phi$ , une transformation non linéaire de l'espace d'entrée  $X$  en un espace de re-description  $\Phi(X)$  :

$$X=(x_1, \dots, x_d)^T \text{ à } \Phi(X)=(\Phi(x_1), \dots, \Phi(x_d), \dots)^T \quad (4.19)$$

Généralement, le vecteur image  $\Phi(x)$  est de dimension supérieure à la dimension de l'espace d'origine. Les données sont projetées via la fonction  $\Phi$  telle que :

$$\Phi(x_i) \cdot \Phi(x_j) = k(x_i, x_j) \quad (4.20)$$

Où  $k$  est appelée fonction noyau ou kernel. C'est-à-dire, le produit scalaire dans l'espace de re-description va être représentable comme un noyau de l'espace d'entrée. Le classifieur est donc construit sans utiliser explicitement la fonction  $\Phi$  [175].

Parmi les noyaux couramment utilisés, on s'intéresse dans cette thèse à la fonction de base radiale (RBF) car elle peut fournir des résultats plus optimaux du classifieur SVM, l'entrée a utilisé la combinaison du paramètre de marge SVM et du paramètre de noyau, et la sortie est la précision du classifieur SVM avec la méthode de validation croisée de  $k$  fois.[176]

Dans cette thèse, nous avons basé sur l'étude de la méthode de classification SVM basé sur la fonction de base radiale (RBF) qui est donnée par la formule suivante :

$$K(x, x') = \exp\left(-\frac{\|x-x'\|^2}{2\sigma^2}\right) \quad (4.21)$$

Où  $\|x - x'\|$  est la distance euclidienne des valeurs de données dans deux espaces de caractéristiques différents et sigma ( $\sigma$ ) est un paramètre libre sur le noyau RBF qui détermine le poids du noyau. Dans SVM, le paramètre  $\sigma$  doit être ajusté pour fournir un résultat de classification plus précis. La valeur par défaut de  $\sigma$  est 1.

#### 4.4.1.2.4 Évaluation des performances

Afin d'évaluer les performances de la classification, il existe différentes mesures statistiques qui peuvent être utilisées : telles que la précision globale de la classification (Pr), qui est la proportion du nombre de prédictions correctes par rapport au nombre total de prédictions, exprimée comme suit :


$$Pr = \frac{\text{Nombre de prédictions correctes}}{\text{nombre total de prédictions}} * 100 \quad (4.22)$$

#### 4.5 Résultats et discussions


Pour mieux comprendre les signes de la SLA du muscle du biceps brachial et leur impact sur le plan temps-fréquence, 8 sujets sains et 8 patients neuropathiques ont été collectés de la base de données EMGLAB. La figure 4.8 représente la méthode de transformée de Fourier à court terme utilisée pour suivre cette pathologie par rapport aux groupes normaux en utilisant deux fenêtres de 256 ms et 512 ms. Les nerfs affectés sont bien observables dans le spectrogramme de puissance du signal EMG. Dans cette méthode analytique, il est évident que le niveau de puissance du spectrogramme des patients qui ont la SLA est significativement plus élevé ( $> 10000$  unités) que les groupes sains ( $< 10000$  unités), la SLA a provoqué un déplacement du spectre de puissance EMG vers les hautes fréquences. Le nombre de pics dans le spectre de puissance des patients sains est supérieur à celui du groupe SLA, ce qui est attendu de la nature de la maladie. Il est repris par la distribution d'énergie du signal dans le domaine temps-fréquence qui fournit des informations sur le comportement musculaire de différentes fibres musculaires, cela signifie comment les muscles réagissent avec la quantité d'énergie qui sera présentée chez les patients sains et pathologiques, elle est plus importante dans le groupe SLA en raison d'une défaillance des nerfs. Sur la base de ces résultats, la sévérité accentuée du signal a fourni un niveau de puissance plus élevé de son spectrogramme.

De plus, cette figure montre une comparaison d'un spectrogramme d'une fenêtre de 256 et 512 ms avec un chevauchement de 50%. Comme on peut le voir, les deux fenêtres sélectionnées montrent que la taille de fenêtre optimale du spectrogramme est importante, lorsque la taille de la fenêtre augmente, les informations de fréquence sont élargies et les informations de temps sont réduites. Il est important de compromettre les domaines temporel et fréquentiel. Ainsi, la sélection de la taille de la fenêtre devrait également être prise en considération [146].







(a)



(b)



(c)



(d)

Figure 4.8 : Spectrogramme du signal EMG, (a) sain ; (b) Spectrogramme de la SLA utilisant une taille de fenêtre de 256 ms et (c) sain ; (d) Spectrogramme SLA utilisant une taille de fenêtre 512 ms [146]

La figure 4.9 représente la deuxième méthode d'analyse temps-fréquence des signaux EMGs obtenus par application de la TOC, pour atteindre l'objectif de déterminer les changements qui se passent au niveau du muscle brachial, cette même base de données a subi de cette transformation pour vérifier la présence de la SLA par cette méthode d'analyse.

Figure 4.9 (a, b, c) représente les scalogrammes temps-fréquence qui correspondent à des segments sains de contraction musculaire volontaire. Plus de composantes de fréquence se trouvent dans ces scalogrammes par rapport aux conditions des scalogrammes SLA (figure 4.9 (d, e, f)). Il est également observé que la localisation instantanée de l'énergie se déplace vers des fréquences plus basses dans les cas neuropathiques [155], les nerfs affectés sont bien observables dans le scalogramme EMG. Dans cette méthode analytique, il est évident que la variation de fréquence du scalogramme SLA est significativement inférieure ( $< 41$  Hz) à celle du groupe normal ( $> 100$  Hz), la variation de fréquence est de l'ordre de (38 à 41 Hz), ce qui est attribué à la participation de fibres musculaires à contraction plus lente et à la synchronisation des unités motrices au cours de la maladie neuropathique [177] par rapport aux conditions saines où la variation se déplace vers des fréquences plus élevées de (109 à 127 Hz). Cette augmentation de fréquence est attribuée à l'augmentation de la vitesse de propagation du potentiel d'action le long des fibres musculaires. Les composantes de fréquence variant dans le

temps des signaux EMGs sont mieux représentées dans le plan temps-fréquence en utilisant la TOC. Cela est dû à la présence d'une visualisation séparable des conditions saines et pathologiques, où les résultats indiquent que l'approche temps-fréquence proposée utilisant l'analyse basée sur la TOC a été utilisée pour des applications aidant à détecter l'existence d'une gravité pathologique. La réduction de ces valeurs caractéristiques peut être attribuée à la participation de fibres musculaires à contraction plus lente et à la synchronisation des unités motrices pendant les conditions de défaillance.




Figure 4.9: Représentation en ondelettes continue à l'aide de db4 au niveau 6 : (a, b, c) conditions de signal EMG saines et (d, e, f) de la SLA [146].

Ces méthodes d'analyse temps-fréquence ont été implémenté par la suite pour l'extraction de plusieurs paramètres mentionné aux paravents, ce qui nous a permis de remplir le tableau (Tab 4. 1), il regroupe les résultats obtenus de différents paramètres et qui seront utilisés dans la classification de différents signaux EMGs. Dans ce travail de thèse, les cas normaux sont définis par N et les cas de la SLA par A.

Tableau 4. 1 : les différents paramètres extraits de la TFR

Sujets Paramètres	Les paramètres extrait de la TFCT								Les paramètres extrait de la TOC							
	256 ms				512 ms				Db4				Db7			
	ER	ES	FMD	FMN	ER	ES	FMD	FMN	En_O	LO	LF M	LO A	En_ O	LO	LFM	LO A
<b>Signaux de la SLA</b>																
A1	4,2342	236 1,8	248,02	247,8 374	4,234 2	236 1,8	248,0 288	247,8 374	1,156 10 <sup>12</sup>	108 140	8,65 22	201 45	1,98 95 10 <sup>12</sup>	274 33	7,661 3	654 7
A2	4,2866	244 7,2	248,01 35	247,8 345	4,286 6	244 7,2	248,0 135	247,8 345	2,100 710 <sup>12</sup>	100 660	8,76 59	191 94	5,31 97 10 <sup>12</sup>	383 73	7,797 9	887 8
A3	4,2655	240 2,8	248,02 97	247,8 35	4,265 4	240 5,9	248,0 33	247,8 233	1,318 10 <sup>12</sup>	104 820	8,70 04	193 16	2,21 77 10 <sup>12</sup>	260 28	7,608 8	636 5,1
A4	4,2827	242 1,9	248,02	247,8 34	4,265 5	240 2,8	248,0 2	247,8 36	9,190 110 <sup>11</sup>	985 70	8,6	191 81	1,95 94 10 <sup>12</sup>	198 83	7,296 5	540 7,1
A5	4,2675	240 8,7	247,98 93	247,8 381	4,241 4	236 1	248,0 4	247,8 32	3,557 10 <sup>12</sup>	154 670	8,97 38	261 88	6,84 10 <sup>12</sup>	515 21	8,145 9	105 38
A6	4,2562	239 4,5	248,03 14	247,8 38	4,267 5	240 8,7	247,9 893	247,8 381	1,391 510 <sup>12</sup>	100 830	8,54 03	191 72	2,66 68 10 <sup>12</sup>	207 52	7,348 7	539 3,2
A7	4,2466	237 8	248,01	247,8 343	4,256 2	239 4,5	248,0 314	247,8 32	1,247 210 <sup>12</sup>	738 81	8,17 18	157 91	1,93 93 10 <sup>12</sup>	194 84	7,913 3	597 4,1
A8	4,2682	242 2,4	248,03 81	247,8 205	4,246 6	237 8	248,0 1	247,8 343	1,318 10 <sup>12</sup>	104 820	8,70 04	193 16	1,99 04 10 <sup>12</sup>	198 02	7,232 4	560 7,6
<b>Signaux normaux</b>																
N1	4,2654	240 5,9	248,03 3	247,8 3	4,274 1	242 8,4	248,0 352	247,8 279	1,293 310 <sup>12</sup>	560 30	7,85 93	132 44	1,07 08 10 <sup>12</sup>	152 33	6,773 7	496 8
N2	4,2753	242 0,7	248,07 28	247,8 41	4,282 7	242 1,9	248,0 41	247,8 401	8,701 910 <sup>11</sup>	663 65	8,28 84	138 68	1,24 88E +12	190 43	7,306 7	502 5,1
N3	4,2876	244 3,1	247,99 04	247,8 315	4,275 3	242 0,7	248,0 728	247,8 41	1,193 410 <sup>12</sup>	584 71	8,07 85	127 40	1,80 49 10 <sup>12</sup>	140 27	6,843 5	433 7,8
N4	4,2414	236 1	248,04 51	247,8 32	4,287 6	244 3,1	248	247,8 315	9,528 10 <sup>11</sup>	461 96	7,77 49	112 09	1,88 28 10 <sup>12</sup>	142 92	7,233 2	532 3,5
N5	4,2682	242 2,4	248,03 81	247,8 3	4,268 2	242 2,4	248,0 381	247,8 3	9,820 610 <sup>11</sup>	874 63	8,57 97	169 61	1,08 96 10 <sup>12</sup>	190 83	6,540 6	534 1,6
N6	4,2845	242 8,4	248	247,8 4	4,284 5	242 8,4	248	247,8 4	1,078 410 <sup>12</sup>	760 81	8,23 51	156 88	1,14 4 10 <sup>12</sup>	188 52	7,121 9	527 3,5
N7	4,2893	243 2,3	248,03 9	247,8 415	4,289 3	243 2,3	248,0 39	247,8 415	8,004 910 <sup>11</sup>	896 22	8,45 67	180 28	1,00 49 10 <sup>12</sup>	123 48	6,687 6	407 6,5
N8	4,2843	242 1,4	248,02 68	247,8 32	4,284 3	242 1,4	248,0 268	247,8 32	9,882 110 <sup>11</sup>	580 96	8,08 66	128 53	1,68 87 10 <sup>12</sup>	190 47	7,085 4	503 6,3

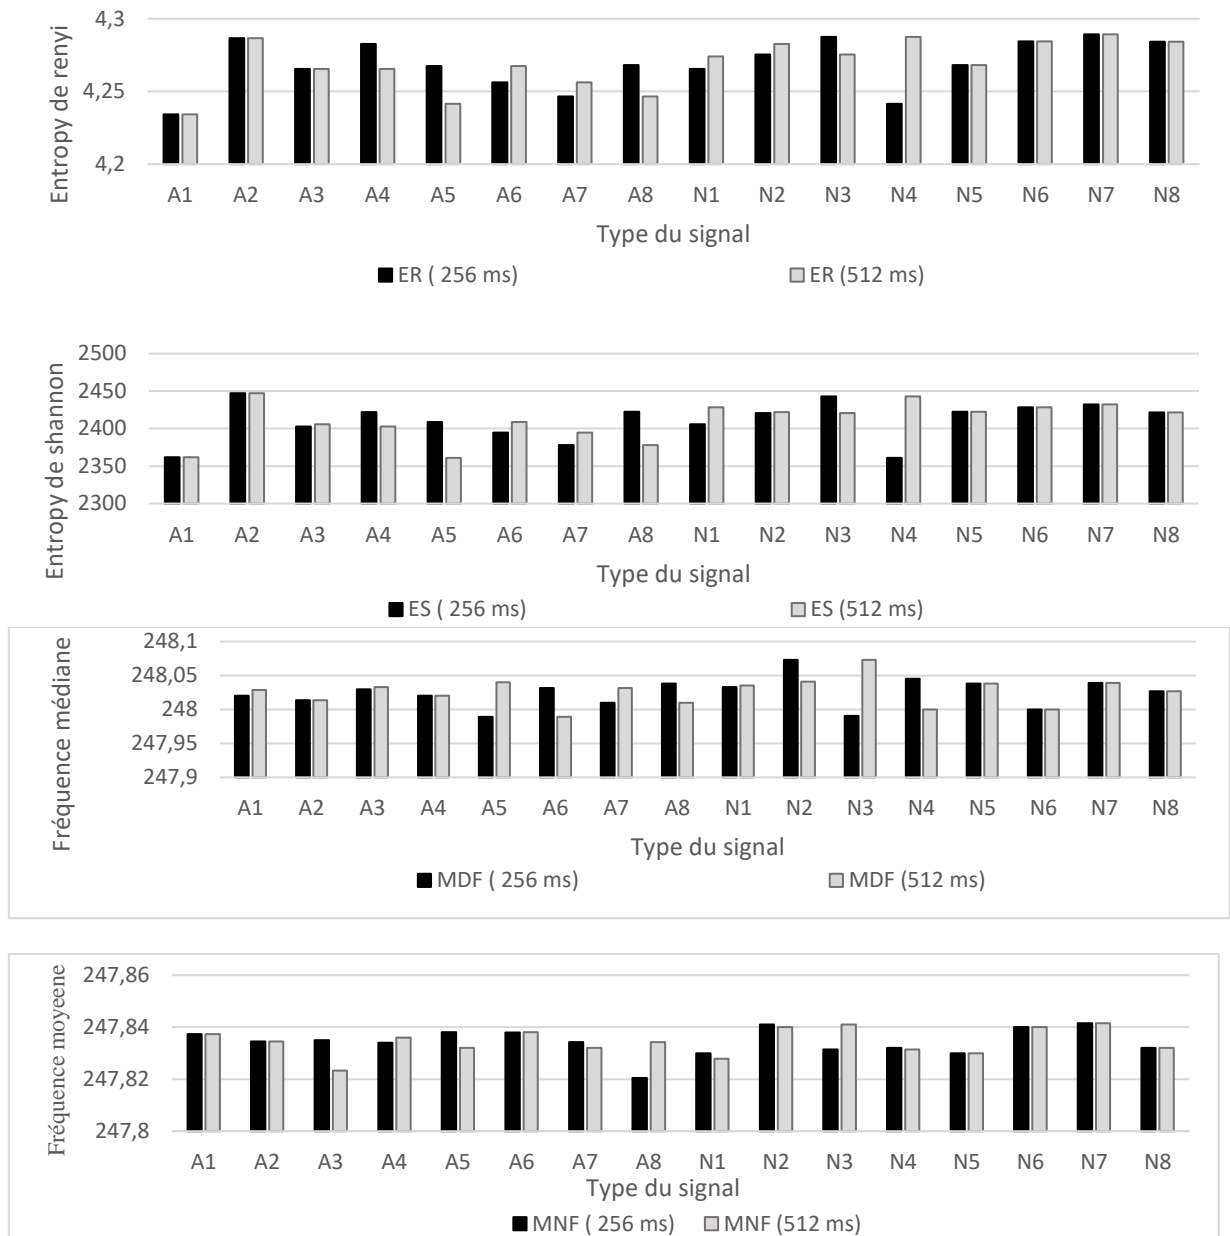


Figure 4.10 : Les histogrammes des paramètres extraits en utilisant le spectrogramme du signal EMG des cas sains (N) et pathologique (A) utilisant une taille de fenêtre 256 et 512 ms [178]

La figure 4.10 montre les histogrammes de huit patients sains (N1,..., N8) et malades (A1,..., A8) basés sur l'extraction de quatre caractéristiques temps-fréquence du spectrogramme (ER, ES, FMD et FMN) pour deux taille des fenêtres de 256 ms (avec le noir) et 512 ms (avec le gris).

La première caractéristique qui est l'entropie de Renyi, ce paramètre représente la quantité d'informations lors du transfert des données et donc une diminution de cette quantité risque de ne pas recevoir une quantité suffisante aux muscles. Pour en savoir plus, la représentation de ce paramètre sous forme des histogrammes des patients atteints de SLA par rapport aux patients sains a été données en utilisant les deux tailles de fenêtre (représentée en noir pour la fenêtre de

256 et en gris pour la fenêtre de taille de 512 ms) où la variation de l'entropie de Renyi dans le cas de la SLA est significativement plus faible que le groupe normal, ce paramètre mesure aussi la complexité du signal EMG. Cela traduit que plus le signal a plusieurs composantes, plus il est informatif, un signal a composante unique implique une valeur d'entropie de Renyi petite (les histogrammes de leurs variations présentent clairement la quantité d'information et la mesure de la complexité du signal des cas sains par rapport aux cas pathologiques). La deuxième caractéristique basée sur l'ES comme indiqué auparavant, ce paramètre mesure la quantité d'information contenue ou délivrée par le signal EMG ; des potentiels d'action musculaire émetteur du signal au récepteur (capteur intramusculaire) ; plus il y aura des informations différentes de l'émetteur, plus l'entropie croit. Cela a montré que les patients touchés par la SLA représentaient une information dépourvue et donc une entropie minimale pour la taille des deux fenêtres.

La troisième caractéristique est la FMD, une légère augmentation est notée des patients en mauvaise santé aux patients en bonne santé pour la taille à deux fenêtres. Pour la 4<sup>ème</sup> caractéristique basée sur la FMN, Une légère diminution est observée entre les patients en bonne santé et les patients en mauvaise santé pour les deux tailles de la fenêtre où la valeur neuropathique de la MNF est petite par rapport au groupe normal, ces deux paramètres de fréquences n'est rien d'autre qu'une simulation de la vitesse de conduction nerveux. C'est un écoulement de l'influx nerveux en temps et en fréquence.

On conclut que plus le patient présente une sévérité accentuée, leurs valeurs d'entropie de Renyi et de Shannon seront de plus en plus importantes et leurs valeurs de fréquence médiane et moyenne diminueront. Cela nous a poussé à recommander les paramètres du spectrogramme d'être des indicateurs pour le suivi de la sévérité pathologique.

Les histogrammes de variation des paramètres temps-fréquence par application de la TOC avec deux ordres de Daubechies en noir (db4) et en gris (db7) est donné par la figure 4.13 de 16 patients (8 sains et 8 pathologiques), ces paramètres incluent l'entropie d'ondelette (En-O), la longueur d'onde (LO), la longueur fractale maximale (LFM) et la longueur d'onde améliorée (LOA).

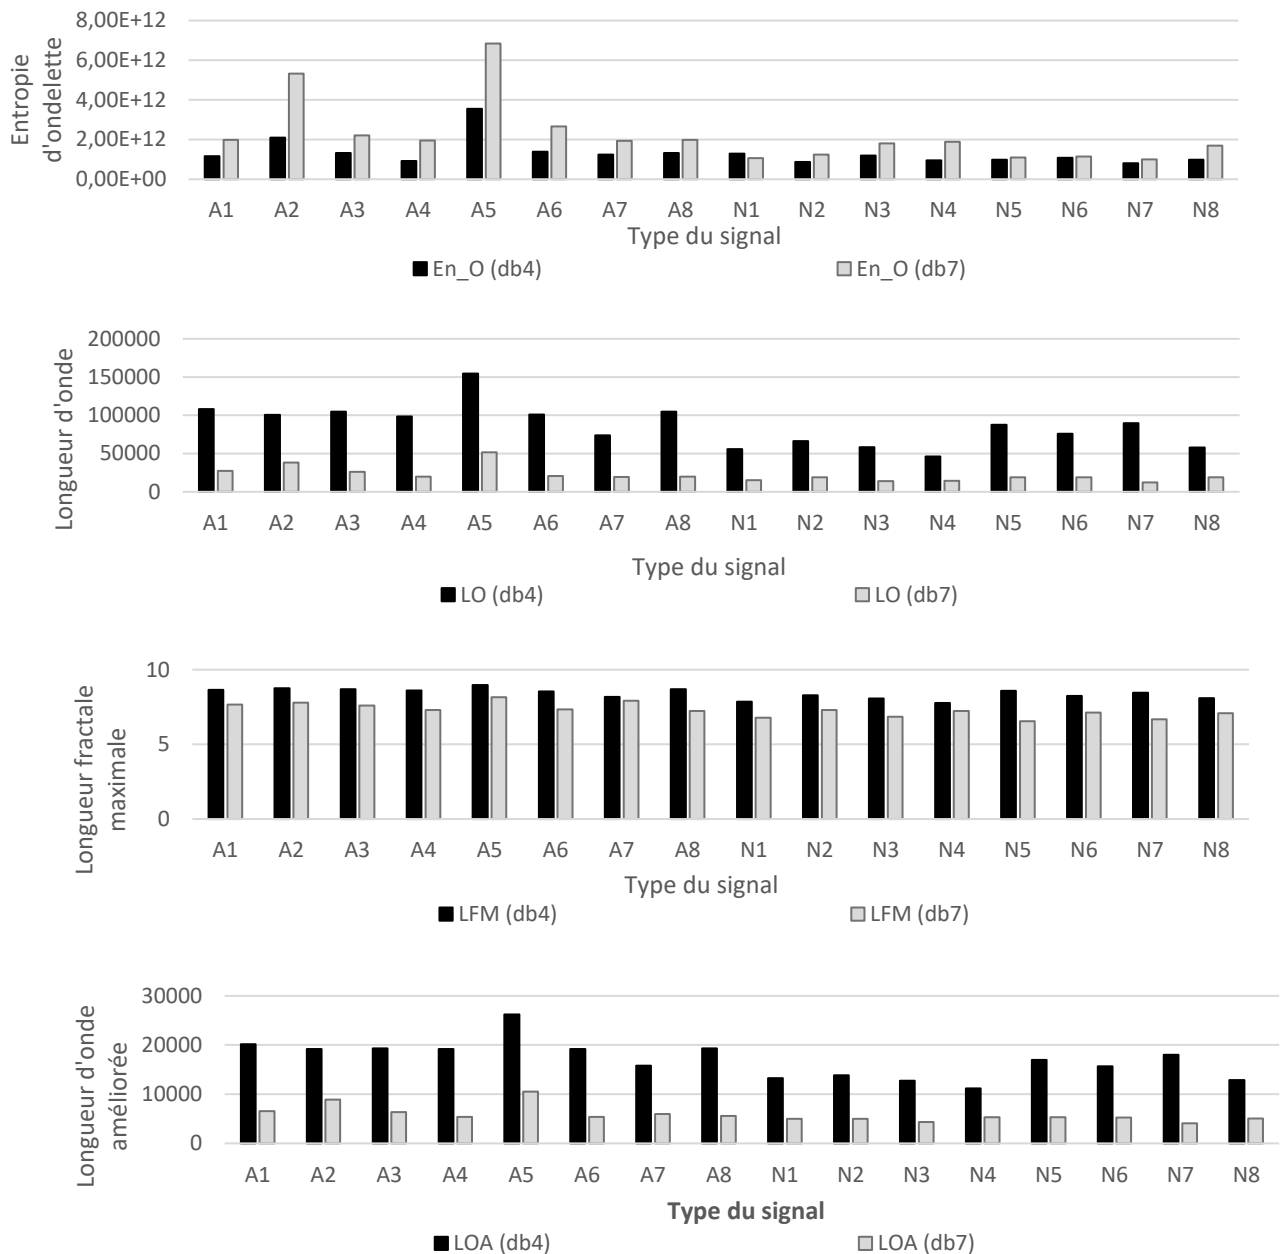


Figure 4.11 : Les histogrammes des paramètres extraits par application de l'ondelette continue du signal EMG des cas sains (N) et pathologique (A) utilisant un ordre de Daubechies 4 et 7.

Le premier paramètre qui est l'entropie d'ondelette est un nouvel outil capable d'analyser les caractéristiques transitoires des signaux non stationnaires. Cette métrique combine la décomposition en ondelettes et l'entropie pour estimer le degré d'ordre / désordre d'un signal avec une résolution temps-fréquence élevée. Initialement, l'entropie de Shannon a été proposée pour quantifier l'énergie dans les sous-bandes d'ondelettes, la distribution métrique ainsi définie étant appliquée à une grande variété de scénarios différents. Un intérêt particulier a montré l'application de l'entropie d'ondelette aux signaux physiologiques, tels que les électrocardiogrammes, les électroencéphalogrammes, les enregistrements de pression intracrânienne ou les potentiels associés évoqués, dans lesquels il est capable de révéler des

informations utiles, par exemple dans la prévention des maladies cardiaques ou la détection de la fatigue au volant.

Une visualisation claire et appréciable des cas normaux et pathologiques est obtenue en appliquant l'entropie d'ondelette, elle est très importante chez les patients qui souffrent de la SLA par rapport aux patients sains pour les deux ordres de Daubechies (db4 et db7)

Pour un Daubechies d'ordre 4, l'En<sub>O</sub> atteint une valeur maximale de  $3.56 \cdot 10^{12}$  chez le 5<sup>ème</sup> (A5) contre une valeur maximale de  $1.29 \cdot 10^{12}$  chez le premier patient sain (N1).

Pour un Daubechies d'ordre 7, ses valeurs minimale et maximale sont comprises entre  $1.94 \cdot 10^{12}$  (A7) et  $6.84 \cdot 10^{12}$  (A5) respectivement chez les patients qui ont la SLA et entre  $10^{12}$  (N7) et  $1.88 \cdot 10^{12}$  (N4) chez les patients sains. Une entropie d'ondelette élevée indique un degré de désordre du signal EMG élevé, cette constatation confirme la présence de la SLA par estimation du degré de désordre du signal neuropathique.

Le deuxième paramètre (la longueur d'onde) qui a été introduit par plusieurs chercheurs qui se traduit par une variation cumulative de l'EMG, il indique le degré de variation du signal EMG [179], ce paramètre caractérise bien la sévérité de la SLA par rapport aux cas normaux avec un Daubechies d'ordre 4 où la gamme de sa variation soit entre 73881 unités (A7) et 154670 unités (A5). En revanche, il ne dépasse pas 89622 unités (N7), la même remarque est donnée pour un Daubechies d'ordre 7 où la variation de la longueur d'onde qui reste pas moins de 19484 unités chez le patient (A7) et pas plus 19083 unités (N5) ; ce paramètre mesure le degré de variation que le signal neuropathique a subi lors de son passage jusqu'aux muscles.

La longueur fractale maximale (MFL) du signal, comme mesure de l'activation musculaire a été proposée. Ceci est similaire à la longueur d'onde mais comme il est à l'échelle logarithmique, il est moins sensible au bruit de fond et est un bon indicateur de la densité des MUAPs quelle que soit la forme [180]. Une augmentation de cette longueur fractale à des petites échelles indique une densité des MUAPs élevée à ces échelles. Avec un Daubechies d'ordre 7, ce paramètre (LFM) a indiqué la présence d'une neuropathie, ces valeurs de la longueur fractale augmentent signalant une augmentation de la densité des MUAPs et donc l'existence de la SLA dans un domaine de dimension fini. Par contre, ces valeurs dans les cas normaux restent extrêmement faibles.

Ce paramètre (LOA) a indiqué la présence d'une sclérose latérale amyotrophique du biceps brachial pour les deux ordres de Daubechies, une augmentation de cette valeur se traduit par une atteinte nerveuse, elle est très importante chez le 5<sup>ème</sup> patient (A5).

On conclut que plus le patient présente une sévérité accentuée, ces paramètres d'ondelette extraits dans cette étude sont de plus en plus importants cela nous a permis de qualifier les paramètres de l'ondelette continue d'être des indicateurs pour le suivi de la sévérité pathologique.

Les résultats des histogrammes présentés ci-dessus ont permis de recommander les paramètres du domaine temps-fréquence pour le suivi des cas sains et neuropathiques (SLA dans cette thèse) et non pas leurs degrés de sévérité

Dans ce qui suit, Ces paramètres ont été utilisés pour séparer les cas sains et ceux qui sont pathologiques par application des méthodes de classification plus appropriées pour cette séparation.

La capacité des caractéristiques du spectrogramme à différencier les conditions saines et malsaines est évaluée par trois algorithmes d'apprentissage automatique pour deux tailles de fenêtre de 256 et 512 ms avec un chevauchement de 50%, le tableau 4.2 décrit la précision de classification des caractéristiques du spectrogramme. La précision de classification moyenne de 87,5% et 92,3% en utilisant RBF-SVM est obtenue pour une fenêtre de 256 et 512 ms respectivement, Cela nous a permis de constater que le spectrogramme avec une fenêtre de 512 ms et RBF-SVM s'adaptent pour une meilleure précision. Une taille de fenêtre de 256 ms est plus préférée qu'une grande taille de fenêtre de 512 ms pour le classifieur LDA car il nous a offert une précision importante dans la discrimination des cas sains et les troubles de la SLA d'environ 81,3% par rapport aux KNN qui offrent des performances élevées (87%) avec une grande taille de fenêtre de 512 ms, la comparaison entre ces classifieurs a qualifié le classifieur RBF-SVM comme le plus préféré car il présente la plus grande précision de 92,3% suivi de KNN avec une taille de fenêtre optimale de 512 ms.

Tableau 4.2 : Précision de classification des caractéristiques du spectrogramme avec deux tailles de fenêtre optimales

Classification complète des fonctionnalités	Précision de classification (%)	
	Fenêtre de 256 ms	Fenêtre de 512 ms
LDA	81.3	79.2
KNN	75	87
RBF-SVM	87.5	92.3

Le tableau 4.3 présente la précision de classification des fonctionnalités TOC pour trois algorithmes d'apprentissage automatique qui ont été appliqués pour différencier les conditions saines et malsaines. La capacité des fonctionnalités TOC est évaluée pour db4 et db7 avec un



composant de détail au niveau 6, la précision de classification des fonctionnalités de scalogramme de 92,3%, 87,5% et 81,3% en utilisant respectivement RBF-SVM, LDA et KNN est obtenue pour db4. À l'opposé, ces classifieurs n'étaient pas recommandés pour les ordres de Daubechies élevés qui précisent respectivement 84%, 81,5% et 75%. Le classifieur RBF-SVM reste le plus préféré car il présente la précision la plus élevée de 92,3% avec un ordre optimal de daubechies (db4).

Tableau 4.3 : Précision de classification des caractéristiques du scalogramme avec deux ordres de Daubechie optimaux

Classification complète des fonctionnalités	Précision de classification (%)	
	db4	db7
LDA	87.5	81.5
KNN	81.3	75
RBF-SVM	92.3	84

La figure suivante (figure 4.14) représente les courbes des classifieurs utilisés pour chaque TFR pour deux conditions optimales de taille de fenêtre pour le spectrogramme et l'ordre de daubechies pour TOC, les résultats ont été discutés en fonction de la précision de classification la plus élevée. Afin d'obtenir des performances élevées, le classificateur RBF-SVM et KNN est recommandé lorsqu'il s'agit de spectrogramme avec une taille de fenêtres élargie de 512 et TOC avec db4, à l'opposé de LDA où la haute précision était réservée là où l'ordre des daubechies et la taille de la fenêtre diminuaient, RBF-SVM a atteint les performances les plus élevées par rapport à autre classifieur introduits dans ce travail, ce qui permet de le qualifier d'être puissant pour distinguer les troubles sains et SLA avec une grande précision.




Figure 4.12 : Les courbes des classifieurs utilisés pour chaque TFR et les conditions optimales de taille de fenêtre et d'ordre de Daubechies [146].

## Conclusion

Dans ce chapitre, nous avons d'abord appliqués les méthodes d'analyse temps-fréquence afin de séparer le signal EMG en neuropathie et sain. Cette méthode basée sur le spectrogramme, la TOC et ses fonctionnalités correspondantes pour comparer leurs performances de classification à l'aide de trois algorithmes d'apprentissages automatiques. Puis, huit caractéristiques sont extraites de la RTF. Ces caractéristiques sélectionnées sont appliquées à trois types de classifieurs et les performances de ces dernières sont comparées. Les résultats démontrent que les techniques temps-fréquence proposées étaient capables de représenter les variations non stationnaires des signaux EMGs, les caractéristiques extraites à partir de ces techniques ont statistiquement différentes significatives dans les conditions saines et SLA. Ainsi l'approche RBF-SVM donne une précision maximale de 92,3% pour une taille de fenêtres élargie de 512 ms et un ordre de Daubechie 4, suivie du LDA et KNN qui étaient recommandé pour un ordre de daubechies optimisé (db4) et une taille de fenêtres de 256 ms pour LDA et 512 ms pour KNN, cela nous a poussé à sélectionner RBF- SVM comme le classifieur le plus puissant avec une taille de fenêtre optimale de 512 ms et un 4ème ordre optimal de Daubechies.

Dans les travaux futurs, nous améliorerons les performances de classification par l'extraction de caractéristiques et en sélectionnant les caractéristiques les plus optimales en sélectionnant celles qui sont les plus performantes. Enfin, nous terminerons cette thèse par une conclusion en proposant quelques recommandations et axes de recherche pour nos futures études.

## Conclusion Générale

Dans cette thèse de doctorat, nous nous sommes intéressés à l'analyse temps-fréquence du signal électromyogramme (EMG) et le suivi des troubles neuromusculaires.

L'approche qui a été adoptée pour le suivi de ces types de pathologie neuromusculaire est celle qu'utilise un clinicien dans l'aide au diagnostic médical. D'abord une étude de recherche bibliographique a été menée. A travers cette étude, le signal électromyographique a été décrit partant de sa source au niveau cellulaire jusqu'à son apparition au niveau du muscle concerné. Cette étude a été suivie d'une étude théorique d'un instrument qui peut être utilisés pour permettre la détection du signal EMG et son acquisition. Le manuscrit traite également notre propre contribution à savoir le traitement numérique du signal EMG. Ce traitement numérique était principalement une analyse temps-fréquence, où les résultats obtenus ont montré que les troubles neuromusculaires sont bien détectés à travers le signal EMG par ces techniques d'analyse. Dans ce sens, un ensemble de données ont été collectées de la base de données EMGLAB de huit patients qui ont atteint la sclérose latérale amyotrophique et huit patients sains, puis traitées pour étudier statistiquement les symptômes de la sclérose latérale amyotrophique (SLA), la SLA dans le domaine temporel est bien remarqué en la comparant avec les cas sains : une information énergétique et une amplitude plus importantes s'accompagnent d'une activité mal préparée, l'information extraite du domaine fréquentiel aussi nous a permis de suivre la SLA : son contenu fréquentiel s'élargie et présente une amplitude maximale vers les basses fréquences en cas de la neuropathie due à une diminution de la vitesse de conduction pour que l'influx nerveux soit transmis mais ces deux domaines sont bien garantis lorsque le signal étudié est stationnaire. En revanche, le signal EMG de nature non stationnaire nous a amené vers des méthodes plus poussées. La SLA en analyse bispectral est recommandée et est appropriée ce qui valorise la sévérité pathologique et une visualisation agréable de la non-gaussianité vers les hautes fréquences a indiqué une sévérité pathologique plus accentuée. Pour aller plus loin, vers une analyse robuste et fiable, l'approche temps-fréquence a été utilisée et son efficacité a été bien démontré dans ce travail de thèse où les méthodes du spectrogramme et de la transformation en ondelette continue ont été implémentées. Les résultats de cette visualisation métrique nous a permis d'extraire les caractéristiques des cas normaux et pathologiques pour les introduire aux trois types de classifieurs et les performances de classification les plus élevées ont été obtenues avec la fonction noyau RBF de la SVM.

Cette thèse nous a permis d'exploiter tous nos acquis obtenus durant notre cursus universitaire, Elle a été une expérience fructueuse qui pourra nous ouvrir les portes vers le monde professionnel.

Notre thèse est loin d'être parfaite à cause de la base de données qui n'est pas riche, elle peut bénéficier de plusieurs améliorations comme travailler sur une base de données sous les mêmes conditions avec des âges au moins proches des patients parce que cet écart peut changer beaucoup.

Tant que le signal EMG est un signal pseudo-stochastique, il y aura un manque des informations ce qui serait des perspectives. Dans le futur, nous pouvons aussi travailler sur une autre base de données locale sur les signaux obtenu d'une main artificielle pour suivre l'activité de l'ensemble des muscles en totalité.

On peut également penser à développer un système automatique de diagnostic des troubles neuromusculaires en utilisant l'apprentissage profond et améliorer les performances de prédiction en exploitant des techniques de traitement du signal plus avancées pour l'extraction de caractéristiques en testant d'autres méthodes de sélection de caractéristiques intrinsèques du signal EMG.

## **Annexe**

### **Publications et communications de l'auteur**

Durant cette thèse, certaines parties de mes recherches ont abouti à quatre articles internationaux de revue à comité de lecture et trois articles de conférence nationale énumérés ci-dessous.

#### **Articles de Revues Internationales**

1. A.MOKDAD, S.M.DEBBAL, F.MEZIANI. Classification of Electromyogram (EMG) Signal using Time Frequency Representation for Diagnosis of Amyotrophic Lateral Sclerosis (ALS) Disorders. International Journal of Advanced Science and Technology Vol. 29, No. 3, (2020), pp. 2899- 2910
2. A.MOKDAD, S.M.DEBBAL. Classification and signal processing analysis Of The pathological electromyogram signal (EMG). International Journal of Medical Engineering and Informatics, 2020 <https://www.inderscience.com/info/ingeneral/forthcoming.php?jcode=ijmei>
3. A.MOKDAD, S.M.DEBBAL, F.MEZIANI. Diagnosis of Amyotrophic Lateral Sclerosis (ALS) Disorders Based on Electromyogram (EMG) Signal Analysis and Feature Selection. Polish Journal of Medical Physics and Engineering Issue26(3) (September 2020).
4. A.MOKDAD, S.M.DEBBAL, F.MEZIANI. Application of the continuous wavelet transform for the analysis of pathological severity degree of electromyograms (EMGs) signals. Polish Journal of Medical Physics and Engineering Issue26(3) (September 2020).

#### **Papiers d'une Conférence Nationale**

1. Aicha. Mokdad, Sidi. Mohammed. Debbal, Fadia Meziani. (2018).” Realization of a device for the evaluation of muscular effort through the electromyogram signal (EMG)", the 8th Doctoral Day in Biological and Medical Engineering, JDGBM'2018, Tlemcen, Algeria, May 10<sup>th</sup>, 2018(Présentation poster).
2. Aicha. Mokdad, Sidi. Mohammed. Debbal, Fadia Meziani. (2019).” Analysis of the surface electromyogram signal (sEMG) based on continuous wavelet transform (CWT)", the 8th Biomedical Maintenance Day of the military hospital, JMB'2019, Algiers, Algeria, October 10<sup>th</sup>, 2019. (Présentation Poster).
3. Aicha. Mokdad, Sidi. Mohammed. Debbal, Fadia Meziani. (2019).” Analysis of the electromyogram signal (EMG) for the evaluation of pathological severity", the 9th Doctoral Day in Biological and Medical Engineering, JDGBM'2019, Tlemcen, Algeria, June 13<sup>th</sup>, 2019. (Présentation orale).

## Bibliographie

- [1] L. P. Rowland . Amyotrophic Lateral Sclerosis: Theories and Therapies. *Ann Neurol.* 35(2): 129-130, 1994. doi: 10.1002/ana.410350202.
- [2] A.B.M. Sayeed Ud Doulaht, Md. AsifIqbal , Marzuka Ahmed Jumana. ALS Disease Detection in EMG Using Time Frequency Method. [EEE/OSA/[APR International Conference on Infonnatics, Electronics & Vision 978-1-4673-1154-0112/\$31.00 ©2012.
- [3] N. A. Kamaruddin, P. I. Khalid, A. Z. Shaameri. The Use of Surface Electromyography in Muscle Fatigue Assessments-A Review. *Jurnal Teknologi.* 2015 Jan 1; 74(6):119-24.
- [4] B. Pandey, & R. B. Mishra. An integrated intelligent computing model for the interpretation of EMG based neuromuscular diseases. *Expert Systems with Applications*, 36(5), 9201–9213, 2009.
- [5] R. Merletti, & H. Hermens. Detection and conditioning of the surface EMG signal. In R. Merletti & P. Parker (Eds.), *Electromyography: Physiology, engineering, and noninvasive applications* (pp. 107–132). New Jersey: John Wiley & Sons, 2004.
- [6] P.A. Karthick, S. Ramakrishnan. Surface electromyography-based muscle fatigue progression analysis using modified B distribution time–frequency features. *Biomedical Signal Processing and Control.* 26:42-51, 2016 Apr 1
- [7] E. A Clancy, L. Liu, P. Liu, D.V. Moyer. Identification of constant-posture EMG–torque relationship about the elbow using nonlinear dynamic models. *IEEE Transactions on Biomedical Engineering.*; 59(1):205-212, 2012 Jan
- [8] G. Wang, Z. Yan, X. Hu, H. Xie, Z. Wang . Classification of surface EMG signals using harmonic wavelet packet transform. *Physiological measurement.* 27(12):1255-1267, 2006 Oct 10
- [9] E. Gokgoz, A. Subasi. Comparison of decision tree algorithms for EMG signal classification using DWT. *Biomedical Signal Processing and Control.* 18: 138-44, 2015 Apr 1
- [10] P.B. Patil, M.S. Chavan. A wavelet-based method for denoising of biomedical signal. *ICPR, Informat. Med. Eng.* 978-1-4673-1039-0/12, 2012.
- [11] I S. Md. Rabiul, X. Huang, D. Sharma. Wavelet based denoising algorithm of the ECG signal corrupted by wgn and poisson noise. *ISCIT.* 978-1-4673-1157-1, 2012
- [12] M. EI hanine, E. Abdelmounim, R. Haddadi, A. Belaguid. Electrocardiogram signal denoising using discrete wavelet transform. *IEEE* 978-1-4799-3824-7/14 (2014).
- [13] M. AlMahamdy, H.B. Riley. Performance Study of Different Denoising Methods for ECG Signals. *Procedia Comput. Sci.* 37 325 –332 (2014).
- [14] M. LIMEM, M. A. HAMDI. Uterine Electromyography signals denoising using discrete wavelet transforms 2015 International Conference on Advances in Biomedical Engineering (ICABME) 978-1-4673-6516-1/15/\$31.00 ©2015 IEEE
- [15] A. Subasi, M. K. Kiyamik. Muscle Fatigue Detection in EMG Using Time-Frequency Methods, ICA and Neural Networks. *J Med Syst.* (2010) 34:777-785, doi: 10.1007/s10916-009-9292-7.
- [16] J. 1. Semmlow. *Biosignal and biomedical image processing, MA TLAB-based applications.* Marcel Dekker, New York, 2004.

- [17] M. R. Canal. Comparison of Wavelet and Short Time Fourier Transform Methods in the Analysis of EMG Signals. *J Med Syst.* 34:91-94, 2010, doi: 10.1007/s1 091 6-008-9219-8.
- [18] L. Y. Cai, Z. Z. Wang, H. H. Zhang. A Surface EMG Signal Identification Method Based on Short-Time Fourier Transform. *Chinese journal of medical instrumentation*, vo1.24, pp. 133-136, March 2000.
- [19] Andreia S. P. Sousa, João Manuel R. S. Tavares. Surface electromyographic amplitude normalization methods: A review. *Electromyography: New Developments*.
- [20] 1Dr. Bharat Mishra, 2Dr. A. K. Wadhvani, 3Shilpi Singh. EMG Signal Classification for Neuromuscular Disorder Using Soft-Computing Techniques. ISSN: 2349-7300 IJIRMP Volume 7, Issue 1, 2019.
- [21] L.J. Myers a,\* , M. Lowery b, M. O'Malley a, C.L. Vaughan c, C. Heneghan a, A. St Clair Gibson d, Y.X.R. Harley c, R. Sreenivasan c. Rectification and Non-linear Pre-processing of EMG Signals for Cortico-Muscular Analysis. *Journal of Neuroscience Methods* 124 (2003) 157-165.
- [22] B. Boashash. Estimating and Interpreting the Instantaneous Frequency of a Signal-Part 1: Fundamentals. *Proc IEEE* 1992; 80:520-38.
- [23] de Coulon F. *Signal Theory and Processing*. Artech house, Inc, 1986.
- [24] T. N. S. Tengku Zawawi<sup>1</sup>, A. R. Abdullah<sup>2</sup>, M.H. Jopri<sup>3</sup>, T. Sutikno<sup>4</sup>, N.M. Saad<sup>5</sup>, R. Sudirman<sup>6</sup>. A Review of Electromyography Signal Analysis Techniques for Musculoskeletal Disorders. *Indonesian Journal of Electrical Engineering and Computer Science* Vol. 11, No. 3, September 2018, pp. 1136~1146.
- [25] J. Too<sup>1</sup>, A.R. Abdullah<sup>1\*</sup>, N. Mohd Saad<sup>2</sup>, N Mohd Ali<sup>1</sup>, T.N.S. Tengku Zawawi<sup>1</sup>. Classification of Myoelectric Signal using Spectrogram Based Window Selection. *International Journal of Integrated Engineering* Vol. 11 No. 4 (2019) 192-199.
- [26] Subasi, Abdulhamit. Classification of EMG Signals Using PSO Optimized SVM for Diagnosis of Neuromuscular Disorders. *Computers in Biology and Medicine* Volume 43, Issue 5 , Pages 576-586, 1 June 2013
- [27] A. Bhattacharya, A. Sarkar, P. Basak. Time Domain Multi-Feature Extraction and Classification of Human Hand Movements Using Surface EMG. 2017 International Conference on Advanced Computing and Communication Systems (ICACCS -2017), Jan. 06 – 07, Coimbatore, INDIA, 2017
- [28] S. NEGI, Y. KUMAR, V. M. MISHRA. Feature Extraction and Classification for EMG Signals Using Linear Discriminant Analysis. 2nd International Conference on Advances in Computing, Communication, & Automation (ICACCA) Bareilly, India pp, 1-6, 2016
- [29] A. Benazzouz, R. Guila, F. Amirouche, Z. E. Hadj Slimane. EMG Feature Selection for Diagnosis of Neuromuscular Disorders. 2019 International Conference on Networking and Advanced Systems (ICNAS) Annaba, Algeria, pp 1-5.
- [30] W. Rose. *Electromyogram Analysis*. KAAP686 Mathematics and Signal Processing for Biomechanics, 2014.
- [31] S. Bouisset et B. Maton. Quelques aspects de la quantification de l'activité musculaire par l'EMG. 2015, <http://edu.mnhn.fr/mod/page/view.php?id=2683>

- [32] L. Chen, Y. Hao. Feature Extraction and Classification of EHG between Pregnancy and Labour Group Using Hilbert-Huang Transform and Extreme Learning Machine. *Comput Math Methods Med*2017 (7949507) 1–9, 2017
- [33] R. D'Alessio, S. Conforto. Extraction of the Envelope from Surface EMG Signals. *IEEE Eng. Medicine Biology*20 (6) 55–61, 2001
- [34] H. Xie, Z. Wang. Mean Frequency Derived Via Hilbert-Huang Transform with Application to Fatigue EMG Signal Analysis. *Computer Methods and Programs in Biomedicine*82 (2) 312–320. 2006
- [35] A. Phinyomark, P. Phukpattaranont, C. Limsakul. Feature reduction and selection for EMG signal classification. *Expert Systems with Applications*. 39 (8):7420-31, 2012 Jun 15
- [36] F. LEBON. Efficiencie du travail mental sur le développement et le recouvrement des capacités motrices. PhD thesis University Claude Bernard, Lyon 2009.
- [37] H. T. Jukka Viitasalo and P. V. Komi. Signal Characteristics of EMG during Fatigue. *Europ. J. appl. Physiol.* 37, 111-121, 1977
- [38] B. Mokhlesabadifarahani., V.K. Gunjan. EMG signal characterization in three of contraction bu Fuzzy Network and feature extraction. *Forensic and Medical Bioinformatics*, DOI 10.1007/978-981-287-320-0\_2. 2015.
- [39] R. A. Malinzak, S.M. Colby, D. T. Kirkendall, B. Yu, W.E. Garrett. A comparison of knee joint motion patterns between men and women in selected athletic tasks. *Clinical biomechanics.*; 16 (5):438-45, 2001 Jun 1
- [40] T.I. Arabadzhiev, V.G. Dimitrov, N.A. Dimitrova, G. V. Dimitrov. Interpretation of EMG integral or RMS and estimates of —neuromuscular efficiency| can be misleading in fatiguing contraction. *Journal of Electromyography and Kinesiology.*; 20(2): 223-32, 2010 Apr 1
- [41] C. Suetta, P. Aagaard, A. Rosted, A. K. Jakobsen, B. Duus, M. Kjaer, S.P. Magnusson. Training-induced changes in muscle CSA, muscle strength, EMG, and rate of force development in elderly subjects after long-term unilateral disuse. *Journal of Applied Physiology*. 2004 Nov; 97(5):1954-61.
- [42] F.Meziani, S.Rerbal & S. M. Debbal. Analyse spectro-temporelle des signaux d'électromyogramme (EMG). Université Tlemcen, 2017.
- [43] S. M. Kay. *Fundamentals of statistical signal processing: Practical algorithm development*. Pearson Education. 2013.
- [44] C.Cabrera. Analyse du Signal Myoélectrique pour l'Évaluation de la Fatigue Périphérique chez des Nageurs de Haut Niveau en Demi-Fond. University of Western Brittany 2014.
- [45] R. E. Bekka, D. Chikouche. Effect of the window length on the EMG spectral estimation through the Blackman-Tukey method. In *Signal Processing and Its Applications*, 2003. Proceedings. Seventh International Symposium; 2: 17-20, 2003
- [46] S. Thongpanja, A. Phinyomark, P. Phukpattaranont, C. Limsakul. Mean and median frequency of EMG signal to determine muscle force based on time-dependent power spectrum. *Elektronika ir Elektrotechnika*.19(3):51-56, 2013
- [47] F. Khanam, M. Ahmad. Frequency based EMG power spectrum analysis of Salat associated muscle contraction. In *2015 International Conference on Electrical & Electronic Engineering (ICEEE)*, Nov 4: pp. 161-164, 2015



- [48] A.Phinyomark, S.Thongpanja, H. Hu, P.Phukpattaranont & C.Limsakul. The Usefulness of Mean and Median Frequencies in Electromyography Analysis Computational Intelligence in Electromyography Analysis. A Perspective on Current Applications and Future Challenges, 2012.
- [49] K. C. Chuaa, V. Chandranb, U. Rajendra Acharyaa, C. M. Lima. Application of Higher Order Statistics/Spectra in Biomedical Signals. *Medical Engineering & Physics* 32 679–689, 2010.
- [50] C. L. Nikias, M. R. Raghuveer. Bispectrum Estimation a Digital Signal Processing Framework. *Proceedings of the IEEE*; 75:869–91, 1987.
- [51] C. L. Nikias, A. P. Petropulu. *Higher-Order Spectra Analysis: a Nonlinear Signal Processing Framework*, Prentice-Hall, Englewood Cliffs, NJ, 1993.
- [52] P.A. Kaplanis, C. S. Pattichis, L. J. Hadjileontiadis, S. M. Panas. Analyse Bispectrale de l'EMG de Surface. Dans : Actes de la 10e conférence électrotechnique méditerranéenne, vol. II. p. 770-3, 2000.
- [53] K. Nazarpour, A. R. Sharafat, S. M. P. Firoozabadi. Application de Statistiques d'Ordre Supérieur à la Classification des Signaux d'Électromyogramme de Surface. *Transactions IEEE on Biomedical Engineering*; 54 (10): 1762–9, 2007.
- [54] M.B. Reaz, M. S. Hussain, F. Mohd-Yasin. Techniques of EMG signal analysis: detection, processing, classification and applications. *Biological procedures online*. Dec 1; 8(1):11-35, 2006
- [55] Deng, Zhenyun, X. Zhu, D. Cheng, M. Zong and S. Zhang. Efficient kNN classification algorithm for big data. *Neurocomputing*, 195, pp. 143-148, 2016
- [56] Yousefi, J. and Hamilton-Wright, A. Characterizing EMG Data Using Machine-Learning Tools. *Computers in biology and medicine*, Volume 51, (2014), pp. 1-13.
- [57] D. Camille. Contribution à l'intégration sur silicium de la transformée en ondelettes Application au traitement d'images. Thèse de doctorat de l'université Montpellier II.2000. pp16-17-21.
- [58] Y. Meyer. *Les ondelettes : Algorithmes et Applications*. Edition Armand Colin. 1994.
- [59] B. Toresani. *Analyse continue par ondelettes*. CNRS Edition. 1995.
- [60] J. Morlet, G. Arens, E. Fourgeau, and D. Giard. Wave propagation and sampling theory 1. Complex signal and scattering in multilayered media. *Geophysics*, 47(2), pp 203-221, 1982.
- [61] J. Kilby, H. Gholam Hosseini. Extracting Effective Features of SEMG Using Continuous Wavelet Transform *Proceedings of the 28th IEEE EMBS Annual International Conference New York City, USA, Aug 30-Sept 3, 2006*
- [62] Merletti et Parker. *Electromyography: Physiology, Engineering and Noninvasive Applications*. IEEE press Engineering in Medicine and Biology Society, Sponsor, 2004.
- [63] Englehart, Kevin, B. Hudgins, P. A Parker, et M. Stevenson. Classification of the myoelectric signal using time-frequency based representations. *Medical engineering & physics*, vol. 21, n°6, p. 431–438, 1999
- [64] K.C Gupta, R.Garg, I.Bahl and P .Bhartis, *Microstripe lines and sloutlines*,second edition ,artech house,Boston ,1996.

- [65] T. N. S. T. Zawawi<sup>1\*</sup>, A. R. Abdullah<sup>2</sup>, R. Sudriman<sup>3</sup>, N. Mohd Saad<sup>4</sup>, T. Jingwei, E. Farina Shair<sup>6</sup>. Classification of EMG Signal for Health Screening Task for Musculoskeletal Disorder. *International Journal of Engineering & Technology*, 8 (1.7) 219-226, 2019
- [66] J. Too<sup>1</sup>, A. R. Abdullah<sup>1</sup>, Norhashimah Mohd Saad<sup>2</sup>, Nursabillilah Mohd Ali<sup>1</sup> · Tengku Nor Shuhada Tengku Zawawi<sup>1</sup>. Exploring the Relation Between EMG Pattern Recognition and Sampling Rate Using Spectrogram. *Journal of Electrical Engineering & Technology* <https://doi.org/10.1007/s42835-019-00083-3>, 2019.
- [67] I. Elamvazuthi, G.A. Ling, K.A.R Ku Nurhanim, P. Vasant, S. Parasuraman. Surface Electromyography (SEMG) Feature Extraction Based on Daubechies Wavelets. *IEEE 8th Conference on Industrial Electronics and Applications (ICIEA)*, pp. 1492–95, <https://doi.org/10.1109/ICIEA.2013.6566603>, 2013
- [68] J. Too<sup>1</sup>, A. R. Abdullah<sup>2</sup>, N. Mohd Saad<sup>3</sup>. Classification of Hand Movements based on Discrete Wavelet Transform and Enhanced Feature Extraction. (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, Vol. 10, No. 6, 2019
- [69] A. Phinyomark, F. Quaine, S. Charbonnier, C. Serviere, F. Tarpin-Bernard, Y. Laurillau. EMG Feature Evaluation for Improving Myoelectric Pattern Recognition Robustness. *Expert Systems with Applications* 40, pp. 4832–4840, 2013.
- [70] A. Phinyomark, A. Nuidod, P. Phukpattaranont, C. Limsakul. Feature Extraction and Reduction of Wavelet Transform Coefficients for EMG Pattern Classification. *Electronics and Electrical Engineering* 122, no. 6 (2012), pp. 27–32, <https://doi.org/10.5755/j01.eee.122.6.1816>
- [71] <https://cnfs.ca/pathologies/sclerose-laterale-amyotrophique>
- [72] T. R. Barbeau. *Muscle Physiology*. Supplements Francis Mario university
- [73] Dr Kayoueche. *Cours de Physiologie Générale*. 2ème partie : LES MUSCLES 2019/2020
- [74] <http://eleves-tpe.skyrock.com/>.
- [75] [http://www.corpshumain.ca/les\\_muscles.php](http://www.corpshumain.ca/les_muscles.php).
- [76] J. Boutonnat et D. Seigneurin. *Tissu musculaire*. Université de Joseph fourier de grenoble 2010-2011.
- [77] H. Cao. *Modélisation et évaluation expérimentale de la relation entre le signal EMG de surface et la force musculaire*. Thèse de doctorat, science de l'ingénieur, université de technologie de Compiègne, France, Janvier 2010.
- [78] <https://www.reseau-canope.fr/corpus/video/le-muscle-moteur-du-mouvement-119.html>
- [79] J-M Mienville. *Physiologie musculaire*. uns.
- [80] <http://amar-constantine.e-monsite.com/pages/anatomie-physiologie/physiologie-de-la-plaque-motrice.html>
- [81] F. Bacou, P. Vigneron. Propriétés des fibres musculaires squelettiques. Influence de L'innervation motrice. *Reproduction nutrition développement*, 1988, 28 (6a), pp.1387-1453.
- [82] K. L. Moore, A. F. Dalley, A. M. Agur. *Clinically oriented anatomy*. Lippincott Williams & Wilkins; 2013 Feb 13.
- [83] A. Egemen and A. Cı̇ğdem. Kinesiology of the elbow complex. *Hand Surgery Orthopaedics and Traumatology*, University of Health Sciences, Diskapi Yildirim Beyazit Training and Research Hospita, Ankara, Turkey,<sup>2</sup>Faculty of Physical Therapy and Rehabilitation, Hacettepe University, Ankara, Turkey.

- [84] D. Besleaga, BS,<sup>2</sup> Vincenzo Castellano, MD,<sup>1,3</sup> C. Lutz, MD,<sup>1,3</sup> and Joseph H. Feinberg, MD, MS<sup>1,3</sup>. Musculocutaneous Neuropathy: Case Report and Discussion. *HSS J.* 2010 Feb; 6(1): 112–116.
- [85] N. B. Corner, et al., Isolated musculocutaneous nerve lesion after shoulder dislocation. *J. R. Army. Med. Corps.* 136 (2), 107108, 1990
- [86] V. Créteur, A. Madani, A. Sattari, W. El Kazzi, S. Bianchi. Ultrasonography of Complications in Surgical Repair of the Distal Biceps Brachii Tendon. *J Ultrasound Med* ; [PubMed: 30027585, 2018.
- [87] S. Saluja, S. S Das, D. Kumar, P. Goswami. Bilateral Threeheaded Biceps Brachii Muscle and its Clinical Implications. *Int J Appl Basic Med Res*; 7(4):266268. [PMC free article: PMC5752815] [PubMed :29308368] 2017.
- [88] C. S. Neer. Anterior acromioplasty for the chronic impingement syndrome in the shoulder. 1972. *J Bone Joint Surg Am.* 87(6):1399. [PubMed: 15930554], 2005
- [89] B.B. Busconi, N. DeAngelis, P. E. Guerrero. The proximal biceps tendon: tricks and pearls. *Sports Med Arthrosc Rev.* 16(3):187-94. [PubMed: 18703980], 2008 Sep.
- [90] O. Jones. The Musculocutaneous Nerve. *TeachMe Anatomy* December 22, 2020 <https://teachmeanatomy.info/upper-limb/nerves/musculocutaneous-nerve/>
- [91] H. Rubana, Chowdhury, Mamun BI Reaz, Mohd Alauddin Bin Mohd Ali, Ashrif A A Bakar, Kalavani Chellappan, et Tae. G. Chang. *Électromyographie de surface de traitement du signal et des techniques de classification, Articles de capteurs (Bâle, Suisse), 2013.*
- [92] A. Champagne. *Évaluation de la fatigabilité musculaire des extenseurs lombo-pelviens : effets de la tâche et de l'âge.* Université du Québec, 2008.
- [93] K. Mebarkia. Paramétrisation des potentiels d'action d'une unité motrice détectés non-invasivement. universite ferhat abbas –setif 1- UFAS (algerie)2014
- [94] T. Kamali, R. Boostani, H. A. Parsaei. Hybrid classifier for characterizing motor unit action potentials in diagnosing neuromuscular disorders. *j biomed phys eng* 2013
- [95] J. C. De Luca, A. Adam, R. Wotiz, L. Donald Gilmore, and S. Hamid Nawab. *Decomposition of Surface EMG Signals.* Boston University, Boston, Massachusetts, 2006.
- [96] G. Whatmore, D. Kohli. *The Physiopathology and Treatment of Functional Disorders.* New York, NY: Grune & Stratton; 1974.
- [97] J. Dumoulin Bisschop, Guy de ; Bence, Yves, Paris, Maloigne, *Electromyographie et electrodiagnostics : vitesses de conduction nerveuse, potentiels évoqués.* 1984.
- [98] A. Gupta, A. Gupta, I. Agarwal. electromyography and its role in dentistry composition et fonction d'un muscle. *Indian journal of clinical and experimental dermatology*, october-december 2016.
- [99] S. Boukhenous, M. Attari, N. Meziane, Y. Remram, A. kahla. Conditionnement du signal physiologique EMG. *Biomeic, tlemcen* 2011-2012.
- [100] M. Z. J. Signal acquisition using surface EMG and circuit design considerations for robotic prosthesis. Ganesh R. Naik, ISBN 978-953-51-0805-4, 2011

- [101] <http://www.anabolicgenes.com/entrainement.html>
- [102] <http://www.spesmedica.com/fr/prodotti/emg/aiguilles-monopolaires-isolees> Teflon sterile. html
- [103] H.P.Cathala, Exploration fonctionnelles du système nerveux. Alger ,1994.
- [104] <http://www.neurosoft.ru/fra/product/neuro-mep-micro-2009/>.
- [105] M. J. S. R Pandey. Data Acquisition and Monitoring of EMG (electromyogram) signals. elk asia pacific journals – special issue ISBN: 978-81-930411-4-7
- [106] J.M. Coudreuse, P. Dupont, C. Nicol. Analyse de la littérature douleurs musculaires post effort delayed post effort muscle soreness. Annales de réadaptation et de médecine physique 47, 290–298, 2004.
- [107] G. Couturier. Amplificateur de Différence et Instrumentation. Dept GEII IUT Bordeaux I, 2000.
- [108] R.Hinzelin. Guide Pratique d'Électromyographie dans les Lésions des Nerfs Périphériques. Paris,1979.
- [109] A. Pérez-Martin, I. Schuster, M. Dauzat. Exploration Neuro-Musculaire : L'exploration fonctionnelle Neuromusculaire. Travaux pratique de physiologie, Faculté de médecine Montpellier-Nîmes, Novembre 2006.
- [110] Y. Wu et al. Overview of the application of EMG recording in the diagnosis and approach of neurological disorders. TNTECH, mai 2013.
- [111] A. Tameem et S. Dan. Clinical Quantitative Electromyography. INTECH, Mai 2013.
- [112] SLA - Sclérose latérale amyotrophique. Centre hospitalier universitaire vaudois 19/03/2019
- [113] MARTIN, CAZENAVE, CATTART, & BRANCHEREAU. Embryonic Alteration of Motoneuronal Morphology Induces Hyperexcitability in the Mouse Model of Amyotrophic Lateral Sclerosis. *Neurobiology of Disease* 54 (June): 116–26. doi:10.1016/j.nbd.2013.02.011, 2013.
- [114] RENTON, CHIÒ, & TRAYNOR. State of Play in Amyotrophic Lateral Sclerosis Genetics. *Nature Neuroscience* 17 (1): 17–23. doi:10.1038/nn.3584, 2013.
- [115] P.-F. Pradat, G. Bruneteau. Quels Sont les Signes Cliniques, Classiques et Inhabituels Devant Faire Évoquer une Sclérose Latérale Amyotrophique ?. *Rev Neurol (Paris)* 2006 ; 162 : Hors série 2, 4S17-4S24.
- [116] E. Brangier et P. Pino. La Sclérose Latérale Amyotrophique Approche Ergonomique d'une Assistance Technique aux Malades en Fin de Vie. *Le Travail Humain*, Vol. 63, No. 2 (juin 2000), pp. 171-190.
- [117] Dr Claire Lewandowski. Maladie de Charcot (SLA) : âge, premiers symptômes, espérance de vie. 04/09/19
- [118] W. TOUIL 'Sclérose Latérale Amyotrophique Diagnostic et Prise en Charge. Université MOHAMMED V- RABAT 2017.
- [119] S. Solnik et al. Teager–Kaiser Operator Improves the Accuracy of EMG Onset Detection Independent of Signal to Noise ratio. *Acta Bioeng Biomech* 10: 65-68, 2008.
- [120] P. Konrad. A Practical Introduction to Kinesiological Electromyography. Noraxon INC. USA, 2005.

- [121] M. Farge. Wavelet Transforms and their Applications to Turbulence. *Annual Review of Fluid Mechanics* 24: 395–457, 1992.
- [122] A. Strazza<sup>1</sup>, F. Verdini<sup>1</sup>, L. Burattini<sup>1</sup>, S. Fioretti<sup>1</sup> and F. Di Nardo. A Time-Frequency Approach for the Assessment of Dynamic Muscle Co-contractions. *IFMBE Proceedings* 68/2, 2019.
- [123] R. Adham, I and S. S. Asfour. Continuous Wavelet Transform Application to EMG Signals During Human Gait. 0-7803-5 148-7/98/ IEEE, 1998.
- [124] O. Tahar and F. Bereksi-Reguig. An Automatic Wavelet Selection Scheme for Heart Sounds Denoising. *Proceedings IWBBIO 2014. Granada* 7-9 April, 2014.
- [125] F. Gabrieli. Apport des Techniques Temps Fréquence à la Caractérisation Mécanique du Corps Humain en Choc. Thèse de doctorat de l'université de la méditerranée 18 février 2010.
- [126] A. Phinyomark, C. Limsakul, P. A. Phukpattaranont, Comparative Study of Wavelet Denoising for Multifunction Myoelectric Control. *ICCAE*. 978-0-7695-3569-2/09, 2009.
- [127] Y. Yin, Y. Hu, P. Liu. The Research on Denoising Using Wavelet Transform. *IEEE ICMT*. 5177-5180, 2011.
- [128] V. Nassiri, M. Aminghafari, A.M. Djafari. Solving Noisy ICA Using Multivariate Wavelet Denoising with an Application to Noisy Latent Variables Regression. *Commun. Stat. Theor. M*. 43:10-12, 2297-2310, 2014.
- [129] D. L. Donoho, and I.M. Johnstone. Adapting to Unknown Smoothness Via Wavelet Shrinkage. *Journal of the American Statistical Association*, 90(432), pp 1200–1224, 1995.
- [130] N. Thakur, L. Mathew. sEMG Signal Classification Using Ensemble Learning Classification Approach and DWT. *Proceeding of IEEE International Conference on Current Trends toward Converging Technologies, Coimbatore, India*, 2018.
- [131] S. Márquez-Figueroa, Y. S. Shmaliy\*, Oscar Ibarra-Manzano. Optimal Extraction of EMG Signal Envelope and Artifacts Removal Assuming Colored Measurement Noise. *Biomedical Signal Processing and Control* 57, 101679, 2020.
- [132] Y.S.Shmaliy. *Continuous-Time Signals*. 1sted., Springer, 2006.
- [133] R.F.M.Kleissen, G.Zilvold. Estimation Uncertainty in Ensemble Averaged Surface EMG Profiles During Gait. *J.Electromyogr. Kinesiol.* 4(2) (1994)83–94.
- [134] C.Ahlström. Processing of the Phonocardiographic Signal Methods for the Intelligent Stethoscope. Thesis No. 1253, Linköping's universities, SE-58185 Linköping, Sweden, pp 34, 2006.
- [135] H. Liang, S. Lukkarinen, and I. Hartimo. Heart Sound Segmentation Algorithm Based on Heart Sound Envelopogram. in *Computers in Cardiology, Lund, Sweden*, pp 105-108, 1997.
- [136] O.P.Neto & E.A. Christou. Rectification of the EMG Signal Impairs the Identification of Oscillatory Input to the Muscle. *Articles from Journal of Neurophysiology* are provided here courtesy of American Physiological Society 2009.
- [137] C. F Amorim, R. A Marson. Application of Surface Electromyography in the Dynamics of Human Movement. *INTECH*, 10.5772/52463, octobre 2000.
- [138] M. A. Oskoei & H. Hu. Support Vector Machine based Classification Scheme for Myoelectric Control Applied to Upper Limb. *IEEE Transactions on Biomedical Engineering*, Vol.55, No.8, pp. 1956-1965, ISSN 0018-9294, 2008.

- [139] S. Du & M. Vuskovic. Temporal vs Spectral Approach to Feature Extraction from Prehensile EMG Signals. Proceedings of IRI 2004 IEEE International Conference on Information Reuse and Integration, pp. 344-350, ISBN 0-7803-8819-4, Las Vegas, NV, USA, November 8-10, 2004.
- [140] D. Farina, & R. Merletti. Comparison of Algorithms for Estimation of EMG Variables during Voluntary Isometric Contractions. Journal of Electromyography and Kinesiology, Vol.10, No.5, pp. 337-349, ISSN 1050-6411, 2000.
- [141] M. Knaflitz, R. Merletti & C. J. De Luca. Inference of Motor Unit Recruitment Order in Voluntary and Electrically Elicited Contractions. Journal of Applied Physiology, Vol.68, No.4, pp. 1657-1667, ISSN 8750-7587, 1990.
- [142] F. B. Stulen, & C. J. De Luca. Frequency Parameters of the Myoelectric Signal as a Measure of Muscle Conduction Velocity. IEEE Transactions on Biomedical Engineering, Vol.28, No.7, pp. 515-523, ISSN 0018-9294, 1981.
- [143] B. U. Kleine, D. F. Stegeman, D. Mund et al. Influence of Motoneuron Firing Synchronization on sEMG Characteristics in Dependence of Electrode Position. J Appl Physiol 2001; 91: 1588-1599.
- [144] D. Farina, R. Merletti et R.M. Enoka. The Extraction of Neural Strategies from the Surface EMG. J Appl Physiol 2004; 96: 1486-1495.
- [145] A. MOKDAD, S. M. DEBBAL, F MEZIANI. Diagnosis of Amyotrophic Lateral Sclerosis (ALS) Disorders Based on Electromyogram (EMG) Signal Analysis and Feature Selection. Polish Journal of Medical Physics and Engineering, Vol 26, Issue 3, September 2020.
- [146] A. Mokdad<sup>1</sup>, S. M. Debbal<sup>2</sup> and F. Meziani<sup>3</sup>. Classification of Electromyogram (EMG) Signal Using Time-Frequency Representation for Diagnosis of Amyotrophic Lateral Sclerosis (ALS) Disorders. International Journal of Advanced Science and Technology, Vol. 29, No. 3, pp. 2899- 2910, 2020.
- [147] Tsai, A.C., Luh, J.J. and Lin, T.T. A Novel STFT-Ranking Feature of Multi-Channel EMG for Motion Pattern Recognition. Expert Systems with Applications, Volume 42, No. 7, pp.3327-3341, 2015
- [148] D. Joshi, B.H. Nakamura, and M.E. Hahn. High energy spectrogram with integrated prior knowledge for EMG-based locomotion classification. Medical Engineering and Physics, Volume 37, No. 5, pp. 518-524, 2015
- [149] Too, J., Abdullah, A.R, Saad, N.M., Ali, N.M and Zawawi, T.N.S.T. Application of Spectrogram and Discrete Wavelet Transform for EMG Pattern Recognition. Journal of Theoretical & Applied Information Technology, Volume 96, No. 10 (2018), pp. 3036-3047
- [150] M. Nikolic. Detailed analysis of clinical electromyography signals: EMG decomposition, findings and firing pattern analysis in controls and patients with myopathy and amyotrophic lateral sclerosis. Ph.D. dissertation, [Online]. Available: <http://www.emglab.net>. 2001
- [151] T.N.S.T. Zawawi, A.R. Abdullah, E.F. Shair, and S.M. Saleh. Performance Comparison of EMG Signal Analysis for Manual Lifting using Spectrogram. Journal of Telecommunication, Electronic and Computer Engineering, Volume 8, No. 7 (2016), pp. 29-34.
- [152] B. Boashash, G. Azemi, N. Ali Khan. Principles of Time-Frequency Feature Extraction for Change Detection in Non-Stationary Signals: Applications to New- Born EEG Abnormality Detection. Pattern Recognit. 48, pp. 616-627, 2014.

- [153] B. Boashash, S. Ouelha, Automatic Signal Abnormality Detection Using Time-Frequency Features and Machine Learning: a Newborn EEG Seizure Case Study, *Know I. Based Syst.* 106, pp. 38–50, 2016
- [154] Mazher, M., Aziz, A.A., Malik, A.S. and Amin, H.U. An EEG-based cognitive load assessment in multimedia learning using feature extraction and partial directed coherence. *IEEE Access*, Volume 5, pp. 14819-14829, 2017.
- [155] P. A. Karthick, D. M. Ghosh and S. Ramakrishnan. Surface Electromyography Based Muscle Fatigue Detection Using High-Resolution Time-Frequency Methods and Machine Learning Algorithms. *Computer methods and programs in biomedicine*, Volume 154, pp. 45-56, 2018
- [156] M. Gonzalez-Izal, A. Malanda, I. Navarro-Amezqueta, E. M. Gorostiaga, F. Mallor, J. Ibanez and M. Izquierdo. EMG Spectral Indices and Muscle Power Fatigue During Dynamic Contractions. *Journal of Electromyography and Kinesiology*, Volume 20, No. 2 (2010), pp. 233-240.
- [157] A. Strazza, F. Verdini, A. Mengarelli, S. Cardarelli, L. Burattini, S. Fioretti, and F. Di Nardo. A Time-Frequency Approach for the Assessment of Dynamic Muscle Co-contractions. *World Congress on Medical Physics and Biomedical Engineering, IFMBE Proceedings 68/2*, 2018.
- [158] B. Hudgins, P. Parker, and R. N. Scott. A New Strategy for Multifunction Myoelectric Control. *IEEE Trans. Biomed. Eng.*, vol. 40, no. 1, pp. 82–94, 1993
- [159] A. RAMMAL. Modélisation Multi-Agent dans un Processus de Gestion Multi Acteur, Application au Maintien à Domicile. Thèse de doctorat de l'Université Toulouse 2010
- [160] O. ALAOUI ISMAILI. Clustering Prédicatif Décrire et Prédire Simultanément. Thèse de doctorat de l'Université Paris–Saclay 10/11/16.
- [161] P. Cunningham, and S.J. Delany. k-nearest neighbor classifiers. *Mult Classif Syst*, 1–17, 2007
- [162] S. Thirumuruganathan. A Detailed Introduction to K-Nearest Neighbor (KNN) Algorithm. 2010.
- [163] E. Fix, J. Hodges. Discriminatory Analysis, Nonparametric Discrimination: Consistency Properties. *International Statistical Review*, 57(3), 238-247, 1989
- [164] Sebastiani, F. Machine Learning in Automated Text Categorization. *ACM computing surveys*, 34(1), 1-47, 2002.
- [165] Prof. Thomas B. Fomby. K-Nearest Neighbors Algorithm Prediction and Classification. Department of Economics, Southern Methodist University, Dallas, TX 75275, February 2008.
- [166] Méthode des KNN, (k nearest neighbors, ou k plus proches voisins). Nicolas Turenne .fr; INRA, 2006.
- [167] BARIGOU, F. Contribution à la Catégorisation de Textes et à l'Extraction d'Information. Thèse de doctorat de l'université d'Oran, 2013.
- [168] I, Naïve Bayes, Estimation de Densité, Apprentissage et KNN, 29 Septembre 2009.
- [169] R. Fisher. The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, 7 :179–188, 1936.

- [170] F. Lotte, M. CONGEDO, A. LECUYER, F. LAMARCHE, B. ARNALDI. A Review of Classification Algorithms for EEG-Based Brain-Computer Interfaces. *Journal of neural engineering*, 4(2) : R1, 2007
- [171] R. ZIANI. Contribution à l'Analyse et à la Classification Automatique des Défauts Mécaniques. Thèse de doctorat, Université Ferhat Abbas – Sétif 1, 2015.
- [172] A. Djeflal. Utilisation des Méthodes Support Vector Machine (SVM) dans l'Analyse des Bases de Données. Thèse de doctorat, Université Mohamed Khider-Biskra, 2012
- [173] F. Zaiz. Les Machines à Vecteurs de Supports (SVM) pour la Reconnaissance des Caractères Manuscrits Arabes. Thèse de doctorat, Université Mohamed Khider Biskra., 2010
- [174] Burges, C. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery* 2(2): 121-167, 1998
- [175] Gunn. Support Vector Machines for Classification and Regression. Technical Report, University of Southampton, 1998.
- [176] C. W. Hsu and C. J. Lin. A simple decomposition method for support vector machine. *Machine Learning*, vol. 46, pp. 219-314, 2002.
- [177] P. Bonato, S.H. Roy, M. Knaflitz, C.J. De Luca. Time-Frequency Parameters of the Surface Myoelectric Signal for Assessing Muscle Fatigue During Cyclic Dynamic Contractions. *IEEE Trans. Biomed. Eng.* 48(7), pp. 745-53, 2001.
- [178] A. Mokdad<sup>1</sup>, S. M. Debbal<sup>2</sup> and F. Meziani<sup>3</sup>. Classification and signal processing analysis Of The pathological electromyogram signal (EMG). *International Journal of Medical Engineering and Informatics (IJMEI)* Inderscience Publishers, 2020.
- [179] A. M. K. A. Sadiq, S. Gul Khawaja, M. U. Akram, A. Saeed. Physical Action Categorization using Signal Analysis and Machine Learning. College of E&ME, National University of Sciences and Technology, Islamabad, Pakistan, <https://arxiv.org/ftp/arxiv/papers/2008/2008.06971.pdf>.
- [180] SP. Arjunan, DK. Kumar: Fractal theory based non-linear analysis of sEMG. *Proceedings of 3rd International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)*, Melbourne, Australia, 545-548, 2007.



## Résumé

Pour un diagnostic fiable de l'état de fonctionnement du muscle et son devenir en cas de maladie, cette étude entend d'analyser pas à pas le signal EMG à partir d'un ensemble de caractéristiques qui étaient auparavant utilisées par plusieurs chercheurs pour traquer les troubles les plus ambigus et leur traitement, nous parlerons ici de la sclérose latérale amyotrophique et les moyens de prouver ou de nier son existence, Cette étude est constitué essentiellement de trois parties, une base de données des signaux EMGs intramusculaire a été collecté, la première partie est basé sur les technique de prétraitement : de débruitage, l'analyse temporelle, fréquentielle et l'analyse bispectrale, la partie suivante qui fera appel à des techniques d'analyse temps-fréquence (transformé de Fourier à court terme, transformée d'ondelettes) pour obtenir des caractéristiques spectro-temporelle des signaux EMGs qui sont de nature non stationnaire, la dernière partie qui pourra utiliser les résultats spectro-temporelle obtenus pour aider à la compréhension et à la classification des signaux EMG selon la pathologie et sa sévérité. Ce sont les différentes étapes qui sont réalisées pour finaliser ce travail.

**Mots clés** \_ électromyographie, sclérose latérale amyotrophique, analyse, classification, sévérité.

---

## Abstract

For a reliable diagnosis of the state of functioning of the muscle and its future in case of disease, this study intends to analyze step by step the EMG signal from a set of characteristics that were previously used by several researchers to track down most ambiguous disorders and their treatment, we will talk here about amyotrophic lateral sclerosis disorder and the means to prove or deny its existence, This study consists essentially of three parts, a database of intramuscular EMGs signals has been collected, the first part is based on preprocessing techniques: denoising, time and frequency analysis and bispectral analysis, the next part which will use time-frequency analysis techniques (short-term Fourier transform, wavelet transform) to obtain spectro-temporal characteristics of the EMGs signals which is non-stationary signal, the last part which will be able to use the spectro-temporal results obtained in understanding and classifying EMG signals according to the pathology and its severity. These are the different steps that are carried out to finalize this work.

**Index Terms** \_ electromyography, amyotrophic lateral sclerosis, analysis, classification, severity.

---

## ملخص

من أجل تشخيص موثوق لحالة العضلات ومستقبلها في حالة المرض، تهدف هذه الدراسة إلى تحليل إشارة المخطط الكهربائي للعضلة خطوة بخطوة من خلال مجموعة من الخصائص التي سبق استخدامها من قبل العديد من الباحثين لتعقب معظم الاضطرابات الغامضة. وعلاجها ، سنتحدث هنا عن التصلب الجانبي الضموري ووسائل إثبات أو نفي وجوده ، تتكون هذه الدراسة أساساً من ثلاثة أجزاء مهمة بعد جمع قاعدة بيانات التخطيط الكهربائي العضلي ، الجزء الأول يعتمد على تقنيات المعالجة : تقليل الضوضاء ، التحليل الزمني و التردد والتحلل ثنائي الطيف ، الجزء التالي الذي سيستخدم تقنيات تحليل الوقت والتردد معا (تحويل فورييه قصير المدى ، تحويل الموج) للحصول على الخصائص الطيفية والزمنية لإشارات ذات الطبيعة غير الثابتة ، الجزء الأخير الذي سوف تكون فيه قادرا على استخدام النتائج الطيفية والزمنية التي تم الحصول عليها لتساعدك في فهم وتصنيف إشارات المخطط الكهربائي العضلي حسب المرض وشدته ، وهذه هي الخطوات المختلفة التي تم تنفيذها لإنهاء هذا العمل.

**كلمات مفتاحية** : لتخطيط الكهربائي للعضلة، التصلب الجانبي الضموري، التحليل، التصنيف، الشدة.