

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 Biomédicale**

**Par : Didi Ahmed Ali**

**Sujet**

**Développement et réalisation d'un dispositif de mesure du signal électromyogramme EMG : analyse et traitement en vue de l'évaluation de la fatigue musculaire**

Soutenue publiquement, le 12 /02 /26 , devant le jury composé de :

M. Salim KERAI	Professeur	Univ. Tlemcen	Président
M. Fethi BEREKSI REGUIG	Professeur	Univ. Tlemcen	Directeur de thèse
M. Lotfi HAMZA CHERIF	Professeur	Univ. Tlemcen	Examineur 1
M. Tahar OMARI	MCA	Univ. Aïn Temouchent	Examineur 2

## Résumé

La présente thèse s'inscrit dans le domaine du génie biomédical et porte sur la prédiction de la force musculaire et la détection des phases locales de fatigue à partir du signal électromyographique de surface (sEMG). Un système matériel dédié a été développé pour l'acquisition synchrone du signal sEMG (1600 Hz) et de la force musculaire (80 Hz) à l'aide d'un amplificateur AD620, d'un module HX711 et d'une carte Arduino/ESP32, assurant une mesure fiable et reproductible.

Sur le plan algorithmique, plusieurs modèles de régression ont été comparés à des approches de classification traditionnelles afin d'évaluer la capacité des modèles à suivre les variations continues de la force et à détecter les transitions entre les trois phases de fatigue (non fatiguée, transition, fatiguée). Dix modèles de régression ont été testés (MLR, Ridge, Lasso, ElasticNet, PCR, PLS, SVR, Random Forest, Gradient Boosting et ANN), avec une validation Leave-One-Subject-Out (LOSO) pour garantir la généralisabilité intersujets.

Une optimisation originale basée sur la minimisation des mismatches (désaccords entre la phase réelle et la phase prédite) a été proposée, en remplacement de l'optimisation classique par corrélation. Cette approche a permis une amélioration significative de la détection des phases de fatigue, confirmant la supériorité des modèles de régression sur les modèles de classification pour ce type d'application biomédicale.

**Mots clés :** sEMG, Force musculaire, Fatigue locale, Régression, Classification, Optimisation, Mismatch, LOSO, Arduino, HX711, AD620.

*Je dédie ce travail  
à la mémoire de mon cher papa.*

## Remerciements

Je tiens avant tout à exprimer ma profonde gratitude à Monsieur le Professeur Bereksi Reguig Fethi, mon directeur de thèse, pour la confiance qu'il m'a accordée, son encadrement rigoureux et sa disponibilité constante tout au long de ces années. Ses conseils avisés, sa rigueur scientifique et sa bienveillance ont été pour moi une source d'inspiration et un modèle de persévérance.

Mes sincères remerciements vont également à Monsieur le Professeur Kerai Salim, président du jury, pour son soutien indéfectible, ses encouragements et sa grande générosité scientifique et humaine.

Je remercie aussi Monsieur le Professeur Hamza Cherif Lotfi et Monsieur le Docteur Omari Tahar pour l'honneur qu'ils me font en acceptant d'examiner ce travail et pour l'intérêt qu'ils portent à mes recherches.

Je souhaite exprimer ma reconnaissance à l'ensemble des enseignants, collègues et membres du laboratoire de Génie Biomédical de l'Université de Tlemcen pour leurs conseils, leur aide technique et leur esprit de collaboration. Je remercie en particulier mes chers amis les enseignants Badir Benkrelifa Lahouaria et Mohamed Debbal de l'Université de Aïn Témouchent, ainsi que le Dr Belaid Boumedyene de l'Université d'Oran, pour leur aide concrète et leur précieux soutien tout au long de ce travail. J'adresse également mes remerciements au Professeur Benali Redouane, au Dr Mohamed Anes Bereksi Reguig et au Dr Kholkhal Mourad de l'Université de Tlemcen pour leur disponibilité, leurs conseils et leur bienveillance.

Mes pensées les plus chaleureuses vont à mes parents pour leur amour, leurs sacrifices et leur confiance inébranlable, ainsi qu'à mes sœurs, en particulier le Dr Ibtissem, pour son aide précieuse, son affection et son soutien constant tout au long de ce parcours.

J'exprime également ma profonde reconnaissance à mon oncle, le Professeur Hacen Dib du département de mathématiques de l'Université de Tlemcen, pour son aide, ses conseils et sa bienveillance.

Je tiens aussi à exprimer toute ma reconnaissance à ma chère épouse, dont la patience, la compréhension et l'encouragement m'ont accompagné jusqu'à l'aboutissement de ce travail et à ma petite fille Hanaa, source inépuisable de joie, de motivation et de lumière dans ma vie.

# Table des matières

<b>Table des figures</b>	<b>9</b>
<b>Liste des tableaux</b>	<b>13</b>
<b>Introduction générale</b>	<b>15</b>
<b>1 Physiologie musculaire et électromyographie de surface</b>	<b>18</b>
1.1 Introduction . . . . .	18
1.2 Le muscle squelettique . . . . .	18
1.2.1 Structure anatomique . . . . .	18
1.2.2 Types de contractions musculaires . . . . .	22
1.2.2.1 Contractions selon la variation de longueur . . . . .	22
1.2.2.2 Contractions selon la vitesse d'exécution . . . . .	24
1.2.2.3 Contractions selon le mode de résistance . . . . .	25
1.2.2.4 Contractions spécialisées . . . . .	25
1.2.3 Physiologie de la contraction musculaire . . . . .	26
1.2.3.1 Commande Cérébrale et Transmission Centrale . . . . .	26
1.2.3.2 Transmission de la commande musculaire . . . . .	27
1.2.3.3 Transmission neuromusculaire . . . . .	28
1.2.3.4 Conduction Intrafibreuse . . . . .	29
1.2.3.5 Contrôle Intracellulaire . . . . .	30
1.2.3.6 Interaction Myofilamentaire . . . . .	31
1.2.3.7 Phase de Relâchement . . . . .	32
1.2.4 Physiologie de la fatigue musculaire . . . . .	32
1.2.4.1 Manifestations macroscopiques . . . . .	32
1.2.4.2 Mécanismes microscopiques . . . . .	34
1.2.5 La force musculaire . . . . .	35
1.2.6 L'électromyographie de surface (sEMG) . . . . .	36
1.2.6.1 Configuration des électrodes . . . . .	36
1.2.7 Relation entre sEMG et fatigue musculaire . . . . .	37
1.3 Conclusion . . . . .	37

<b>2</b>	<b>Développement d'un système d'enregistrement EMG/Force pour l'étude de la fatigue musculaire</b>	<b>38</b>
2.1	Introduction . . . . .	38
2.2	Mesure des signaux biologiques . . . . .	39
2.2.1	L'électromyogramme . . . . .	39
2.2.1.1	Amplification différentielle avec l'AD620 . . . . .	40
2.2.1.2	Centrage du signal via le LM358 . . . . .	41
2.2.1.3	Tampon de sortie . . . . .	41
2.2.1.4	Alimentation symétrique simulée (ICL7660) . . . . .	42
2.2.2	La force musculaire . . . . .	42
2.2.2.1	Principe de fonctionnement du pont de Wheatstone . . . . .	42
2.2.2.2	Extraction et interfaçage du signal avec HX711 . . . . .	43
2.2.2.3	Choix de la fréquence d'échantillonnage . . . . .	44
2.2.3	Acquisition des signaux . . . . .	44
2.2.3.1	La carte ESP32-WROOM-32 . . . . .	44
2.2.3.2	Intégration du signal EMG (via la carte AD620) . . . . .	45
2.2.3.3	Lecture du signal de force via le module HX711 . . . . .	45
2.2.3.4	Synchronisation des deux signaux . . . . .	46
2.2.3.5	Schéma du montage expérimental . . . . .	46
2.2.3.6	Chaîne d'acquisition . . . . .	47
2.3	Conclusion . . . . .	48
<b>3</b>	<b>Extraction multi-domaines des paramètres EMG</b>	<b>49</b>
3.1	Introduction . . . . .	49
3.2	Protocole expérimental d'acquisition des signaux EMG et de force . . . . .	50
3.3	Prétraitement du signal EMG . . . . .	50
3.3.1	Filtrage . . . . .	51
3.3.2	Segmentation du signal . . . . .	51
3.4	Extraction des paramètres EMG . . . . .	52
3.4.1	Paramètres temporels . . . . .	53
3.4.2	Paramètres fréquentiels . . . . .	54
3.4.3	Paramètres temps-fréquence . . . . .	55
3.4.4	Paramètres non-linéaires . . . . .	55
3.5	Résultats et discussion . . . . .	55
3.5.1	Visualisation des paramètres EMG . . . . .	55
3.5.2	Interprétation qualitative . . . . .	67
3.5.3	Corrélation entre paramètres et force . . . . .	68

3.5.4	Construction de la matrice de paramètres (+ normalisation) . . . . .	71
3.6	Conclusion . . . . .	71
<b>4</b>	<b>Détection des phases de fatigue par classification supervisée</b>	<b>73</b>
4.1	Introduction . . . . .	73
4.2	Méthodologie de classification . . . . .	74
4.2.1	Stratégie de validation inter-sujets (LOSO) . . . . .	74
4.2.2	Constitution des ensembles de données . . . . .	75
4.2.3	Modèles de classification évalués . . . . .	76
4.2.3.1	Classificateurs linéaires et simples . . . . .	76
4.2.3.2	Classifieur à base de distance . . . . .	76
4.2.3.3	Classifieur à marge maximale . . . . .	76
4.2.3.4	Classifieurs par arbres de décision . . . . .	76
4.2.3.5	Méthodes d'ensemble . . . . .	77
4.2.3.6	Réseau de neurones . . . . .	78
4.2.3.7	Méthodes floues . . . . .	78
4.2.4	Indicateur principal de performance . . . . .	78
4.3	Résultats expérimentaux . . . . .	79
4.3.1	Résultats individuels pour chaque sujet . . . . .	79
4.3.2	Meilleur modèle par sujet . . . . .	87
4.3.3	Top 3 des modèles par sujet . . . . .	88
4.3.4	Analyse croisée des performances . . . . .	89
4.4	Visualisation colorée des phases de fatigue sur le signal EMG	90
4.5	Discussion . . . . .	98
4.5.1	Interprétation des performances globales . . . . .	98
4.5.2	Robustesse des classifieurs simples vs complexes . . . . .	99
4.6	Conclusion . . . . .	99
<b>5</b>	<b>Prédiction continue de la force musculaire et détection indirecte de la fatigue</b>	<b>100</b>
5.1	Introduction . . . . .	100
5.2	Méthodologie globale . . . . .	101
5.2.1	Workflow complet de prédiction . . . . .	102
5.2.2	Modèles de régression testés . . . . .	103
5.2.2.1	Modèles linéaires . . . . .	103
5.2.2.2	Modèles non linéaires . . . . .	104
5.2.3	Validation croisée inter-sujets (LOSO) . . . . .	104

5.2.4	Optimisation des caractéristiques par exclusion unitaire (LOFO)	105
5.2.5	Critère d'évaluation	106
5.3	Résultats expérimentaux	106
5.3.1	Analyse de la persistance des caractéristiques sélectionnées	106
5.3.2	Analyse individuelle des résultats par sujet	107
5.3.3	Visualisation de la force prédite par le meilleur modèle	108
5.3.4	Détection des phases de fatigue à partir de la force prédite	117
5.3.5	Analyse globale de la performance des modèles	124
5.4	Conclusion	126
	<b>Conclusion générale</b>	<b>127</b>
	<b>Bibliographie</b>	<b>129</b>

# Table des figures

1.1	Schéma des trois différents types de muscles : squelettique, lisse et cardiaque [1] . . . . .	19
1.2	Vue antérieure et postérieure des muscles squelettiques du corps humain [2] . . . . .	20
1.3	Structure du muscle squelettique [2] . . . . .	21
1.4	Structure de la fibre musculaire [2] . . . . .	22
1.5	Types de contractions musculaires (concentrique-excentrique-isométrique) [3] . . . . .	24
1.6	Structure de l'unité motrice [2] . . . . .	28
1.7	La jonction neuro musculaire [4] . . . . .	29
1.8	Schéma illustrant les différentes lignes et bandes qui constituent le sarcomère [1] . . . . .	31
1.9	Cycle d'interaction actine-myosine sous contrôle de l'ATP et du calcium . . . . .	32
1.10	Echelle de Borg [5] . . . . .	33
1.11	Accumulation des métabolites impliquées dans la fatigue musculaire . . . . .	35
2.1	Carte d'amplification EMG [6] . . . . .	40
2.2	Schéma électrique détaillé de la carte d'amplification [7] . . . . .	41
2.3	Dynamomètre EH-108 [8] . . . . .	42
2.4	Le convertisseur HX-711 [9] . . . . .	43
2.5	La carte d'acquisition ESP wroom 32 [10] . . . . .	45
2.6	Montage HX711+ EH108 connecté à l'ESP32-WROOM-32 [11] . . . . .	47
2.7	Système d'acquisition des signaux EMG et Force . . . . .	48
3.1	Signal EMG (exemple : sujet 3) . . . . .	51
3.2	Visualisation des 23 paramètres EMG sur 50 segments du signal . . . . .	67
3.3	Force observée sujet 3 . . . . .	69
4.1	Les accuracies moyennes . . . . .	90

4.2	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 1, en utilisant le classifieur optimal pour chacun. . . . .	91
4.3	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 2, en utilisant le classifieur optimal pour chacun. . . . .	91
4.4	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 3, en utilisant le classifieur optimal pour chacun. . . . .	92
4.5	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 4, en utilisant le classifieur optimal pour chacun. . . . .	92
4.6	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 5, en utilisant le classifieur optimal pour chacun. . . . .	93
4.7	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 6, en utilisant le classifieur optimal pour chacun. . . . .	93
4.8	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 7, en utilisant le classifieur optimal pour chacun. . . . .	94
4.9	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 8, en utilisant le classifieur optimal pour chacun. . . . .	94
4.10	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 9, en utilisant le classifieur optimal pour chacun. . . . .	95
4.11	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 10, en utilisant le classifieur optimal pour chacun. . . . .	95
4.12	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 11, en utilisant le classifieur optimal pour chacun. . . . .	96
4.13	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 12, en utilisant le classifieur optimal pour chacun. . . . .	96
4.14	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 13, en utilisant le classifieur optimal pour chacun. . . . .	97

4.15	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 14, en utilisant le classifieur optimal pour chacun. . . . .	97
4.16	Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 15, en utilisant le classifieur optimal pour chacun. . . . .	98
5.1	Architecture complète du processus de prédiction continue de la force musculaire à partir de signaux EMG . . . . .	102
5.2	Force observée et prédite avec la méthode GradientBoosting pour le sujet 1. . . . .	109
5.3	Force observée et prédite avec la méthode GradientBoosting pour le sujet 2. . . . .	109
5.4	Force observée et prédite avec la méthode GradientBoosting pour le sujet 3. . . . .	110
5.5	Force observée et prédite avec la méthode GradientBoosting pour le sujet 4. . . . .	110
5.6	Force observée et prédite avec la méthode GradientBoosting pour le sujet 5. . . . .	111
5.7	Force observée et prédite avec la méthode GradientBoosting pour le sujet 6. . . . .	111
5.8	Force observée et prédite avec la méthode GradientBoosting pour le sujet 7. . . . .	112
5.9	Force observée et prédite avec la méthode GradientBoosting pour le sujet 8. . . . .	112
5.10	Force observée et prédite avec la méthode GradientBoosting pour le sujet 9. . . . .	113
5.11	Force observée et prédite avec la méthode GradientBoosting pour le sujet 10. . . . .	113
5.12	Force observée et prédite avec la méthode GradientBoosting pour le sujet 11. . . . .	114
5.13	Force observée et prédite avec la méthode GradientBoosting pour le sujet 12. . . . .	114
5.14	Force observée et prédite avec la méthode GradientBoosting pour le sujet 13. . . . .	115
5.15	Force observée et prédite avec la méthode GradientBoosting pour le sujet 14. . . . .	115
5.16	Force observée et prédite avec la méthode GradientBoosting pour le sujet 15. . . . .	116

5.17	Force prédite avec la méthode GradientBoosting pour le sujet 1.	117
5.18	Force prédite avec la méthode GradientBoosting pour le sujet 2.	118
5.19	Force prédite avec la méthode GradientBoosting pour le sujet 3.	118
5.20	Force prédite avec la méthode GradientBoosting pour le sujet 4.	119
5.21	Force prédite avec la méthode GradientBoosting pour le sujet 5.	119
5.22	Force prédite avec la méthode GradientBoosting pour le sujet 6.	120
5.23	Force prédite avec la méthode GradientBoosting pour le sujet 7.	120
5.24	Force prédite avec la méthode GradientBoosting pour le sujet 8.	121
5.25	Force prédite avec la méthode GradientBoosting pour le sujet 9.	121
5.26	Force prédite avec la méthode GradientBoosting pour le sujet 10. . . . .	122
5.27	Force prédite avec la méthode GradientBoosting pour le sujet 11. . . . .	122
5.28	Force prédite avec la méthode GradientBoosting pour le sujet 12. . . . .	123
5.29	Force prédite avec la méthode GradientBoosting pour le sujet 13. . . . .	123
5.30	Force prédite avec la méthode GradientBoosting pour le sujet 14. . . . .	124
5.31	Force prédite avec la méthode GradientBoosting pour le sujet 15. . . . .	124
5.32	Nombre total de mismatches par modèle de régression. . . . .	125
5.33	Accuracy moyenne par modèle de régression. . . . .	125

# Liste des tableaux

3.1	Corrélation de Pearson entre les paramètres EMG et la force (sur les 30% supérieurs) : sujet 3 . . . . .	70
4.1	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 1 . . . . .	80
4.2	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 2 . . . . .	80
4.3	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 3 . . . . .	81
4.4	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 4 . . . . .	81
4.5	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 5 . . . . .	82
4.6	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 6 . . . . .	82
4.7	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 7 . . . . .	83
4.8	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 8 . . . . .	83
4.9	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 9 . . . . .	84
4.10	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 10 . . . . .	84
4.11	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 11 . . . . .	85
4.12	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 12 . . . . .	85
4.13	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 13 . . . . .	86
4.14	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 14 . . . . .	86

4.15	Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 15 . . . . .	87
4.16	Performances des modèles par sujet . . . . .	87
4.17	Top modèles et leurs performances par sujet . . . . .	88
4.18	Modèles et leur nombre d'apparitions dans le Top 3 . . . . .	89
5.1	Résultats comparatifs des méthodes de régression et machine learning . . . . .	108

# Introduction

La fatigue musculaire constitue un phénomène physiologique complexe, se traduisant par une réduction progressive de la capacité d'un muscle à générer de la force. Ce processus multifactoriel est influencé par des aspects métaboliques, neurologiques, mécaniques et psychologiques. Sa compréhension et sa quantification sont devenues des enjeux majeurs dans de nombreux domaines, notamment en médecine physique, en rééducation fonctionnelle, en ergonomie, en sport de haut niveau, et plus récemment dans le développement de systèmes d'assistance robotisée ou de neuroprothèses. La capacité à détecter, modéliser et suivre l'évolution de la fatigue musculaire ouvre des perspectives importantes en matière de prévention des blessures, d'optimisation de la performance et d'assistance personnalisée.

Dans ce contexte, l'électromyographie de surface (EMG) s'impose comme un outil non invasif privilégié pour accéder aux informations électrophysiologiques relatives à l'activité musculaire. Le signal EMG reflète les potentiels d'action générés lors de la contraction musculaire, et peut ainsi être exploité pour suivre les modifications du recrutement moteur au cours de l'effort. Cependant, la richesse et la complexité du signal EMG nécessitent des traitements sophistiqués pour en extraire des descripteurs pertinents et fiables. Par ailleurs, le lien entre l'activité électrique mesurée et la force générée n'est ni linéaire ni universel, d'où l'intérêt d'approches d'apprentissage automatique capables de modéliser ces relations complexes.

La présente thèse s'inscrit dans une démarche pluridisciplinaire qui vise à développer une architecture complète, modulaire et évolutive, pour l'analyse automatique de la fatigue musculaire à partir de signaux EMG. Cette architecture repose sur deux axes complémentaires : un axe matériel, centré sur la conception d'un dispositif d'acquisition synchronisé EMG/force à base de composants discrets, et un axe logiciel, basé sur le traitement avancé du signal, l'extraction de caractéristiques multi-domaines et l'application de modèles d'intelligence artificielle pour la classification ou la régression des états de fatigue.

Cette thèse apporte ainsi une contribution originale à la fois instrumentale et algorithmique pour l'analyse de la fatigue musculaire. Elle démontre la pertinence d'approches hybrides combinant des mesures simples, des traitements avancés du signal, et des modèles intelligents pour une inférence physiologique fiable et généralisable.

Le chapitre 1 établit les bases théoriques et physiologiques de l'étude. Il présente les mécanismes de la contraction musculaire, les facteurs contribuant à l'apparition de la fatigue, ainsi que les différents types de fatigue (centrale, périphérique). Il introduit également l'électromyographie de surface en tant qu'outil d'analyse du système neuromusculaire, et présente les principaux paramètres classiquement extraits du signal EMG dans une optique de quantification de la fatigue.

Le chapitre 2 est consacré à la conception du système d'acquisition. Celui-ci a été élaboré à partir de composants électroniques simples (amplificateur instrumentation AD620, convertisseur analogique-numérique HX711, microcontrôleur ESP32), dans le but d'obtenir une solution économique, flexible et transportable. Le système permet l'enregistrement simultané de l'EMG et de la force de préhension via un capteur dynamique, avec une fréquence d'échantillonnage adaptée à la dynamique des signaux d'intérêt. Les spécifications techniques, le schéma électronique, le traitement numérique embarqué ainsi que l'interface de récupération des données sont présentés en détail.

Les chapitres 3 et 4 se concentrent exclusivement sur le traitement logiciel et les méthodes d'apprentissage automatique. Le chapitre 3 décrit la chaîne de traitement du signal EMG : filtrage, segmentation normalisée de la contraction en 50 fenêtres, et extraction de 23 paramètres couvrant plusieurs domaines (temps, fréquence, temps-fréquence, complexité). Cette base de données paramétrique constitue l'entrée des modèles d'apprentissage développés ultérieurement. Le chapitre 4 explore une approche classique et directe de classification supervisée des états de fatigue. Chaque segment EMG est étiqueté selon sa position dans la contraction (non fatigué, transition, fatigué), en se basant sur des seuils relatifs appliqués à la courbe de force mesurée. Treize modèles de classification sont comparés (SVM, KNN, arbres de décision, forêts aléatoires, réseaux de neurones, etc.) dans un protocole strict de validation croisée inter-sujets (LOSO). Les performances sont analysées selon plusieurs métriques et montrent une performance maximale atteignant 82 % pour le meilleur modèle.

Le chapitre 5 propose une alternative méthodologique plus souple : l'approche par régression continue de la force musculaire. Plutôt que de classifier les états de fatigue directement, cette stratégie consiste à estimer la force

générée à chaque segment EMG, puis à reconstituer les phases de fatigue par seuillage sur la courbe de force prédite. Dix modèles de régression (linéaires, non linéaires, neuronaux) sont évalués. Une sélection automatique des caractéristiques par LOFO est intégrée dans chaque itération du protocole LOSO.

# Chapitre 1

## Physiologie musculaire et électromyographie de surface

### 1.1 Introduction

Le muscle squelettique constitue l'un des piliers fondamentaux du mouvement humain. Par sa structure hautement organisée, il permet de convertir l'énergie chimique en travail mécanique, assurant ainsi la locomotion, le maintien postural, et l'interaction avec l'environnement. Comprendre les bases physiologiques du fonctionnement musculaire est essentiel non seulement en biomécanique et en médecine du sport, mais également dans les domaines de la rééducation, de la robotique et de la recherche clinique. Ce chapitre explore en profondeur l'architecture du muscle squelettique, les types de contractions possibles, les mécanismes neuromusculaires de la contraction, ainsi que les phénomènes liés à la fatigue musculaire. Il s'achève par une présentation de l'électromyographie de surface (sEMG), une méthode non invasive permettant de quantifier l'activité musculaire en temps réel et de mieux comprendre la relation entre l'activité électrique et la performance motrice.

### 1.2 Le muscle squelettique

#### 1.2.1. Structure anatomique

Le muscle squelettique présente une organisation hiérarchique complexe et fascinante, depuis l'échelle moléculaire jusqu'à l'organe complet, constituant l'un des systèmes biologiques les plus sophistiqués de l'organisme humain [12], [13]. Le corps humain comprend plus de 650 muscles squelettiques distincts, représentant environ 40 à 45% de la masse corporelle totale chez l'adulte sain, ce qui en fait le tissu le plus abondant de notre organisme [14]. Cette impressionnante diversité musculaire s'étend des muscles les plus volumineux,

comme le grand fessier qui peut peser plus de 1,5 kilogramme, aux plus minuscules, tels que le muscle stapédien de l'oreille moyenne qui ne mesure que quelques millimètres et constitue le plus petit muscle du corps humain [15]. Chaque muscle, qu'il contrôle les mouvements grossiers de locomotion ou les ajustements les plus fins de la posture et de l'expression faciale, partage une architecture fondamentale remarquablement conservée tout en présentant des adaptations spécifiques à sa fonction particulière [12], [16].

Cette organisation hiérarchique exceptionnelle permet une coordination parfaite entre des millions, voire des milliards d'unités contractiles microscopiques, orchestrant une symphonie mécanique d'une complexité inouïe [12], [13]. Depuis les contractions quasi-imperceptibles des muscles oculomoteurs qui permettent le suivi visuel précis d'un objet en mouvement, jusqu'aux contractions explosives et synchronisées de centaines de muscles lors d'un saut en hauteur, cette architecture permet de générer une gamme stupéfiante de mouvements [15], [17]. La précision peut atteindre des niveaux extraordinaires, comme dans les gestes du chirurgien ou du musicien virtuose, tandis que la puissance peut culminer avec des forces dépassant plusieurs fois le poids corporel lors d'efforts maximaux [16]. Cette dualité entre précision et puissance trouve son origine dans l'organisation hiérarchique unique du muscle squelettique, où chaque niveau structural contribue à cette performance remarquable [13], [18].

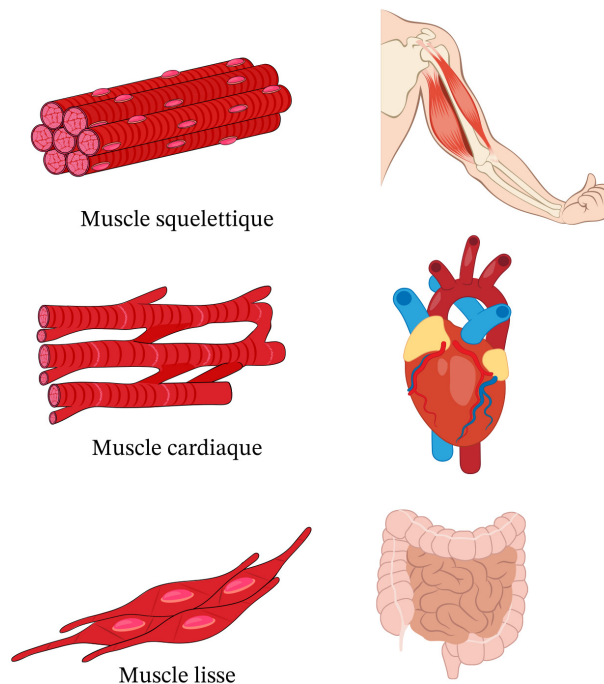


FIGURE 1.1 – Schéma des trois différents types de muscles : squelettique, lisse et cardiaque [1]




FIGURE 1.2 – Vue antérieure et postérieure des muscles squelettiques du corps humain [2]

L'ensemble du muscle est maintenu par un système d'enveloppes conjonctives qui assurent sa cohésion structurelle. L'épimysium forme l'enveloppe externe constituée de tissu conjonctif dense irrégulier, se prolongeant aux extrémités pour former les tendons qui s'insèrent sur les os [19]. Cette enveloppe protectrice renferme une organisation interne tout aussi sophistiquée, où le péri-mysium divise le muscle en faisceaux appelés fascicules, contenant chacun 10 à 100 fibres musculaires [20]. Au niveau le plus fin, l'endomysium entoure individuellement chaque fibre musculaire, créant un microenvironnement riche en capillaires sanguins et terminaisons nerveuses, essentiels à l'oxygénation, à l'approvisionnement métabolique et à la conduction neuromusculaire [21]. Ce réseau conjonctif joue également un rôle crucial dans la transmission latérale de la force entre les fibres et vers le tendon [22].




FIGURE 1.3 – Structure du muscle squelettique [2]

Chaque fibre musculaire constitue une cellule extraordinaire par ses dimensions, pouvant atteindre 30 cm de longueur et 10 à 100  $\mu\text{m}$  de diamètre. Cette cellule géante multinucléée révèle une adaptation remarquable à sa fonction contractile, avec ses noyaux positionnés en périphérie sous la membrane plasmique appelée sarcolemme. Le cytoplasme, nommé sarcoplasme, contient de nombreuses myofibrilles disposées parallèlement à l'axe de la fibre, occupant la majeure partie de l'espace cellulaire et conférant à la cellule son potentiel contractile [23].

Ces myofibrilles, représentant 80% du volume cellulaire, révèlent une organisation d'une précision microscopique. Elles sont constituées d'une succession de sarcomères, unités contractiles de base mesurant environ 2,5  $\mu\text{m}$  de longueur au repos [24]. Chaque sarcomère, délimité par les disques Z, présente une alternance caractéristique de bandes sombres (bandes A) et claires (bandes I), créant l'aspect strié distinctif du muscle squelettique. Cette striation n'est pas qu'esthétique mais reflète l'organisation moléculaire précise nécessaire à la contraction [25].

Au cœur du sarcomère, deux types de filaments protéiques orchestrent le phénomène contractile. Les filaments épais de 15 nm de diamètre, composés de myosine, occupent le centre du sarcomère et forment la bande A. En parallèle, les filaments fins de 7 nm de diamètre, composés d'actine, de tro-

pomyosine et de troponine, s'étendent de part et d'autre des disques Z dans les bandes I. Cette disposition géométrique permet un glissement optimal des filaments lors de la contraction [26].




FIGURE 1.4 – Structure de la fibre musculaire [2]

## 1.2.2. Types de contractions musculaires

Les contractions musculaires se classifient selon plusieurs critères, principalement en fonction de la variation de longueur du muscle et de la vitesse d'exécution. Cette classification permet de comprendre les différents modes de fonctionnement du système musculaire et leurs applications pratiques.

### 1.2.2.1. Contractions selon la variation de longueur

Les contractions musculaires se divisent en trois grandes catégories selon que le muscle change de longueur ou reste stable pendant l'effort.

La **contraction concentrique** constitue le type de contraction le plus familier, où le muscle se raccourcit tout en développant une tension. Durant cette phase, les filaments d'actine et de myosine glissent l'un sur l'autre, rapprochant les points d'insertion du muscle [27].

Cette contraction s'observe lors de la phase montante d'une flexion du biceps avec haltère, où le muscle biceps brachial se raccourcit pour fléchir l'avant-bras sur le bras [28]. L'énergie mécanique produite est positive, le muscle effectuant un travail moteur [29]. Cette contraction permet d'accélérer un segment corporel ou de vaincre une résistance externe [30].

La *contraction excentrique* présente des caractéristiques opposées, le muscle s'allongeant tout en maintenant une tension active. Paradoxalement, le muscle résiste à un étirement imposé par une force externe supérieure à la force qu'il développe. Cette situation se rencontre lors de la phase descendante contrôlée d'une flexion du biceps, où le muscle s'allonge progressivement pour freiner la descente de l'haltère. L'énergie mécanique est négative, le muscle effectuant un travail résistant. Cette contraction joue un rôle crucial dans le contrôle moteur, permettant de décélérer des mouvements, d'amortir des chocs ou de résister à la gravité. Elle génère des forces supérieures aux contractions concentriques pour une même activation nerveuse, mais provoque davantage de micro-lésions musculaires, expliquant les courbatures retardées [31].

La *contraction isométrique* se caractérise par une tension musculaire sans modification de la longueur du muscle. Les filaments contractiles tentent de glisser mais ne peuvent se raccourcir en raison d'une résistance externe égale à la force développée [29]. Cette situation s'observe lors du maintien d'une position, comme tenir un objet à bout de bras ou maintenir une position de planche. Aucun travail mécanique n'est produit au sens physique, mais le muscle consomme de l'énergie pour maintenir la tension. Cette contraction permet de stabiliser les articulations et de maintenir des postures [32].

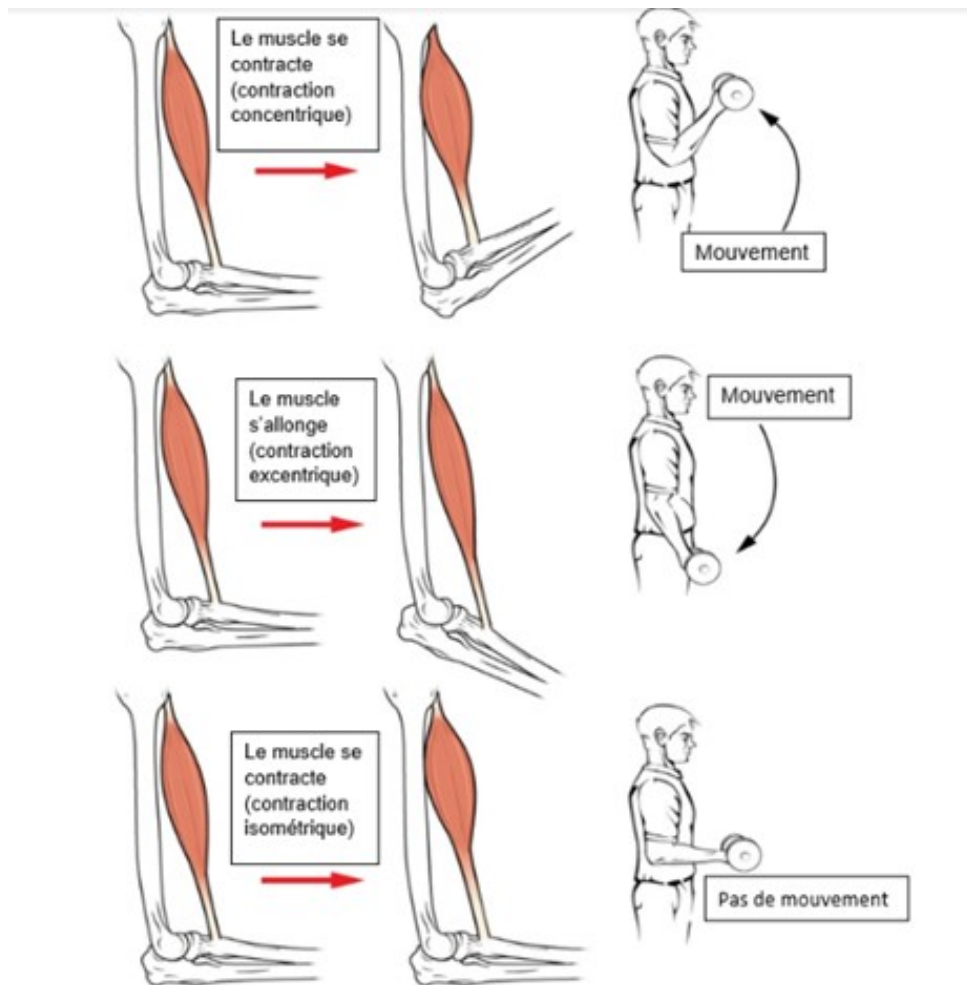


FIGURE 1.5 – Types de contractions musculaires (concentrique-excentrique-isométrique) [3]

#### 1.2.2.2. Contractions selon la vitesse d'exécution

La vitesse de contraction influence profondément les caractéristiques mécaniques et physiologiques de l'effort musculaire.

Les **contractions isocinétiques** maintiennent une vitesse angulaire constante grâce à un dispositif mécanique spécialisé qui ajuste automatiquement la résistance. Cette contraction artificielle, uniquement possible avec des appareils sophistiqués, permet au muscle de développer sa force maximale sur toute l'amplitude du mouvement [33]. Elle présente un intérêt majeur en rééducation et en évaluation de la force musculaire, car elle élimine les variations de résistance liées aux changements d'angles articulaires. La vitesse peut être lente pour privilégier la force maximale ou rapide pour se rapprocher des gestes sportifs.

Les **contractions balistiques** se caractérisent par une accélération explosive initiale suivie d'une phase de décélération. Le muscle se contracte violemment au début du mouvement puis se relâche partiellement, le mouve-

ment se poursuivant par inertie. Cette contraction s'observe dans les gestes de lancer, de frappe ou de saut, où la vitesse initiale d'activation détermine la performance finale. Elle sollicite particulièrement les fibres musculaires rapides et le système nerveux dans sa capacité de recrutement explosif [34].

#### 1.2.2.3. Contractions selon le mode de résistance

La nature de la résistance rencontrée influence le type de contraction développée.

Les *contractions isotoniques* théoriques maintiennent une tension constante, mais cette situation pure n'existe pratiquement jamais en raison des variations d'angles articulaires et de bras de levier [35]. Les exercices avec poids libres s'en rapprochent sans l'atteindre parfaitement. Cette contraction permet un travail dans l'amplitude complète du mouvement avec une charge relativement stable.

Les *contractions auxotoniques* représentent la réalité de la plupart des mouvements naturels, où la tension varie constamment en fonction de l'angle articulaire, de la vitesse d'exécution et des caractéristiques biomécaniques du système de leviers osseux [36].

Cette variation de tension reflète l'adaptation continue du muscle aux contraintes changeantes du mouvement.

#### 1.2.2.4. Contractions spécialisées

Certaines formes particulières de contraction méritent une attention spécifique en raison de leurs applications pratiques.

La *contraction pliométrique* combine une phase excentrique rapide immédiatement suivie d'une phase concentrique explosive. Cette séquence tire parti du réflexe myotatique et de l'élasticité des structures tendineuses pour amplifier la force produite. Elle s'observe dans les sauts avec contremouvement, où la flexion rapide des membres inférieurs précède immédiatement l'extension explosive. Cette contraction améliore la puissance et la réactivité musculaire [37].

Les *contractions intermittentes* alternent phases de contraction et de relâchement selon des cycles prédéfinis. Elles permettent une récupération partielle entre les efforts et trouvent leur application dans l'entraînement fractionné ou la rééducation progressive [38].

Cette diversité de contractions musculaires illustre la remarquable adaptabilité du système neuromusculaire aux exigences variées de la motricité humaine, chaque type répondant à des besoins spécifiques de performance, de contrôle ou de développement des qualités physiques.

### 1.2.3. Physiologie de la contraction musculaire

La contraction musculaire est un processus complexe qui implique une coordination entre le système nerveux central, le système nerveux périphérique et la fibre musculaire. Ce mécanisme, initié par un ordre volontaire ou réflexe, permet la transformation d'un signal électrique en mouvement mécanique grâce au glissement des filaments d'actine et de myosine. Voici les étapes clés, depuis le cerveau jusqu'au retour au repos.

#### 1.2.3.1. Commande Cérébrale et Transmission Centrale

Le mouvement volontaire prend naissance au niveau du cortex cérébral, plus précisément dans les régions motrices situées dans le lobe frontal. La principale structure impliquée est le cortex moteur primaire (aire 4 de Brodmann), localisé sur le gyrus précentral. Il est organisé somatotopiquement, chaque région contrôlant une zone précise du corps selon la carte de l'homoncule moteur. Les zones représentant les mains, le visage et les muscles orofaciaux y occupent une surface disproportionnellement grande, traduisant leur richesse en contrôle moteur fin [12], [39]. En amont du cortex moteur primaire, les aires prémotrices et l'aire motrice supplémentaire (aires 6 et 8 de Brodmann) jouent un rôle fondamental dans la planification et la coordination du mouvement. Ces régions interviennent dans la sélection des stratégies motrices adaptées au contexte (intention, anticipation, séquence de mouvements, mémoire motrice) [12], [40].

En parallèle, deux structures sous-corticales majeures participent à l'optimisation du mouvement :

- Les ganglions de la base (striatum, pallidum, noyau subthalamique et substance noire), qui filtrent et affinent les programmes moteurs, en inhibant les mouvements inappropriés et facilitant ceux souhaités.
- Le cervelet, qui joue un rôle crucial dans la coordination temporelle, la précision, et l'ajustement en temps réel des mouvements. Il compare le mouvement prévu avec le mouvement exécuté, générant des corrections motrices fines.

L'intégration entre ces différentes régions corticales et sous-corticales constitue un réseau moteur hiérarchisé, dynamique et plastique, capable d'ajuster en permanence l'activité motrice en fonction des objectifs, de l'apprentissage et des rétroactions sensorielles [12], [40].

### 1.2.3.2. Transmission de la commande musculaire

Une fois le mouvement volontaire initié au niveau cortical, la commande motrice est transmise vers la périphérie via les voies descendantes, dont la principale est la voie corticospinale (ou voie pyramidale). Cette voie part du cortex moteur primaire, descend à travers la capsule interne, traverse le tronc cérébral, puis subit une décussation (croisement) au niveau du bulbe rachidien. Ainsi, les hémisphères cérébraux contrôlent préférentiellement les muscles du côté opposé du corps. Après le croisement, les fibres corticospinales continuent leur trajet dans la moelle épinière et se terminent dans la corne antérieure de la substance grise, où elles établissent une synapse directe ou indirecte avec les motoneurones alpha [41].

Ces motoneurones alpha représentent la dernière étape de la commande motrice. Leurs corps cellulaires sont situés dans la corne antérieure, et leurs axones efférents quittent la moelle épinière via les racines ventrales pour former un nerf moteur périphérique. Chaque motoneurone innerve un groupe spécifique de fibres musculaires appartenant à un même muscle. L'ensemble formé par un motoneurone et les fibres musculaires qu'il contrôle est appelé unité motrice [12].

Toutes les fibres d'une unité motrice sont du même type (rapides, lentes, résistantes à la fatigue, etc.) et se contractent simultanément lors de l'activation du motoneurone. La précision du mouvement dépend fortement de la taille des unités motrices : les muscles fins comme ceux des doigts ou des muscles oculaires présentent de petites unités motrices (10–100 fibres), tandis que les muscles posturaux ou locomoteurs, comme le quadriceps, en possèdent de beaucoup plus grandes (plusieurs centaines à milliers de fibres par motoneurone).

Cette organisation hiérarchique permet une modulation fine de la force musculaire par le recrutement progressif des unités motrices selon le principe de Henneman, allant des plus petites aux plus grandes [42], et constitue la base physiologique de l'activité enregistrée par électromyographie de surface (sEMG) [43].




FIGURE 1.6 – Structure de l'unité motrice [2]

### 1.2.3.3. Transmission neuromusculaire

La jonction neuromusculaire constitue l'interface fonctionnelle entre le système nerveux et le muscle squelettique. Elle permet la conversion d'un signal électrique nerveux en un signal chimique, puis en un nouveau signal électrique musculaire, qui initiera la contraction. Ce processus est précis, rapide et hautement spécialisé.

Lorsque le potentiel d'action arrive à l'extrémité de l'axone moteur, il déclenche l'ouverture des canaux calciques voltage-dépendants, entraînant une entrée massive d'ions calcium ( $\text{Ca}^{2+}$ ) dans la terminaison présynaptique. Cette élévation du calcium intracellulaire induit la fusion des vésicules synaptiques avec la membrane de l'axone et la libération d'acétylcholine (ACh) dans la fente synaptique [44].

L'acétylcholine diffuse rapidement et se fixe sur les récepteurs nicotiques de l'élément post-synaptique, qui est la membrane de la fibre musculaire (appelée sarcolemme). Cette fixation ouvre des canaux ioniques perméables aux ions sodium ( $\text{Na}^+$ ), entraînant une entrée massive de  $\text{Na}^+$  dans la cellule musculaire. Ce flux ionique provoque une dépolarisation locale du sarcolemme [45].

À l'état de repos, le potentiel de membrane de la fibre musculaire est d'environ  $-70$  mV, maintenu par la pompe  $\text{Na}^+/\text{K}^+$ -ATPase et la distribution inégale des ions de part et d'autre de la membrane. Lors de la stimulation, ce potentiel devient progressivement moins négatif, et si un seuil critique (environ  $-55$  mV) est atteint, un potentiel d'action musculaire est généré. Ce signal se propage alors le long de la membrane musculaire dans les deux directions, assurant une activation coordonnée de l'ensemble de la fibre [46].

Ce mécanisme de transduction neuromusculaire est fondamental : toute altération de cette chaîne de transmission peut entraîner des troubles moteurs, et c'est à ce niveau précis que de nombreuses toxines ou pathologies (comme la myasthénie) peuvent agir. En conditions normales, il permet un couplage efficace entre l'activité nerveuse et la contraction musculaire, et représente la source initiale du signal capté par l'électromyographie de surface (sEMG) [47].




FIGURE 1.7 – La jonction neuro musculaire [4]

#### 1.2.3.4. Conduction Intrafibreuse

Une fois le potentiel d'action musculaire généré au niveau du sarcolemme, il se propage rapidement dans toute la fibre musculaire grâce à un système spécialisé appelé tubules transverses (ou tubules T). Ces invaginations du sarcolemme permettent la transmission du signal électrique en profondeur, jusqu'aux régions centrales de la cellule, garantissant une activation syn-

chrone des myofibrilles [48, 49].

Le signal électrique atteint alors la triade, structure composée d'un tubule T encadré par deux citernes terminales du réticulum sarcoplasmique. Cette organisation est essentielle pour le couplage excitation-contraction. Le potentiel d'action active les récepteurs dihydropyridiniques (DHPR) situés sur les tubules T, qui, par interaction mécanique, ouvrent les récepteurs de la ryanodine (RyR1) sur la membrane du réticulum sarcoplasmique [50]. Il en résulte une libération massive d'ions  $\text{Ca}^{2+}$  dans le cytoplasme musculaire.

Cette élévation transitoire de calcium intracellulaire constitue le signal déclencheur de la contraction musculaire. La précision de ce mécanisme garantit une réponse rapide, coordonnée et proportionnée à la commande nerveuse [51].

#### 1.2.3.5. Contrôle Intracellulaire

La libération de calcium intracellulaire constitue le signal clé de déclenchement de la contraction musculaire. Suite à la stimulation électrique transmise par les tubules T, les récepteurs de la ryanodine (RyR1) situés sur le réticulum sarcoplasmique s'ouvrent, libérant une grande quantité d'ions  $\text{Ca}^{2+}$  dans le sarcoplasme [52]. Ce calcium se lie à la troponine C, une sous-unité du complexe troponine localisée sur les filaments fins (actine).

Cette fixation induit une modification conformationnelle du complexe troponine-tropomyosine, exposant les sites actifs de l'actine et permettant l'interaction avec les têtes de myosine. Ce processus constitue le point de départ de la formation des ponts croisés et de la production de force contractile [51].

Afin de visualiser les structures impliquées, la figure ?? illustre un sarcomère, unité structurale répétée du muscle strié. On y distingue les filaments fins insérés aux lignes Z, les filaments épais centrés sur la ligne M, ainsi que les bandes I, A et la zone H, dont la dynamique conditionne le raccourcissement musculaire.




FIGURE 1.8 – Schéma illustrant les différentes lignes et bandes qui constituent le sarcomère [1]

La concentration de calcium reste élevée tant que la stimulation perdure. Lorsque le signal cesse, les pompes SERCA réabsorbent activement le  $\text{Ca}^{2+}$  dans le réticulum sarcoplasmique, initiant ainsi la phase de relaxation [50].

#### 1.2.3.6. Interaction Myofilamentaire

Une fois les sites actifs de l'actine exposés, les têtes de myosine, chargées en énergie par l'hydrolyse de l'ATP, se lient à ces sites spécifiques, formant des ponts transversaux. Ce contact déclenche le cycle des interactions actine-myosine, aussi appelé cycle des ponts croisés, tel que décrit par Huxley [27]. Chaque tête de myosine effectue alors un mouvement de bascule (ou «power stroke») qui entraîne le glissement de l'actine vers le centre du sarcomère, provoquant le raccourcissement musculaire. L'ADP et le phosphate inorganique sont ensuite libérés, et une nouvelle molécule d'ATP se fixe sur la tête de myosine, induisant sa dissociation de l'actine, conformément au modèle formalisé par Hill [53]. Tant que le calcium est présent et que l'ATP est disponible, ce cycle se répète, assurant une contraction soutenue. Ce mécanisme moléculaire permet une conversion efficace de l'énergie chimique en force mécanique, à l'origine du mouvement volontaire, comme détaillé par Gordon et al. [54]. En l'absence de calcium, la tropomyosine revient bloquer les sites actifs, stoppant ainsi l'interaction actine-myosine.

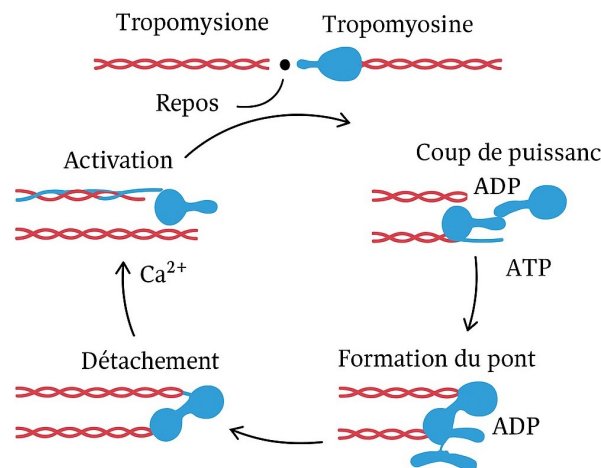


Figure 5. Cycle d'interaction actine-myosine sous contrôle de l'ATP et du calcium.

FIGURE 1.9 – Cycle d'interaction actine-myosine sous contrôle de l'ATP et du calcium

### 1.2.3.7. Phase de Relâchement

La phase de relâchement musculaire commence dès que cesse le potentiel d'action, interrompant la libération de calcium par les canaux ryanodine (RyR1) du réticulum sarcoplasmique. Les ions  $\text{Ca}^{2+}$  sont ensuite activement recaptés par les pompes SERCA, qui les transportent de nouveau dans le réticulum en consommant de l'ATP [55]. Cette chute de calcium cytosolique induit la dissociation du  $\text{Ca}^{2+}$  de la troponine C, ce qui permet à la tropomyosine de retrouver sa position inhibitrice sur les filaments d'actine, bloquant ainsi les interactions actine-myosine [56]. Le sarcomère revient alors à sa longueur initiale, marquant la relaxation musculaire. Ce processus est essentiel pour garantir l'alternance rapide contraction-relâchement. Des défauts de recapture calcique peuvent provoquer une rigidité ou une faiblesse musculaire, comme observé dans certaines dystrophies ou fatigues prolongées [57].

## 1.2.4. Physiologie de la fatigue musculaire

### 1.2.4.1. Manifestations macroscopiques

La fatigue musculaire se manifeste d'abord au niveau macroscopique par une diminution progressive de la capacité du muscle à générer de la force ou à maintenir une performance soutenue. Cette altération de la fonction musculaire est souvent observée lors d'un exercice prolongé ou intense. Elle se traduit par une baisse de la force maximale volontaire, un allongement du temps de contraction, une altération de la coordination motrice et parfois une incapacité à poursuivre l'effort malgré la volonté du sujet [58]. Les facteurs

influençant cette fatigue comprennent l'intensité de l'exercice, la durée, l'état nutritionnel, la température corporelle, et l'état d'entraînement de l'individu [59]. D'un point de vue clinique ou expérimental, la fatigue est souvent évaluée à l'aide d'indicateurs tels que la force résiduelle, l'électromyogramme de surface (sEMG), ou encore la perception subjective de l'effort (échelle de Borg) [60]. On distingue également deux grandes catégories de fatigue : la fatigue centrale, d'origine neurologique, et la fatigue périphérique, liée aux processus locaux au sein du muscle.

Niveau de l'effort	Perception de l'intensité
0	Rien du tout
0,5	Très, très facile
1	Très facile
2	Facile
3	Moyen
4	Un peu difficile
5	Difficile
6	Plus difficile
7	Très difficile
8	
9	Très, très difficile
10	Maximum

FIGURE 1.10 – Echelle de Borg [5]

#### 1.2.4.2. Mécanismes microscopiques

À l'échelle cellulaire, la fatigue musculaire résulte principalement de l'accumulation de métabolites produits au cours de la contraction, tels que les ions hydrogène ( $H^+$ ), le phosphate inorganique (Pi), l'ADP et le lactate. Ces substances perturbent le bon déroulement de la contraction en interférant avec la libération du calcium, la sensibilité des filaments d'actine à ce calcium, et le cycle de ponts d'union actine-myosine [61], [62].

L'augmentation des ions  $H^+$  abaisse le pH intracellulaire, ce qui inhibe l'activité des enzymes contractiles et perturbe le couplage excitation-contraction [63]. Le Pi, en particulier, semble jouer un rôle clé en réduisant la libération du calcium par le réticulum sarcoplasmique et en inhibant la force des ponts actine-myosine [64]. Par ailleurs, un dysfonctionnement mitochondrial peut également aggraver la fatigue, en réduisant la disponibilité de l'ATP nécessaire à la contraction.

Le lactate, produit final de la glycolyse anaérobie. Bien qu'il ne soit pas directement responsable de l'acidification, son accumulation reflète une forte sollicitation des voies énergétiques rapides et un déséquilibre entre l'apport et la demande en oxygène. Le lactate peut également influencer l'excitabilité neuromusculaire et altérer l'homéostasie ionique, contribuant indirectement à la baisse de performance.

D'autres composés, tels que l'ammoniac ( $NH_3$ ) et les espèces réactives de l'oxygène (ROS), participent également à la fatigue musculaire. L'ammoniac, produit par la désamination des acides aminés, peut altérer la fonction neuronale et contribuer à la fatigue centrale. Quant aux ROS, leur accumulation excessive entraîne un stress oxydatif qui perturbe les structures contractiles et aggrave le dysfonctionnement musculaire [65].

Les perturbations observées peuvent aussi inclure une altération de la transmission neuromusculaire ou une désorganisation du système tubulaire transverse, réduisant l'efficacité du signal électrique. Enfin, des mécanismes adaptatifs tels que le recrutement de fibres supplémentaires ou le ralentissement du cycle contractile visent à maintenir la performance, mais ne sont efficaces que temporairement [66].




FIGURE 1.11 – Accumulation des métabolites impliquées dans la fatigue musculaire

### 1.2.5. La force musculaire

La force musculaire désigne la capacité d'un muscle ou d'un groupe musculaire à exercer une tension contre une résistance. Elle est le produit d'une interaction complexe entre les propriétés mécaniques du muscle, le système nerveux, et les conditions externes de la contraction. On distingue généralement la force maximale volontaire, mesurée lors d'un effort isométrique, et la force dynamique, mesurée lors de mouvements concentriques ou excentriques [67].

D'un point de vue physiologique, la force générée dépend directement du nombre de fibres musculaires activées, de leur taille, et de la fréquence de stimulation. Une fréquence plus élevée permet le phénomène de sommation des secousses musculaires, menant à une contraction tétonique plus puissante. Le degré de recrutement des unités motrices (motoneurones + fibres associées) joue aussi un rôle clé. Les petites unités (fibres de type I) sont activées en premier, suivies des unités plus grosses (fibres de type II), selon le principe de Henneman.

Par ailleurs, la force dépend aussi de facteurs structuraux, comme la longueur initiale du muscle (relation tension-longueur), la vitesse de contraction (relation force-vitesse), ainsi que l'angle articulaire au moment de l'effort. La relation force-vitesse, décrite par Hill dès 1938, indique qu'un muscle produit moins de force à mesure que la vitesse de raccourcissement augmente [68].

D'autres éléments influencent également la force musculaire, tels que la température, la fatigue, et les facteurs motivationnels ou psychologiques. De manière plus globale, la force musculaire peut être considérée comme un indicateur indirect de la santé neuromusculaire, d'où son importance dans les contextes cliniques, sportifs et de recherche [69].

### 1.2.6. L'électromyographie de surface (sEMG)

L'électromyographie de surface (sEMG) est une méthode non invasive permettant d'enregistrer l'activité électrique produite par les muscles squelettiques lors de leur contraction. Contrairement à l'électromyographie à aiguille, qui explore l'activité intracellulaire à l'aide d'électrodes insérées dans le muscle, la sEMG utilise des électrodes placées à la surface de la peau pour capter les potentiels d'action résultant de l'activité des unités motrices [70]. Cette technique est largement utilisée en biomécanique, rééducation, ergonomie et contrôle des prothèses [71].

Le signal sEMG est influencé par de nombreux facteurs, tels que la profondeur des fibres musculaires, l'impédance cutanée, la position des électrodes, et le filtrage électrique appliqué [72]. Malgré sa sensibilité aux artefacts de mouvement ou au bruit, la sEMG reste un outil précieux pour étudier la fatigue musculaire, la coordination motrice et l'intensité de l'effort musculaire [73].

L'interprétation correcte du signal sEMG exige une compréhension fine de la physiologie neuromusculaire et des paramètres techniques de l'enregistrement [74].

#### 1.2.6.1. Configuration des électrodes

La qualité et la fiabilité du signal sEMG dépendent fortement de la configuration des électrodes utilisées. En général, on utilise des électrodes de surface en argent-chlorure d'argent (Ag/AgCl), en raison de leur faible polarisation et de leur bonne stabilité électrique. Ces électrodes sont souvent jetables, pré-gélifiées, et posées par paire selon un espacement standard de 1 à 2 cm, aligné sur les fibres musculaires.

La configuration la plus courante est bipolaire : deux électrodes actives enregistrent la différence de potentiel électrique généré par les fibres musculaires situées en dessous, tandis qu'une troisième électrode de référence est placée sur une zone électriquement neutre, comme une apophyse osseuse [75]. Cette configuration permet de réduire les interférences provenant d'autres muscles ou sources externes.

Avant la pose des électrodes, la peau est généralement préparée par nettoyage à l'alcool, voire abrasion légère, afin de réduire l'impédance de contact et d'améliorer le rapport signal/bruit [76].

L'orientation, l'espacement et le placement des électrodes sont cruciaux, car une mauvaise configuration peut entraîner des signaux atténués, un croisement inter-musculaire, ou des erreurs d'interprétation [30].

### 1.2.7. Relation entre sEMG et fatigue musculaire

La surface électromyographie (sEMG) permet de détecter les manifestations périphériques de la fatigue musculaire à travers les modifications du signal électrique recueilli à la surface de la peau. Lors d'un exercice prolongé, le muscle actif présente des altérations de l'activité neuromusculaire, reflétant une réponse d'adaptation face à l'effort soutenu. Ces changements sont captés par le sEMG et traduisent un épuisement progressif des ressources contractiles et métaboliques du muscle [70].

La fatigue induit une reconfiguration du recrutement des unités motrices ainsi qu'une modification de la synchronisation de leur décharge. Le système nerveux central tente alors de compenser la baisse d'efficacité des fibres actives en sollicitant davantage d'unités motrices ou en modifiant leur rythme d'activation [77]. Ces ajustements, bien que compensatoires au début, deviennent insuffisants lorsque la fatigue progresse, ce qui affecte la stabilité et la cohérence du signal sEMG.

L'analyse du sEMG, bien qu'influencée par des facteurs techniques et physiologiques, reste une méthode fiable pour suivre l'installation de la fatigue musculaire en temps réel, notamment dans les contextes cliniques, ergonomiques ou sportifs [76], [78].

## 1.3 Conclusion

Ce premier chapitre a permis d'établir les fondations nécessaires à la compréhension du fonctionnement musculaire, en explorant successivement l'organisation anatomique du muscle squelettique, les mécanismes de la contraction, les types de fatigue, ainsi que les principes de l'électromyographie de surface (sEMG). Cette base physiologique et technique est indispensable pour aborder les analyses plus avancées présentées dans les chapitres suivants. En effet, les connaissances acquises ici sur la structure musculaire, la transmission neuromusculaire et la relation entre activité électrique et contraction mécanique seront mobilisées pour étudier, à l'aide du signal EMG, les variations de la force musculaire et les manifestations de la fatigue. Les chapitres à venir approfondiront l'exploitation de ces signaux, en combinant modélisation, extraction de caractéristiques et méthodes d'interprétation, dans le but de détecter de manière fiable et automatique les phases de fatigue musculaire.

# Chapitre 2

## Développement d'un système d'enregistrement EMG/Force pour l'étude de la fatigue musculaire

### 2.1 Introduction

L'analyse biomédicale des fonctions musculaires exige des systèmes de mesure fiables, précis et économiquement accessibles. Dans le cadre de cette étude, un système complet a été développé pour mesurer deux signaux physiologiques majeurs : l'électromyogramme de surface (EMG) et la force musculaire. Ces deux signaux, respectivement d'origine électrique et mécanique, permettent de capturer la dynamique neuromusculaire au cours d'un effort soutenu, notamment dans le contexte de la fatigue musculaire.

Contrairement aux systèmes commerciaux souvent coûteux et peu flexibles, le système présenté ici repose exclusivement sur des composants discrets : un amplificateur d'instrumentation AD620 pour l'EMG, un dynamomètre EH108 associé à un convertisseur HX711 pour la force, et un microcontrôleur ESP32-WROOM-32 comme unité centrale de traitement. Cette approche modulaire permet non seulement de réduire les coûts, mais également d'assurer une personnalisation complète des paramètres de mesure et de traitement.

L'ensemble du système a été conçu en vue d'une acquisition synchrone, avec des fréquences adaptées à chaque type de signal : 2000 Hz pour l'EMG afin de couvrir une large bande passante, et 10 Hz pour la force, correspondant aux variations lentes caractéristiques des efforts isométriques prolongés. L'objectif final est de disposer d'un signal EMG suffisamment propre pour permettre la prédiction continue de la force musculaire par des approches d'intelligence artificielle, même en l'absence d'un capteur de force en temps réel.

Ce chapitre détaille les éléments matériels du système, en mettant l'accent sur la chaîne de mesure analogique de l'EMG, la modification du dynamomètre EH108 pour une sortie numérique, et le rôle central du microcontrôleur ESP32-WROOM-32 dans l'orchestration de l'acquisition. Des figures illustratives, des schémas de connexion et des références techniques viendront appuyer cette présentation.

## 2.2 Mesure des signaux biologiques

L'analyse de la fatigue musculaire repose sur la mesure simultanée de deux signaux complémentaires : le signal électromyographique de surface (sEMG) et la force musculaire développée au cours d'une contraction. Ces deux grandeurs sont d'origine différente — électrique pour l'EMG, mécanique pour la force — mais toutes deux reflètent l'état fonctionnel du muscle. Leur acquisition parallèle permet d'établir une relation temporelle entre l'activation neuromusculaire et la production de force, ouvrant la voie à l'identification de signatures spécifiques de la fatigue.

Le système mis en œuvre repose sur des composants électroniques discrets, combinant fiabilité, simplicité, et faible coût. La section suivante détaille les deux chaînes de mesure développées : l'une pour le signal EMG, l'autre pour la force musculaire.

### 2.2.1. L'électromyogramme

L'acquisition du signal électromyographique (EMG) nécessite un conditionnement précis du signal en raison de son amplitude très faible (0.1 à 5 mV) et de sa susceptibilité au bruit. Une carte d'amplification analogique a donc été utilisée à base de composants discrets afin de répondre à ces exigences. Elle repose principalement sur l'amplificateur instrumentation AD620, le double amplificateur opérationnel LM358, et le convertisseur de tension ICL7660.




FIGURE 2.1 – Carte d’amplification EMG [6]

Cette carte a été conçue pour amplifier les signaux différentiels issus d’électrodes de surface (Ag/AgCl), appliquées sur le muscle fléchisseur radial du carpe (FCR), sans recours à un filtrage matériel passif ou actif. Le montage privilégie la simplicité, la portabilité et l’intégration avec des microcontrôleurs tels que l’ESP32.

#### 2.2.1.1. Amplification différentielle avec l’AD620

Le cœur de la carte est le AD620 (Analog Devices), un amplificateur instrumentation très répandu dans les applications biomédicales. Il présente une très haute impédance d’entrée, un faible bruit, une faible dérive thermique, et un CMRR élevé ( $> 100$  dB) [7]. Ces caractéristiques en font un choix optimal pour l’amplification des signaux EMG.

Le gain du circuit est défini par une résistance externe  $R_G$ , insérée entre les broches 1 et 8 du composant, selon la formule :

$$\text{Gain} = 1 + \frac{49.9k\Omega}{R_G}$$

Dans notre montage,  $R_G$  est composée de deux résistances fixes de  $1k\omega$  en série avec un potentiomètre de  $10k\omega$  (P1). Cette configuration permet d’ajuster le gain de manière continue dans une plage allant d’environ 5 à 49, en fonction de l’intensité du signal mesuré.

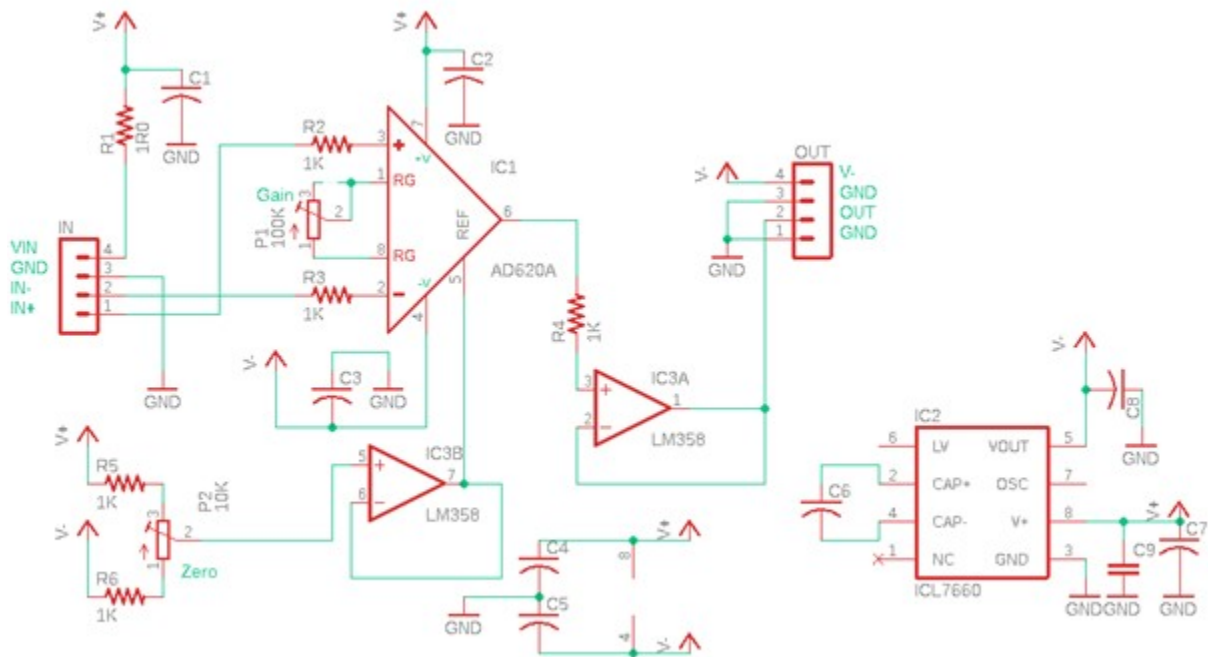


FIGURE 2.2 – Schéma électrique détaillé de la carte d'amplification [7]

### 2.2.1.2. Centrage du signal via le LM358

Le signal EMG amplifié par l'AD620 est naturellement centré autour de 0 V. Or, les microcontrôleurs comme l'ESP32 n'acceptent que des tensions strictement positives sur leurs entrées analogiques. Il est donc nécessaire de décaler le signal (offset) pour le placer dans la fenêtre [0 V ; 3.3 V].

Ce décalage est assuré par un circuit formé d'un pont diviseur (R5 et R6) et d'un suiveur de tension basé sur le LM358 (IC3B). La tension de référence ainsi créée (environ 2.5 V) est appliquée à la broche VREF de l'AD620, ce qui décale tout le signal amplifié autour de cette valeur [79].

Cette opération permet une compatibilité directe avec l'ADC de l'ESP32, sans saturation ni coupure du signal.

### 2.2.1.3. Tampon de sortie

Le signal ainsi amplifié et centré est ensuite appliqué à un second amplificateur opérationnel du LM358 (IC3A), configuré en tampon (buffer). Ce buffer :

- réduit l'impédance de sortie,
- protège les étages précédents de la charge de l'ADC,
- et stabilise la tension pour une conversion analogique-numérique plus fiable.

Ce montage garantit une transmission propre du signal vers le microcontrôleur, même si le câble est long ou soumis à des interférences.

#### 2.2.1.4. Alimentation symétrique simulée (ICL7660)

Pour plus de flexibilité, la carte inclut un convertisseur de tension ICL7660 (Intersil), qui produit une tension négative  $-5\text{ V}$  à partir d'une source  $+5\text{ V}$  unique. Ce composant fonctionne par pompe de charge interne, avec un jeu de condensateurs assurant l'oscillation et la stabilisation [80].

La tension négative peut être exploitée dans le futur pour alimenter des filtres actifs ou des circuits différentiels symétriques, augmentant ainsi la dynamique de traitement.

#### 2.2.2. La force musculaire

L'évaluation de la force musculaire constitue une composante essentielle de l'analyse fonctionnelle du muscle. Dans cette étude, la force a été mesurée à l'aide du dynamomètre EH108, un dispositif manuel initialement destiné à un usage clinique, et modifié ici pour permettre une acquisition numérique précise. L'appareil repose sur une cellule de charge interne basée sur la configuration classique du pont de Wheatstone, une architecture standard pour la mesure de la déformation mécanique.



FIGURE 2.3 – Dynamomètre EH-108 [8]

##### 2.2.2.1. Principe de fonctionnement du pont de Wheatstone

La cellule de charge intégrée au EH108 est constituée de quatre jauges de contrainte, montées en pont de Wheatstone. Ce montage permet de convertir la déformation mécanique (provoquée par l'effort de compression) en une

variation de tension différentielle. Les deux bornes d'excitation (E+ et E-) alimentent le pont, tandis que les deux autres (S+ et S-) fournissent un signal analogique proportionnel à la force exercée.

Ce signal, de très faible amplitude (quelques millivolts au maximum), nécessite une amplification et une conversion analogique-numérique de haute précision.

#### 2.2.2.2. Extraction et interfaçage du signal avec HX711

Le dynamomètre ne disposant pas de sortie exploitable en l'état, une intervention matérielle a été réalisée pour accéder aux fils internes de la cellule de charge. Les quatre fils E+, E-, S+, et S- ont été identifiés, soudés et connectés à un module de conditionnement HX711, spécialement conçu pour interfacer des ponts de jauges avec des microcontrôleurs.




FIGURE 2.4 – Le convertisseur HX-711 [9]

Le HX711 (Avia Semiconductor) est un convertisseur analogique-numérique 24 bits dédié aux cellules de charge. Il intègre :

- un amplificateur faible bruit (gain fixe de 128 sur le canal A),
- un filtrage numérique intégré (notch filter à 50/60 Hz),
- une interface série 2 fils (DT, SCK) compatible avec ESP32 ou Arduino,
- et une consommation réduite ( $< 1.5$  mA).

La haute résolution (24 bits) permet de détecter de très faibles variations de force, offrant une excellente sensibilité. La connexion s'effectue comme suit :

- E+ et E- de la cellule vers les broches E+ et E- du HX711 (alimentation du pont)
- S+ et S- vers A+ et A- (entrée différentielle du canal A)
- DT et SCK vers deux broches GPIO libres du microcontrôleur

### 2.2.2.3. Choix de la fréquence d'échantillonnage

Le HX711 permet deux modes de lecture : 10 Hz ou 80 Hz. Dans le cadre de cette étude, une fréquence d'acquisition lente 10 Hz a été volontairement choisie pour suivre la diminution progressive de la force lors d'un protocole de fatigue musculaire isométrique. Cette fréquence suffit pour capter les tendances lentes du signal, tout en réduisant les besoins de traitement en temps réel.

## 2.2.3. Acquisition des signaux


L'acquisition simultanée des signaux biologiques, à savoir l'électromyogramme (EMG) et la force musculaire, a été centralisée à l'aide d'un microcontrôleur ESP32-WROOM-32, qui combine robustesse matérielle, polyvalence d'interface et flexibilité logicielle. Ce composant joue un rôle clé dans le système en assurant la lecture, la synchronisation et la transmission des deux types de signaux, via une architecture légère et portable.

### 2.2.3.1. La carte ESP32-WROOM-32

L'ESP32-WROOM-32, développé par Espressif Systems, est un système sur puce (SoC) doté d'un double cœur Xtensa LX6 cadencé jusqu'à 240 MHz, d'une mémoire vive de 520 kB et d'une mémoire flash SPI intégrée allant jusqu'à 16 MB. Il dispose également de nombreuses interfaces de communication, incluant Wi-Fi, Bluetooth 4.2/BLE, SPI, I2C, UART, et surtout jusqu'à 18 canaux ADC 12 bits, ce qui le rend particulièrement adapté à l'acquisition de signaux analogiques [81]. Parmi ses avantages clés :

- Entrées analogiques haute résolution (0-3.3 V, 12 bits) via ADC internes.
- Interface numérique simple (GPIO) pour modules externes comme le HX711.
- Programmation accessible via Arduino IDE, avec une vaste communauté de support.
- Consommation ajustable avec modes basse énergie (deep sleep < 10  $\mu$ A).
- Port micro-USB intégré pour alimentation, communication et debug.

Le modèle que nous avons utilisé est un DevKitC (30 broches) alimenté en 5 V via USB, avec régulation interne à 3.3 V pour l'ESP32 et ses périphériques.



Le HX711 utilise une interface série à deux fils :

- DT (data) connecté ici à GPIO 16
- SCK (clock) connecté à GPIO 4

Ce module offre une résolution très fine ( $0.1-1\mu\text{V}$ ) et un gain programmable (par défaut 128), rendant possible la mesure précise de très faibles variations de force. Il fournit des données toutes les 100 ms (10 Hz), ce qui est suffisant pour le suivi des tendances lentes comme celles observées lors de la fatigue musculaire [83].

Le microcontrôleur récupère ces données en utilisant la bibliothèque HX711.h, qui facilite les opérations de calibration (`set_scale()`), de remise à zéro (`tare()`) et de lecture (`get_units()`).

#### **2.2.3.4. Synchronisation des deux signaux**

Le système est conçu pour assurer la synchronisation temporelle des deux flux à travers l’environnement de développement intégré d’Arduino (IDE) :

- Le signal EMG est acquis en continu, à fréquence fixe, et stocké dans un buffer circulaire.
- Le signal de force est échantillonné toutes les 100 ms, avec timestamp, puis aligné avec les échantillons EMG les plus proches dans le post-traitement.

Cette synchronisation est essentielle pour permettre une corrélation temporelle exacte entre l’activité électrique et la force musculaire, notamment pour les analyses de latence, de couplage neuromusculaire ou de détection de phase.

#### **2.2.3.5. Schéma du montage expérimental**

La figure suivante illustre le montage de la chaîne de mesure de la force musculaire, reliant le dynamomètre EH108, le module HX711, et le microcontrôleur ESP32-WROOM-32. Elle met en évidence les connexions entre les quatre fils du pont de Wheatstone (E+/E-, S+/S-), les broches du HX711, et les entrées numériques de l’ESP32 (DT et SCK).




FIGURE 2.6 – Montage HX711+ EH108 connecté à l’ESP32-WROOM-32 [11]

Dans ce montage :

- La cellule de charge intégrée dans le EH108 est reliée à l’entrée différentielle A+/A- du HX711.
- Les broches E+ et E- alimentent le pont.
- Les lignes DT (Data) et SCK (Clock) sont respectivement connectées aux broches GPIO 16 et GPIO 4 du microcontrôleur ESP32.
- HX711 est alimenté en 3.3 V, régulée par l’ESP32 lui-même via le port USB.

#### 2.2.3.6. Chaîne d’acquisition

La figure ci-dessous représente la chaîne d’acquisition utilisée pour l’enregistrement simultané des signaux EMG et de la force musculaire. Elle illustre l’interconnexion des différents modules du système, depuis les capteurs et circuits de conditionnement jusqu’à la carte d’acquisition et l’ordinateur, où les signaux sont visualisés et sauvegardés pour l’analyse. Cette représentation synthétique permet de situer l’ensemble du dispositif expérimental avant la conclusion générale.

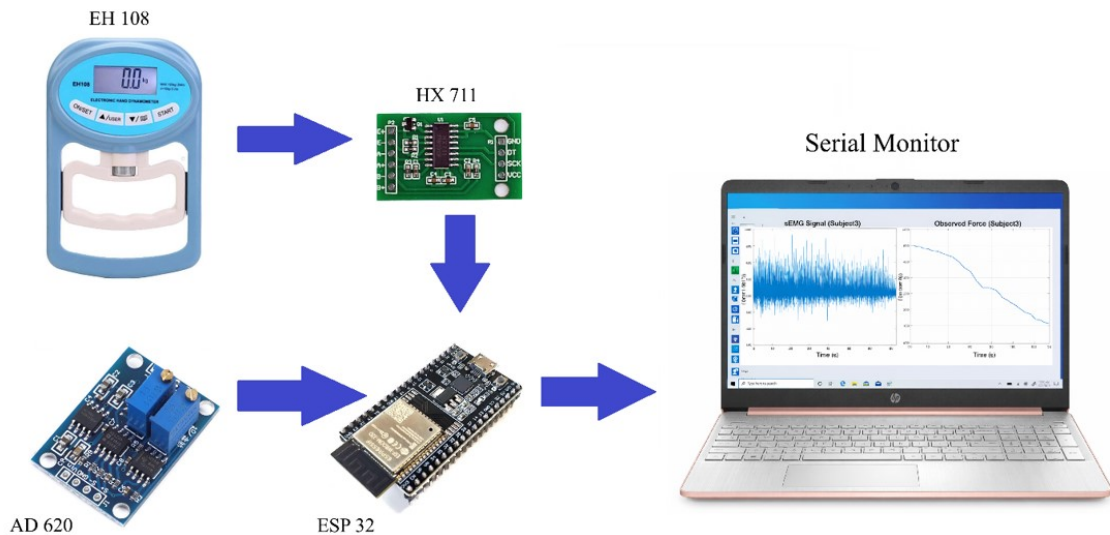


FIGURE 2.7 – Système d’acquisition des signaux EMG et Force

## 2.3 Conclusion

Ce chapitre a présenté l’architecture matérielle mise en place pour la mesure conjointe de l’activité électromyographique et de la force musculaire. À partir de composants accessibles et bien documentés, une solution complète a été développée, intégrant :

- Une chaîne analogique d’amplification et de conditionnement du signal EMG autour du composant AD620 [84].
- Une conversion numérique précise de la force musculaire via un module HX711 24 bits interfacé au dynamomètre EH108 [83].
- Un microcontrôleur ESP32-WROOM-32 jouant un rôle pivot dans la synchronisation, la lecture et la transmission des données [82].

Cette plateforme offre une grande souplesse pour le traitement différé, et permet l’expérimentation de différents algorithmes d’analyse des signaux. Elle constitue une base solide pour les travaux décrits dans les chapitres suivants, où seront développées des méthodes de classification des phases de fatigue (Chapitre 4) et des approches de régression pour la prédiction continue de la force (Chapitre 5).

Par ailleurs, cette approche montre qu’il est possible de construire un système biomédical fiable à faible coût, sans compromettre la qualité des signaux, pourvu que les exigences en matière d’amplification, de centrage, de filtrage implicite et d’échantillonnage soient rigoureusement respectées.

# Chapitre 3

## Extraction multi-domaines des paramètres EMG

### 3.1 Introduction

L'étude de la fatigue musculaire à travers l'électromyographie de surface (sEMG) nécessite une représentation quantitative et fiable du signal EMG. Cependant, ce dernier est intrinsèquement non stationnaire, bruité, et fortement influencé par les caractéristiques individuelles du sujet, telles que l'endurance musculaire. Afin d'en extraire des indicateurs pertinents, il est essentiel de passer par une chaîne de traitement robuste, incluant le prétraitement du signal, sa segmentation, et l'extraction de paramètres informatifs.

Ce chapitre présente la méthodologie mise en œuvre pour transformer les signaux bruts d'EMG en une matrice de caractéristiques exploitable par des modèles d'apprentissage automatique. Après un prétraitement rigoureux visant à améliorer la qualité du signal, une segmentation adaptative en 50 segments est appliquée. Pour chaque segment, 23 descripteurs multi-domaines sont extraits : ces paramètres couvrent les domaines temporel, fréquentiel, temps-fréquence et non-linéaire, afin de capter l'ensemble des dimensions de l'activité musculaire.

L'analyse qualitative de ces paramètres permet de visualiser leur comportement dynamique au cours de la contraction. Par ailleurs, une analyse de corrélation entre les paramètres EMG et la force mesurée est réalisée dans la zone non-fatiguée du signal, afin d'identifier les descripteurs les plus sensibles à l'évolution de la force musculaire. Enfin, une matrice normalisée de caractéristiques est construite pour chaque sujet, constituant l'entrée des modèles prédictifs développés dans les chapitres suivants.

## 3.2 Protocole expérimental d'acquisition des signaux

### EMG et de force

L'acquisition simultanée de l'activité électromyographique (EMG) et de la force musculaire a été réalisée au niveau des muscles fléchisseurs de l'avant-bras.

Trois électrodes de surface ont été placées selon la configuration bipolaire standard : deux électrodes actives positionnées sur le ventre musculaire des fléchisseurs de l'avant-bras, et une électrode de référence placée sur une zone osseuse neutre afin de minimiser les interférences et le bruit électrique.

Le sujet était assis confortablement et tenait un dynamomètre instrumenté contenant une cellule de charge permettant la mesure de la force de préhension.

L'acquisition des données était lancée via le moniteur série de l'Arduino IDE. Durant les cinq premières secondes, aucune contraction n'était demandée au sujet afin d'effectuer la tare automatique de la cellule de charge et d'établir une référence de force nulle.

Après cette phase d'initialisation, le sujet était invité à serrer le dynamomètre avec la force maximale jusqu'à atteindre l'épuisement musculaire, correspondant à un état de fatigue sévère. La contraction était maintenue jusqu'à incapacité de maintenir la force.

L'acquisition était ensuite arrêtée manuellement. Les données enregistrées comprenaient trois colonnes synchronisées : le signal EMG, la force mesurée et le temps. Ces données étaient ensuite copiées et sauvegardées dans un fichier texte pour traitement et analyse ultérieurs.

### 3.3 Prétraitement du signal EMG

Le signal électromyographique de surface (sEMG) est soumis à plusieurs types de bruit et d'artefacts qui peuvent compromettre l'analyse subséquente. Un prétraitement adéquat est donc indispensable pour garantir la fiabilité des paramètres extraits. Ce prétraitement inclut notamment un filtrage rigoureux et une segmentation précise du signal en fenêtres temporelles.

### 3.3.1. Filtrage

Le signal EMG brut est affecté par différents types de perturbations, notamment le bruit de haute fréquence, les artefacts de mouvement et les interférences électriques de 50 Hz. Pour améliorer le rapport signal/bruit, un filtrage passe-bande est généralement appliqué, suivi d'un filtre Notch.

Dans ce travail, un filtre passe-bande de 5 à 500 Hz a été utilisé pour conserver les composantes physiologiquement significatives du sEMG, tout en éliminant les basses fréquences dues aux mouvements et les hautes fréquences liées aux interférences. Par ailleurs, un filtre Notch centré à 50 Hz a été appliqué pour atténuer les interférences du réseau électrique, très courantes dans les environnements cliniques ou de laboratoire [85].

Le filtrage a été réalisé numériquement à l'aide de filtres de Butterworth d'ordre 4, appliqués en mode zéro-phase pour éviter toute distorsion temporelle du signal [86]. Cette étape est cruciale pour assurer la fidélité des descripteurs temporels et fréquentiels extraits par la suite.




FIGURE 3.1 – Signal EMG (exemple : sujet 3)

### 3.3.2. Segmentation du signal

La segmentation constitue une étape fondamentale dans l'analyse du signal EMG, car elle permet de diviser le signal continu en segments exploitables pour l'extraction des caractéristiques. Dans cette étude, le signal EMG de chaque sujet a été divisé uniformément en 50 segments, quelle que soit sa durée totale.

La durée de chaque segment n'est donc pas fixe en millisecondes, mais dépend directement de la durée de la contraction enregistrée, laquelle varie selon l'endurance musculaire propre à chaque individu. Cette approche adaptative permet de s'ajuster à la variabilité inter-sujets : un sujet ayant une bonne endurance musculaire produit un signal plus long, générant ainsi des segments plus longs ; à l'inverse, un sujet fatigué plus rapidement produira des segments plus courts.

Ce choix méthodologique présente deux avantages :

- il assure une couverture homogène de l'ensemble du signal,
- et il permet de comparer un nombre constant de segments ( $n = 50$ ) entre les sujets, facilitant l'analyse statistique et l'apprentissage automatique.

Chaque segment ainsi obtenu est ensuite traité indépendamment pour le calcul des 23 paramètres multi-domaines décrits dans la section suivante. Des approches similaires de segmentation proportionnelle ont déjà été validées dans des contextes EMG dynamiques et inters individuellement variables [87], [88].

### 3.4 Extraction des paramètres EMG

L'analyse du signal EMG repose sur l'extraction de caractéristiques quantitatives permettant de résumer son comportement à chaque instant. Ces paramètres sont calculés segment par segment, selon une segmentation en 50 portions égales, dont la durée dépend de celle du signal, elle-même liée à l'endurance musculaire du sujet.

Au total, 23 paramètres multi-domaines ont été extraits pour chaque segment. Ils sont regroupés en quatre catégories : temporels, fréquentiels, temps-fréquence, et non linéaires. Ces paramètres ont été choisis pour leur capacité à représenter la dynamique musculaire, la densité spectrale, la complexité du signal et son contenu énergétique.

Le calcul des caractéristiques a été implémenté dans un script **MATLAB** sur chaque segment du signal EMG. Le processus inclut le calcul de moyennes, de variances, d'indices spectraux, d'entropies et d'énergies spécifiques via des transformées adaptées (Fourier, EMD, S-Transform, Wigner-Ville). Ce traitement a permis d'obtenir une matrice ( $50 \times 23$ ), où chaque ligne représente un segment et chaque colonne une caractéristique. Cette matrice constitue la base des modèles de régression et de classification développés dans les chapitres suivants.

### 3.4.1. Paramètres temporels

Les paramètres temporels sont dérivés directement de l'amplitude du signal EMG dans le domaine temporel. Ils sont simples à calculer mais offrent une première représentation robuste de l'intensité, de la variabilité et de la structure des signaux musculaires. Huit paramètres ont été retenus dans cette catégorie :

1. **MAV** (*Mean Absolute Value*) : moyenne des valeurs absolues du segment. C'est une mesure simple mais efficace de l'activité musculaire globale [89].
2. **WL** (*Waveform Length*) : somme des différences absolues entre échantillons consécutifs. Elle reflète à la fois l'amplitude et la fréquence des variations du signal [90].
3. **RMS** (*Root Mean Square*) : racine carrée de la moyenne des carrés des amplitudes. Elle est interprétée comme une mesure de l'énergie effective du signal [89, 91].
4. **Amplitude Range** : différence entre la valeur maximale et la valeur minimale du segment, traduisant l'étendue d'activation musculaire instantanée [91].
5. **Variance** : mesure de la dispersion du signal autour de sa moyenne. Elle est sensible aux changements de niveau d'activation ou à l'apparition de la fatigue [89].
6. **Form Factor** : ratio entre RMS et MAV, souvent utilisé pour distinguer les signaux bruités des signaux musculaires réguliers.
7. **Integrated EMG (IEMG)** : somme des valeurs absolues du signal, proche du MAV mais non normalisée. Elle est utile pour quantifier la charge musculaire cumulée sur une durée donnée [89].
8. **Cross Rate** : nombre de points où l'EMG dépasse un certain seuil, divisé par la durée du segment. Ce paramètre donne une idée de la fréquence des événements moteurs [92].
9. **Waveform Index** : rapport entre l'énergie absolue et l'énergie quadratique du signal. Il reflète l'efficacité spectrale d'un segment EMG et peut distinguer les signaux dominés par des composantes continues ou pulsées.
10. **Skewness** : mesure de l'asymétrie statistique de la distribution du signal autour de sa moyenne. Un skewness non nul traduit un déséquilibre dans les activations musculaires [93].

Ces paramètres sont utilisés depuis plusieurs décennies dans le domaine de l'analyse EMG pour des applications allant du contrôle de prothèses à l'analyse de la fatigue musculaire. Leur combinaison permet une représentation compacte mais puissante de l'activité électrique du muscle.

### 3.4.2. Paramètres fréquentiels

Les paramètres fréquentiels permettent de quantifier la distribution de l'énergie du signal EMG dans le domaine des fréquences. Ils sont largement utilisés pour détecter les modifications liées à la fatigue, au type de contraction ou au niveau d'activation musculaire. Sept paramètres ont été retenus :

1. **Mean Frequency** : fréquence moyenne du spectre de puissance. Elle représente une estimation globale de la composante fréquentielle dominante du signal [94].
2. **Median Frequency** : fréquence qui divise le spectre en deux zones d'énergie égale. Sa décroissance est associée à la fatigue musculaire [94].
3. **Spectral Centroid** : centre de gravité du spectre d'amplitude, mesurant la localisation moyenne de l'énergie spectrale [95].
4. **Dominant Frequency** : fréquence correspondant au pic le plus élevé dans le spectre de puissance. Elle reflète la composante la plus énergétique du signal EMG [96].
5. **Spectral Slope** : pente de la régression linéaire du spectre en échelle semi-logarithmique. Elle renseigne sur la décroissance spectrale, sensible à la qualité du signal.
6. **High-to-Low Frequency Ratio** : rapport entre l'énergie des hautes fréquences ( $>300$  Hz) et celle des basses ( $<20$  Hz), indiquant les variations du recrutement musculaire [94].
7. **Combined Index (mean and median)** : moyenne arithmétique entre la Mean Frequency et la Median Frequency. Ce paramètre composite permet de capter plus finement l'évolution du contenu spectral.

### 3.4.3. Paramètres temps-fréquence

Les paramètres temps-fréquence sont conçus pour analyser simultanément les variations temporelles et spectrales du signal EMG. Ils sont particulièrement adaptés à la nature non stationnaire du signal musculaire. Trois paramètres ont été extraits :

1. **S-Transform** : moyenne des coefficients issus de la transformée en S, qui combine localisation temporelle et précision fréquentielle [97].
2. **Wigner-Ville Distribution** : moyenne des valeurs de la distribution temps-fréquence de Wigner-Ville. Bien qu'elle offre une résolution élevée, elle peut être affectée par des interférences croisées [98].
3. **Teager-Kaiser Energy** : énergie instantanée évaluée à l'aide de l'opérateur de Teager-Kaiser. Ce paramètre est sensible aux changements brusques et aux onsets musculaires [99].

### 3.4.4. Paramètres non-linéaires

Les paramètres non linéaires permettent de quantifier des propriétés complexes du signal EMG, comme la dispersion, l'imprédictibilité ou la parcimonie. Ils complètent utilement les analyses classiques par leur capacité à détecter des changements subtils ou chaotiques.



1. **Shanon Entropy** : mesure l'imprévisibilité ou la complexité du signal. Une entropie élevée reflète un signal irrégulier ou bruité [95].
2. **Hoyer's Sparsity** : indice mesurant la concentration de l'énergie sur quelques échantillons. Un signal très "sparse" indique des activations brèves et intenses [100].
3. **Hilbert-Huang Transform** : variance des composantes issues de la décomposition empirique en modes intrinsèques (EMD). Cette méthode est efficace pour les signaux non stationnaires, tels que l'EMG [101].



## 3.5 Résultats et discussion



### 3.5.1. Visualisation des paramètres EMG

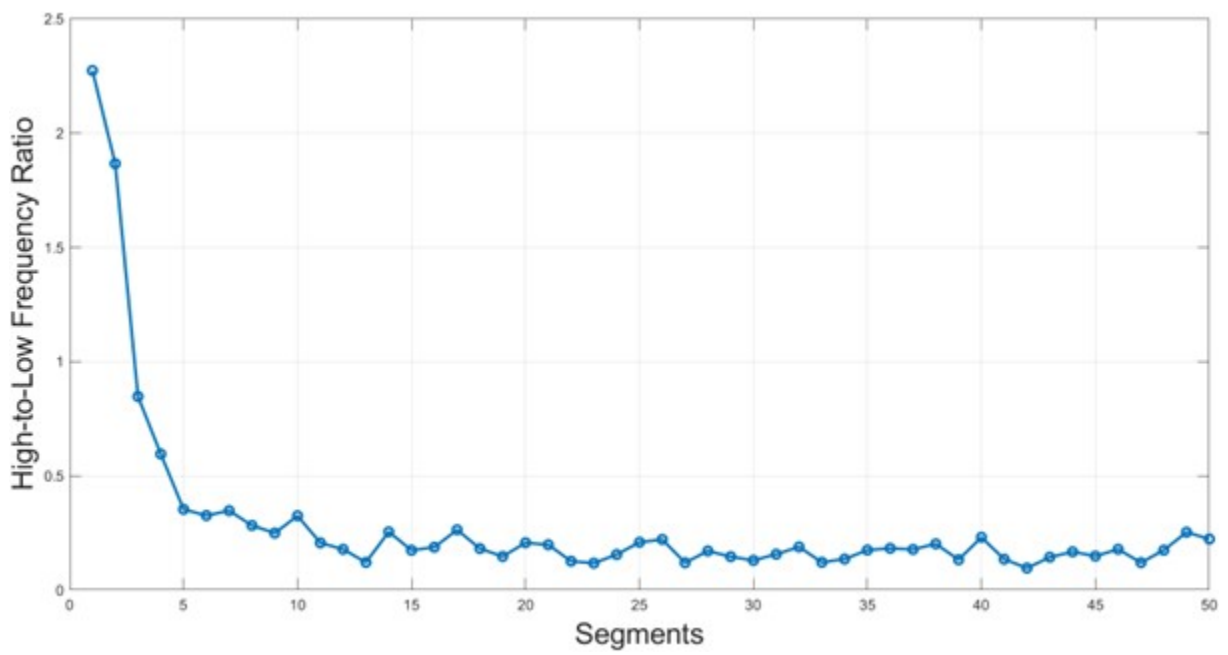

Afin de mieux comprendre le comportement dynamique des descripteurs extraits, chacun des 23 paramètres EMG a été tracé sur les 50 segments du signal pour un sujet représentatif. Dans cette section, nous avons choisi de présenter les résultats correspondant au sujet 3, utilisé ici à titre d'exemple pour illustrer la variabilité et l'évolution des paramètres extraits.



Chaque courbe illustre l'évolution temporelle d'un paramètre donné tout au long de la contraction musculaire, selon une segmentation en 50 portions voir figure 3.2.





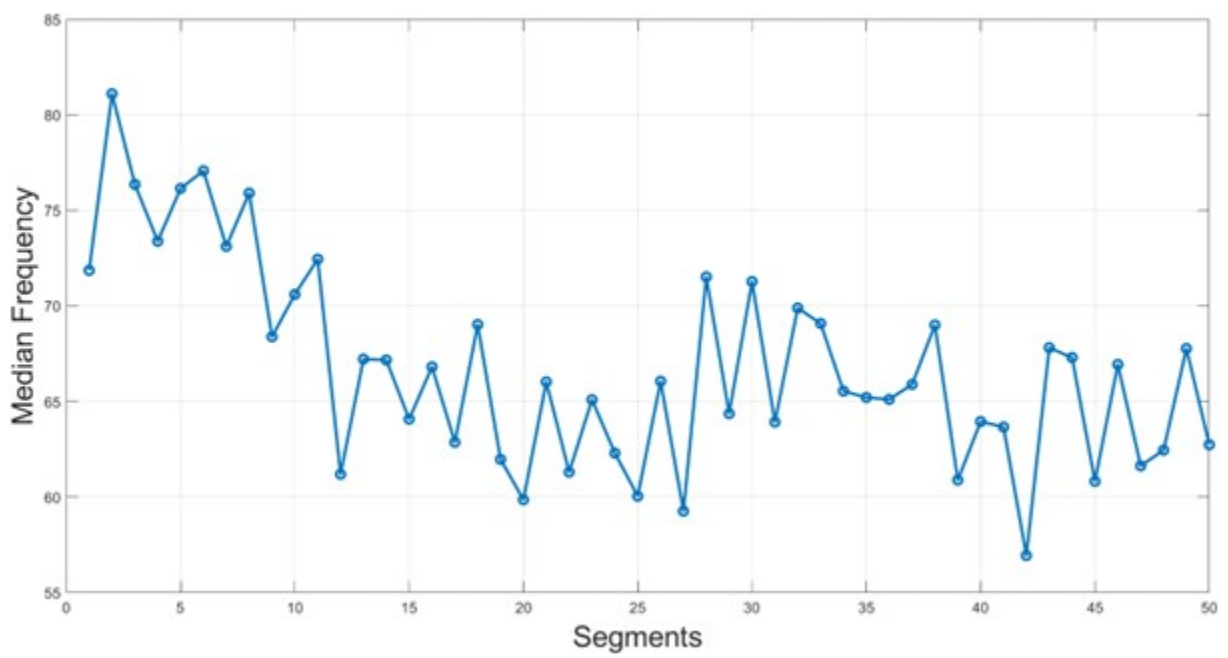



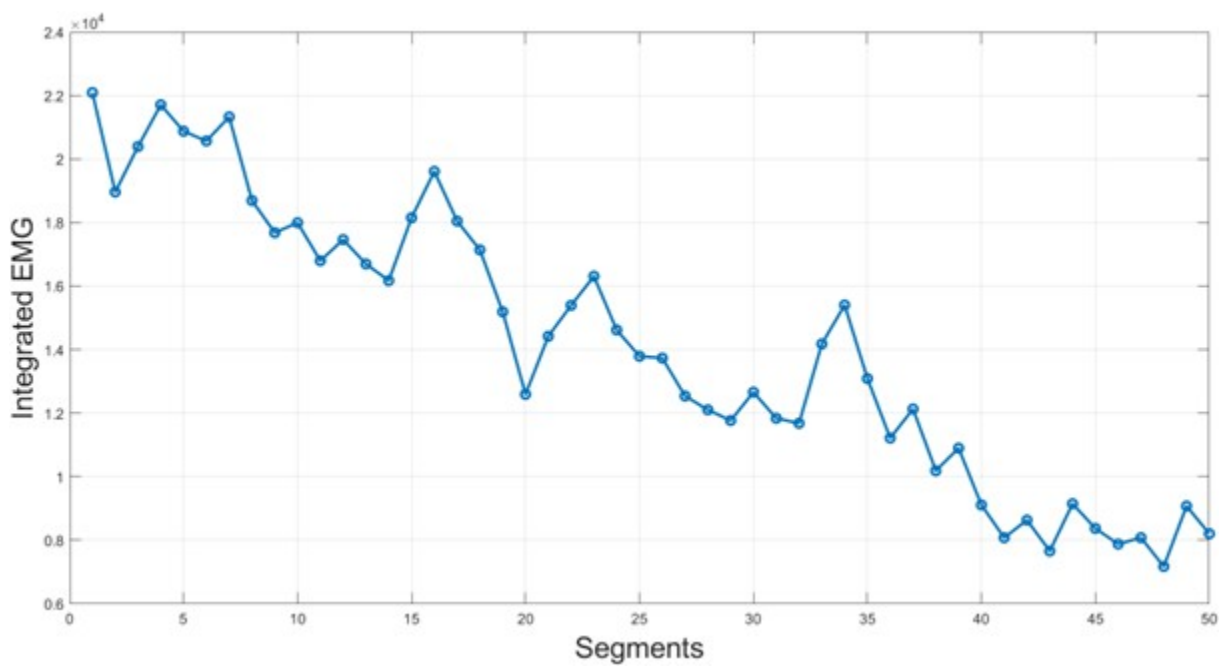




























FIGURE 3.2 – Visualisation des 23 paramètres EMG sur 50 segments du signal

### 3.5.2. Interprétation qualitative

L'examen visuel des 23 paramètres EMG extraits pour le sujet 3, représenté sur les 50 segments du signal, permet de mieux cerner la dynamique de la contraction musculaire au fil du temps. Les tracés révèlent des profils variés : certains paramètres suivent une tendance décroissante nette, d'autres fluctuent fortement ou restent relativement stables. Cette diversité reflète les multiples dimensions de l'activité musculaire capturées par les descripteurs.

Parmi les paramètres temporels, on observe que MAV, RMS, IEMG, Waveform Length et Amplitude Range décroissent de façon progressive et assez régulière, témoignant d'une réduction de l'intensité du signal EMG, possiblement liée à la fatigue musculaire. Crossing Rate présente également une décroissance, suggérant une diminution des événements moteurs rapides. À l'inverse, Variance, Form Factor, Waveform Index et Skewness présentent des profils plus bruités, sans tendance claire, ce qui peut s'expliquer par une variabilité inter-segmentaire ou une sensibilité accrue aux micro-fluctuations du signal.

Concernant les paramètres fréquentiels, Mean Frequency, Median Frequency et Spectral Centroid montrent une légère tendance à la baisse sur les segments, conforme aux observations classiques de la fatigue musculaire.

Cependant, Dominant Frequency et Spectral Slope présentent des courbes irrégulières, marquées par des oscillations parfois abruptes. Le High-to-Low Frequency Ratio, bien que plus stable, présente une légère remontée dans les derniers segments, traduisant un éventuel changement de stratégie de

recrutement musculaire. Le Combined Index (moyenne de Mean et Median Frequency) suit globalement la même dynamique que ses composantes, avec une stabilité relative.

Du côté des paramètres non-linéaires, Shanon Entropy et Hilbert-Huang Transform révèlent des variations importantes d'un segment à l'autre, reflet d'une évolution de la complexité du signal au cours de l'effort. Hoyer's Sparsity, en revanche, reste quasi constant, ce qui indique que la distribution de l'énergie sur les échantillons reste similaire au cours de la contraction.

Enfin, les paramètres temps-fréquence présentent des comportements plus difficiles à interpréter. Teager-Kaiser Energy décroît globalement mais avec des irrégularités locales notables. Wigner-Ville Distribution montre une alternance de pics et de creux, caractéristique de cette méthode sensible aux interférences croisées. S-Transform, quant à elle, reste relativement stable mais peu discriminante.

En résumé, certains paramètres révèlent une décroissance claire au cours des segments - notamment ceux liés à l'intensité ou à la fréquence - tandis que d'autres affichent une forte variabilité inter-segmentaire ou un comportement neutre. Cette diversité justifie l'étape de corrélation objective entre chaque paramètre et la force musculaire présentée dans la section suivante.

### **3.5.3. Corrélation entre paramètres et force**

Dans le but d'identifier les caractéristiques EMG les plus représentatives de l'évolution de la force musculaire, une analyse de corrélation a été réalisée entre chaque paramètre extrait et la force enregistrée.

Le signal de force a été segmenté en 50 portions, de manière identique au signal EMG. Pour chaque segment, une moyenne de la force a été calculée, produisant ainsi un vecteur de 50 valeurs représentant l'évolution de la force musculaire au cours du temps. Afin de cibler les phases physiologiquement pertinentes, la corrélation a été calculée uniquement sur les 30% des premiers segments, correspondant à la zone supérieure de la force maximale [102].

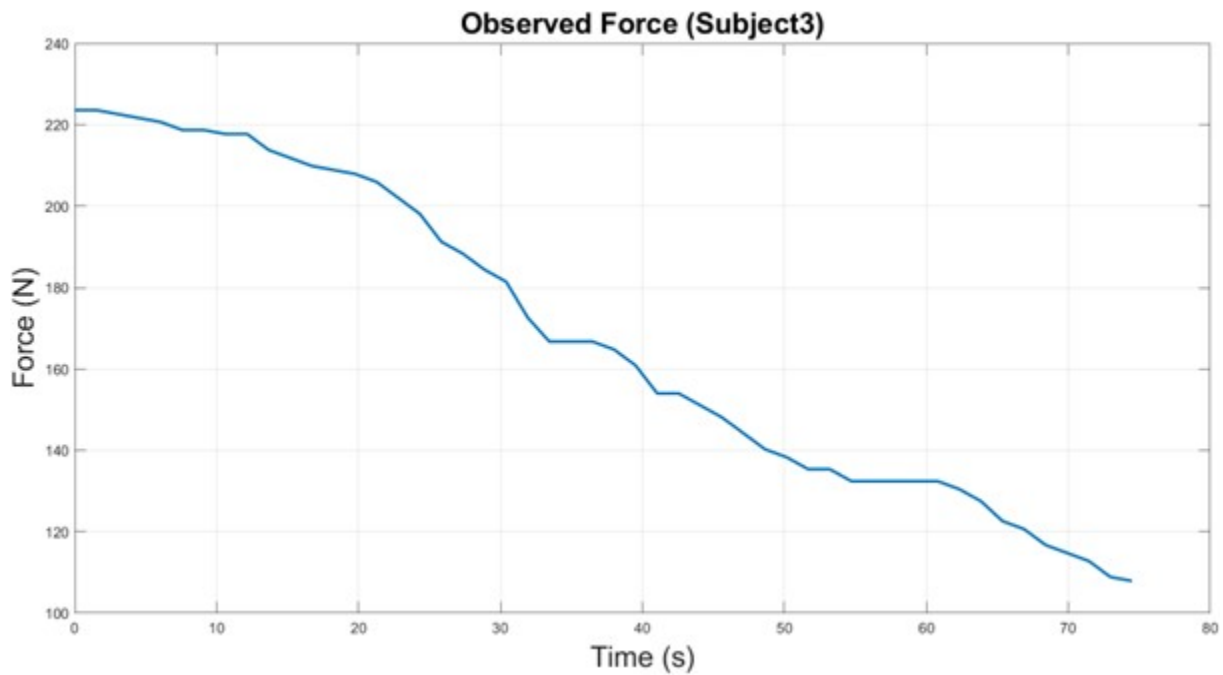


FIGURE 3.3 – Force observée sujet 3

Ce choix méthodologique repose sur le fait que les deux premières phases physiologiques, à savoir la non-fatigue et la transition vers la fatigue, se concentrent généralement dans cette plage élevée de force. En se restreignant à cette portion, l'objectif est d'évaluer la capacité des paramètres EMG à suivre fidèlement la force dans des conditions de contraction optimale, avant l'apparition d'une fatigue prononcée.

Les résultats obtenus à l'aide du coefficient de corrélation de Pearson sont présentés dans le tableau ci-dessous. Ils mettent en évidence d'importantes disparités entre les descripteurs, certains affichant une corrélation élevée avec la force, d'autres au contraire étant peu ou pas corrélés, voire inversement proportionnels.

	<b>Feature</b>	<b>Domain</b>	<b>r (Pearson)</b>
1	Mean Absolute Value	Time	0.79
2	Spectral Centroid	Frequency	0.72
3	Shanon Entropy	Nonlinear	-0.36
4	Combined Index (mean and median)	Frequency	0.86
5	Waveform Length	Time	0.93
6	Mean Frequency	Frequency	0.88
7	Amplitude Range	Time	0.40
8	High-to-Low Frequency Ratio	Frequency	0.65
9	Root Mean Square	Time	0.70
10	Hoyer's Sparsity	Nonlinear	-0.85
11	Crossing Rate	Time	0.68
12	Variance	Time	0.69
13	Waveform Index	Time	0.85
14	Median Frequency	Frequency	0.79
15	Form Factor	Time	-0.85
16	Integrated EMG	Time	0.79
17	Dominant Frequency	Frequency	0.09
18	Spectral Slope	Frequency	-0.02
19	Skewness	Time	-0.87
20	Hilbert-Huang transform	Nonlinear	0.52
21	S-Transform	Time-Frequency	0.80
22	Teager-Kaiser Energy	Time	0.87
23	Wigner-Ville Distribution	Time-Frequency	0.69

TABLE 3.1 – Corrélacion de Pearson entre les paramètres EMG et la force (sur les 30% supérieurs) : sujet 3

On remarque que plusieurs paramètres temporels et fréquentiels présentent une corrélation forte avec la force (par exemple : Waveform Length  $\mathbf{r} = \mathbf{0.93}$ , Mean Frequency  $\mathbf{r} = \mathbf{0.88}$ , Combined Index  $\mathbf{r} = \mathbf{0.86}$ ). À l'inverse, des paramètres non linéaires comme Hoyer's Sparsity ou Skewness montrent une corrélation négative marquée, ce qui peut refléter une inversion dans la complexité ou la distribution du signal à haute intensité.

Cette analyse permet donc de sélectionner les paramètres les plus sensibles à la contraction musculaire en phase non fatiguée, et servira de base à la construction de modèles prédictifs plus fiables dans les chapitres suivants.

### 3.5.4. Construction de la matrice de paramètres (+ normalisation)

À la suite de l'extraction des 23 caractéristiques pour chacun des 50 segments du signal EMG, une matrice de paramètres a été constituée. Chaque ligne de cette matrice représente un segment temporel du signal, et chaque colonne correspond à un descripteur extrait. Ainsi, pour chaque sujet, une matrice de  $50 \times 23$  a été obtenue. Cette matrice intègre l'ensemble des informations temporelles, fréquentielles, temps-fréquence et non-linéaires extraites du signal musculaire, permettant une représentation compacte mais complète de l'activité électromyographique segmentée. L'objectif est de fournir une base de données exploitable pour l'apprentissage automatique, qu'il s'agisse de tâches de classification des états de fatigue ou de régression de la force musculaire.

En parallèle, le signal de force a été segmenté de manière identique en 50 portions, et une valeur moyenne de force a été calculée pour chaque segment. Cela a permis d'obtenir un vecteur de  $50 \times 1$ , associé directement à la matrice des paramètres EMG.

Avant l'exploitation de ces données par les modèles de régression ou de classification, une étape de normalisation a été réalisée. Chaque colonne de la matrice a été standardisée à l'aide de la méthode z-score, c'est-à-dire centrée autour de zéro et réduite à une variance unitaire. Cette opération est essentielle pour garantir que les paramètres, qui peuvent avoir des ordres de grandeur très différents, soient comparables et équilibrés dans les modèles d'apprentissage supervisé.

Ce prétraitement numérique assure une convergence plus stable des algorithmes d'optimisation et réduit les biais liés à l'échelle des données. La matrice normalisée finale constitue ainsi l'entrée principale pour les modèles développés dans les chapitres suivants.

## 3.6 Conclusion

Ce chapitre a détaillé le processus complet de transformation du signal EMG brut en une représentation vectorielle normalisée, apte à l'analyse quantitative. Après filtrage et segmentation du signal en 50 portions, 23 paramètres caractéristiques ont été extraits pour chaque segment, couvrant les principales dimensions du signal musculaire. Les visualisations obtenues ont mis en évidence des tendances spécifiques à certains paramètres, en lien avec la contraction musculaire et la fatigue.

L'analyse de corrélation avec la force mesurée dans la phase de non-fatigue a permis de sélectionner des paramètres significatifs, tels que la Waveform Length ou la Mean Frequency, qui présentent une forte sensibilité à l'évolution de la force. La constitution d'une matrice de taille  $50 \times 23$  par sujet, suivie d'une normalisation z-score, garantit une base solide pour les algorithmes d'apprentissage supervisé.

Ces représentations serviront dans les chapitres suivants à modéliser la force musculaire ou à détecter les phases de fatigue, exclusivement à partir du signal EMG.

# Chapitre 4

## Détection des phases de fatigue par classification supervisée

### 4.1 Introduction

La détection automatique des phases de fatigue musculaire à partir du signal électromyographique (EMG) constitue un enjeu majeur dans le domaine de la biomécanique et du suivi neurophysiologique. Contrairement aux méthodes subjectives ou invasives, l'analyse des caractéristiques extraites du signal EMG permet une estimation non intrusive de l'état fonctionnel du muscle en temps réel. Dans cette optique, ce chapitre explore l'application de techniques de classification supervisée pour distinguer trois états physiologiques – non fatigue, transition et fatigue – sur la base d'un ensemble de paramètres extraits d'enregistrements EMG.

Plusieurs travaux ont exploré l'utilisation des signaux sEMG pour la détection des états musculaires et l'identification des phases de fatigue, en s'appuyant sur des caractéristiques statistiques et des techniques d'apprentissage supervisé. Isa et Aris [103] ont utilisé la programmation génétique (GP) pour évaluer la fatigue musculaire localisée lors d'exercices isométriques à partir de mesures EMG de surface. Leur approche distingue les phases de non-fatigue, de transition vers la fatigue et de fatigue en faisant évoluer une population de classifieurs entraînés sur des caractéristiques statistiques telles que RMS, l'entropie, la kurtosis et l'asymétrie (skewness). L'identification explicite de la phase de transition souligne l'intérêt de modèles EMG interprétables pour le suivi du développement de la fatigue et, sans nécessiter de mesures de force, montre une précision de classification prometteuse chez plusieurs individus.

Dans une étude rapportée, Atzori et al. [104] proposent un cadre hybride combinant régression et classification afin d'assurer un contrôle simultané et gradué de la force au niveau du poignet à l'aide des signaux EMG. Leur

méthode utilise un classifieur à apprentissage multi-noyaux pour identifier les classes de mouvement, suivi de régressions par réseaux de neurones spécifiques à chaque classe afin d'estimer les sorties de force correspondantes. Cette approche en deux étapes améliore la précision de la prédiction de la force, en particulier pour des degrés de liberté complexes tels que la pronation et la supination.

Afin d'assurer une évaluation fiable et généralisable, une validation inter-sujets rigoureuse de type Leave-One-Subject-Out (LOSO) a été adoptée. Treize modèles de classification, allant des méthodes linéaires simples aux approches d'ensemble plus complexes, ont été comparés sur la base de cinq métriques de performance, avec l'accuracy comme indicateur principal. L'objectif est double : identifier les modèles les plus performants et robustes, tout en analysant leur capacité à généraliser les détections au-delà du sujet utilisé pour l'entraînement.

## 4.2 Méthodologie de classification

Cette section décrit l'approche méthodologique adoptée pour classifier les différentes phases de fatigue musculaire à partir des signaux EMG traités. L'objectif est d'évaluer de manière rigoureuse la capacité de plusieurs algorithmes supervisés à discriminer automatiquement les états de non-fatigue, de transition et de fatigue, à partir de paramètres extraits du signal. Le protocole repose sur une validation inter-sujets (LOSO) garantissant l'indépendance des données de test, et sur une représentation normalisée des caractéristiques EMG. Treize modèles de classification, couvrant un large spectre de complexité algorithmique, sont comparés selon des critères quantitatifs standards tels que l'accuracy, la précision, le rappel, le F1-score et la spécificité.

### 4.2.1. Stratégie de validation inter-sujets (LOSO)

Pour évaluer la robustesse des modèles de classification, une validation croisée de type Leave-One-Subject-Out (LOSO) a été utilisée. Ce protocole consiste à isoler successivement les données d'un sujet pour les utiliser exclusivement comme ensemble de test, tandis que les données des  $N-1$  autres sujets servent à l'entraînement. Cette procédure est répétée pour l'ensemble des sujets, garantissant ainsi que chaque modèle est évalué sur des données totalement indépendantes de celles utilisées pour l'apprentissage.

Le principal intérêt de cette approche est d'assurer une évaluation réaliste de la capacité de généralisation du modèle à un nouvel individu. Contraire-

ment aux validations croisées classiques par segments aléatoires, la validation LOSO empêche tout chevauchement potentiel entre les données d'entraînement et de test, ce qui est particulièrement crucial dans le contexte de signaux physiologiques comme l'EMG [105].

Bien que cette méthode soit plus exigeante en termes de temps de calcul, elle reste une référence en matière de validation inter-sujets dans les domaines biomédicaux.

#### 4.2.2. Constitution des ensembles de données

Les données utilisées pour la classification proviennent d'enregistrements synchronisés du signal électromyographique (EMG) et de la force musculaire, acquis au cours d'une contraction isométrique soutenue. Pour chaque sujet, le signal EMG a été prétraité à travers des étapes de filtrage, de découpage en segments fixes, et de normalisation, avant d'être converti en une représentation numérique à l'aide de 23 paramètres issus de domaines variés : temporel, fréquentiel, temps-fréquence, et non linéaire. Le résultat de ce processus est une matrice de caractéristiques de taille  $S \times 23S$  où  $S$  est le nombre de segments extraits pour le sujet considéré.

Les étiquettes de classe ont été générées automatiquement à partir du signal de force, selon une stratégie de seuillage standardisée. Plus précisément, la force maximale de chaque session a été identifiée, puis deux seuils ont été définis à 90% et 70% de cette valeur. À chaque segment EMG est associée la valeur moyenne de force correspondante, et une phase de fatigue lui est attribuée selon les règles suivantes :

- **Phase 1** : non-fatigue si la force moyenne est supérieure à 90% de la maximale.
- **Phase 2** : transition si la force est comprise entre 70% et 90%.
- **Phase 3** : fatigue si la force est inférieure à 70%.

Ce découpage permet d'étiqueter objectivement l'évolution de la fatigue musculaire sans intervention manuelle, et repose sur une méthodologie déjà utilisée dans la littérature [106].

L'ensemble complet des données inclut 15 sujets, chacun contribuant à la base d'apprentissage et de test selon le protocole LOSO. Pour chaque itération, une matrice d'apprentissage est construite en concaténant les données des 14 sujets d'entraînement, tandis que les données du sujet test sont gardées pour l'évaluation. Afin de garantir une homogénéité des échelles entre les différentes variables, chaque matrice a été standardisée individuellement par z-score, centrant chaque feature autour de zéro et lui attribuant une variance unitaire.

### 4.2.3. Modèles de classification évalués

Afin de comparer de manière complète et équitable différentes approches de classification, treize modèles ont été sélectionnés et regroupés selon leur nature algorithmique. Chaque méthode a été testée indépendamment sur les mêmes matrices de caractéristiques EMG à l'aide de la validation LOSO, sans ajustement spécifique à un sujet donné.

#### 4.2.3.1. Classificateurs linéaires et simples

##### 1. Linear Discriminant Analysis (LDA)

LDA projette les données dans un espace où la séparation linéaire entre les classes est maximisée. Il est rapide, interprétable et robuste lorsque les classes ont des covariances similaires.

##### 2. Quadratic Discriminant Analysis (QDA)

QDA autorise une matrice de covariance propre à chaque classe, permettant des frontières de décision quadratiques. Il est plus flexible que LDA, au prix d'une plus grande sensibilité au surapprentissage.

##### 3. Naive Bayes (NB)

Ce classifieur probabiliste repose sur le théorème de Bayes avec hypothèse d'indépendance entre les variables. Il est efficace pour les problèmes simples et peu coûteux en calcul.

##### 4. Nearest Centroid (Centroid)

Ce modèle attribue un échantillon à la classe dont le centroïde (moyenne vectorielle) est le plus proche. Il est non paramétrique, rapide et simple à implémenter.

#### 4.2.3.2. Classifieur à base de distance

##### K-Nearest Neighbors (KNN)

KNN classe un échantillon en fonction des classes les plus fréquentes parmi ses K plus proches voisins. Bien qu'il ne nécessite pas d'entraînement, il peut être lent à la prédiction et sensible à la distribution locale des données.

#### 4.2.3.3. Classifieur à marge maximale

##### Support Vector Machine (SVM)

SVM cherche un hyperplan qui maximise la marge entre les classes. Avec des fonctions noyaux, il permet de traiter des cas non linéaires. C'est un modèle performant et très utilisé en biomédical [107].

#### 4.2.3.4. Classifieurs par arbres de décision

##### Decision Tree (CART)

Ce modèle partitionne récursivement l'espace des caractéristiques à l'aide de

règles conditionnelles. Il est facilement interprétable mais peut souffrir de surapprentissage.

#### 4.2.3.5. Méthodes d'ensemble

##### 1. **Random Forest (RF)**

Random Forest est une agrégation de nombreux arbres de décision construits sur des sous-échantillons aléatoires des données et des caractéristiques. Il offre de très bonnes performances et une bonne robustesse [107].

##### 2. **Bagging**

Le bagging (Bootstrap Aggregating) crée plusieurs versions du même modèle de base (souvent un arbre) sur des échantillons bootstrapés, puis en agrège les décisions, ce qui réduit la variance.

##### 3. **Gradient Boosting (GB)**

Le boosting construit des modèles faibles séquentiellement, en corrigeant les erreurs du précédent. Il est plus lent mais très performant, notamment sur des données complexes.

#### 4.2.3.6. Réseau de neurones

##### **Artificial Neural Network (ANN)**

Les réseaux de neurones apprennent des représentations complexes grâce à des couches denses. Même une architecture simple peut capturer des dynamiques non linéaires dans les signaux EMG.

#### 4.2.3.7. Méthodes floues

##### 1. **Fuzzy K-Nearest Neighbors (Fuzzy-KNN)**

Cette variante floue de KNN intègre un degré d'appartenance flou dans le vote des voisins, permettant de mieux gérer les zones de transition ou d'ambiguïté entre classes.

##### 2. **Fuzzy Decision Tree**

Contrairement à un arbre classique, chaque décision dans un arbre flou est associée à une probabilité d'appartenance. Ce modèle est adapté à la nature incertaine des signaux physiologiques.

Chaque classifieur a été testé de façon équitable sur les 15 sujets, dans un cadre de validation inter-sujets rigoureux.

#### 4.2.4. Indicateur principal de performance

L'accuracy a été choisie comme indicateur principal pour évaluer les performances des modèles de classification dans cette étude. Elle représente la proportion de segments EMG correctement classés par rapport au nombre total de segments.

Étant donné que les résultats de classification ont été stockés sous forme de nombre de mismatches (c'est-à-dire de segments mal classés), l'accuracy a été calculée selon la formule suivante :

$$\text{Accuracy} = 1 - \frac{\text{Nombre de mismatches}}{\text{Nombre total de segments}}$$

Ce lien direct entre erreurs et performance globale permet une comparaison simple, fiable et homogène entre les différents modèles testés et les différents sujets.

Ce critère a été utilisé tout au long de l'analyse (sections 4.3.1 à 4.3.4) pour :

- évaluer les performances individuelles de chaque modèle par sujet,
- identifier le(s) meilleur(s) modèle(s),
- établir les moyennes par méthode,
- et extraire les top 3 les plus récurrents.

D'autres métriques classiques de classification comme le rappel, la précision, le F1-score et la spécificité ont également été calculées pour chaque classe, mais elles ont été utilisées à titre complémentaire seulement, sans influencer la sélection finale des meilleurs modèles [108].

### 4.3 Résultats expérimentaux

L'ensemble des modèles de classification a été évalué sur quinze sujets, à l'aide de treize méthodes différentes. Cinq métriques ont été calculées pour chaque combinaison sujet/modèle : l'accuracy, la précision, le rappel, le F1-score et la spécificité. Les résultats sont organisés en plusieurs niveaux d'analyse : performances individuelles par sujet, identification du meilleur modèle pour chaque cas, décompte des modèles les plus performants dans le top 3, et enfin une analyse croisée des performances. Ces résultats permettent de mettre en évidence non seulement l'efficacité des différentes approches, mais aussi leur robustesse face à la variabilité interindividuelle du signal EMG.

#### 4.3.1. Résultats individuels pour chaque sujet

L'analyse des performances de classification a été menée individuellement pour chacun des 15 sujets afin d'évaluer la robustesse des modèles face à la variabilité interindividuelle du signal EMG. Pour chaque sujet, les treize modèles ont été testés, et les cinq métriques de performance - accuracy, précision, rappel, F1-score, et spécificité - ont été calculées à partir des prédictions.

Les résultats détaillés montrent une hétérogénéité importante entre les sujets, tant en termes d'accuracy globale que de modèle optimal. Par exemple, le modèle Naive Bayes a atteint une accuracy maximale de 0.90 pour le sujet 4, tandis que le modèle Random Forest a été le plus performant pour plusieurs sujets (notamment les sujets 5, 6, 7, 11, 13, 14 et 15) avec des accuracy variant entre 0.64 et 0.96. Dans certains cas, plusieurs modèles ont obtenu une accuracy équivalente, traduisant une égalité de performance entre classifieurs pour un sujet donné (e.g., sujet 5 avec Random Forest, Boosting et QDA à 0.96).

Les tableaux suivants présentent, pour chaque sujet, les valeurs complètes

des métriques calculées pour tous les modèles testés. Ces observations mettent en lumière la nécessité d'un choix personnalisé du classifieur en fonction du profil EMG de l'individu, ce qui justifie les analyses complémentaires des sections suivantes.

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.8800	0.8100	0.8600	0.8300	0.9300
2	ANN	0.8000	0.6700	0.7400	0.7000	0.8800
3	NaiveBayes	0.4000	0.4600	0.5200	0.4900	0.7600
4	Centroid	0.8400	0.7700	0.8600	0.8100	0.9200
5	LDA	0.8400	0.7700	0.8600	0.8100	0.9200
6	QDA	0.7400	0.6400	0.7700	0.7000	0.8900
7	Bagging	0.8600	0.8100	0.8100	0.8100	0.8900
8	KNN	0.7200	0.5500	0.6800	0.6100	0.8400
9	RandomForest	0.8800	0.8700	0.8200	0.8400	0.9000
10	Boosting	0.8800	0.7700	0.8000	0.7900	0.9400
11	DecisionTree	0.7800	0.6300	0.6900	0.6600	0.8400
12	RUSBoost	0.8800	0.7900	0.8400	0.8200	0.9400
13	SubspaceDisc	0.6800	0.4000	0.6200	0.4900	0.8500

TABLE 4.1 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 1

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.9200	0.8100	0.7900	0.8000	0.9500
2	ANN	0.6800	0.6600	0.7400	0.7000	0.8800
3	NaiveBayes	0.7600	0.6800	0.7800	0.7200	0.9100
4	Centroid	0.8200	0.6400	0.6900	0.6600	0.9000
5	LDA	0.8200	0.6400	0.6900	0.6600	0.9000
6	QDA	0.9000	0.7700	0.8400	0.8000	0.9600
7	Bagging	0.8600	0.7300	0.8200	0.7700	0.9500
8	KNN	0.8000	0.6600	0.7400	0.7000	0.9100
9	RandomForest	0.8600	0.7300	0.8200	0.7700	0.9500
10	Boosting	0.8600	0.7300	0.8200	0.7700	0.9500
11	DecisionTree	0.7200	0.6700	0.7600	0.7100	0.9000
12	RUSBoost	0.8600	0.7300	0.8200	0.7700	0.9500
13	SubspaceDisc	0.8200	0.6000	0.5000	0.5500	0.7700

TABLE 4.2 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 2

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.7400	0.7200	0.6600	0.6900	0.8600
2	ANN	0.7400	0.6200	0.6400	0.6300	0.8600
3	NaiveBayes	0.7000	0.7500	0.7400	0.7400	0.8700
4	Centroid	0.7800	0.7600	0.7200	0.7400	0.8800
5	LDA	0.7800	0.7600	0.7200	0.7400	0.8800
6	QDA	0.7400	0.6800	0.6800	0.6800	0.8700
7	Bagging	0.7000	0.6600	0.6500	0.6500	0.8500
8	KNN	0.7000	0.6100	0.6300	0.6200	0.8500
9	RandomForest	0.7400	0.7100	0.7000	0.7000	0.8700
10	Boosting	0.7000	0.7300	0.6500	0.6900	0.8500
11	DecisionTree	0.7800	0.7300	0.7300	0.7300	0.8900
12	RUSBoost	0.7600	0.7700	0.7200	0.7500	0.8800
13	SubspaceDisc	0.5600	0.5000	0.4400	0.4700	0.7300

TABLE 4.3 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 3

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.7600	0.7500	0.7200	0.7300	0.8600
2	ANN	0.6800	0.7000	0.5900	0.6400	0.8200
3	NaiveBayes	0.2800	0.4900	0.4400	0.4600	0.7100
4	Centroid	0.6600	0.7800	0.6600	0.7200	0.8600
5	LDA	0.7000	0.7400	0.6000	0.6700	0.8400
6	QDA	0.5600	0.7600	0.6600	0.7100	0.8200
7	Bagging	0.6200	0.7500	0.6400	0.6900	0.8400
8	KNN	0.5600	0.3800	0.4200	0.4000	0.8000
9	RandomForest	0.6800	0.7700	0.6700	0.7200	0.8600
10	Boosting	0.5600	0.7400	0.5600	0.6400	0.8100
11	DecisionTree	0.6400	0.7800	0.6800	0.7300	0.8500
12	RUSBoost	0.6200	0.7700	0.6700	0.7200	0.8500
13	SubspaceDisc	0.6800	0.4300	0.5900	0.5000	0.8400

TABLE 4.4 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 4

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.7800	0.7900	0.6400	0.7100	0.8200
2	ANN	0.8000	0.8200	0.6400	0.7200	0.8400
3	NaiveBayes	0.8600	0.8200	0.7500	0.7800	0.9000
4	Centroid	0.8400	0.8500	0.6900	0.7700	0.8800
5	LDA	0.8400	0.8500	0.6900	0.7700	0.8800
6	QDA	0.7800	0.7900	0.6400	0.7100	0.8200
7	Bagging	0.8400	0.8800	0.7500	0.8100	0.8600
8	KNN	0.8000	0.8200	0.6700	0.7400	0.8300
9	RandomForest	0.8200	0.8400	0.6900	0.7600	0.8500
10	Boosting	0.7600	0.7500	0.6100	0.6800	0.8000
11	DecisionTree	0.7800	0.8100	0.6700	0.7300	0.8100
12	RUSBoost	0.8000	0.7600	0.6900	0.7300	0.8500
13	SubspaceDisc	0.6400	0.2100	0.3300	0.2600	0.6700

TABLE 4.5 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 5

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.8600	0.8000	0.8500	0.8300	0.9200
2	ANN	0.9200	0.8700	0.9200	0.8900	0.9500
3	NaiveBayes	0.7800	0.6900	0.7900	0.7400	0.9100
4	Centroid	0.8200	0.7700	0.8100	0.7900	0.9200
5	LDA	0.8200	0.7700	0.8100	0.7900	0.9200
6	QDA	0.7800	0.7100	0.7800	0.7400	0.9000
7	Bagging	0.8800	0.8900	0.8800	0.8800	0.9100
8	KNN	0.7600	0.7000	0.7600	0.7300	0.8500
9	RandomForest	0.7800	0.7700	0.7700	0.7700	0.8500
10	Boosting	0.8400	0.7900	0.8300	0.8100	0.9000
11	DecisionTree	0.8600	0.8200	0.8500	0.8400	0.9100
12	RUSBoost	0.7600	0.7500	0.7500	0.7500	0.8500
13	SubspaceDisc	0.6400	0.4300	0.5000	0.4700	0.7100

TABLE 4.6 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 6

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.9000	0.9400	0.8900	0.9200	0.9300
2	ANN	0.7600	0.7600	0.7800	0.7700	0.8800
3	NaiveBayes	0.7400	0.8500	0.8100	0.8300	0.8800
4	Centroid	0.8400	0.8900	0.8100	0.8500	0.9000
5	LDA	0.8200	0.8800	0.7900	0.8300	0.8800
6	QDA	0.7800	0.8500	0.7400	0.7900	0.8600
7	Bagging	0.8000	0.8300	0.8000	0.8200	0.8800
8	KNN	0.7800	0.7800	0.7700	0.7800	0.8700
9	RandomForest	0.8600	0.8900	0.8400	0.8600	0.9100
10	Boosting	0.8000	0.8100	0.7800	0.8000	0.8800
11	DecisionTree	0.7400	0.7500	0.7700	0.7600	0.8600
12	RUSBoost	0.8200	0.8200	0.8400	0.8300	0.9000
13	SubspaceDisc	0.5400	0.5100	0.4000	0.4500	0.6900

TABLE 4.7 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 7

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.8000	0.8400	0.7100	0.7700	0.8500
2	ANN	0.7000	0.7200	0.6000	0.6500	0.7900
3	NaiveBayes	0.7600	0.8000	0.6700	0.7300	0.8200
4	Centroid	0.7400	0.7700	0.6200	0.6900	0.8100
5	LDA	0.7400	0.7700	0.6200	0.6900	0.8100
6	QDA	0.7400	0.7800	0.6400	0.7000	0.8100
7	Bagging	0.7000	0.6700	0.6000	0.6300	0.7800
8	KNN	0.6800	0.6500	0.5500	0.5900	0.7700
9	RandomForest	0.7600	0.8000	0.6700	0.7300	0.8200
10	Boosting	0.7400	0.7700	0.6600	0.7100	0.8100
11	DecisionTree	0.7600	0.8000	0.6700	0.7300	0.8200
12	RUSBoost	0.7400	0.7800	0.6400	0.7000	0.8100
13	SubspaceDisc	0.6000	0.5300	0.3800	0.4400	0.6800

TABLE 4.8 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 8

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.8000	0.7600	0.8100	0.7900	0.9200
2	ANN	0.8400	0.7900	0.8300	0.8100	0.9400
3	NaiveBayes	0.9000	0.8700	0.9500	0.9100	0.9600
4	Centroid	0.8200	0.8200	0.8800	0.8500	0.9300
5	LDA	0.8200	0.8200	0.8800	0.8500	0.9300
6	QDA	0.9200	0.8600	0.8300	0.8500	0.9600
7	Bagging	0.9000	0.8700	0.9500	0.9100	0.9600
8	KNN	0.8800	0.8100	0.8500	0.8300	0.9500
9	RandomForest	0.9600	0.9300	0.9800	0.9600	0.9800
10	Boosting	0.9200	0.8600	0.9300	0.8900	0.9700
11	DecisionTree	0.8000	0.7000	0.7700	0.7300	0.9100
12	RUSBoost	0.9000	0.8700	0.9500	0.9100	0.9600
13	SubspaceDisc	0.7000	0.5600	0.3800	0.4500	0.6900

TABLE 4.9 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 9

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.8800	0.8600	0.8200	0.8400	0.9300
2	ANN	0.8400	0.7900	0.7900	0.7900	0.9300
3	NaiveBayes	0.9400	0.9200	0.9700	0.9400	0.9800
4	Centroid	0.8800	0.8300	0.8600	0.8500	0.9400
5	LDA	0.8800	0.8300	0.8600	0.8500	0.9400
6	QDA	0.9200	0.8800	0.8600	0.8700	0.9600
7	Bagging	0.9200	0.8800	0.9000	0.8900	0.9600
8	KNN	0.8400	0.7800	0.7600	0.7700	0.9000
9	RandomForest	0.9600	0.9300	0.9500	0.9400	0.9800
10	Boosting	0.9600	0.9300	0.9500	0.9400	0.9800
11	DecisionTree	0.8200	0.7700	0.7800	0.7800	0.9100
12	RUSBoost	0.9200	0.8800	0.9300	0.9000	0.9700
13	SubspaceDisc	0.6800	0.5500	0.4300	0.4900	0.7200

TABLE 4.10 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 10

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.9200	0.9700	0.8500	0.9100	0.9000
2	ANN	0.9000	0.8100	0.7800	0.8000	0.9400
3	NaiveBayes	0.9400	0.9700	0.8900	0.9300	0.9300
4	Centroid	0.9000	0.9100	0.8400	0.8800	0.9000
5	LDA	0.9000	0.9100	0.8400	0.8800	0.9000
6	QDA	0.9000	0.9600	0.8100	0.8800	0.8800
7	Bagging	0.9200	0.9300	0.8800	0.9000	0.9200
8	KNN	0.8400	0.7700	0.7900	0.7800	0.8700
9	RandomForest	0.9400	0.9400	0.9200	0.9300	0.9400
10	Boosting	1.0000	1.0000	1.0000	1.0000	1.0000
11	DecisionTree	0.8800	0.8700	0.8300	0.8500	0.8900
12	RUSBoost	0.9400	0.9400	0.9200	0.9300	0.9400
13	SubspaceDisc	0.7400	0.5800	0.4000	0.4700	0.6200

TABLE 4.11 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 11

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.8800	0.8000	0.8600	0.8300	0.9400
2	ANN	0.6600	0.5800	0.6300	0.6000	0.8400
3	NaiveBayes	0.8800	0.8900	0.7700	0.8200	0.8900
4	Centroid	0.8600	0.8400	0.7000	0.7600	0.9000
5	LDA	0.8600	0.8400	0.7000	0.7600	0.9000
6	QDA	0.9200	0.9300	0.8400	0.8800	0.9300
7	Bagging	0.6800	0.7000	0.5900	0.6400	0.8100
8	KNN	0.8200	0.7700	0.7200	0.7500	0.8400
9	RandomForest	0.6400	0.6900	0.5700	0.6300	0.7900
10	Boosting	0.8200	0.7900	0.7800	0.7800	0.8600
11	DecisionTree	0.6000	0.5000	0.5600	0.5300	0.7600
12	RUSBoost	0.6800	0.7500	0.7100	0.7300	0.8400
13	SubspaceDisc	0.6800	0.2300	0.3300	0.2700	0.6700

TABLE 4.12 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 12

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.6400	0.6500	0.6900	0.6700	0.8100
2	ANN	0.5200	0.5400	0.6400	0.5900	0.7100
3	NaiveBayes	0.5200	0.7300	0.7100	0.7200	0.7500
4	Centroid	0.6400	0.7500	0.6100	0.6700	0.7900
5	LDA	0.6600	0.7600	0.6100	0.6700	0.7900
6	QDA	0.6200	0.6400	0.7000	0.6700	0.7600
7	Bagging	0.6200	0.7100	0.7100	0.7100	0.7600
8	KNN	0.5600	0.5900	0.6500	0.6200	0.7200
9	RandomForest	0.6000	0.6300	0.6900	0.6600	0.7500
10	Boosting	0.6000	0.6600	0.6600	0.6600	0.7800
11	DecisionTree	0.5400	0.5300	0.5900	0.5600	0.7300
12	RUSBoost	0.6800	0.7100	0.7700	0.7400	0.8200
13	SubspaceDisc	0.6000	0.2000	0.3300	0.2500	0.6700

TABLE 4.13 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 13

	<b>Méthode</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Specifity</b>
1	SVM	0.7000	0.7200	0.6900	0.7000	0.8100
2	ANN	0.6000	0.6800	0.6000	0.6400	0.7700
3	NaiveBayes	0.5400	0.6400	0.5500	0.5900	0.7300
4	Centroid	0.5800	0.5900	0.5100	0.5500	0.7200
5	LDA	0.6400	0.6100	0.5400	0.5700	0.7500
6	QDA	0.7200	0.6500	0.6600	0.6500	0.7800
7	Bagging	0.6800	0.6500	0.6500	0.6500	0.7700
8	KNN	0.6200	0.6500	0.6100	0.6300	0.7600
9	RandomForest	0.6800	0.6500	0.6500	0.6500	0.7700
10	Boosting	0.6600	0.6400	0.6400	0.6400	0.7600
11	DecisionTree	0.6400	0.7200	0.7000	0.7100	0.8100
12	RUSBoost	0.6200	0.6500	0.6400	0.6400	0.7600
13	SubspaceDisc	0.6600	0.5500	0.3800	0.4500	0.6900

TABLE 4.14 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 14

	Méthode	Accuracy	Précision	Recall	F1-score	Specifity
1	SVM	0.8200	0.7700	0.7100	0.7400	0.8500
2	ANN	0.8000	0.7600	0.7300	0.7500	0.8600
3	NaiveBayes	0.6800	0.7200	0.7100	0.7200	0.8300
4	Centroid	0.8200	0.7700	0.6600	0.7100	0.8500
5	LDA	0.8200	0.7700	0.6600	0.7100	0.8500
6	QDA	0.7800	0.7300	0.6900	0.7100	0.8300
7	Bagging	0.8200	0.7500	0.6800	0.7100	0.8300
8	KNN	0.8000	0.7600	0.6900	0.7200	0.8600
9	RandomForest	0.8400	0.7400	0.7000	0.7200	0.8400
10	Boosting	0.8000	0.6300	0.5900	0.6100	0.8300
11	DecisionTree	0.8000	0.6200	0.6800	0.6500	0.8400
12	RUSBoost	0.7600	0.5900	0.6600	0.6300	0.8300
13	SubspaceDisc	0.7600	0.5800	0.4400	0.5000	0.7100

TABLE 4.15 – Valeurs complètes des métriques calculées pour tous les modèles testés : sujet 15

### 4.3.2. Meilleur modèle par sujet

L'identification du ou des meilleurs modèles pour chaque sujet a été réalisée en comparant directement les valeurs d'accuracy des 13 classifieurs testés. Dans certains cas, plusieurs modèles ont obtenu exactement la même performance maximale. Le tableau ci-dessous récapitule les modèles ayant atteint la meilleure accuracy pour chaque sujet :

Sujet	Modèle(s)	Accuracy
1	SVM, RandomForest, Boosting, RUSBoost	0.8800
2	SVM	0.9200
3	Centroid, LDA	0.7800
4	SVM	0.7600
5	NaiveBayes	0.8600
6	ANN	0.9200
7	SVM	0.9000
8	SVM	0.8000
9	RandomForest	0.9600
10	RandomForest, Boosting	0.9600
11	Boosting	1.0000
12	QDA	0.9200
13	RUSBoost	0.6800
14	QDA	0.7200
15	RandomForest	0.8400

TABLE 4.16 – Performances des modèles par sujet

Ce tableau montre que SVM apparaît dans le top pour 6 sujets, ce qui

en fait le modèle le plus fréquemment performant. Il est suivi de Random Forest (4 sujets), Boosting (3 sujets), et QDA (3 sujets également). Des modèles comme RUSBoost, ANN, Naive Bayes, Centroid, et LDA n'apparaissent qu'une ou deux fois chacun. Ce résultat confirme que bien qu'un modèle puisse offrir une performance exceptionnelle sur un sujet donné, sa régularité sur l'ensemble des sujets constitue un critère déterminant pour évaluer sa robustesse globale.

### 4.3.3. Top 3 des modèles par sujet

Pour affiner l'analyse comparative entre classifieurs, le tableau suivant présente les trois meilleurs modèles pour chaque sujet, en fonction de leur accuracy. Lorsque plusieurs modèles obtiennent une valeur identique d'accuracy, ils sont tous inclus, même si cela conduit à plus de trois modèles listés. Cette approche vise à ne pas négliger les cas d'égalité parfaite, fréquents dans les scénarios de performances proches.

Sujet	Top Modèles	Accuracies
1	RUSBoost, Boosting, RandomForest, SVM	0.88, 0.88, 0.88, 0.88
2	SVM, QDA, RUSBoost, Boosting, RandomForest, Bagging	0.92, 0.90, 0.86, 0.86, 0.86, 0.86
3	DecisionTree, LDA, Centroid	0.78, 0.78, 0.78
4	SVM, LDA, SubspaceDisc, RandomForest, ANN	0.76, 0.70, 0.68, 0.68, 0.68
5	NaiveBayes, Bagging, LDA, Centroid	0.86, 0.84, 0.84, 0.84
6	ANN, Bagging, Boosting	0.92, 0.88, 0.84
7	SVM, RandomForest, RUSBoost	0.90, 0.86, 0.82
8	SVM, NaiveBayes, RandomForest	0.80, 0.76, 0.76
9	RandomForest, Boosting, NaiveBayes, RUSBoost, Bagging	0.96, 0.92, 0.90, 0.90, 0.90
10	RandomForest, Boosting, RUSBoost, QDA	0.96, 0.96, 0.92, 0.92
11	Boosting, NaiveBayes, RandomForest, RUSBoost	1.00, 0.94, 0.94, 0.94
12	QDA, NaiveBayes, LDA, Centroid	0.92, 0.88, 0.86, 0.86
13	RUSBoost, LDA, Centroid	0.68, 0.66, 0.64
14	QDA, Bagging, RandomForest	0.72, 0.68, 0.68
15	RandomForest, SVM, LDA, Centroid	0.84, 0.82, 0.82, 0.82

TABLE 4.17 – Top modèles et leurs performances par sujet

Cette analyse confirme que certains modèles se démarquent par leur régularité dans les performances de haut niveau. Random Forest, SVM, Boosting, et RUSBoost apparaissent ainsi très fréquemment parmi les trois premiers modèles, suggérant une bonne stabilité inter-sujets. En revanche, d'autres méthodes comme Naive Bayes, Centroid ou LDA apparaissent davantage de façon ponctuelle.

Afin de mieux visualiser la régularité des performances, le tableau suivant synthétise le nombre total de présences dans le Top 3 pour chaque classifieur, tous sujets confondus :

Modèle	Nombre d'apparitions dans le Top 3
RandomForest	10
SVM	10
Boosting	5
Bagging	5
LDA	5
NaiveBayes	4
Centroid	4
RUSBoost	4
QDA	3
ANN	3
DecisionTree	2
SubspaceDisc	2
KNN	1

TABLE 4.18 – Modèles et leur nombre d'apparitions dans le Top 3

#### 4.3.4. Analyse croisée des performances

L'analyse croisée entre la fréquence d'apparition dans le Top 3 (cf. section 4.3.3) et les accuracies moyennes (cf. Figure 4.1) met en évidence deux modèles particulièrement performants : SVM et Random Forest. Ces deux méthodes se démarquent à la fois par leur présence fréquente dans le Top 3 (10 sujets sur 15) et par des valeurs d'accuracy moyennes parmi les plus élevées, respectivement 0.82 pour SVM et 0.80 pour Random Forest (voir la figure).




FIGURE 4.1 – Les accuracies moyennes

Cette convergence entre régularité inter-sujets et performance moyenne élevée conforte leur statut de modèles robustes et fiables pour la détection des phases de fatigue musculaire à partir des signaux EMG. À l'inverse, certains modèles comme Naive Bayes ou Subspace Discriminant présentent des performances plus modestes, avec des accuracies moyennes inférieures à 0.72 et un faible nombre de présences dans les meilleurs résultats, ce qui suggère une moindre stabilité.

Enfin, des modèles comme Boosting, LDA ou Bagging montrent des résultats intermédiaires, avec une accuracy moyenne autour de 0.79–0.80 et 4 à 5 présences dans le Top 3, ce qui indique une performance correcte mais moins dominante que celle de SVM et Random Forest.

## 4.4 Visualisation colorée des phases de fatigue sur le signal EMG

Pour chaque sujet, le signal EMG a été coloré selon les prédictions de phase de fatigue fournies par le meilleur classifieur, sélectionné en fonction de l'accuracy maximale obtenue lors de la validation croisée. Cette approche permet de visualiser directement, et de manière individuelle, la qualité de détection obtenue pour chacun des cas étudiés.

La figure suivante regroupe les signaux EMG colorés des 15 sujets, en utilisant un code couleur constant :

- Vert : phase de non-fatigue
- Bleu : phase de transition
- Rouge : phase de fatigue




FIGURE 4.2 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 1, en utilisant le classifieur optimal pour chacun.




FIGURE 4.3 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 2, en utilisant le classifieur optimal pour chacun.




FIGURE 4.4 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 3, en utilisant le classifieur optimal pour chacun.




FIGURE 4.5 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 4, en utilisant le classifieur optimal pour chacun.




FIGURE 4.6 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 5, en utilisant le classifieur optimal pour chacun.




FIGURE 4.7 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 6, en utilisant le classifieur optimal pour chacun.




FIGURE 4.8 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 7, en utilisant le classifieur optimal pour chacun.




FIGURE 4.9 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 8, en utilisant le classifieur optimal pour chacun.




FIGURE 4.10 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 9, en utilisant le classifieur optimal pour chacun.




FIGURE 4.11 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 10, en utilisant le classifieur optimal pour chacun.




FIGURE 4.12 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 11, en utilisant le classifieur optimal pour chacun.




FIGURE 4.13 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 12, en utilisant le classifieur optimal pour chacun.

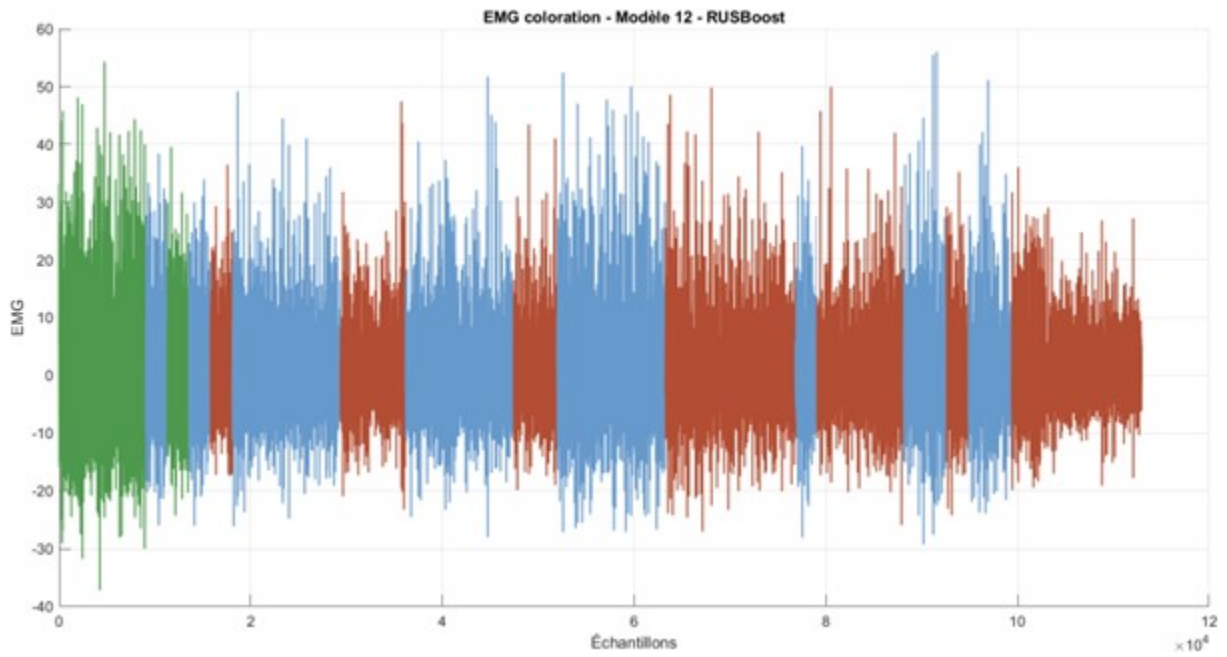


FIGURE 4.14 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 13, en utilisant le classifieur optimal pour chacun.




FIGURE 4.15 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 14, en utilisant le classifieur optimal pour chacun.




FIGURE 4.16 – Visualisation des signaux EMG colorés selon les prédictions de phase pour le sujet 15, en utilisant le classifieur optimal pour chacun.

Il est important de noter que, bien que les phases soient globalement bien détectées, des erreurs de classification subsistent dans la majorité des cas. En effet, des mismatches locaux apparaissent dans les signaux EMG de 14 sujets sur 15, traduisant des transitions floues entre les états de fatigue et des limites dans la capacité discriminante des modèles. Ces erreurs se manifestent par des interruptions ponctuelles dans la couleur attendue ou par des segments courts mal attribués, typiquement en phase de transition. Seul le sujet 11 a présenté un signal entièrement cohérent avec les phases attendues, sans aucune erreur détectée.

## 4.5 Discussion

### 4.5.1. Interprétation des performances globales

L'évaluation comparative des 13 classifieurs sur 15 sujets met en évidence une large variabilité des performances, illustrant l'influence des différences interindividuelles dans les signaux EMG. Les meilleurs résultats ont été obtenus avec SVM et Random Forest, qui ont non seulement atteint les accuracies les plus élevées, mais ont également montré une constance remarquable à travers les sujets. Cette stabilité est un critère crucial pour les applications biomédicales où la généralisation inter-sujets est recherchée. À l'opposé, des modèles comme Naive Bayes ou Subspace Discriminant présentent des performances nettement inférieures, tant en termes d'accuracy moyenne que de classement dans le Top 3.

### 4.5.2. Robustesse des classifieurs simples vs complexes

Les résultats suggèrent que les classifieurs dits complexes, tels que Random Forest, Boosting ou SVM, offrent une meilleure robustesse et une capacité accrue à modéliser les dynamiques non linéaires des signaux EMG. Ils apparaissent régulièrement dans les meilleures performances, et ce, avec une stabilité notable sur l'ensemble des sujets. En revanche, les classifieurs simples comme LDA, Centroid ou Naive Bayes, bien qu'efficaces dans certains cas isolés, montrent des performances plus hétérogènes. Leur simplicité algorithmique, bien qu'avantageuse en termes de rapidité et d'interprétabilité, semble limiter leur capacité à capturer la complexité intrinsèque des signaux électromyographiques lors de contractions prolongées.

## 4.6 Conclusion

Les résultats présentés dans ce chapitre mettent en lumière l'intérêt et les limites des différentes méthodes de classification appliquées aux signaux EMG. Parmi les treize modèles testés, SVM et Random Forest se démarquent nettement, tant par leur accuracy moyenne élevée que par leur fréquence d'apparition dans le Top 3 des modèles par sujet. Cette double supériorité, en précision et en régularité interindividuelle, confirme leur pertinence pour une détection fiable des phases de fatigue musculaire.

À l'inverse, certains classifieurs simples, bien que performants dans des cas isolés, souffrent d'un manque de robustesse face à la variabilité naturelle des signaux. Ces observations soulignent l'importance de privilégier des modèles capables de capter la complexité non linéaire des signaux EMG, tout en restant généralisables. Les analyses menées constituent une base solide pour les approches de prédiction continue développées au chapitre suivant, qui s'affranchiront de l'étiquetage supervisé en estimant directement la force musculaire à partir de l'EMG. Les résultats présentés dans ce chapitre ont conduit à la publication d'un article scientifique [109]

# Chapitre 5

## Prédiction continue de la force musculaire et détection indirecte de la fatigue

### 5.1 Introduction

L'estimation de la force musculaire à partir du signal EMG représente un enjeu crucial dans les domaines du contrôle moteur, de la rééducation fonctionnelle et de l'assistance robotisée. Cette étude propose une démarche continue de régression pour modéliser finement l'évolution de la force générée par un sujet en contraction isométrique. Ce processus permet, en parallèle, de détecter les trois phases de fatigue (non-fatigue, transition et fatigue) à partir des dynamiques de la force estimée.

De nombreuses études se sont concentrées sur la modélisation de la relation sEMG–force à l'aide de méthodes de régression et d'apprentissage automatique, afin d'estimer avec précision la force musculaire dans des contextes biomécaniques et de rééducation. Yokoyama et al. [110] étudient la capacité des signaux EMG de surface à prédire la force de préhension en utilisant diverses approches de régression intégrées dans un système de gant portable. Parmi les modèles testés, les réseaux de neurones artificiels (ANN) surpassent significativement toutes les méthodes linéaires dans plusieurs scénarios de validation. L'étude met en évidence la capacité des ANN à capturer les relations complexes et non linéaires inhérentes à la dynamique sEMG–force, établissant ainsi leur avantage pour l'estimation biomécanique en temps réel dans des environnements portables contraints.

Ye et al. [111] examinent la prédiction de la force des doigts à partir des signaux sEMG à l'aide de modèles de régression. En comparant plusieurs techniques, notamment la régression linéaire multiple (MLR) et les méthodes Light Gradient Boosting (LightGBM), ils montrent que LightGBM améliore

significativement la précision prédictive. Leur approche combine une sélection optimale des caractéristiques avec une régression non linéaire afin de mieux capturer la complexité de la relation sEMG–force. L’étude souligne la pertinence croissante de l’apprentissage par ensembles pour l’estimation de la force basée sur le sEMG, en particulier dans les applications nécessitant précision et adaptabilité. Mokri et al. [112] introduisent un cadre d’apprentissage automatique pour estimer la force musculaire des membres inférieurs à partir des signaux sEMG dans un contexte de rééducation. À travers des comparaisons systématiques, la régression par vecteurs de support (SVR) surpasse les modèles de forêts aléatoires en précision et en fiabilité, notamment lorsqu’elle est associée à un réglage des paramètres basé sur un algorithme génétique. L’étude souligne l’intérêt de la modélisation par régression pour la transformation sEMG-force et valide la SVR comme un outil robuste pour la prédiction biomécanique dans les applications cliniques et robotiques.

Ce chapitre détaille la méthodologie de régression développée à cet effet, basée sur un jeu de 23 paramètres EMG extraits dans les 50 segments, un protocole d’entraînement inter-sujets (validation croisée LOSO), et une optimisation itérative des features (LOFO). Dix modèles de régression issus d’approches linéaires, non linéaires et neuronales ont été comparés de manière rigoureuse exclusivement selon leur capacité à détecter correctement les phases de fatigue via une logique de seuillage appliquée à la force prédite.

Les résultats expérimentaux présentés dans ce chapitre couvrent plusieurs aspects : la persistance des caractéristiques sélectionnées, la comparaison détaillée des erreurs de prédiction (mismatches) pour chaque sujet et chaque modèle, la visualisation qualitative des courbes de force estimée, ainsi que la coloration des signaux EMG selon les phases détectées. Enfin, une synthèse statistique permet de dégager le modèle le plus performant.

## 5.2 Méthodologie globale

Ce chapitre repose sur une approche continue de prédiction de la force musculaire à partir des signaux électromyographiques (EMG), dans l’objectif de reconstituer les différentes phases de fatigue musculaire sans classification explicite.

Contrairement aux méthodes discrètes vues au chapitre précédent, où les fenêtres EMG étaient directement étiquetées par classe de fatigue, l’approche proposée repose sur une estimation de la force de préhension à chaque instant, suivie d’une interprétation indirecte de la fatigue à partir du niveau de force prédit.

- La méthodologie développée s'organise autour des étapes suivantes :
- la préparation des données EMG (filtrage, segmentation) et leur association à la force de référence,
  - l'extraction de paramètres multi-domaines représentatifs de l'activité musculaire,
  - l'application d'une optimisation croisée par sujet (LOSO) combinant apprentissage et sélection automatique des caractéristiques pertinentes,
  - la prédiction de la force musculaire sur le sujet laissé de côté,
  - la détection des phases de fatigue via un seuillage de la force prédite.

### 5.2.1. Workflow complet de prédiction

Le schéma ci-dessous (Figure 5.1) illustre l'architecture complète du processus de prédiction continue de la force musculaire à partir de signaux EMG, jusqu'à la détection des phases de fatigue :

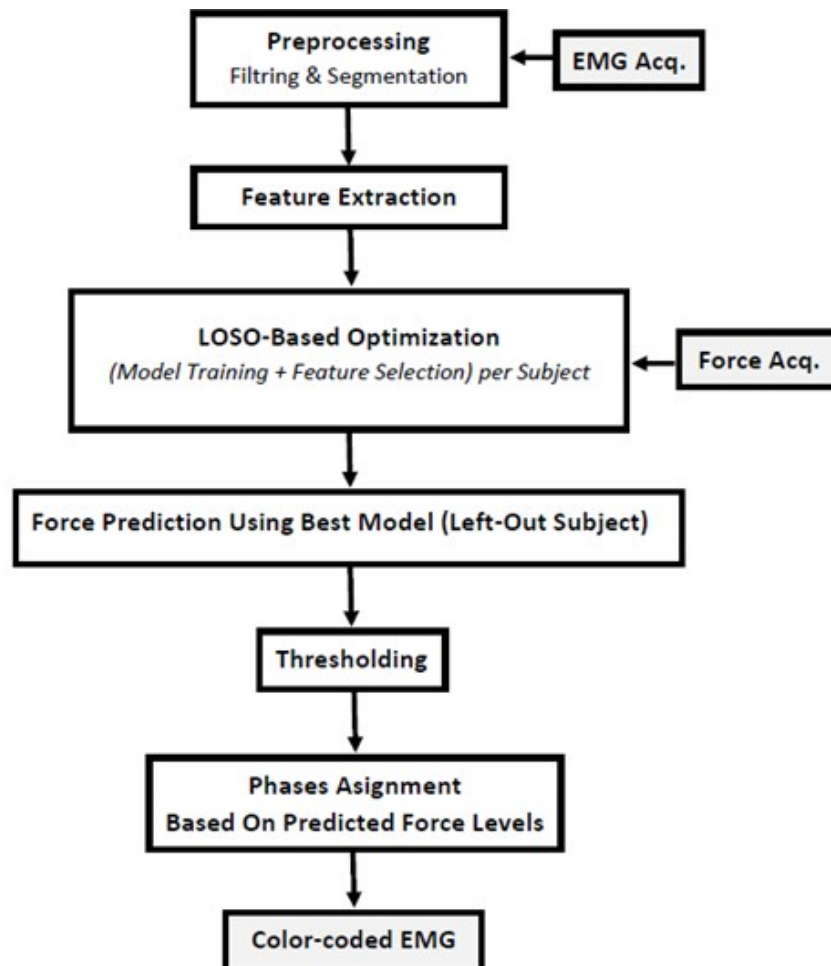


FIGURE 5.1 – Architecture complète du processus de prédiction continue de la force musculaire à partir de signaux EMG

Ce pipeline s'appuie sur les étapes suivantes :

1. Prétraitement et extraction des caractéristiques : Les signaux EMG sont filtrés, segmentés, puis traduits en 23 paramètres représentatifs de l'activité musculaire (cf. Chapitre 3).
2. Optimisation croisée inter-sujets (LOSO) : À chaque itération, un sujet est laissé pour test, les autres servant à l'entraînement du modèle et à la sélection dynamique des caractéristiques les plus pertinentes.
3. Prédiction de la force : La force est estimée via le modèle de régression offrant le meilleur compromis entre généralisation et précision.
4. Seuillage et attribution des phases : La force prédite est segmentée en trois niveaux (non-fatigué, transition, fatigué), afin de reconstruire les phases de fatigue.
5. Coloration de l'EMG : Les fenêtres EMG sont ensuite codées par couleur selon les phases détectées, permettant une visualisation directe et continue de la progression de la fatigue musculaire.

Ce workflow unifie l'analyse EMG, la régression et l'inférence des états de fatigue, tout en respectant une validation stricte inter-sujets. Il servira de base aux analyses quantitatives et qualitatives présentées dans les sections suivantes.

### **5.2.2. Modèles de régression testés**

Dans cette étude, dix modèles de régression ont été évalués pour leur capacité à prédire la force de préhension à partir des caractéristiques EMG. Ces modèles ont été choisis afin de couvrir à la fois des approches linéaires classiques et des approches non linéaires capables de capturer des relations complexes entre les variables.

#### **5.2.2.1. Modèles linéaires**

Les modèles suivants supposent une relation linéaire (ou linéarisable) entre les descripteurs EMG et la force musculaire :

1. Régression linéaire multiple (MLR) : modèle de base, sans régularisation, souvent utilisé comme point de référence [30].
2. Ridge Regression : ajoute une pénalisation L2 pour réduire la variance du modèle [113].
3. Lasso Regression : ajoute une pénalisation L1 favorisant la sélection automatique de variables [113].
4. Elastic Net : combine les pénalités L1 et L2 pour un compromis entre sélection et régularisation [114].

5. Régression sur composantes principales (PCR) et régression par moindres carrés partiels (PLSR) : projettent les données sur un espace latent, respectivement sans et avec prise en compte de la variable cible [115].

#### 5.2.2.2. Modèles non linéaires

Ces modèles visent à modéliser des relations complexes et non linéaires entre les paramètres EMG et la force :

1. Support Vector Regression (SVR) : basé sur la théorie des machines à vecteurs de support, performant dans les cas de dimensionnalité élevée [116].
2. Forêt aléatoire de régression (Random Forest) : ensemble d'arbres de décision, robuste au sur-apprentissage et capable de modéliser des interactions non linéaires [117].
3. Gradient Boosting Regression (GBR) : combinaison séquentielle d'arbres faibles pour améliorer la précision [117].
4. Réseau de neurones artificiel (ANN) : capable d'apprendre des relations complexes mais requiert un réglage fin des hyperparamètres et un grand volume de données pour généraliser correctement [118].

L'objectif est de comparer ces modèles non seulement en termes de performance brute, mais surtout selon leur aptitude à reconstruire correctement les niveaux de force associés aux différentes phases de fatigue musculaire.

#### 5.2.3. Validation croisée inter-sujets (LOSO)

Dans le but d'évaluer la capacité des modèles de régression à généraliser à de nouveaux individus, une validation croisée inter-sujets de type Leave-One-Subject-Out (LOSO) a été adoptée.

Cette approche consiste à isoler, à chaque itération, les données d'un sujet pour les utiliser exclusivement comme ensemble de test, tandis que les données des 14 autres sujets servent à l'entraînement du modèle. Ce processus est répété autant de fois qu'il y a de sujets ( $N = 15$ ), en faisant tourner le sujet exclu. À la fin de la validation, chaque participant aura été utilisé exactement une fois pour l'évaluation.

Pour chaque itération, les 10 modèles de régression étudiés (linéaires, non linéaires et neuronaux) sont entraînés sur les données des 14 sujets, à partir des 23 caractéristiques EMG extraites comme décrit dans le chapitre 3. Une étape d'optimisation des caractéristiques, propre à chaque itération, est également réalisée sur le jeu d'entraînement — elle est détaillée dans la section 5.2.4.

Une fois le modèle optimisé, il est appliqué sur le sujet laissé de côté pour prédire la force musculaire segment par segment, puis reconstituer les phases de fatigue via un seuillage fixe. Cette procédure garantit l'indépendance totale entre les données de test et d'entraînement, évitant ainsi tout risque de surapprentissage ou de biais lié à la similarité inter-sujets.

Le protocole LOSO est particulièrement adapté aux signaux biomédicaux, dont la variabilité interindividuelle est élevée. Il permet d'obtenir une évaluation robuste de la performance des modèles en conditions réalistes, et de mesurer précisément leur capacité à généraliser à un nouveau profil neuromusculaire.

Les résultats individuels de cette validation, ainsi que les comparaisons de performance entre modèles, sont présentés en détail dans la section 5.3.

#### **5.2.4. Optimisation des caractéristiques par exclusion unitaire (LOFO)**

L'optimisation des caractéristiques EMG est réalisée selon une méthode itérative d'exclusion unitaire (Leave-One-Feature-Out, LOFO), appliquée séparément pour chaque itération de validation inter-sujets (LOSO). Le but est de réduire le nombre de caractéristiques tout en maximisant la capacité du modèle à détecter correctement les phases de fatigue à partir de la force prédite.

Le processus démarre avec l'ensemble complet des 23 paramètres extraits par fenêtre. Un premier entraînement est réalisé sur les 14 sujets du jeu d'apprentissage, avec ces 23 caractéristiques, pour prédire la force du sujet laissé en test. À partir de cette force prédite, les phases de fatigue sont reconstruites via seuillage, et comparées aux phases observées. Le nombre total de mismatches (erreurs d'attribution de phase) est alors calculé.

À chaque itération suivante, une seule caractéristique est testée pour exclusion. Le modèle est réentraîné avec un sous-ensemble de taille réduite (par exemple 22 caractéristiques à la première itération), et les mismatches sont recalculés. Si le retrait de cette caractéristique améliore la détection (mismatches en baisse), elle est exclue de façon permanente. Sinon, elle est réintégrée. La procédure se poursuit ainsi de manière cumulative : à chaque étape, le modèle est réentraîné avec l'ensemble actuel des caractéristiques restantes, et chaque nouvelle exclusion potentielle est évaluée par comparaison directe des erreurs de phase. Ce mécanisme progressif permet une sélection adaptative, propre à chaque combinaison sujet-test / modèle, et focalisée sur le critère final d'intérêt : la reconstruction correcte des phases de fatigue.

Contrairement à des méthodes plus générales de sélection de variables

(comme l’analyse de variance ou les critères d’importance globale), la stratégie LOFO ici intégrée est entièrement pilotée par l’amélioration des performances cliniquement utiles [119, 120] .

### 5.2.5. Critère d’évaluation

L’évaluation des performances ne repose pas sur des métriques classiques de régression, mais exclusivement sur la capacité du modèle à reconstruire correctement les phases de fatigue à partir de la force prédite.

Pour chaque sujet, la courbe de force prédite est transformée en trois phases (non-fatigue, transition, fatigue) par un seuillage fixe, conformément à la méthode décrite en section 5.4.1. Ces phases sont ensuite comparées aux phases de référence issues de la force mesurée. Chaque discordance entre la phase prédite et la phase réelle est comptabilisée comme un mismatch.

L’accuracy individuelle pour chaque sujet est calculée par :

$$\text{Accuracy}_{\text{sujet}} = 1 - \frac{\text{mismatches}}{50}$$

Où 50 correspond au nombre de segments analysés par sujet.

L’accuracy globale du modèle est ensuite définie comme :

$$\text{Accuracy}_{\text{modèle}} = 1 - \frac{\text{mismatches totaux}}{750}$$

Cette métrique reflète directement l’objectif final du protocole : détecter de manière fiable les phases de fatigue à partir des signaux EMG, via la prédiction de la force musculaire. Elle permet ainsi de comparer les modèles en fonction de leur utilité physiologique et clinique, plutôt que de leur simple précision numérique.

## 5.3 Résultats expérimentaux

### 5.3.1. Analyse de la persistance des caractéristiques sélectionnées

L’algorithme d’optimisation LOFO appliqué en validation croisée inter-sujets (LOSO) a permis d’identifier les caractéristiques EMG les plus pertinentes pour la prédiction de la force et, par extension, pour la détection des phases de fatigue. Afin d’évaluer la robustesse des descripteurs sélectionnés, une analyse de présence a été réalisée pour chacune des 23 caractéristiques dans les modèles finaux, tous sujets confondus.

La figure ci-dessous illustre le taux de présence (%) de chaque caractéristique, c’est-à-dire le pourcentage d’occurrences où elle a été conservée après optimisation, sur l’ensemble des 15 itérations (sujets) et des 10 modèles de

régression. Une valeur de 94 % indique par exemple qu'une caractéristique a été jugée pertinente dans 141 cas sur 150 (15 sujets  $\times$  10 modèles).

Globalement, toutes les caractéristiques présentent une fréquence de rétention supérieure à 75 %, ce qui suggère que l'ensemble initial de 23 paramètres était globalement informatif. Toutefois, certaines caractéristiques ressortent particulièrement :

- Hoyer's Sparsity et Wigner-Ville Distribution affichent la fréquence maximale de 94 %, traduisant une contribution très régulière dans les prédictions.
- Waveform Length, Form Factor, et Hilbert-Huang Transform suivent de près avec une présence de 92 %.
- Spectral Slope, Crossing Rate, Mean Frequency, Waveform Index, et Shanon Entropy atteignent également ou dépassent les 90 %.

À l'inverse, les caractéristiques Dominant Frequency et Teager-Kaiser Energy présentent les taux de rétention les plus bas (76 %), ce qui laisse entrevoir une contribution plus contextuelle ou spécifique à certains profils EMG.

Cette analyse met en lumière la stabilité inter-modèle et inter-sujet de certaines caractéristiques, notamment celles issues des domaines non linéaire et temps-fréquence, souvent associées à l'évolution de la fatigue musculaire [108, 121]. Une interprétation physiologique détaillée de ces variables est proposée en section 5.4.2.

### 5.3.2. Analyse individuelle des résultats par sujet

Afin d'évaluer finement les performances des différents modèles de régression optimisés, un tableau récapitulatif des mismatches a été établi pour chacun des 15 sujets. Pour rappel, un mismatch correspond à une erreur de classification d'une phase de fatigue à partir de la force prédite, une fois comparée à la segmentation de référence obtenue à partir de la force observée.

Le tableau ci-dessous présente le nombre total de mismatches par modèle et par sujet :

Sujet	MLR	Ridge	Lasso	EN	PCR	PLS	SVR	RF	GB	ANN
1	10	2	11	2	12	2	45	4	2	9
2	3	3	3	3	9	2	42	4	2	2
3	17	18	18	18	23	17	26	13	1	16
4	8	9	9	9	14	8	41	6	5	9
5	8	8	8	8	16	10	1	7	3	5
6	6	7	5	7	13	5	46	7	4	13
7	18	20	18	18	23	18	40	9	3	23
8	12	15	14	14	20	15	11	15	11	12
9	6	8	9	9	12	8	11	2	5	5
10	7	11	0	11	17	10	23	3	0	11
11	0	5	5	5	12	1	2	1	1	8
12	8	8	8	8	10	8	36	11	6	7
13	5	5	5	5	18	7	46	7	2	7
14	11	11	11	11	15	11	43	10	1	11
15	8	9	8	8	12	9	44	9	3	7
<b>Total</b>	127	139	132	136	226	131	457	108	49	145

TABLE 5.1 – Résultats comparatifs des méthodes de régression et machine learning

Ces résultats mettent en évidence des disparités importantes entre les modèles. En particulier, les approches linéaires telles que MLR, Ridge, Lasso, ou ElasticNet maintiennent des performances moyennes, avec des mismatches modérés mais constants. Les modèles PLS et PCR montrent des performances variables, parfois très proches des linéaires, notamment pour certains sujets.

En revanche, les performances du SVR sont instables et souvent inférieures, avec un grand nombre de mismatches, dépassant parfois les 40 erreurs sur 50 fenêtres, ce qui indique une mauvaise capacité de généralisation. À l’opposé, le modèle Gradient Boosting (GB) affiche systématiquement de faibles valeurs de mismatches, se positionnant comme le modèle le plus régulier et performant. Il est suivi de près par Random Forest (RF) et Artificial Neural Network (ANN) sur certains sujets, bien que ces derniers présentent davantage de variance.

### 5.3.3. Visualisation de la force prédite par le meilleur modèle

Cette section présente, pour chacun des 15 sujets, les courbes de force observée et de force prédite obtenues à l’aide du modèle Gradient Boosting, sélectionné automatiquement comme étant le plus performant pour chaque sujet selon le critère de minimisation des mismatches.

Et voici les courbes comparatives pour l’ensemble des sujets, illustrant la qualité de la prédiction sur les 50 segments temporels. Ces visualisations permettent d’évaluer visuellement l’alignement entre la force réelle et la force

estimée, étape préalable à la détection des phases de fatigue :




FIGURE 5.2 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 1.




FIGURE 5.3 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 2.




FIGURE 5.4 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 3.




FIGURE 5.5 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 4.




FIGURE 5.6 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 5.




FIGURE 5.7 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 6.




FIGURE 5.8 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 7.




FIGURE 5.9 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 8.




FIGURE 5.10 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 9.




FIGURE 5.11 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 10.




FIGURE 5.12 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 11.




FIGURE 5.13 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 12.




FIGURE 5.14 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 13.




FIGURE 5.15 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 14.




FIGURE 5.16 – Force observée et prédite avec la méthode GradientBoosting pour le sujet 15.

### 5.3.4. Détection des phases de fatigue à partir de la force prédite

À partir des courbes de force prédites générées par le modèle Gradient Boosting, un seuillage automatique a été appliqué pour attribuer à chaque intervalle temporel l'une des trois phases de fatigue :

- Vert : Phase 1 - Non-fatiguée
- Bleu : Phase 2 - Transition vers la fatigue
- Rouge : Phase 3 - Fatiguée

Ces phases sont déterminées exclusivement à partir de la force estimée, sans utiliser d'information directe sur la réalité physiologique du sujet.

Et voici les signaux EMG colorés en fonction des phases détectées pour chacun des 15 sujets. Cette représentation visuelle permet d'apprécier la progression de la fatigue musculaire au fil du temps, conformément à la dynamique extraite indirectement via la prédiction de la force :




FIGURE 5.17 – Force prédite avec la méthode GradientBoosting pour le sujet 1.

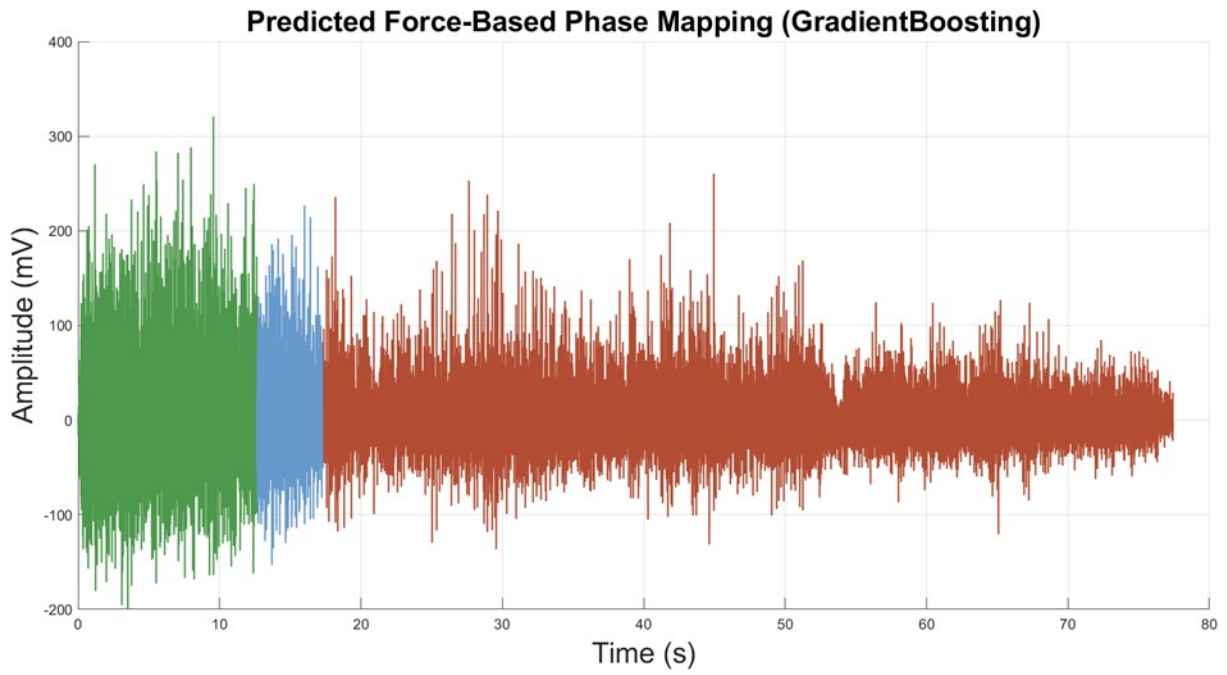


FIGURE 5.18 – Force prédite avec la méthode GradientBoosting pour le sujet 2.




FIGURE 5.19 – Force prédite avec la méthode GradientBoosting pour le sujet 3.




FIGURE 5.20 – Force prédite avec la méthode GradientBoosting pour le sujet 4.




FIGURE 5.21 – Force prédite avec la méthode GradientBoosting pour le sujet 5.




FIGURE 5.22 – Force prédite avec la méthode GradientBoosting pour le sujet 6.




FIGURE 5.23 – Force prédite avec la méthode GradientBoosting pour le sujet 7.




FIGURE 5.24 – Force prédite avec la méthode GradientBoosting pour le sujet 8.




FIGURE 5.25 – Force prédite avec la méthode GradientBoosting pour le sujet 9.




FIGURE 5.26 – Force prédite avec la méthode GradientBoosting pour le sujet 10.




FIGURE 5.27 – Force prédite avec la méthode GradientBoosting pour le sujet 11.




FIGURE 5.28 – Force prédite avec la méthode GradientBoosting pour le sujet 12.




FIGURE 5.29 – Force prédite avec la méthode GradientBoosting pour le sujet 13.




FIGURE 5.30 – Force prédite avec la méthode GradientBoosting pour le sujet 14.




FIGURE 5.31 – Force prédite avec la méthode GradientBoosting pour le sujet 15.

### 5.3.5. Analyse globale de la performance des modèles

L'évaluation des performances de chaque modèle de régression a été réalisée en agrégeant les mismatches obtenus sur l'ensemble des 15 sujets. Le total des mismatches pour chaque modèle, ainsi que l'accuracy globale correspondante, sont présentés ci-dessous sous forme d'histogrammes.




FIGURE 5.32 – Nombre total de mismatches par modèle de régression.




FIGURE 5.33 – Accuracy moyenne par modèle de régression.

On observe que le modèle Gradient Boosting obtient les meilleures performances, avec seulement 49 mismatches sur 750 cas, ce qui correspond à une accuracy moyenne de 93.5 %. Ce résultat met en évidence la capacité supérieure de ce modèle à prédire correctement la force et, par conséquent, à détecter avec précision les phases de fatigue.

## 5.4 Conclusion

Ce chapitre a présenté une approche complète de prédiction continue de la force musculaire à partir du signal EMG, avec pour objectif la détection automatique des phases de fatigue. Grâce à un pipeline structuré, intégrant un entraînement inter-sujets (LOSO), une optimisation itérative des caractéristiques (LOFO) et une évaluation spécifique basée sur les mismatches de phase, dix modèles de régression ont été comparés de manière rigoureuse.

Les résultats expérimentaux ont mis en évidence des disparités notables entre les modèles. Parmi eux, le Gradient Boosting s'est démarqué comme le modèle le plus performant, avec une accuracy moyenne de 93,5 % sur l'ensemble des sujets. Il a été identifié comme le meilleur modèle pour 12 des 15 sujets, confirmant sa robustesse et sa capacité d'adaptation inter-sujets. Ce modèle a non seulement montré une excellente concordance entre les courbes de force prédite et observée, mais également une détection fiable des transitions vers la fatigue.

Les visualisations qualitatives des signaux EMG colorés ont renforcé la pertinence de l'approche proposée, illustrant visuellement les trois phases de fatigue (non-fatigue, transition, fatigue) avec une bonne cohérence temporelle. Au-delà des performances chiffrées, cette méthodologie offre un cadre automatisé, reproductible et inter-sujet pour le suivi de la fatigue musculaire. Les travaux présentés dans ce chapitre ont fait l'objet d'un article soumis à la revue Journal of Engineering Science and Technology (JESTEC) [122]

# Conclusion générale

Ce travail de thèse a permis de développer une architecture complète, modulaire et performante pour l'estimation de la force musculaire et la détection automatique des phases de fatigue à partir du signal EMG de surface. L'approche adoptée s'appuie sur une double contribution : d'une part la réalisation d'un système matériel d'acquisition synchronisée EMG/force basé sur des composants économiques, et d'autre part le développement d'un pipeline logiciel basé sur le traitement avancé des signaux et l'application de méthodes d'apprentissage automatique.

Sur le plan logiciel, deux approches ont été étudiées et comparées dans des conditions expérimentales strictes : la classification directe des états de fatigue, et la régression continue de la force musculaire suivie d'un seuillage automatique. Les résultats montrent clairement que l'approche par régression permet une détection plus fine et plus fiable des trois phases de fatigue musculaire. Elle atteint une accuracy moyenne de 93,5 %, contre 82 % pour le meilleur modèle de classification. En outre, la classification souffre d'un taux non négligeable de confusion entre les états de transition, ce qui peut poser des problèmes dans un contexte clinique ou fonctionnel. La régression, en reconstruisant la dynamique de la force, fournit un signal plus fluide et évite les ruptures logiques liées aux erreurs de classification.

Au-delà des performances numériques, cette approche offre une plus grande adaptabilité aux systèmes embarqués et aux applications temps réel. La prédiction continue de la force constitue une information plus exploitable que des étiquettes catégorielles, notamment dans des boucles de rétroaction (bio-feedback, contrôle moteur assisté, exosquelettes).

En conclusion, cette thèse a montré que la modélisation de la force à partir du signal EMG permet non seulement d'estimer efficacement la dynamique musculaire, mais également d'identifier les états de fatigue avec une précision élevée. Elle constitue ainsi une avancée méthodologique dans l'interprétation automatisée des signaux EMG.

Parmi les perspectives envisagées, un développement majeur consiste à intégrer ces algorithmes dans un dispositif embarqué temps réel, capable :

1. d'extraire automatiquement les paramètres EMG à la volée,
2. de prédire la force en continu,
3. et de détecter dynamiquement l'état du muscle.

Ce système pourrait être exploité en contexte de rééducation, de monitoring sportif, ou d'assistance intelligente. Une extension naturelle de ce travail consistera également à enrichir les descripteurs EMG via l'analyse temps-fréquence à l'aide de la transformée en ondelettes discrètes (DWT), permettant une meilleure capture des variations non stationnaires typiques du signal EMG. À l'avenir, la base de données sera élargie afin d'inclure un plus grand nombre de participants, en intégrant à la fois des sujets sains et des patients, afin d'améliorer la robustesse et la validité clinique des modèles proposés.

# Bibliographie

- [1] Nagwa. Lesson explainer : Structure des muscles, 2025. Page consultée le 04 juin 2025.
- [2] Institut de myologie. Connaissances sur le muscle, 2025. Page consultée le 04 juin 2025.
- [3] Kin-option. Les différentes contractions de nos muscles, 2021. Page consultée le 04 juin 2025.
- [4] labster. La jonction neuromusculaire et la transmission neuromusculaire. Page consultée le 05 juin 2025.
- [5] FICHE SANTÉ MPOC. Utiliser l'échelle de borg. Page consultée le 05 juin 2025.
- [6] protosupplies. Carte d'amplification emg. Page consultée le 08 juin 2025.
- [7] Analogdevices. Low cost low power instrumentation amplifier. Page consultée le 08 juin 2025.
- [8] Dynamomètre eh-108. Page consultée le 08 juin 2025.
- [9] Le convertisseur hx-711. Page consultée le 08 juin 2025.
- [10] La carte d'acquisition esp wroom 32. Page consultée le 08 juin 2025.
- [11] Random nerd tutorials. Esp32 with load cell and hx711 amplifier. Page consultée le 08 juin 2025.
- [12] Eric R. Kandel, James H. Schwartz, Thomas M. Jessell, Steven A. Siegelbaum, and A. J. Hudspeth. *Principles of Neural Science*. McGraw-Hill, 5 edition, 2013.
- [13] B. Alberts et al. *Molecular Biology of the Cell*. Garland Science, 6 edition, 2015.
- [14] M. T. Murray and J. A. Delp. The isometric functional capacity of muscles that cross the elbow. *Journal of Biomechanics*, 28(5) :469–480, 1995.
- [15] D. A. Neumann. *Kinesiology of the Musculoskeletal System*. Elsevier, 3 edition, 2016.

- [16] S. M. McMahon. *Skeletal muscle structure and function in Exercise Physiology : Nutrition, Energy, and Human Performance*. Lippincott Williams and Wilkins, 8 edition, 2019.
- [17] R. H. Fitts. The cross-bridge cycle and skeletal muscle fatigue. *J. Appl. Physiol.*, 104(2) :551–558, 2008.
- [18] M. Enoka and R. S. Duchateau. Translating fatigue to human performance. *Med. Sci. Sports Exerc.*, 48(11) :2228—2238, 2016.
- [19] J. Gordon Betts et al. *Anatomy and Physiology*. OpenStax, 2 edition, 2022.
- [20] Lindsay M. Biga et al. *Anatomy and Physiology*. OpenStax, 2 edition, 2019.
- [21] J. C. Cramer et al. *Anatomy, Skeletal Muscle*. StatPearls, 1 edition, 2023.
- [22] P. P. Purslow. The structure and role of intramuscular connective tissue in muscle function. *Frontiers in Physiology*, 11(485), 2020.
- [23] Nousseiba ABED. Physiologie et physiopathologie de la cellule musculaire. Polycopié de cours, 2020. Master de Physiologie Cellulaire et Physiopathologie.
- [24] Lewis J. et al. Alberts B., Johnson A. *Molecular Biology of the Cell*. Garland Science. Chapitre 16 : The Cytoskeleton and Muscle Contraction, 7 edition, 2022.
- [25] Lumen Learning. Types of muscle tissue and fibers, 2023. Page consultée le 04 juin 2025.
- [26] Geoffrey M Cooper. *The cell, A Molecular Approach*. NCBI Bookshelf, 2 edition, 2023.
- [27] A. F. Huxley. Muscle structure and theories of contraction. *Prog. Biophys. Biophys. Chem.*, 7 :255–318, 1957.
- [28] D. G. Sale. Influence of exercise and training on motor unit activation. *Exerc. Sport Sci. Rev.*, 15 :95–151, 1987.
- [29] R. M. Enoka. *Neuromechanics of Human Movement*. Champaign, IL : Human Kinetics, 5 edition, 2015.
- [30] D. Winter. *Biomechanics and Motor Control of Human Movement*. John Wiley and Sons, 4 edition, 2009.
- [31] D. A. Jones. High- and low-frequency fatigue revisited. *Acta Physiol. Scand.*, 156(3) :265–270, 1996.

- [32] M. Lephart et al. The role of proprioception in the management and rehabilitation of athletic injuries. *Am. J. Sports Med.*, 25(1) :130–137, 1997.
- [33] J. A. Dvir. *Muscle Testing, Interpretation and Clinical Applications*. Edinburgh : Churchill Livingstone, 2 edition, 2004.
- [34] M. McBride et al. The effect of heavy- vs. light-load jump squats on the development of strength, power, and speed. *J. Strength Cond. Res.*, 16(1) :75–82, 2002.
- [35] HENRY HUDDART. *Muscle Isotonic Contraction*, pages 296–318. Springer, 2013.
- [36] Lieber R. L. *Skeletal Muscle Structure, Function, and Plasticity*. Lippincott Williams and Wilkins chap. 3–4 (Skeletal muscle contraction), 3 edition, 2010.
- [37] H. Hirayama et al. Plyometric training favors optimizing muscle–tendon behavior during stretch–shortening cycle exercise. *Frontiers in Physiology*, 8 :16, 2017.
- [38] M. Staniszewski et al. Effect of rest duration between sets on fatigue and recovery after plyometric exercise. *Scientific Reports*, 14(1) :66146, 2024.
- [39] M. F. Bear and al. *Neuroscience : Exploring the Brain*. Wolters Kluwer, 4 edition, 2016.
- [40] A. R. Crossman and D. Neary. *Neuroanatomy : An Illustrated Colour Text*. Churchill Livingstone, 5 edition, 2015.
- [41] StatPearls. Neuroanatomy, lateral corticospinal tract, 2023. Page consultée le 04 juin 2025.
- [42] T. Gordon et al. The resilience of the size principle in the organization of motor unit properties in normal and reinnervated adult skeletal muscles. *Can J Physiol Pharmacol.*, 14(82) :8–9, 2004.
- [43] F. Felissi and A. Del Viccio. Frontiers in neurology, "surface electromyography : What limits its use in exercise and neuromuscular fatigue ? *Frontiers in Neurology*, 11, 2020.
- [44] StatPearls. Physiology, acetylcholine, 2023. Page consultée le 04 juin 2025.
- [45] Sanes J. R. and Lichtman J. W. Induction, assembly, maturation and maintenance of a postsynaptic apparatus. *Nature Reviews Neuroscience*, 11(2) :791–805, 2001.

- [46] Lumen Learning. Neural stimulation of muscle contraction, 2023. Page consultée le 04 juin 2025.
- [47] The brain from top to bottom. The role of the neuromuscular junction in muscle contraction. Page consultée le 04 juin 2025.
- [48] M. Pizarro E. Ríos. Voltage sensor of excitation–contraction coupling in skeletal muscle. *Physiol. Rev.*, 71(3), 1991.
- [49] H. Westerblad D. G. Allen, G. D. Lamb. Skeletal muscle fatigue : cellular mechanisms. *Physiol. Rev.*, 88, 2008.
- [50] A. O. Jorgensen C. Franzini-Armstrong. Structure and development of e-c coupling units in skeletal muscle. *Annual Review of Physiology*, 56, 1994.
- [51] J. E. Hall. *Guyton and Hall Textbook of Medical Physiology*. Elsevier, 13 edition, 2015.
- [52] Fernando J Amador et al. Ryanodine receptor calcium release channels : lessons from structure-function studies. *Physiol. Rev.*, 82, 2002.
- [53] T. L. Hill. Theoretical formalism for the sliding filament model of contraction of striated muscle. part i. *Progress in Biophysics and Molecular Biology*, 28(4), 1974.
- [54] A. M. Gordon and al. Regulation of contraction in striated muscle. *Physiological Reviews*, 80(2), 2000.
- [55] D. H. MacLennan and E. G. Kranias. Phospholamban : a crucial regulator of cardiac contractility. *Nature Reviews Molecular Cell Biology*, 4(7), 2003.
- [56] C. Franzini-Armstrong and F. Protasi. Ryanodine receptors of striated muscles : a complex channel capable of multiple interactions. *Physiological Reviews*, 77(3), 1997.
- [57] J. D. Baylor and S. Hollingworth. Calcium indicators and calcium signalling in skeletal muscle fibres during excitation–contraction coupling. *Progress in Biophysics and Molecular Biology*, 105(3), 2011.
- [58] S. C. Gandevia. Spinal and supraspinal factors in human muscle fatigue. *Physiological Reviews*, 81(4), 2001.
- [59] Enoka R. M. and Duchateau J. Muscle fatigue : what, why and how it influences muscle function. *The Journal of Physiology*, 586(1), 2008.
- [60] G. A. Borg. Psychophysical bases of perceived exertion. *Medicine and Science in Sports and Exercise*, 14(5), 1982.

- [61] H. et al. Westerblad. Muscle fatigue : lactic acid or inorganic phosphate the major cause. *News in Physiological Sciences*, 17, 2002.
- [62] R. H. Fitts. Mechanisms of muscular fatigue. *Physiological Reviews*, 74(1), 1994.
- [63] et al. Debold, E. P. Effects of ph and phosphate on cross-bridge cycling and muscle fatigue. *Journal of Applied Physiology*, 100(3), 2006.
- [64] Allen D. G. and Westerblad H. Role of phosphate and calcium stores in muscle fatigue. *Journal of Physiology*, 536(3), 2001.
- [65] D. J. et al. Wilkinson. Ammonia metabolism, the brain and fatigue. *Progress in Neurobiology*, 91(3), 2010.
- [66] Bigland-Ritchie B. and Woods. Changes in muscle contractile properties and neural control during human muscular fatigue. *Muscle and Nerve*, 7(9), 1984.
- [67] A. K. Powers and E. T. Howley. *Exercise Physiology : Theory and Application to Fitness and Performance*. McGraw-Hill Education, 10 edition, 2017.
- [68] A. V. Hill. The heat of shortening and the dynamic constants of muscle. *Proceedings of the Royal Society B*, 126, 1938.
- [69] D. C. Clark and K. Manini. Functional consequences of sarcopenia and dynapenia in the elderly. *Current Opinion in Clinical Nutrition and Metabolic Care*, 13(3), 2010.
- [70] R. Merletti and P. A. Parker. *Electromyography : Physiology Engineering, and Noninvasive Applications*. Institute of Electrical and Electronics Engineers, 2004.
- [71] D. Farina et al. The extraction of neural strategies from the surface emg. *Journal of Applied Physiology*, 96(4), 2004.
- [72] L. S. De Luca. The use of surface electromyography in biomechanics. *Journal of Applied Biomechanics*, 13(2), 1997.
- [73] E. A. Clancy and N. Hogan. Relating agonist-antagonist electromyograms to joint torque during isometric, quasi-isotonic, nonfatiguing contractions. *IEEE Trans. Biomed. Eng.*, 44(10), 1997.
- [74] C. J. De Luca. Surface electromyography : Detection and recording. *Delsys Inc. Technical Report*, 2006.
- [75] M. Hermens et al. Development of recommendations for semg sensors and sensor placement procedures. *Journal of Electromyography and Kinesiology*, 10(5), 2000.

- [76] SENIAM Project. Surface electromyography for the non-invasive assessment of muscles – european recommendations. *SENIAM*, 1999.
- [77] D. B. Popovic and T. Sinkjaer. Control of movement for the physically disabled : Control for rehabilitation technology. *Springer Science and Business Media*, 2001.
- [78] D. Farina and R. Merletti. Methods for estimating muscle fibre conduction velocity from surface emg signals. *Medical and Biological Engineering and Computing*, 39(2), 2001.
- [79] Texas instruments. Industry-standard dual operational amplifiers. Page consultée le 08 juin 2025.
- [80] RENESAS. Icl7660, icl7660a. Page consultée le 08 juin 2025.
- [81] Esp32-wroom-32. Page consultée le 08 juin 2025.
- [82] Random nerd tutorials. Esp32 adc – read analog values with arduino ide. Page consultée le 08 juin 2025.
- [83] Mesure du poids. Page consultée le 08 juin 2025.
- [84] EDN. Ad620 ia module. Page consultée le 08 juin 2025.
- [85] Y. Wang and J. Yang. Wavelet denoising of electromyography. *J. Biomech.*, 39(4), 2006.
- [86] V. et al. Gupta. Surface emg measurements at the throat during dry and wet swallowing. dysphagia. *Dysphagia*, 11, 1996.
- [87] D. Farina et al. The extraction of neural strategies from the surface emg : An update. *Journal of Applied Physiology*, 117(11), 2014.
- [88] G. Kaur et al. Comparison of the techniques used for segmentation of emg signals. *Mathematical and Computational Methods*, 2009.
- [89] M. R. Ahsan et al. Electromyography (emg) signal based hand gesture recognition using artificial neural network (ann). *Proc. 4th Int. Conf. on Mechatronics (ICOM)*, 2011.
- [90] A. Phinyomark and al. Evaluation of emg feature extraction for hand movement recognition based on euclidean distance and standard deviation. *The 2010 ECTI International Confernce on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, 2010.
- [91] Arabadzhiev TI et al. Interpretation of emg integral or rms and estimates of "neuromuscular efficiency" can be misleading in fatiguing contraction. *J Electromyogr Kinesiol.*, 20(2), 2010.

- [92] Rissanen S et al. Analysis of surface emg signal morphology in parkinson's disease. *Physiol Meas.*, 28(12), 2007.
- [93] Sirinee Thongpanja et al. Probability density functions of stationary surface emg signals in noisy environments. *IEEE Transactions on Instrumentation and Measurement*, 65(7), 2016.
- [94] Ki et al. Lee. Estimating muscle fatigue of the biceps brachii using high to low band ratio in emg during isotonic exercise. *International Journal of Precision Engineering and Manufacturing*, 10, 2009.
- [95] N. et al. Pakniyat. Decoding of facial muscle-brain relation by information-based analysis of electromyogram (emg) and electroencephalogram (eeg) signals. *Waves in Random and Complex Media*, 34(4), 2021.
- [96] Farina D. Van Heusden K. Ma. Z. and Lorrain T. Quantification of muscle fatigue using the dominant frequency of surface emg. *Biomedical Signal Processing and Control*, 52, 2019.
- [97] B. Li et al. Lower limb motion recognition based on surface electromyography decoding using s-transform energy concentration. *Machines*, 13, 2025.
- [98] Mahdi Khezri and Mehran Jahed. An inventive quadratic time-frequency scheme based on wigner-ville distribution for classification of semg signals. *IEEE Xplorer*, 2007.
- [99] Solnik S et al. Teager-kaiser operator improves the accuracy of emg onset detection independent of signal-to-noise ratio. *Acta Bioeng Biomech.*, 10(2), 2008.
- [100] P. O. Hoyer. Non-negative matrix factorization with sparseness constraints. *Journal of Machine Learning Research*, 5, 2004.
- [101] H. Xie et Z. Wang. Mean frequency derived via hilbert-huang transform with application to fatigue emg signal analysis. *Comput. Methods Programs Biomed.*, 82, 2006.
- [102] M. Nakada S. Demura and Y. Nagasawa. Gender difference in subjective muscle-fatigue sensation during sustained muscle force exertion. *Tohoku J. Exp. Med.*, 215(3), 2008.
- [103] Isa M. M. N. M. and Aris M. S. M. Classification of localized muscle fatigue with genetic programming on semg during isometric contraction. *in Proceedings of the 2009 International Conference on Signal Processing Systems, Singapore*, pages 401–405, 2009.

- [104] Muller J. Atzori M. and al. Combined classification and regression for simultaneous and proportional emg control of wrist forces. *in Proceedings of the 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Milan, Italy*, pages 2917–2920, 2015.
- [105] S. Oskoei and H. Hu. Support vector machine-based classification scheme for myoelectric control applied to upper limb. *IEEE Transactions on Biomedical Engineering*, 55(8), 2008.
- [106] A. Elcadi et al. Fatigue classification in static contractions using semg and force signals. *Biomedical Signal Processing and Control*, 52(101591), 2019.
- [107] F. Sepulveda A. M. Al-Mulla and M. Colley. A review of non-invasive techniques to detect and predict localised muscle fatigue. *Sensors*, 11(4), 2011.
- [108] P. Phukpattaranont T. Phinyomark and C. Limsakul. Feature reduction and selection for emg signal classification. *Expert Systems with Applications*, 39(8), 2012.
- [109] Didi A. A. and Bereksi Reguig F. Modeling local muscle fatigue phases from emg : A comparative study of classification and regression approaches. *Edelweiss Applied Science and Technology*, 9(6) :925–938, DOI : 10.55214/25768484.v9i6.7976., 2025.
- [110] Yokoyama K. and al. An evaluation of hand-force prediction using artificial neural-network regression models of surface emg signals for handwear devices. *Journal of Biomechanical Science and Engineering*, 4(12) :1–13, 2017.
- [111] Zemiti N. and al. Optimal feature selection for emg-based finger force estimation using lightgbm model. *IEEE International Conference Robotics and Biomimetics (ROBIO), Dali, China*, pages 2672–2677, 2019.
- [112] Mokri C. and al. Muscle force estimation from lower limb emg signals using novel optimised machine learning techniques. *Medical and Biological Engineering and Computing*, 3(60) :683–699, 2022.
- [113] R. Tibshirani. Regression shrinkage and selection via the lasso. *J. Royal Stat. Soc.*, 58(1), 1996.
- [114] H. Zou and T. Hastie. Regularization and variable selection via the elastic net. *J. Royal Stat. Soc.*, 67(2), 2005.

- [115] M. Sjöström S. Wold and L. Eriksson. Pls-regression : a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*, 58(2), 2001.
- [116] A. J. Smola and B. Schölkopf. A tutorial on support vector regression. *Statistics and Computing*, 14, 2004.
- [117] J. H. Friedman. Greedy function approximation : A gradient boosting machine. *Annals of Statistics*, 29(5), 2001.
- [118] Y. Bengio Y. LeCun and G. Hinton. Deep learning. *Nature*, 521, 2015.
- [119] D. Ghimire and Y. Lee. Nonlinear feature transformation and selection for improved muscle fatigue classification using emg signals. *Biomedical Signal Processing and Control*, 68, 2021.
- [120] M. Z. Iqbalet al. Efficient feature selection and classification for human activity recognition using hybrid techniques. *Sensors*, 20(8), 2020.
- [121] M. Boostani and M. B. Moradi. Evaluation of the forearm emg signal features for the control of a prosthetic hand. *Physiological Measurement*, 24(2), 2003.
- [122] Didi A. A. and Bereksi Reguig F. Detection of local muscle fatigue phases from semg using optimized regression models under loso cross-validation. *Journal of Engineering Science and Technology (Soumis le 6 septembre 2025 – Première réponse reçue le 25 novembre 2025 : conditionally accepted with minor/major corrections)*.

## Résumé

La présente thèse s'inscrit dans le domaine du génie biomédical et porte sur la prédiction de la force musculaire et la détection des phases locales de fatigue à partir du signal électromyographique de surface (sEMG). Un système matériel dédié a été développé pour l'acquisition synchrone du signal sEMG (1600 Hz) et de la force musculaire (80 Hz) à l'aide d'un amplificateur AD620, d'un module HX711 et d'une carte Arduino/ESP32, assurant une mesure fiable et reproductible. Sur le plan algorithmique, plusieurs modèles de régression ont été comparés à des approches de classification traditionnelles afin d'évaluer la capacité des modèles à suivre les variations continues de la force et à détecter les transitions entre les trois phases de fatigue (non fatiguée, transition, fatiguée). Dix modèles de régression ont été testés (MLR, Ridge, Lasso, ElasticNet, PCR, PLS, SVR, Random Forest, Gradient Boosting et ANN), avec une validation Leave-One-Subject-Out (LOSO) pour garantir la robustesse et la généralisation inter-sujets. Une optimisation originale basée sur la minimisation des mismatches (désaccords entre la phase réelle et la phase prédite) a été proposée, en remplacement à l'optimisation classique par corrélation. Cette approche a permis une amélioration significative de la détection des phases de fatigue, confirmant la supériorité des modèles de régression sur les modèles de classification pour ce type d'application biomédicale.

**Mots clés :** sEMG, Force musculaire, Fatigue locale, Régression, Classification, Optimisation, Mismatch, LOSO, Arduino, HX711, AD620.

## Abstract

This thesis falls within the field of biomedical engineering and focuses on predicting muscle force and detecting local fatigue phases using surface electromyography (sEMG) signals. A dedicated hardware system was developed for the synchronous acquisition of sEMG signals (1600 Hz) and muscle force (80 Hz) using an AD620 amplifier, an HX711 module, and an Arduino/ESP32 board, ensuring reliable and reproducible measurements. On the algorithmic front, several regression models were compared with traditional classification approaches to evaluate the models' ability to track continuous variations in force and detect transitions between three fatigue phases (non-fatigued, transition, fatigued). Ten regression models were tested (MLR, Ridge, Lasso, ElasticNet, PCR, PLS, SVR, Random Forest, Gradient Boosting, and ANN), using Leave-One-Subject-Out (LOSO) validation to ensure robustness and inter-subject generalization. An original optimization method based on minimizing mismatches (discrepancies between the actual and predicted phases) was proposed, replacing traditional correlation-based optimization. This approach led to a significant improvement in detecting fatigue phases, confirming the superiority of regression models over classification models for this type of biomedical application.

**Keywords:** sEMG, Muscle force, Local fatigue, Regression, Classification, Optimization, Mismatch, LOSO, Arduino, HX711, AD620.

## ملخص البحث

تندرج هذه الأطروحة ضمن مجال الهندسة الطبية الحيوية، وتتمحور حول التنبؤ بالقوة العضلية والكشف عن مراحل التعب الموضوعي انطلاقاً من إشارة التخطيط الكهربائي للعضلات السطحي (sEMG). تم تطوير نظام عتادي مخصص للاستحواذ المتزامن على إشارة sEMG (بتردد 1600 هرتز) والقوة العضلية (بتردد 80 هرتز) باستخدام مضخم AD620، ووحدة HX711، ولوحة Arduino/ESP32، مما يضمن قياساً موثقاً وقابلاً للتكرار. من الناحية الخوارزمية، تمت مقارنة عدة نماذج انحدار مع مناهج التصنيف التقليدية لتقييم قدرة النماذج على تتبع التغيرات المستمرة في القوة والكشف عن الانتقالات بين مراحل التعب الثلاث (غير متعب، مرحلة انتقالية، متعب). تم اختبار عشرة نماذج انحدار (MLR, Ridge, Lasso, ElasticNet, PCR, PLS, SVR, Random Forest, Gradient Boosting, ANN)، مع اعتماد بروتوكول التحقق Leave-One-Subject-Out (LOSO) لضمان متانة النتائج وقابليتها للتعميم بين الأفراد. كما تم اقتراح تحسين مبتكر يعتمد على تقليل "عدم التطابق" (الاختلاف بين المرحلة الحقيقية والمرحلة المتوقعة)، كبديل للتحسين الكلاسيكي المعتمد على الارتباط. وقد سمح هذا النهج بتحقيق تحسن ملحوظ في الكشف عن مراحل التعب، مؤكداً تفوق نماذج الانحدار على نماذج التصنيف في هذا النوع من التطبيقات الطبية الحيوية.

**الكلمات المفتاحية:** sEMG، القوة العضلية، التعب الموضوعي، الانحدار، التصنيف، التحسين، عدم التطابق (Mismatch)، بروتوكول LOSO، أروينو، AD620، HX711.