

République Algérienne Démocratique et Populaire
الجمهورية الجزائرية الديمقراطية الشعبية
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
وزارة التعليم العالي و البحث العلمي
École nationale Polytechnique



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département électronique

Mémoire de projet de fin d'études
Pour l'obtention du diplôme d'Ingénieur d'État en Électronique

Classification des mouvements de la main basée sur des modèles d'apprentissage automatique

Massylia KHELAFI & Walid ZEGAOUI

Sous la direction de Mme. Latifa HAMAMI Prof. ENP, Alger

Présenté et soutenu publiquement le 25/06/2023 auprès des membres du jury :

| | | |
|---------------------|-------------------------|------------------|
| Président | M. Hicham BOUSBIA-SALAH | Prof. ENP, Alger |
| Promotrice | Mme. Latifa HAMAMI | Prof. ENP, Alger |
| Examinatrice | Mme. Fatiha LANI | MAA. ENP, Alger |

ENP 2023

10, Avenue des Frères Oudek, Hassen Badi, BP. 182, 16200 El Harrach, Alger, Algérie.

www.enp.edu.dz

République Algérienne Démocratique et Populaire
الجمهورية الجزائرية الديمقراطية الشعبية
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
وزارة التعليم العالي و البحث العلمي
École nationale Polytechnique



المدرسة الوطنية المتعددة التقنيات
Ecole Nationale Polytechnique

Département électronique

Mémoire de projet de fin d'études
Pour l'obtention du diplôme d'Ingénieur d'État en Électronique

Classification des mouvements de la main basée sur des modèles d'apprentissage automatique

Massylia KHELAFI & Walid ZEGAOUI

Sous la direction de Mme. Latifa HAMAMI Prof. ENP, Alger

Présenté et soutenu publiquement le 25/06/2023 auprès des membres du jury :

| | | |
|---------------------|-------------------------|------------------|
| Président | M. Hicham BOUSBIA-SALAH | Prof. ENP, Alger |
| Promotrice | Mme. Latifa HAMAMI | Prof. ENP, Alger |
| Examinatrice | Mme. Fatiha LANI | MAA. ENP, Alger |

ENP 2023

10, Avenue des Frères Oudek, Hassen Badi, BP. 182, 16200 El Harrach, Alger, Algérie.

www.enp.edu.dz

ملخص

تستخدم إشارات تخطيط كهربية العضل (EMG) على نطاق واسع في العديد من المجالات. ومع ذلك ، نظرًا لصغر حجم مجموعة البيانات ، فإن تصنيف إشارات EMG في حركات اليد يمثل مهمة صعبة. تقترح بعض الدراسات بنى معقدة للتغلب على هذا القيد ، لكن هذه البنى تتطلب موارد أجهزة كبيرة ووقت معالجة. الهدف من هذه الدراسة هو اقتراح نهج قائم على التعلم الآلي لتصنيف حركات اليد بدقة ضمن قيود وقت المعالجة المحدود والموارد.

كلمات مفتاحية : التعلم الآلي، تصنيف إشارات EMG، إشارات تخطيط كهربية العضل.

Abstract

Electromyographic (EMG) signals are widely used in many fields. However, due to the small size of the data set, the classification of EMG signals into hand movements represents a difficult task. Some studies propose complex architectures to overcome this constraint, but these architectures require significant hardware resources and processing time. The aim of this study is to propose a machine-learning-based approach for accurately classifying hand movements within the constraints of limited processing time and resources.

Keywords : Machine learning, Classification of EMG signals, Electromyographic.

Résumé

Les signaux électromyographiques (EMG) sont largement utilisés dans de nombreux domaines. Cependant, en raison de la taille réduite de l'ensemble de données, la classification des signaux EMG en mouvements de la main représente une tâche difficile. Certaines études proposent des architectures complexes pour surmonter cette contrainte, mais ces architectures requièrent d'importantes ressources matérielles et un temps de traitement considérable. L'objectif de cette étude est de proposer une approche basée sur l'apprentissage automatique permettant de classer avec précision les mouvements de la main tout en respectant des contraintes de temps de traitement et de ressources limitées.

Mots clés : Apprentissage automatique, Classification des signaux EMG, Électromyographique.

Dédicace

"Ce travail est dédié à mes merveilleux parents qui n'ont jamais cessé de m'encourager et de m'accompagner tout au long de ma vie. J'espère sincèrement avoir atteint le niveau des personnages principaux des histoires que vous me racontiez lorsque j'étais enfant.

À ma magnifique sœur, tu n'as jamais cessé de m'encourager, d'être à mes côtés et de me prodiguer tes conseils. Luffy peut encore chercher le One Piece, mais pour moi, je l'ai toujours eu en toi.

À mes chères tantes, mes deuxièmes mères, celles qui n'ont jamais dit non à mes exigences et qui n'ont épargné aucun effort pour me rendre heureuse, merci de m'avoir encouragé et guidé tout au long de ces années.

À mes oncles, Je vous remercie pour vos mots d'encouragements ainsi que votre gentillesse et votre présence. Et à mes chers cousins, que je considère comme mes frères et sœurs, merci d'embellir ma vie de cette façon si merveilleuse.

Je dédie également ce travail aux personnes qui nous ont malheureusement quittés trop tôt, mon grand-père ainsi que mes deux grand-mères. Que Dieu vous accueille dans son vaste paradis.

Je tiens à exprimer ma profonde gratitude à mes amis et à ma magnifique promotion "ELN MATCH". Vous avez contribué à faire de ces dernières années une période inoubliable. Je vous remercie d'avoir été présents à mes côtés, tant dans les moments heureux que dans les moments difficiles. Votre présence a apporté des éclats de rire et des larmes de joie à ma vie. Merci pour tout ce que vous avez fait.

Je souhaite exprimer ma profonde gratitude pour votre disponibilité constante à répondre à mes questions et à m'encourager. Un immense merci à Amina, Maria, Mohamed, Ramzi et Lynda, votre soutien inconditionnel a été d'une valeur inestimable pour moi.

À tous ceux que j'aime."

- Massylia

Dédicace

”À ceux qui ont donné un sens à mon parcours,

C’est avec une profonde gratitude que je dédie ce projet de fin d’études à toutes les personnes qui ont contribué à sa réalisation. Le chemin jusqu’à ce moment n’a pas été sans embûches, mais grâce à votre soutien, votre amour et votre encouragement, j’ai pu franchir chaque étape avec détermination et persévérance.

À ma famille bien-aimée, à mes chers parents, mes piliers indéfectibles qui ont constamment soutenu et encouragé ma persévérance au fil de ces années d’études. Merci du fond du cœur pour votre soutien et votre contribution exceptionnelle.

À ”ELN MATCH”, ma promo qui restera à jamais gravée dans ma mémoire, avec laquelle j’ai partagé ces trois dernières années intenses, riches en émotions, tantôt heureuses, tantôt éprouvantes. Je vous suis reconnaissant pour toutes les contributions inestimables que vous avez apportées.

À mes amis, mes camarades de l’école, je tiens à vous remercier, tout particulièrement : Abderezak, Said, Achraf, Abdelbaki, Abdellah, Abderahmane, Mehdi, Mehdi, Tarek, Adel, Malek, Jugo, Imad, Lounes, Souhila, Ferial, Sabrina, Wissal, Soumia, Serine, Ilhem, Houda et Sonia pour vos conseils précieux et votre soutien.

À tous ceux qui me sont chers, à vous tous.”

- Walid

Remerciements

Nous tenons à exprimer notre sincère gratitude à notre promotrice, Prof. Latifa HAMAMI, qui nous a soutenu tout au long de ce travail. Nous la remercions pour sa patience, sa motivation, sa disponibilité et son dévouement sans pareil. Nous n'aurions pas pu espérer un meilleur superviseur et mentor.

Nous remercions tout particulièrement les membres du jury qui ont accepté de consacrer leur temps à examiner ce travail : Monsieur Hicham BOUSBIA-SALAH, Professeur à l'Ecole Nationale Polytechnique, Madame Fatiha LANI, Enseignante à l'Ecole Nationale Polytechnique.

Nous tenons à adresser nos remerciements et notre gratitude à tous nos professeurs de l'Ecole Nationale Polytechnique, qui nous ont guidé tout au long de nos cinq années d'études.

Nous remercions également tous nos collègues de l'Ecole Nationale Polytechnique, avec qui nous avons partagé de précieux moments.

Enfin, nous remercions tous ceux qui nous ont aidé de près ou de loin tout au long de notre cursus académique.

Massylia et Walid.

Table des matières

Liste des tableaux

Table des figures

Liste des abréviations

| | |
|---|-----------|
| Introduction générale | 16 |
| 1 Généralités sur les signaux EMG | 19 |
| 1.1 Introduction | 20 |
| 1.2 Signaux EMG | 20 |
| 1.2.1 Caractéristiques des signaux EMG | 20 |
| 1.2.2 Modélisation mathématique | 21 |
| 1.3 Types d'électrodes | 22 |
| 1.3.1 Électrodes de surface (sEMG) | 22 |
| 1.3.2 Électrodes sans fil | 23 |
| 1.3.3 Électrodes à aiguilles | 24 |
| 1.4 L'effet Crosstalk | 25 |
| 1.5 Caractéristiques des paires d'électrodes | 25 |
| 1.5.1 Matière utilisée | 26 |
| 1.5.2 Forme et Taille de l'électrode | 26 |
| 1.5.3 Distance inter-électrodes | 27 |
| 1.6 Anatomie de l'avant - bras | 27 |
| 1.7 Placement des électrodes | 28 |
| 1.7.1 Configuration autour de l'avant-bras | 28 |
| 1.7.2 Configuration spécifique | 29 |
| 1.7.3 Configuration en grille | 29 |
| 1.8 Placement de l'électrode de référence | 30 |
| 1.9 Application des signaux EMG | 31 |
| 1.10 Etat de l'art | 31 |
| 1.11 Conclusion | 33 |
| 2 Système de détection de mouvements de la main à partir des signaux EMG | 34 |
| 2.1 Introduction | 35 |
| 2.2 Acquisition des données | 36 |
| 2.3 Prétraitement | 36 |
| 2.3.1 Amplification du signal EMG | 37 |

| | | |
|----------|--|-----------|
| 2.3.2 | Filtrage du signal EMG | 37 |
| 2.3.3 | Rectification du signal EMG | 38 |
| 2.3.4 | Normalisation du signal EMG | 39 |
| 2.4 | Fenêtrage et extraction des caractéristiques | 40 |
| 2.4.1 | Fenêtrage | 40 |
| 2.4.2 | Extraction des caractéristiques | 42 |
| 2.5 | Réduction de la dimensionnalité | 46 |
| 2.5.1 | Sélection des caractéristiques | 46 |
| 2.5.2 | Projection des caractéristiques | 46 |
| 2.6 | Classification | 48 |
| 2.6.1 | Méthode de classification | 48 |
| 2.6.2 | GridSearchCV | 51 |
| 2.7 | Modèles individuels Vs Modèles généraux | 52 |
| 2.8 | Conclusion | 54 |
| 3 | Méthodologie et implémentation | 55 |
| 3.1 | Introduction | 56 |
| 3.2 | Logiciels, librairies et matériels | 56 |
| 3.2.1 | Logiciels, librairies | 56 |
| 3.3 | Schéma général | 58 |
| 3.4 | Capteurs EMG | 59 |
| 3.4.1 | Composants internes des capteurs EMG | 60 |
| 3.5 | Choix du microcontrôleur | 65 |
| 3.5.1 | STM32 Blue Pill | 66 |
| 3.5.2 | ST-LINK V2 | 67 |
| 3.5.3 | Timer | 68 |
| 3.5.4 | Convertisseur analogique-numérique (CAN) | 68 |
| 3.5.5 | Protocole de communication UART | 70 |
| 3.5.6 | Convertisseur USB-TTL | 72 |
| 3.5.7 | Programmation du microcontrôleur | 72 |
| 3.6 | Modèle Proposé | 74 |
| 3.6.1 | Pseudo-Code | 75 |
| 3.7 | Interface Graphique | 77 |
| 3.7.1 | Interface Base de données | 78 |
| 3.7.2 | Interface Classification | 79 |
| 3.8 | Conclusion | 80 |
| 4 | Résultats et évaluation expérimentale | 81 |
| 4.1 | Introduction | 82 |
| 4.2 | Ensemble de données | 82 |
| 4.2.1 | Répartition des données | 83 |
| 4.3 | Métriques d'évaluations utilisées | 84 |
| 4.3.1 | La précision (Accuracy) | 84 |
| 4.3.2 | Matrice de confusion | 85 |
| 4.4 | Variations du nombre d'électrodes utilisées | 87 |
| 4.4.1 | Discussion des résultats | 88 |

| | | |
|-------|---|------------|
| 4.5 | Test du fenêtrage | 88 |
| 4.5.1 | Discussion des résultats | 89 |
| 4.6 | Test des caractéristiques | 90 |
| 4.6.1 | Discussion des résultats | 91 |
| 4.7 | Test de la réduction de la dimension avec l'ACP | 92 |
| 4.7.1 | Discussion des résultats | 92 |
| 4.8 | Test sur la base de données | 93 |
| 4.9 | Récapitulatif des résultats | 97 |
| 4.10 | Conclusion | 99 |
| | Conclusion et perspectives | 100 |
| | Bibliographie | 103 |
| | Annexes | 109 |

Liste des tableaux

| | | |
|------|---|----|
| 1.1 | Avantages et inconvénients des différents types d'électrodes | 24 |
| 1.2 | Les performances atteintes dans l'état de l'art | 33 |
| 2.1 | Résumé des fréquences d'échantillonnage et des méthodes de prétraitement et de fenêtrage utilisées dans la littérature | 41 |
| 2.2 | Résumé des caractéristiques et classifieurs utilisés dans la littérature | 52 |
| 2.3 | Avantages et inconvénients des modèles individuels et généraux | 54 |
| 3.1 | Configuration de l'UART | 71 |
| 4.1 | Les différents mouvements de la main | 83 |
| 4.2 | Répartition de notre ensemble de données | 84 |
| 4.3 | Taux de classification des mouvements par variation des nombres d'élec- trodes et des mouvements | 88 |
| 4.4 | Résultats de la précision par variation de la taille de la fenêtre | 89 |
| 4.5 | Résultats de la précision par variation du pourcentage d'incrementation (taille de la fenêtre fixe = 200) | 89 |
| 4.6 | Temps d'exécution de chaque type de fenêtrage | 89 |
| 4.7 | Performances atteintes sur chaque mouvement avec les caractéristiques temporelles | 90 |
| 4.8 | Performances atteintes sur chaque mouvement avec les caractéristiques fré- quentielles | 90 |
| 4.9 | Performances atteintes sur chaque mouvement avec les caractéristiques temporelles et fréquentielles | 91 |
| 4.10 | Comparaison des performances et des temps de calcul avec et sans utiliza- tion de l'ACP | 92 |
| 4.11 | Les performances atteintes sur chaque sujet | 93 |
| 4.12 | Résultats des métriques sur chaque sujet | 95 |

Table des figures

| | | |
|------|---|----|
| 1.1 | Schéma illustrant une unité motrice et la manière dont un signal EMG de surface peut être enregistré à partir d'un muscle à l'aide d'une électrode bipolaire (deux contacts d'électrode) [6]. | 21 |
| 1.2 | Montage bipolaire | 26 |
| 1.3 | Emplacement des muscles fléchisseurs (a) et extenseurs (b) de l'avant bras [13] | 28 |
| 1.4 | Configuration autour de l'avant bras | 29 |
| 1.5 | Illustrations des différentes configurations | 30 |
| 1.6 | Illustrations de l'emplacement de l'électrode de référence | 31 |
| 2.1 | Schéma synoptique d'un système de classification des signaux EMG | 35 |
| 2.2 | Rectification du signal EMG | 38 |
| 2.3 | Fenêtrage disjoint [5] | 40 |
| 2.4 | Fenêtrage superposé [5] | 41 |
| 2.5 | Représentation du principe de l'ACP [39] | 47 |
| 2.6 | Principe du SVM | 48 |
| 2.7 | Principe du k-NN | 49 |
| 2.8 | Principe du RF | 50 |
| 2.9 | Principe du LDA | 50 |
| 2.10 | La fonction logistique | 51 |
| 3.1 | Schéma-bloc du système de détection des mouvements de la main | 58 |
| 3.2 | Les différentes versions des capteurs EMG | 59 |
| 3.3 | Composants internes des capteurs EMG | 60 |
| 3.4 | Circuit de rectification du signal (Annexe 4.10) | 62 |
| 3.5 | Filtre actif passe-bas du 1er ordre | 64 |
| 3.6 | Amplificateur inverseur | 65 |
| 3.7 | STM32 Blue Pill Pinout | 67 |
| 3.8 | Boot mode | 67 |
| 3.9 | Fonctionnement du double mode régulier simultané | 69 |
| 3.10 | Trame de données en UART | 71 |
| 3.11 | Couche d'abstraction de Stmcubeide [48] | 72 |
| 3.12 | Ecran de configuration du microcontrôleur | 73 |
| 3.13 | Schéma synoptique du modèle proposé | 74 |
| 3.14 | Interface de Base de données | 79 |
| 3.15 | Interface de classification | 80 |
| 4.1 | Exemple de collecte de données | 83 |
| 4.2 | Matrice de confusion | 85 |

| | | |
|------|---|-----|
| 4.3 | Matrice de confusion générale | 86 |
| 4.4 | Emplacement des électrodes | 87 |
| 4.5 | Matrices de confusion du meilleur sujet pour les classifieurs SVM, k-NN et RF | 96 |
| 4.6 | Matrices de confusion du meilleur sujet pour les classifieurs LDA et LR . . | 96 |
| 4.7 | Les performances atteintes (Sujets 1 - 10) | 97 |
| 4.8 | Les performances atteintes (Sujets 11 - 20) | 97 |
| 4.9 | Performances moyennes atteintes des 20 sujets | 98 |
| 4.10 | Moyennes de sensibilités et de spécificités des 20 sujets | 98 |
| 11 | Dimensions du capteurs EMG | 112 |
| 12 | Schéma électrique du capteurs EMG | 112 |
| 13 | Fonctionnalités de base de l'interface graphique | 113 |
| 14 | Exemples de messages d'erreurs courants et leur présentation dans l'interface | 114 |

Liste des abréviations

A/N *Analogique-Numérique.*

ACC *Average Amplitude Change.*

ACP *Analyse en composantes principales.*

ANN *Artificial Neural Network.*

AOP *Amplificateur Opérationnel.*

ARM *Advanced RISC Machine.*

AVC *Accident Vasculaire Cérébral.*

CAN *Convertisseur Analogique-Numérique.*

CNN *Convolutional Neural Network.*

CPU *Central Processing Unit.*

DASDV *Difference Absolute Standard Deviation Value.*

DMA *Direct Memory Access.*

DSP *Digital Signal Processing.*

DT *Decision Tree.*

ECG *Électrocardiogramme.*

EEG *Électroencéphalographie.*

EMG *Électromyographie.*

FPCB *Flexible Printed Circuit Board.*

FR *Frequency Ratio.*

GND *Ground.*

GPIO *General Purpose Input/Output.*

GUI *Graphical User Interface.*

HAL *Hardware Abstraction Layer.*

HJP *Hjorth Parameters.*

HSE *High-Speed External.*

HSI *High-Speed Internal.*

I²C *Inter-Integrated Circuit.*

IC *Integrated Circuit.*

IED *Inter Electrode Distance.*

iEMG *Integrated EMG.*

ISR *Interrupt Service Routine.*

k-NN *K-Nearest Neighbors.*

LDA *Linear Discriminant Analysis.*

LQFP *Low Quad Flat Package.*

LR *Logistic Regression.*

MAV *Mean Absolute Value.*

MCA *Multiple Correspondence Analysis.*

MCU *Microcontroller Unit.*

MDF *Median Frequency.*

MID *Middle*

MMDC *Mathematical Model for Dynamic Contraction.*

MMSC *Mathematical Model for Static Contraction.*

MNF *Mean Frequency.*

MNP *Mean Power.*

MPU *Memory Protection Unit.*

MRMR *Minimum Redundancy - Maximum Relevance.*

MU *Motor Unit.*

MUAP *Motor Unit Action Potential.*

MYOP *Myopulse Percentage Rate.*

NB *Naive Bayes.*

PCB *Printed Circuit Board.*

PKF *Peak Frequency.*

QDA *Quadratic Discriminant Analysis.*

RBF *Radial Basis Function.*

RF *Random Forest.*

RMS *Root Mean Square.*

RSS *Root Sum Square.*

sEMG *Surface Electromyography.*

SENIAM *Surface ElectroMyoGraphy for the Non-Invasive Assessment of Muscles.*

SFS *Sequential Forward Selection.*

SNR *Signal-to-Noise Ratio.*

SPI *Serial Peripheral Interface.*

SRAM *Static Random Access.*

SSC *Slope Sign Change.*

SSI *Simple Square Integral.*

SVM *Support Vector Machine.*

t-SNE *t-distributed Stochastic Neighbor Embedding.*

TTL *Transistor-Transistor Logic.*

TTP *THE Total Power.*

UART *Universal Asynchronous Receiver Transmitter.*

ULDA *Uncorrelated Linear Discriminant Analysis.*

USB *Universal Serial Bus.*

VAR *Variance.*

WAMP *Willison Amplitude.*

WL *Waveform Length.*

ZC *Zero Crossing.*

Introduction générale

Introduction générale

L'évolution technologique a considérablement transformé notre quotidien, et les dispositifs informatiques sont devenus essentiels dans nos vies. Des ordinateurs portables aux smartphones en passant par les montres connectées, nous sommes entourés de technologies qui facilitent nos tâches quotidiennes et enrichissent nos expériences. Cette présence massive de dispositifs informatiques souligne l'importance de l'interaction homme-machine, où la reconnaissance gestuelle humaine joue un rôle crucial.

Parmi les différents signaux physiologiques, les signaux électromyographiques (EMG) ont été relativement moins explorés par rapport aux signaux EEG et ECG, qui ont bénéficié d'une attention plus soutenue dans la recherche et les applications cliniques. Toutefois, il convient de noter que ces dernières années, les signaux EMG ont commencé à susciter un intérêt croissant et à faire l'objet de recherches plus approfondies. Le signal EMG correspond à un signal électrique mesuré à partir de l'activité électrique des muscles. Il reflète les contractions et les relaxations musculaires qui se produisent lors d'un mouvement spécifique. Ce signal est généralement une fonction du temps et peut être décrit en termes d'amplitude et de fréquence. L'analyse du signal EMG présente des défis en raison de sa nature stochastique et de la présence de diverses sources de bruit lors de sa capture. Ces facteurs rendent complexe l'analyse, la classification et la distinction des différents mouvements basés sur le signal EMG.

La reconnaissance des mouvements de la main à partir des signaux EMG est une branche de la reconnaissance gestuelle humaine qui se focalise sur l'utilisation des signaux électriques produits par les muscles lors de la contraction pour interpréter les gestes effectués. Actuellement, ces systèmes sont utilisés, par exemple, dans plusieurs applications telles que les prothèses intelligentes [1], la reconnaissance de la langue des signes [2], les dispositifs de rééducation [3] et les dispositifs de contrôle de la réalité virtuelle [1].

Les bases de données contenant des signaux EMG présentent généralement une taille réduite ce qui constitue une contrainte pour la bonne classification de ces derniers. Pour remédier à cela, de nombreuses études ont adopté des approches basées sur des architectures de réseaux de neurones convolutifs (CNN) et des modèles de transfert d'apprentissage afin d'obtenir des performances de classification élevées. Toutefois, l'utilisation de telles méthodes requiert des ressources matérielles substantielles et entraîne des temps de traitement considérables, ce qui rend leur implémentation problématiques. Ainsi, l'objectif de cette recherche consiste à proposer un modèle de prétraitement et de classification

qui soit à la fois performant, économiquement efficace en termes de ressources, et capable d'être mis en œuvre dans des délais réduits.

Ce mémoire est divisé en quatre chapitres qui sont structurés comme suit :

Le premier chapitre introduit les généralités des signaux EMG et présente les travaux de recherches réalisés dans le domaine de la reconnaissance des mouvements, fournissant ainsi une vue d'ensemble des bases des signaux EMG et des avancés dans l'identification et l'analyse des mouvements à partir de ces signaux.

Le deuxième chapitre se concentre sur les étapes de traitement qui forment un système de détection des mouvements de la main à partir des signaux EMG.

Le troisième chapitre expose la méthodologie utilisée et détaille sa mise en œuvre matérielle, en présentant les étapes clés de notre approche. Nous y mettons en évidence les outils et les ressources et techniques employées.

Dans le quatrième chapitre de notre travail, nous présenterons les différents résultats obtenus grâce à l'utilisation du modèle proposé. Nous examinerons en détail les performances de la classification et discuterons de l'efficacité de notre approche dans la résolution du problème. De plus, nous mettrons en évidence les limitations et les aspects à améliorer.

Enfin, nous terminons ce mémoire par une conclusion et quelques perspectives pour un futur travail.

Chapitre 1

Généralités sur les signaux EMG

1.1 Introduction

Dans ce chapitre nous aborderons l'aspect théorique du sujet en examinant en détail les principes fondamentaux des signaux EMG et leur relation avec l'anatomie musculaire. Nous plongerons dans les concepts théoriques essentiels pour comprendre le fonctionnement des signaux EMG.

De plus, nous discuterons des différentes méthodes utilisées pour enregistrer ces signaux EMG. Nous explorerons les techniques d'électrodes de surface, les aiguilles intramusculaires et d'autres approches d'enregistrement, en mettant en évidence leurs avantages et leurs limites spécifiques.

En outre, nous dresserons un état de l'art en se basant sur les recherches et résultats les plus récents, afin de présenter les avancées significatives dans la compréhension et l'application des signaux EMG.

Cette combinaison d'aspects théoriques, de méthodes d'enregistrement et d'un état de l'art approfondi nous permettra de fournir une vision globale et d'actualité du sujet, en soulignant les avancées clés qui ont contribué à une meilleure compréhension et à une utilisation plus efficace de ces signaux dans divers domaines de recherche et d'application.

1.2 Signaux EMG

L'électromyographie (EMG), parfois appelée activité myoélectrique, est une technique qui permet de mesurer et d'analyser l'activité électrique des muscles pendant des actions volontaires ou involontaires. Cette activité électrique est produite par des unités motrices situées à l'intérieur du tissu musculaire. Pour réaliser cette mesure, on utilise des capteurs EMG ou un électromyographe, qui enregistrent le signal électrique produit par les unités motrices. L'enregistrement de cette activité est appelé électromyogramme. Il est important de ne pas confondre les termes EMG (la technique), l'électromyographe (l'outil) et électromyogramme (l'enregistrement), qui font référence à des concepts différents dans la mesure de l'activité électrique musculaire.

1.2.1 Caractéristiques des signaux EMG

En ce qui concerne la physiologie d'un muscle squelettique, le potentiel entre la partie interne et la partie externe d'une fibre est d'environ (-70 mV -80 mV) au repos [4][5]. Lorsque le cerveau envoie une impulsion au muscle, deux potentiels d'actions sont créés dans chaque fibre au niveau de la jonction neuromusculaire. Ces potentiels d'actions se propagent de la jonction neuromusculaire aux tendons. Pour produire de la force, le cerveau doit envoyer un train d'impulsions à certaines ou à toutes les unités motrices d'un muscle. Le nombre d'unités motrices actives et l'intervalle entre deux impulsions consécutives est considéré comme une quantité aléatoire qui augmente avec la force musculaire. Le

train d'impulsions envoyés par le cerveau à une fibre musculaire crée en elle un train de potentiels d'action. La sommation des trains de potentiels d'action de toutes les fibres d'une unité motrice est appelée train de potentiel d'action d'unité motrice (MUAP). L'EMG mesuré par un capteur est la sommation des trains de MUAP des unités motrices qui composent un muscle. Ces potentiels d'action se produisent à des moments aléatoires, de sorte que le signal EMG puisse varier entre des tensions positives et négatives à tout moment [4].

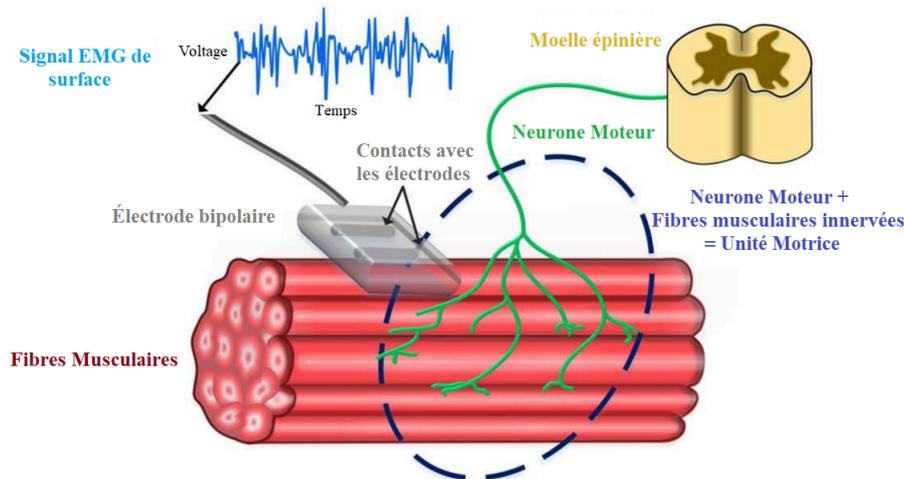


FIG. 1.1 : Schéma illustrant une unité motrice et la manière dont un signal EMG de surface peut être enregistré à partir d'un muscle à l'aide d'une électrode bipolaire (deux contacts d'électrode) [6].

Il existe deux approches pour acquérir le signal EMG en fonction du type de capteur de réception : l'électromyographie intramusculaire et l'électromyographie de surface (sEMG). Lors de la détection et de l'enregistrement du signal EMG, deux problèmes principaux préoccupent la fidélité du signal. Le premier est le rapport signal sur bruit (SNR)¹. De manière générale, on entend par bruit : les signaux électriques qui ne font pas partie du signal EMG désiré. Le deuxième problème est la distorsion du signal. Ce qui signifie que la contribution relative de toute composante de fréquence dans le signal EMG ne doit pas être altérée.

1.2.2 Modélisation mathématique

Il existe deux types de contractions musculaires : la contraction statique et la contraction dynamique. Dans la contraction statique, la longueur des fibres musculaires ne change pas et les articulations ne bougent pas, mais les fibres musculaires se contractent tout de même. Par exemple, lorsque quelqu'un maintient sa main immobile. Dans la contraction dynamique, il y a des changements dans la longueur des fibres musculaires et les articulations bougent. Par exemple, lorsque quelqu'un agite sa main pour faire le signe de salutation.

¹Le rapport des puissances entre la partie du signal qui représente une information et le reste, qui constitue un bruit de fond

Les signaux EMG peuvent être modélisés comme un processus stochastique² qui dépend des deux types de contractions décrites ci-dessus .

- a) Le modèle mathématique pour une contraction statique (MMSC) est un processus stationnaire³, car la moyenne et la covariance restent approximativement les mêmes au fil du temps, et l'EMG dépend uniquement de la force musculaire [5].

$$EMG(t) = \sum_{i=1}^N s_i(t) * m_i(t) \quad (1.1)$$

Où N est le nombre des unités motrices (MU) actives, $s_i(t)$ est le train d'impulsions qui indique les moments actifs de chaque MU, $m_i(t)$ sont les MUAP de chaque MU, et $*$ dénote la convolution.

- b) Le modèle mathématique d'une contraction dynamique (MMDC) est un processus non stationnaire, et son modèle mathématique est décrit par l'équation 1.2 ci-dessous :

$$EMG(t) = a(t)w(t) + n(t) \quad (1.2)$$

Où $a(t)$ est une fonction qui indique l'intensité du signal EMG (le signal utile), $w(t)$ est un processus gaussien $\mathcal{N}(0, \sigma_w)$ représentant l'aspect stochastique du signal EMG (le signal porteur), et $n(t)$ est un processus gaussien $\mathcal{N}(0, \sigma_n)$ qui représente le bruit provenant des capteurs et des artefacts du signal, avec $\sigma_n \ll \sigma_w$.

1.3 Types d'électrodes

Les électrodes électromyographiques (EMG) sont utilisées pour détecter et enregistrer l'activité électrique des muscles. Elles captent les signaux électriques produits lors de la contraction du muscle étudié. Les signaux électriques passent ensuite par des étapes de prétraitement et de classification ou d'analyse afin d'évaluer la fonction musculaire. Ces électrodes sont généralement utilisées pour détecter d'éventuelles anomalies ou dysfonctionnement musculaire en médecine de sport pour suivre une rééducation ou pour d'autres applications de la médecine et des sciences biomédicales. Il existe différents types d'électrodes électromyographiques, les unes sont directement insérées dans le muscle (électrodes dites invasives), et les autres sont placées en surfaces (électrodes non-invasives). Nous allons citer dans ce qui suit une liste non exhaustive de ces différents types :

1.3.1 Électrodes de surface (sEMG)

Il s'agit du type d'électrodes EMG le plus couramment utilisé. Elles sont placées sur la peau à proximité du muscle étudié. Il existe deux types d'électrodes de surface : les électrodes humides (*wet electrodes*) et les électrodes sèches (*dry electrodes*) [7].

²Représente une évolution, discrète ou à temps continu, d'une variable aléatoire.

³Processus dont les propriétés statistiques restent constantes dans le temps

Les électrodes humides

C'est un type d'électrodes de surface qui utilise un gel afin d'améliorer la conductivité électrique entre l'électrode et la peau. L'électrode est généralement composée de petits disques en métal qui se trouvent au centre d'un patch adhésif afin de faciliter son adhérence à la peau. On retrouve très souvent des électrodes en argent ou en acier inoxydable qui ont une conductivité élevée et sont assez stables à long terme. On peut aussi retrouver des électrodes en platine ou en or qui ont une excellente conductivité mais leur coût de fabrication est assez élevé.



Les électrodes sèches

Ce type d'électrodes de surface ne nécessite pas l'utilisation d'un gel conducteur. Elles sont directement placées au contact de la peau. Elles peuvent être fabriquées en laboratoire en suivant des caractéristiques précises que l'on détaillera plus bas.



Les électrodes sèches peuvent être imprimées sur des PCB (circuit imprimé classique), ou en utilisant des FPCB (circuit imprimé flexible) [8]. Elles sont plus avantageuses dans certaines situations, car elles ne laissent pas d'empreinte ou de trace sur le bras du sujet.

1.3.2 Électrodes sans fil

Il s'agit d'un nouveau type d'électrodes EMG qui utilisent la technologie sans fil pour transmettre les données à un ordinateur ou à un appareil mobile. Elles sont généralement utilisées pour la surveillance à domicile ou pour des études de recherches où la mobilité est importante [9].



1.3.3 Électrodes à aiguilles

Également appelées électrodes intramusculaires. Les électrodes à aiguilles sont insérées directement dans le muscle à tester. Elles sont plus invasives que les électrodes de surface et sont généralement utilisées à des fins de diagnostic ou de recherche. Ce type d'électrode n'est donc pas adéquat avec notre application. De plus, étant donné que l'EMG à aiguille implique l'insertion et le déplacement d'une électrode à aiguille à travers un muscle, des risques potentiels existent, notamment la douleur, les saignements ou la formation d'hématomes. Étant donné les risques cités précédemment, l'utilisation de ce type d'électrodes est strictement réservée aux personnels qualifiés [8].



Avant de choisir une électrode EMG, il est important de comprendre les avantages et les inconvénients des différents types d'électrodes, nous avons dressé le tableau 1.1 comparatif ci-dessous :

| Type d'électrodes | Avantages | Inconvénients |
|-------------------------------|--|--|
| Électrodes de surface humides | <ul style="list-style-type: none"> - Non-invasives - Facilité d'utilisation - Coût bas - Meilleure qualité du signal - Meilleure adhérence - Adaptées aux signaux faibles - Disponibilité | <ul style="list-style-type: none"> - Utilisation à usage unique - Risque de fuite du gel conducteur^a - Nécessite un nettoyage préalable de la peau |
| Électrodes de surface sèches | <ul style="list-style-type: none"> - Non-invasives - Facilité d'utilisation - Durabilité - Ne nécessite pas de nettoyage préalable | <ul style="list-style-type: none"> - Variabilité du contact - Effet de l'humidité et de la transpiration sur la qualité du signal. - Impédance électrique haute et instable |
| Électrodes à aiguille | <ul style="list-style-type: none"> - Précision de la mesure - Fiabilité | <ul style="list-style-type: none"> - Invasives - Risque de douleur, saignement et formation d'hématomes^b - Portée limitée |
| Électrodes sans fil | <ul style="list-style-type: none"> - Élimination de l'interférence des fils - Mobilité améliorée/confort | <ul style="list-style-type: none"> - Risque d'interférences - Nécessité d'une alimentation électrique - Coûteuse |

TAB. 1.1 : Avantages et inconvénients des différents types d'électrodes

^aIl existe des électrodes pré-gélifiées (pas de risque de fuite du gel)

^bCes risques sont minimales lorsque la procédure est effectuée par un personnel qualifié

Suite à l'étude comparative des avantages et des inconvénients qu'offrent ces différents types d'électrodes, nous avons opté pour les électrodes de surface humide (pré-gélifiées). Car, ces électrodes sont faciles d'utilisation et elles sont disponibles dans le marché. De plus, elles sont du type *snap* électrodes compatibles avec les connecteurs *snap-on*, ce qui permet une installation rapide et facile.

1.4 L'effet Crosstalk

Le *Crosstalk* est défini comme la contamination du signal EMG par l'activité myo-électrique générée dans un muscle voisin [10]. En d'autres termes c'est un phénomène indésirable qui peut se produire lors de l'enregistrement des signaux EMG à partir des muscles. Il se produit lorsque les signaux électriques provenant d'un muscle spécifique sont captés par une électrode adjacente, créant ainsi une interférence. Lorsqu'une électrode EMG est placée sur la peau pour enregistrer l'activité musculaire, elle capte les signaux électriques produits par les fibres musculaires en dessous. Cependant, en raison de la proximité des muscles adjacents, il peut y avoir une "fuite" de signal électrique provenant de ces muscles vers l'électrode, ce qui est connu sous le nom de *crosstalk*.

L'effet de *crosstalk* peut avoir plusieurs causes. Par exemple, une mauvaise isolation entre les électrodes peut permettre aux signaux de se propager d'une électrode à l'autre. De plus, les muscles adjacents peuvent également générer des signaux EMG similaires, ce qui peut entraîner une interférence entre les électrodes. Dans les cas les plus extrêmes, les interférences croisées peuvent donner l'impression qu'un muscle génère une activité myoélectrique alors qu'il ne l'est pas réellement [10].

Cet effet peut être réduit davantage grâce à une localisation adéquate des électrodes de surface sur le muscle et en réduisant la distance entre les électrodes. Il convient de placer les électrodes au centre du ventre musculaire, loin des bordures, bien que cela puisse être difficile pour les muscles plus petits. [10]

1.5 Caractéristiques des paires d'électrodes

Les travaux du projet européen *Surface EMG for Non-Invasive Assessment of Muscles* (SENIAM) sont largement reconnus et utilisés comme référence dans le domaine de l'EMG de surface. Le SENIAM a effectué des recherches approfondies et a établi des recommandations concernant les matériaux utilisés et les distances inter-électrodes pour les mesures de sEMG de base.

Dans ce qui suit, nous nous référerons principalement aux travaux du projet européen SENIAM pour les recommandations sur l'EMG de surface. Cependant, il convient de noter que nous examinerons également d'autres études et recherches pertinentes dans le domaine.

Le terme "capteur" est utilisé à la place de "électrode" pour souligner le fait que chaque mesure de sEMG (électromyographie de surface) nécessite un ensemble d'au moins deux électrodes individuelles. Dans la plupart des situations pratiques, un montage d'électrodes bipolaires est utilisé pour l'enregistrement du sEMG. Cela signifie qu'un seul signal sEMG est capté en tant que différence de potentiel électrique entre deux électrodes (e_1 et e_2)

positionnées relativement proches l'une de l'autre sur le muscle, l'autre électrode (e3) servant de masse est placée sur une surface osseuse, ce montage est représenté par la figure 1.2. Plusieurs facteurs tels que les formes, les tailles, et la distance inter-électrodes (IED) peuvent influencer l'enregistrement obtenu à partir d'un montage bipolaire de sEMG.

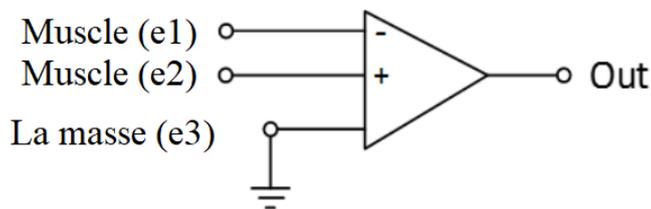


FIG. 1.2 : Montage bipolaire

1.5.1 Matière utilisée

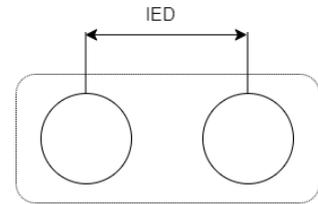
Un inventaire a montré que différents types de matériaux sont utilisés, principalement Ag/AgCl, AgCl, Ag, Au, dont les électrodes Ag/AgCl sont les plus courantes. Elles assurent une transition stable avec un faible bruit et sont facilement disponibles dans le commerce. Les électrodes sont généralement combinées à un gel d'électrode. Des électrodes pré-gélifiées et non gélifiées sont disponibles dans le commerce. Le gel et la pâte d'électrode sont utilisés pour réduire l'impédance électrode-peau. Une faible impédance permet des enregistrements stables et un faible niveau de bruit des électrodes. Comme l'utilisation d'électrodes non gélifiées est encombrante et prend du temps, il est recommandé d'utiliser des électrodes pré-gélifiées, bien que les performances des électrodes pré-gélifiées et des électrodes non gélifiées soient similaires.

1.5.2 Forme et Taille de l'électrode

La forme et la taille de la zone conductrice des électrodes sEMG peuvent être soit rectangulaires (carrées ou en forme de barre), ou circulaires (en forme d'épingle), sans grande différence en termes de performance et de zone de captation. SENIAM recommande que la taille maximale de l'électrode en direction des fibres musculaires soit circulaire avec un diamètre de 10 mm. L'analyse de la littérature a permis de constater qu'une grande variété d'électrodes était utilisée, avec des barres ou des broches dont les dimensions varient en termes de diamètre et de longueur.

1.5.3 Distance inter-électrodes

L'IED (Distance Inter-Électrodes) correspond à la distance entre les zones conductrices de deux électrodes bipolaires, comme illustré par la Figure. L'influence de l'IED sur le *crosstalk* est pertinente en raison des différentes tailles de muscle. SENIAM recommande d'appliquer l'électromyographie de surface (sEMG) bipolaire autour de l'emplacement recommandé du capteur avec un IED de 20 mm. On constate l'utilisation d'autres distances inter-électrode mais celles ci sont toujours proches de 20 mm (16 mm [11], 21 mm [12]).



1.6 Anatomie de l'avant - bras

Dans cette partie, nous allons examiner les divers muscles qui se trouvent dans l'avant-bras et la position optimale pour placer les électrodes de mesure de notre système. Notre attention portera principalement sur les muscles fléchisseurs et extenseurs qui contrôlent les mouvements des doigts de la main.

En ce qui concerne les muscles extenseurs, voici quelques exemples :

- Extenseur commun des doigts
- Extenseur radial du carpe
- Long extenseur du pouce
- Court extenseur du pouce
- Extenseur de l'index

En ce qui concerne les muscles fléchisseurs :

- Fléchisseur superficiel des doigts
- Fléchisseur radial du carpe
- Fléchisseur profond des doigts
- Long fléchisseur du pouce

La figure 1.3 représente les emplacements des muscles fléchisseurs et extenseurs de l'avant-bras.

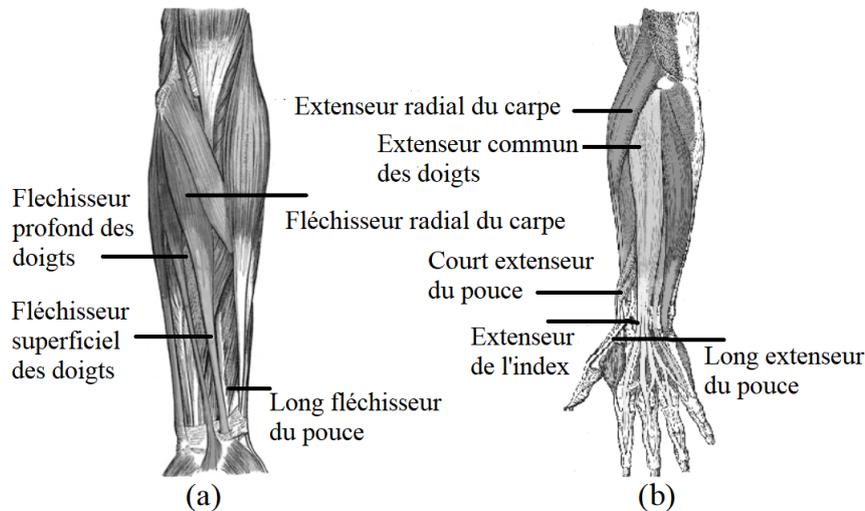


FIG. 1.3 : Emplacement des muscles fléchisseurs (a) et extenseurs (b) de l'avant bras [13]

En ce qui concerne la motricité de l'avant-bras, il existe deux types de muscles qui travaillent ensemble pour permettre des mouvements précis et contrôlés des doigts : les muscles responsables de l'extension (les extenseurs) qui se trouvent principalement dans la partie postérieure de l'avant-bras comme l'extenseur commun des doigts, le long extenseur du pouce, le court extenseur du pouce et l'extenseur de l'index. D'autre part, les muscles de flexion (les fléchisseurs) sont concentrés dans la partie antérieure de l'avant-bras comme le fléchisseur superficiel des doigts, le fléchisseur profond des doigts et le long fléchisseur du pouce. Les mouvements des doigts sont souvent le résultat de la coordination complexe de plusieurs muscles de l'avant-bras et de la main travaillant ensemble, ce qui permet une grande variété de mouvements complexes et précis.

1.7 Placement des électrodes

Différentes configurations de placement des électrodes sont utilisées en électromyographie de surface (sEMG) pour enregistrer les signaux musculaires. Cela comprend une configuration autour de l'avant-bras, une configuration spécifique avec des paires d'électrodes positionnées à des endroits spécifiques, ainsi qu'une configuration en grille. Chaque configuration a ses propres caractéristiques distinctes.

1.7.1 Configuration autour de l'avant-bras

Dans cette configuration, les électrodes sont positionnées de manière circulaire autour de l'avant-bras, généralement à des intervalles réguliers. Elle est souvent utilisée pour capturer l'activité électrique globale d'un groupe musculaire étendu sur l'avant-bras. Les électrodes sont généralement disposées de manière à former une boucle continue autour du bras. L'électrode de référence peut être positionnée entre les deux électrodes bipolaires comme dans le cas du myo armband en figure 4.6a ou dans une région osseuse adjacente

montrée dans la figure 4.6b. Il est important de noter que dans cette configuration, l'aspect du crosstalk mentionné précédemment est omniprésent, car les signaux provenant des muscles voisins peuvent interférer avec les électrodes voisines [14].



FIG. 1.4 : Configuration autour de l'avant bras

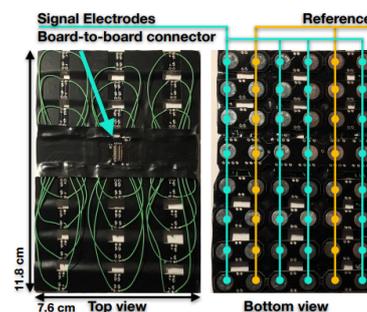
1.7.2 Configuration spécifique

Dans cette configuration, des paires d'électrodes sont positionnées à des endroits spécifiques sur les muscles d'intérêt. Elle est utilisée pour cibler et enregistrer spécifiquement l'activité électrique de muscles particuliers. Cette configuration permet une meilleure localisation des signaux musculaires et une analyse plus spécifique des muscles individuels [15].

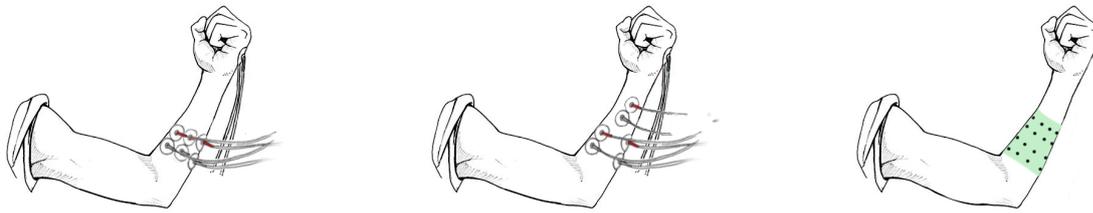


1.7.3 Configuration en grille

La configuration en grille se distingue par un plus grand nombre d'électrodes utilisées, souvent disposées dans une matrice régulière. Elle permet une couverture spatiale plus fine et une meilleure résolution des signaux musculaires. Les électrodes de référence sont intercalées entre les paires d'électrodes bipolaires, ce qui améliore la précision des mesures. Contrairement à la configuration autour du bras, où l'électrode de référence peut être séparée des électrodes bipolaires, la configuration en grille garantit que chaque paire d'électrodes a une référence commune [16].



Les illustrations ci-dessous mettent en évidence les différentes configurations abordées précédemment.



(a) Autour de l'avant bras

(b) Spécifique

(c) En grille

FIG. 1.5 : Illustrations des différentes configurations

Dans le cadre de notre étude, nous avons choisi la configuration spécifique pour le placement des électrodes.

1.8 Placement de l'électrode de référence

L'électrode de référence (parfois appelée électrode de masse) est nécessaire pour fournir une référence commune à l'entrée différentielle du préamplificateur dans l'électrode. À cette fin, l'électrode de référence doit être placée aussi loin que possible et sur un tissu électriquement neutre (par exemple sur une proéminence osseuse).

Cette disposition est souvent peu pratique car la séparation des fils de l'électrode de détection et de l'électrode de référence nécessite deux fils entre les deux électrodes et l'amplificateur. Dans le cas des électrodes séparées, cela est facile à mettre en place car chaque électrode a son propre fil.

L'électrode de référence doit avoir de fortes propriétés adhésives qui la fixent à la peau avec une grande stabilité mécanique.

Les gels conducteurs d'électricité sont particulièrement adaptés à cet usage. Souvent, les bruits parasites des lignes électriques peuvent être réduits et éliminés par un placement judicieux de l'électrode de terre.

Les illustrations suivantes présentent les différentes configurations possibles pour l'électrode de référence.

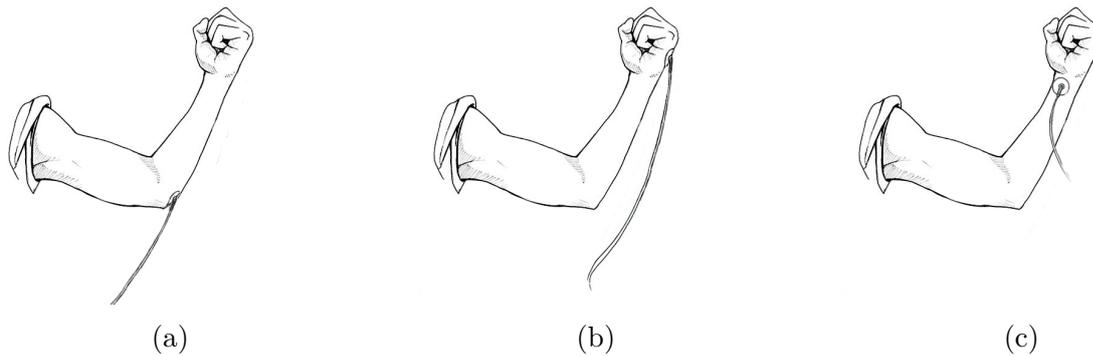


FIG. 1.6 : Illustrations de l'emplacement de l'électrode de référence

1.9 Application des signaux EMG

Les signaux EMG trouvent des applications dans plusieurs domaines, notamment la prévention des blessures sportives, la conception ergonomique, la rééducation musculaire et la motricité assistée.

Les athlètes utilisent l'EMG pour éviter les dommages musculaires lors des évaluations de performance. L'EMG peut être utilisé pour développer des mesures de fatigue musculaire dont la surveillance pré- et postopératoire et la réadaptation [17]. Ces dernières années, l'EMG est devenue à travers le temps un moyen de référence pour la réadaptation physique et l'aide à la mobilité. Par exemple, les exosquelettes motorisés contrôlés par des signaux EMG aident les personnes atteintes de paralysies ou de faiblesse musculaires à marcher ou à se tenir debout ou à réapprendre à contrôler un membre tel que la main. Les prothèses myoélectriques contrôlées par des signaux EMG sont également utilisées pour aider les personnes ayant subi une amputation à contrôler leur orthèse avec des mouvements musculaires résiduels [18]. Les signaux EMG trouvent également des applications dans l'interface Homme-machine pour contrôler diverses applications par le biais de la contraction musculaire. Par exemple, les interfaces cerveau-ordinateur peuvent être utilisées pour interagir avec les jeux vidéos ou d'autres applications informatiques par la contraction de muscles spécifiques. Des robots industriels peuvent également être contrôlés par des signaux EMG pour aider les travailleurs à effectuer des tâches répétitives ou dangereuses avec leurs mouvements musculaires.

1.10 Etat de l'art

Dans cette partie, nous effectuons une analyse et synthèse des recherches les plus récentes portant sur la reconnaissance en temps réel des gestes de la main en utilisant l'électromyographie de surface (sEMG) et l'apprentissage automatique. Les résultats de cette analyse sont synthétisés dans le tableau 1.2.

Wan-Ting Shi et al. [19] ont développé un système de reconnaissance de motifs sEMG

à deux canaux dans le but d'identifier les mouvements de la main humaine et de contrôler une main bionique qui peut reproduire les mêmes mouvements. Les résultats hors ligne de l'étude ont montré que l'approche *k-Nearest Neighbors* (k-NN) a été adoptée pour identifier quatre gestes distincts de la main avec une précision de classification de plus de 80% en utilisant soit *Mean Absolute Value* (MAV) ou *Waveform Length* (WL) pour une seule caractéristique temporelle. Les résultats en ligne ont montré que la précision de classification a atteint 94%. En outre, leur main bionique a pu imiter avec précision quatre mouvements spécifiques de la main humaine via un contrôle EMG.

Motoche et al. [14], un modèle de reconnaissance de gestes de la main basé sur les signaux EMG de surface a été présenté. Dans ce modèle, ils ont utilisé le *Artificial Neural Network* (ANN) pour la classification qui a été personnalisée pour chaque utilisateur et a nécessité 5 répétitions pour chaque classe à reconnaître. Il répond en 29,38 ms, ce qui est en dessous de la limite de temps réel définie (300 ms). En outre, le modèle a montré une précision de reconnaissance de 90,7% en utilisant différents types de caractéristiques temporelles, fréquentielles et temps-fréquences.

Raurale et al. [20] ont présenté une nouvelle approche dans le domaine temporel, qui permet de déterminer les mouvements du poignet et de la main à partir des signaux EMG enregistrés à la surface de la peau. Ils ont utilisé un ensemble très simple de caractéristiques temporelles (*Integrated EMG* "iEMG", *Variance* "VAR" et *Root Sum Square* "RSS") pour représenter l'activité sur chacun des huit canaux de données EMG, ainsi qu'une classification basée sur la fonction *Radial Basis Function* (RBF), 9 mouvements de la main peuvent être classifiés avec une précision supérieure à 99%.

Pancholi et al. [21] ont développé un système de reconnaissance en temps réel des gestes pour les personnes amputées. Ce système peut être utilisé pour le contrôle myo-électrique des prothèses dans un environnement en temps réel, 6 mouvements de la main ont été classifiés avec une précision supérieure à 94%. Ils ont utilisé un processeur *Digital Signal Processors* (DSP) qui intègre quatre caractéristiques du domaine temporel ainsi qu'un classificateur *Linear discriminant analysis* (LDA).

Das et al. [22] ont présenté une méthode efficace de reconnaissance et de classification des gestes de la main. Deux mouvements différents de la main, à savoir l'ouverture de la main et la fermeture de la main, ont été classifiés à l'aide des classificateurs *Support Vector Machine* (SVM) et k-NN, avec une précision d'environ 96,58% en utilisant cinq caractéristiques du domaine temporel.

Il existe encore plusieurs autres recherches qui ont été effectuées dans le domaine de la reconnaissance en temps réel des gestes de la main, nous en avons cité quelques un dans le tableau 1.2 ci-dessous :

| Auteurs | Capteur utilisé | Nombre de mouvement | Précision (%) | Année |
|--------------------------|----------------------------|---------------------|---------------|-------|
| Wan-Ting Shi et al. [19] | MA300 | 4 | 94.00 | 2018 |
| Motoche et al. [14] | Myo armband | 5 | 90.70 | 2018 |
| Yang et al. [23] | Homemade | 9 | 92.20 | 2019 |
| Malesevic et al. [24] | Homemade | 13 | 82.39 | 2018 |
| Das et al. [22] | Homemade | 2 | 96.58 | 2018 |
| Raurale et al. [20] | Myo armband | 9 | 99.03 | 2019 |
| Pancholi et al. [21] | Analog Front End (ADS1298) | 6 | 94.14 | 2019 |
| Liang et al. [25] | Homemade | 9 | 95.00 | 2019 |

TAB. 1.2 : Les performances atteintes dans l'état de l'art

1.11 Conclusion

En conclusion, nous avons examiné plusieurs aspects clés liés aux signaux EMG. Tout d'abord, nous avons étudié les caractéristiques des signaux EMG, qui fournissent des informations sur l'activité musculaire. Ensuite, nous avons exploré les types d'électrodes couramment utilisées dans la littérature, en mettant en évidence leurs caractéristiques et leurs avantages respectifs. De plus, nous avons analysé l'anatomie de l'avant-bras, ce qui nous a permis de comprendre l'emplacement optimal des électrodes pour une acquisition précise des signaux EMG. Ensuite, nous avons abordé l'application des signaux EMG dans divers domaines, tels que la rééducation musculaire et la motricité assistée. Enfin, nous avons effectué un état de l'art pour identifier les avancées récentes dans le domaine de l'analyse des signaux EMG. Ces connaissances approfondies fourniront les bases nécessaires permettant d'aborder les prochaines étapes du développement d'un système de reconnaissance des mouvements utilisant les signaux EMG.

Dans le prochain chapitre, nous nous concentrerons sur les étapes de traitement d'un système de reconnaissance des mouvements basé sur les signaux EMG. Nous examinerons en détail les différentes étapes impliquées dans le traitement des signaux EMG, à savoir : le prétraitement des données, l'extraction des caractéristiques pertinentes et la classification des mouvements.

Chapitre 2

Systeme de détection de
mouvements de la main à partir des
signaux EMG

2.1 Introduction

Dans ce chapitre, nous aborderons les différentes étapes de traitement d'un système de reconnaissance des mouvements en utilisant les signaux EMG. Tout d'abord, nous examinerons l'étape d'acquisition des données. Cette étape consiste à enregistrer les signaux EMG à l'aide d'électrodes placées sur la peau. Ensuite, nous nous concentrerons sur les méthodes de prétraitement des signaux EMG. Ces méthodes sont essentielles pour éliminer les interférences indésirables afin d'améliorer la qualité des signaux enregistrés. Dans la littérature, on ajoute une étape de post-traitement afin d'augmenter la précision de classification [14].

Une fois que les signaux EMG ont été prétraités, nous examinerons les différentes étapes de fenêtrages et d'extractions des caractéristiques temporelles et fréquentielles. Cette étape consiste à extraire des informations pertinentes à partir des signaux EMG qui peuvent être utilisés pour représenter les motifs d'activité musculaire.

Ensuite, nous discuterons de la réduction de la dimensionnalité, une étape optionnelle dans le traitement des signaux EMG. Cette étape vise à réduire le nombre de caractéristiques tout en préservant les informations les plus pertinentes et en éliminant les redondances. L'objectif est d'obtenir un ensemble de caractéristiques plus compact et significatif, permettant une représentation efficace des signaux EMG. Nous aborderons différentes techniques de réduction de la dimensionnalité, telles que l'analyse en composantes principales (ACP).

Enfin, nous discuterons des différents types de modèles de classification utilisés, tels que les machines à vecteurs de support (SVM), mais il est à noter que bien que ces étapes et méthodes soient influentes sur les résultats et les performances de notre système, la qualité de données récoltées reste primordiale afin de classifier les différents mouvements de la main. Nous expliquerons également la différence entre les modèles individuels, qui sont adaptés à chaque utilisateur, et les modèles généraux, qui sont entraînés sur un ensemble de données représentatif de la population.

Dans l'ensemble, ce chapitre vise à présenter les différentes étapes de traitement d'un système de reconnaissance des signaux EMG. La figure 2.1 montre les différentes étapes de notre système de reconnaissance des signaux EMG et les différentes méthodes utilisées à chaque étape qui sont décrites par la suite.

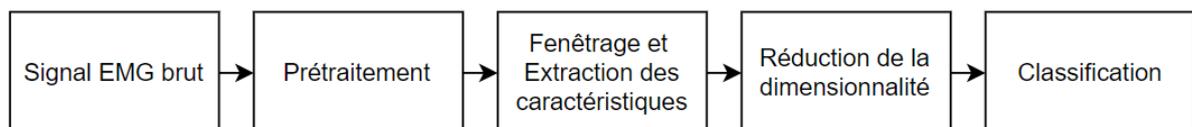


FIG. 2.1 : Schéma synoptique d'un système de classification des signaux EMG

2.2 Acquisition des données

Au stade de l'acquisition des données, les signaux EMG sont collectés à partir de capteurs EMG, qui peuvent être des dispositifs commerciaux (dédiés à cette application) ou bien artisanaux (*homemade*). Les signaux EMG sont obtenus en suivant un protocole expérimental où l'utilisateur est amené à effectuer différents mouvements de la main en produisant une série de contractions (5-8s) délimitée par des périodes de repos (3-5s). Afin d'enregistrer ces signaux musculaires plusieurs capteurs bipolaires sont placés à la surface de la peau. Les paires d'électrodes doivent être positionnées parallèlement à la fibre musculaire comme présenté au paragraphe 1.7.

La fréquence d'échantillonnage du signal EMG collecté est une caractéristique importante de l'acquisition des données.

Selon la théorie de l'échantillonnage de Shannon Nyquist, afin de préserver fidèlement un signal, le taux d'échantillonnage doit être au moins deux fois supérieur à sa fréquence maximale. Mathématiquement cela peut être exprimé par la formule suivante :

$$F_m = \frac{f_e}{2} \quad (2.1)$$

Où f_e est la fréquence d'échantillonnage et F_m fréquence maximale du signal.

Dans le cas des signaux EMG de surface, environ 95% de leur puissance principale est représentée par des harmoniques jusqu'à 400 – 500 kHz, tandis que le reste est principalement attribuable au bruit provenant des électrodes et de l'équipement. Dans de nombreux travaux de recherches, on observe fréquemment l'utilisation d'une fréquence d'échantillonnage de 1 kHz pour l'acquisition des signaux EMG [22][26][16]. Li et al. [27] ont relevé l'influence de la fréquence d'échantillonnage sur la précision de classification des signaux EMG, comparé à une fréquence d'échantillonnage de 1 kHz, une fréquence de 500 kHz n'a entraîné qu'une diminution de 0,8% de la précision de la classification chez les sujets valides (non amputés).

L'utilisation d'une fréquence d'échantillonnage de moins de 1 kHz réduit le nombre de données collectées, ce qui peut entraîner une réduction de la complexité du calcul. Cependant, il est important de prendre en compte l'influence de l'équipement utilisé et de la qualité des électrodes EMG sur la précision de la classification. Dans le cas où les électrodes EMG ne fournissent pas des mesures précises et exactes, fixer la fréquence d'échantillonnage à 1 kHz ou plus afin d'obtenir plus de données pourrait être une contrepartie intéressante pour améliorer la précision de la classification.

2.3 Prétraitement

L'étape de prétraitement est une étape importante dans tout système de reconnaissances de signaux, cette étape conditionne le signal d'entrée (signal brut) afin d'améliorer

la robustesse des données par rapport aux interférences potentielles en augmentant le rapport signal/bruit (SNR) afin d'améliorer les caractéristiques distinctives du signal EMG et de résoudre l'une des problématiques qui diminue la fidélité du signal EMG. Parmi les exemples d'interférences, on peut citer le déplacement des électrodes, qui entraîne une modification des fibres musculaires étudiées, les interférences des lignes électriques qui introduisent la fréquence fondamentale et les harmoniques du réseau électrique dans le signal enregistré, les artefacts de mouvement, les changements d'impédance de l'interface électrode-peau ou les mouvements du câble qui introduisent un bruit de basse fréquence. Plusieurs méthodes peuvent être utilisées lors de cette étape, on peut citer :

2.3.1 Amplification du signal EMG

Les signaux EMG sont généralement de faible amplitude, ce qui rend difficile leurs analyses et leurs interprétations précises. Ainsi, l'utilisation d'une amplification adéquate permet d'augmenter l'amplitude des signaux EMG, les rendant plus facilement détectables et mesurables [28].

2.3.2 Filtrage du signal EMG

L'étape de filtrage des signaux est une étape cruciale dans l'analyse et la récolte des signaux EMG, elle vise à éliminer les interférences indésirables et à mettre en évidence les caractéristiques spécifiques des signaux musculaires. Les filtres utilisés peuvent être classés en deux catégories principales : les filtres analogiques et les filtres numériques.

Filtres analogiques

Ils sont souvent utilisés pour éliminer les hautes fréquences indésirables et réduire les bruits électriques. Ils peuvent être implémentés à l'aide de circuits électroniques spécialisés, intégrés dans les amplificateurs EMG ou dans des dispositifs externes.

Filtres numériques

Ce type de filtres est couramment utilisé en raison de sa flexibilité et de sa capacité à être ajusté en fonction des besoins spécifiques. Les filtres numériques permettent d'effectuer une grande variété d'opérations de filtrage, notamment le filtrage passe-bas, passe-haut et passe-bande, permettant de sélectionner les fréquences pertinentes du signal EMG.

Dans le cas du signal EMG, deux types de filtres sont utilisés. Nous trouvons une utilisation récurrente du filtre Notch à 50 Hz [29][30]. Un filtre Notch (coupe-bande) est spécifiquement conçu pour supprimer une bande de fréquence étroite autour d'une fréquence centrale spécifiée. Dans le cas du traitement des signaux EMG, la fréquence centrale du filtre coupe-bande est réglée sur la fréquence de la ligne électrique 50 Hz

(Dans certains pays elle est de 60Hz). Le filtre coupe-bande atténue ou supprime les interférences de la ligne électrique tout en préservant les composantes du signal EMG dans la plage de fréquence souhaitée.

Le deuxième type de filtre employé est un filtre passe-bande qui vise à éliminer les bruits générés par les couches de la peau se situant à des fréquences supérieures à 500 Hz et inférieures à 10 Hz. Certains auteurs avancent également l'existence de bruits à des fréquences supérieures à 10 Hz, ce qui les amène à utiliser des filtres capables de supprimer jusqu'à 20 Hz [31].

Pour notre projet, nous avons choisi de nous conformer à la majorité des études dans la littérature en optant pour un filtre passe-bande de 20 Hz à 450 Hz.

2.3.3 Rectification du signal EMG

Cette étape vise à convertir les signaux électromyographiques alternatifs en signaux unidirectionnels (positifs) pour faciliter leur analyse et leur interprétation. Les signaux EMG enregistrés initialement sont de nature biphasique, alternant entre des valeurs positives et négatives en fonction de l'activité musculaire.

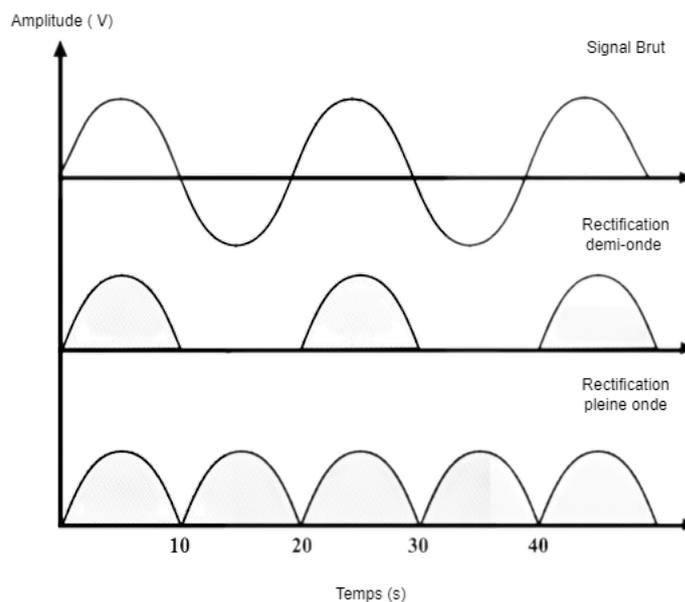


FIG. 2.2 : Rectification du signal EMG

Rectification demi-onde (unidirectionnelle)

Dans ce cas, seules les parties positives du signal EMG sont conservées, tandis que les parties négatives sont supprimées. Cela peut être réalisé en utilisant un redresseur à diode simple qui permet le passage du courant uniquement lorsque le signal est positif .

Rectification pleine onde (bidirectionnelle)

Dans ce cas, toutes les parties du signal EMG, qu'elles soient positives ou négatives, sont converties en valeurs positives. Cela peut être réalisé en utilisant un redresseur en pont, également appelé pont de diodes, qui permet le passage du courant dans les deux directions.

Les capteurs utilisés dans ce travail intègrent des composants qui effectuent les étapes essentielles de filtrage, de rectification et d'amplification du signal. Ces processus sont nécessaires pour conditionner le signal brut capté, en réduisant le bruit, en sélectionnant les fréquences pertinentes et en amplifiant les signaux faibles. Des filtres numériques sont aussi utilisés afin d'améliorer la qualité du signal récolté. Les détails techniques spécifiques aux capteurs utilisés et les composants intégrés sont décrits au chapitre 3.

2.3.4 Normalisation du signal EMG

La normalisation des signaux EMG est importante car les caractéristiques des signaux peuvent varier considérablement en fonction de facteurs tels que l'emplacement des électrodes, l'anatomie individuelle et la force musculaire. Pour permettre la comparaison entre différents sujets ou sessions d'acquisition, il est essentiel de normaliser les signaux EMG [32].

Il n'y a pas de méthode de normalisation qui soit universellement reconnue comme étant la meilleure, différentes approches ont été employées dans la littérature pour normaliser les signaux EMG, notamment la normalisation par la valeur maximale du signal, où les amplitudes sont divisées par la valeur maximale enregistrée, et la normalisation par la valeur moyenne du signal, où les valeurs sont divisées par la moyenne afin d'obtenir des valeurs normalisées.

Pour notre projet nous avons opté sur la normalisation par standardisation qui consiste à centrer les données en soustrayant la moyenne de l'ensemble des données, puis en les divisant par l'écart-type. Cela permet de transformer les données en une distribution avec une moyenne de zéro et un écart-type de un. La formule mathématique pour la normalisation par standardisation est la suivante :

$$x_{norm} = \frac{x_i - moyenne(x)}{\sigma(x)} \quad (2.2)$$

Où :

x_i : La valeur du $i^{\text{ème}}$ échantillon

$moyenne(x)$: La moyenne de l'ensemble des échantillons

$\sigma(x)$: L'écart-type de l'ensemble des échantillons

La normalisation par standardisation présente plusieurs avantages. Elle permet de centrer les données autour de zéro, ce qui peut faciliter l'apprentissage des modèles d'apprentissage automatique en réduisant les biais introduits par les valeurs élevées ou basses.

Elle rend également les caractéristiques comparables et permet de mieux interpréter les coefficients des modèles.

2.4 Fenêtrage et extraction des caractéristiques

2.4.1 Fenêtrage

Il existe deux types de fenêtrage couramment utilisés dans le traitement de l'EMG, l'utilité de cette méthode est de générer plus de données à partir des données initiales afin d'augmenter la taille de la base de données et ainsi augmenter la précision de classification.

- **Le schéma de fenêtrage disjoint :**

Les fenêtres de traitement sont séparées les unes des autres sans chevauchement entre les fenêtres voisines comme montré dans la figure 2.3. Chaque fenêtre est analysée indépendamment, ce qui facilite le traitement des données [33].

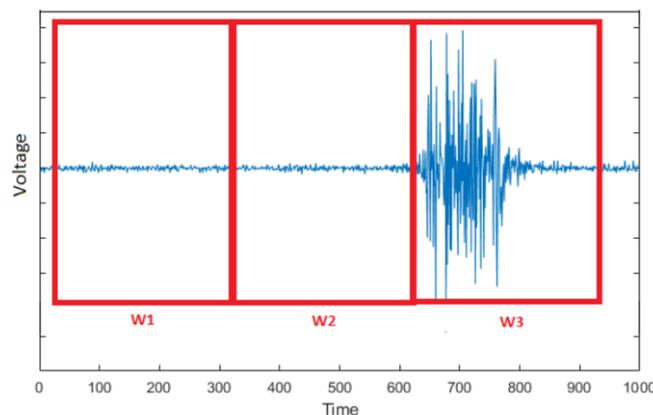


FIG. 2.3 : Fenêtrage disjoint [5]

Nous calculons le nombre de nouveaux signaux générés à partir d'un signal $s(t)$ par la formule suivante :

$$N_{FD} = \frac{\text{Longueur du signal}}{\text{Taille de la fenetre}} \quad (2.3)$$

Où N_{FD} correspond au nombre des nouveaux signaux générés (données).

Cependant, cette méthode peut conduire à la perte d'informations précieuses dans les zones de transition entre les fenêtres, ce qui peut affecter les performances de classification.

- **Le schéma de fenêtrage superposé :**

Les fenêtres de traitement se chevauchent partiellement les unes sur les autres comme illustré dans la figure 2.4 . Les caractéristiques sont calculées pour chaque

fenêtre chevauchante, ce qui permet d'obtenir une analyse plus fine des signaux EMG. Cette méthode peut être plus efficace pour la classification car elle permet de capturer des informations importantes qui peuvent être perdues dans le schéma de fenêtrage disjoint [23].

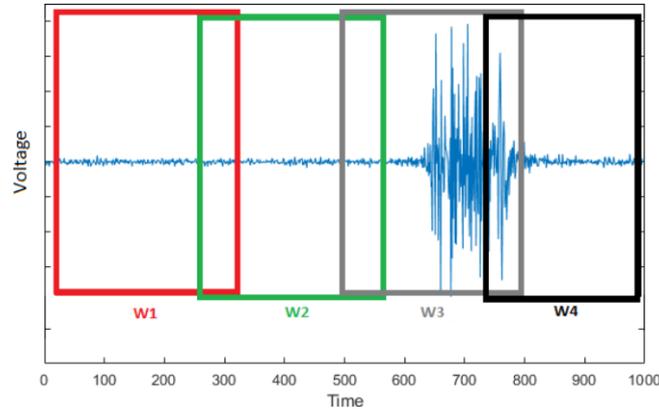


FIG. 2.4 : Fenêtrage superposé [5]

La formule qui permet de calculer le nombre des nouveaux signaux générés par cette méthode est la suivante :

$$N_{FS} = \frac{\text{Longueur du signal} - \text{Taille de la fenetre}}{\text{Incrément}} + 1 \quad (2.4)$$

Cependant, cette méthode nécessite davantage de ressources informatiques pour le traitement des données, ce qui peut entraîner des coûts de calcul plus élevés, en particulier dans la phase de test de certains classificateurs.

Le tableau 2.1 présente un résumé des fréquences d'échantillonnage ainsi que des méthodes de prétraitement et de fenêtrage employées dans la littérature.

| Auteurs | Capteur utilisé | Fréquence (Hz) | Prétraitement | Fenêtrage |
|--------------------------|----------------------------|----------------|---------------|-----------|
| Wan-Ting Shi et al. [19] | MA300 | 1000 | NI | FD |
| Motoche et al. [14] | Myo armband | 200 | FL et RE | FS |
| Yang et al. [23] | Homemade | 1000 | NI | FS |
| Malesevic et al. [24] | Homemade | 1600 | NI | FS |
| Das et al. [22] | Homemade | 1000 | FL | FS |
| Raurale et al. [20] | Myo armband | 200 | NI | FS |
| Pancholi et al. [21] | Analog Front End (ADS1298) | 1000 | FL | FS |
| Liang et al. [25] | Homemade | 2000 | FL et RE | FD et GD |

FD : Fenêtrage Disjoint ; **FS** : Fenêtrage Superposé ; **FL** : Filtrage ; **RE** : Rectification ; **NI** : Non Indiqué

TAB. 2.1 : Résumé des fréquences d'échantillonnage et des méthodes de prétraitement et de fenêtrage utilisées dans la littérature

2.4.2 Extraction des caractéristiques

L'extraction de caractéristiques est une étape importante dans le prétraitement dans l'analyse des signaux d'électromyographie (EMG). Deux approches courantes pour l'extraction de caractéristiques : l'analyse dans le domaine temporel et l'analyse dans le domaine fréquentiel. L'analyse dans le domaine temporel implique l'examen des caractéristiques des variations d'amplitudes du signal au fil du temps, tandis que l'analyse dans le domaine fréquentiel implique l'examen du contenu fréquentiel du signal. Ces caractéristiques peuvent ensuite être utilisées pour classifier et interpréter les signaux EMG, fournissant des informations sur l'activité musculaire.

- **Caractéristiques temporelles :**

- **Integrated EMG (IEMG) :**

- C'est un paramètre qui permet de mesurer l'activité musculaire en intégrant la valeur absolue du signal sEMG. Il est couramment utilisé dans des domaines tels que la reconnaissance de modèles et la médecine clinique [34].

$$\text{IEMG} = \sum_{i=1}^N |x_i| \quad (2.5)$$

Où x_i représente le $i^{\text{ème}}$ échantillon du signal EMG et N représente le nombre d'échantillons du signal EMG.

- **Mean Absolute Value (MAV) :**

- C'est la valeur moyenne de l'amplitude absolue du signal traité par la méthode de la fenêtre temporelle. Tout comme la caractéristique IEMG, elle est souvent utilisée comme indicateur de la maladie, en particulier dans la détection du signal EMG de surface pour le contrôle des membres prothétiques [34].

$$\text{MAV} = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (2.6)$$

- **Simple Square Integral (SSI) :**

- Elle représente l'énergie du signal EMG. C'est la somme des carrés des amplitudes des signaux EMG. En général, cette caractéristique est définie comme l'indice d'énergie du signal EMG [34].

$$\text{SSI} = \sum_{i=1}^N x_i^2 \quad (2.7)$$

- **Root mean square (RMS) :**

- C'est la racine carrée de la moyenne des valeurs au carré, et est une caractéristique EMG largement utilisée, qui est liée à la force de contraction des muscles et à l'état de fatigue musculaire [34].

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (2.8)$$

The Waveform Length (WL) :

Ou *waveform feature*, elle décrit la complexité des signaux EMG. Cette caractéristique est la longueur cumulative de la forme d'onde entière [34].

$$WL = \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (2.9)$$

Average Amplitude Change (ACC) :

Elle est pratiquement équivalent à la caractéristique de longueur d'onde WL, à l'exception du fait que la longueur d'onde est moyennée [35]

$$AAC = \frac{1}{N} \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (2.10)$$

Difference Absolute Standard Deviation Value (DASDV) :

Elle ressemble à une combinaison de caractéristiques WL et RMS, qui peut être considérée comme l'écart-type de la longueur d'onde [34].

$$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} - x_i)^2} \quad (2.11)$$

Zero Crossing (ZC) :

Elle est définie comme le nombre de fois où le signal passe par zéro, ce qui peut refléter le degré de fluctuation des données ponctuelles et est une caractéristique importante de la reconnaissance de signal. En fixant un seuil, les fluctuations de tension faibles peuvent être évitées et le bruit sera éliminé [34].

$$ZC = \sum_{i=1}^N [\text{sgn}(x_i \times x_{i+1}) \cap |x_i - x_{i+1}| \geq \text{threshold}] \quad (2.12)$$

$$\text{sgn}(x) = \begin{cases} 1, & \text{if } x < 0 \\ 0, & \text{otherwise} \end{cases}$$

Myopulse Percentage Rate (MYOP) :

C'est la moyenne d'une série de sorties *myopulse*, et la sortie *myopulse* est égale à 1 si le signal myoélectrique est supérieur à un seuil prédéfini [34].

$$MYOP = \frac{1}{N} \sum_{i=1}^N [f(x_i)] \quad (2.13)$$

$$f(x) = \begin{cases} 1, & \text{if } x \geq \text{threshold} \\ 0, & \text{otherwise} \end{cases}$$

Wilson Amplitude (WAMP) :

Comme le ZC, cette caractéristique peut être utilisée pour obtenir des informations de fréquence du signal myoélectrique dans le domaine temporel. Il est déterminé par la différence entre les amplitudes de signaux EMG adjacents et un seuil prédéterminé [34].

$$\text{WAMP} = \sum_{i=1}^{N-1} [f |x_n - x_{n+1}|] \quad (2.14)$$

$$f(x) = \begin{cases} 1, & \text{if } x \geq \text{threshold} \\ 0, & \text{otherwise} \end{cases}$$

Slope sign change (SSC) :

Elle est similaire aux caractéristiques ZC, MYOP et WAMP, et peut également être utilisée pour obtenir des informations de domaine de fréquence à partir du domaine temporel du signal. Le seuil est de préférence de 50 à 100 mV. La valeur du seuil doit être déterminée en fonction de l'équipement actuel et du bruit [34].

$$\text{SSC} = \sum_{i=2}^{N-1} [f [(x_i - x_{i-1}) \times (x_i - x_{i+1})]] \quad (2.15)$$

$$f(x) = \begin{cases} 1, & x \geq \text{threshold} \\ 0, & \text{otherwise} \end{cases}$$

Hjorth Parameters (HJP) :

Les paramètres de Hjorth sont obtenus en appliquant des techniques de traitement du signal dans le domaine temporel, ce qui permet d'obtenir des informations sur les propriétés statistiques du signal. Les trois paramètres de Hjorth sont : **l'activité, la mobilité et la complexité.** [36]

- L'activité :

L'activité donne une mesure de l'écart-type au carré de l'amplitude du signal $x(t)$, indiquant la surface du spectre de puissance dans le domaine fréquentiel. Autrement dit, la valeur de l'activité est élevée si les composantes de fréquence plus élevées sont plus courantes, et faible sinon. L'activité correspond à la variance du signal [36].

$$\text{Activity} = \text{var}(x(t)) \quad (2.16)$$

- La mobilité :

La mobilité représente la fréquence moyenne ou la proportion de l'écart-type du spectre de puissance. Elle est définie comme la racine carrée de l'activité de la première dérivée du signal divisée par l'activité du signal [36].

$$\text{Mobility} = \sqrt{\frac{\text{Activity}(x'(t))}{\text{Activity}(x(t))}} \quad (2.17)$$

- La complexité :

La complexité indique dans quelle mesure la forme d'un signal est similaire à celle d'une onde sinusoïdale pure, et donne une estimation de la largeur de bande du signal. Elle est définie comme le rapport entre la mobilité de la première dérivée et la mobilité du signal [36].

$$\text{Complexity} = \frac{\text{Mobility}(x'(t))}{\text{Mobility}(x(t))} \quad (2.18)$$

• Caractéristiques fréquentielles :

Mean frequency (MNF) :

La fréquence moyenne d'un spectre est calculée comme la somme du produit de l'intensité du spectrogramme (en dB) et de la fréquence, divisée par la somme totale de l'intensité du spectrogramme [34].

$$\text{MNF} = \frac{\sum_{j=1}^M f_j P_j}{\sum_{j=1}^M P_j} \quad (2.19)$$

Où f_j représente la fréquence du spectre de la $j^{\text{ème}}$ composante fréquentielle, P_j représente sa puissance spectrale et M représente la plage de fréquences considérée.

Peak frequency (PKF) :

C'est la fréquence maximale dans une plage de fréquences considérées du signal EMG. [34].

$$\text{PKF} = \max(P_j), \quad j = 1, \dots, M \quad (2.20)$$

The Total power (TTP) :

C'est la somme des puissances de toutes les composantes fréquentielles considérées. [34].

$$\text{TTP} = \sum_{j=1}^M P_j \quad (2.21)$$

Median frequency (MDF) :

C'est une fréquence à laquelle le spectre est divisé en deux régions d'amplitude égale ; en d'autres termes, le MDF est la moitié de la caractéristique TTP. [35].

$$\sum_{j=1}^{\text{MDF}} P_j = \sum_{j=\text{MDF}}^M P_j = \frac{1}{2} \sum_{j=1}^M P_j \quad (2.22)$$

Mean power (MNP) :

C'est la puissance moyenne du spectre d'énergie de l'EMG de surface [34].

$$\text{MNP} = \frac{\sum_{j=1}^M P_j}{M} \quad (2.23)$$

Toutes ces caractéristiques temporelles et fréquentielles seront exploitées dans nos études pour extraire le maximum d'informations de notre signal EMG.

2.5 Réduction de la dimensionnalité

Pour créer un ensemble de caractéristiques approprié pour la classification des mouvements de la main, certaines considérations clés doivent être prises en compte [12].

- (i) Il est important d'inclure des caractéristiques qui possèdent des informations discriminatoires de haut niveau.
- (ii) Les caractéristiques fortement corrélées entre elles doivent être exclues.
- (iii) Le nombre de caractéristiques doit être réduit au minimum afin de lutter contre l'influence de la "malédiction de la dimension"¹.

Ces aspects peuvent être traités en utilisant des techniques de réduction de la dimensionnalité, qui améliorent la robustesse de l'algorithme de classification en supprimant les caractéristiques fortement corrélées. On ne retrouve pas souvent cette étape dans un schéma classique d'un SRM (système de reconnaissances des mouvements), bien qu'elle ne soit pas nécessaire, la réduction de la dimensionnalité peut améliorer de manière significative la précision de la classification et réduire les coûts de calcul [37].

Deux méthodes peuvent être utilisées lors de cette étape :

La sélection des caractéristiques et la projection des caractéristiques, Il existe certains travaux qui combinent ces deux méthodes en les cascasant, le résultat de la sélection des caractéristiques est utilisé comme entrée d'un algorithme de projection [29].

2.5.1 Sélection des caractéristiques

Elle aide à éliminer les caractéristiques redondantes ou moins discriminantes, plusieurs méthodes peuvent être utilisées et chaque méthode a un objectif différent, on peut citer des méthodes comme sequential forward selection (SFS) et Maximum-Relevance Minimum-Redundancy (MRMR) [38], Mutual Information-Based Feature Reduction (MCA) [29].

2.5.2 Projection des caractéristiques

La projection des caractéristique transforme et réduit la dimensionnalité de l'espace des caractéristiques d'origine. Des exemples de projection de caractéristiques comprennent l'analyse en composantes principales (PCA) non supervisée et l'analyse discriminante

¹Se réfère aux problèmes rencontrés lorsque le nombre de caractéristiques des données d'entraînement devient élevé par rapport à la taille de l'ensemble de données. Cela peut entraîner une baisse des performances du modèle et une augmentation de la complexité computationnelle

linéaire non corrélée supervisée (ULDA). On peut aussi citer des méthodes comme t-distributed stochastic neighbor embedding (t-SNE) et Isomap.

Analyse en Composante Principales

Dans notre projet, nous avons opté pour la réduction de dimension en utilisant l'analyse en composantes principales (ACP). L'analyse en composantes principales est une technique statistique largement utilisée pour transformer un ensemble de variables corrélées en un nouvel ensemble de variables non corrélées, appelées composantes principales. Cette approche nous permet de simplifier la complexité des données tout en conservant les informations essentielles.

L'objectif principal de l'ACP est de trouver une représentation linéaire des données qui capture le maximum de variance. Cela signifie que les premières composantes principales expliquent la majeure partie de la variabilité des données, tandis que les composantes suivantes capturent une part de variance décroissante comme montré dans la figure 2.5.

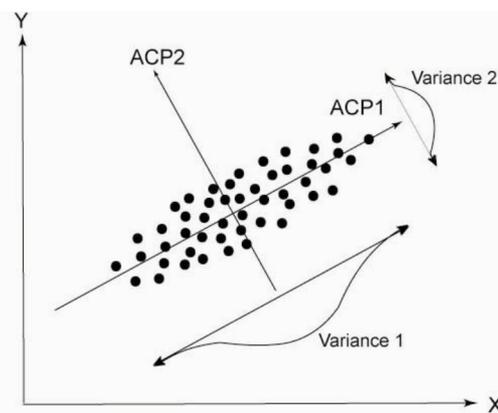


FIG. 2.5 : Représentation du principe de l'ACP [39]

La réduction de dimension offerte par l'ACP présente plusieurs avantages. Tout d'abord, elle permet de traiter des ensembles de données de grande dimension en éliminant les redondances et en conservant uniquement les informations les plus significatives. Cela peut faciliter l'interprétation des données et réduire les coûts de calcul. De plus, l'ACP peut être utilisée pour détecter des relations linéaires cachées entre les variables, ce qui peut être utile dans la détection de motifs ou de structures des ensembles de données.

En résumé, dans notre projet, nous avons choisi d'utiliser l'analyse en composantes principales pour réduire la dimension de nos données. Cette approche nous permet de simplifier la complexité des données, de détecter des relations linéaires cachées et de conserver les informations les plus pertinentes. En utilisant l'ACP, nous pouvons obtenir une représentation plus concise des données, facilitant ainsi l'analyse et l'interprétation des résultats.

2.6 Classification

La classification est une étape primordiale pour la reconnaissance des gestes en utilisant les signaux EMG, car elle permet de détecter et de différencier les différents mouvements musculaires. Les performances de cette étape sont fortement impactées par les étapes antérieures précédemment citées : la collecte des données, le prétraitement, la segmentation et l'extraction et la sélection finale des caractéristiques.

2.6.1 Méthode de classification

Dans l'état de l'art, une variété de techniques de classification a été utilisée, telle que les SVM, KNN, Random Forest, LDA et la régression logistique. Chacune de ces techniques peut être utilisée en fonction de la nature des données et du problème de classification. Dans cette introduction, nous allons discuter brièvement de chacune de ces techniques de classification :

- **Support Vector Machines (SVMs) :**

Les SVM sont des algorithmes d'apprentissage supervisé utilisés pour la classification et la régression. L'objectif des SVM est de trouver un hyperplan² qui sépare les données en deux classes de manière optimale en maximisant la marge entre les deux classes. Ce classifieur peut être utilisé pour traiter des données de grande dimension et sont efficaces pour traiter des problèmes de classification non linéaires. La figure ci-dessous 2.6 illustre le principe de fonctionnement du SVM (Support Vector Machine) en deux dimensions (2D) et trois dimensions (3D).

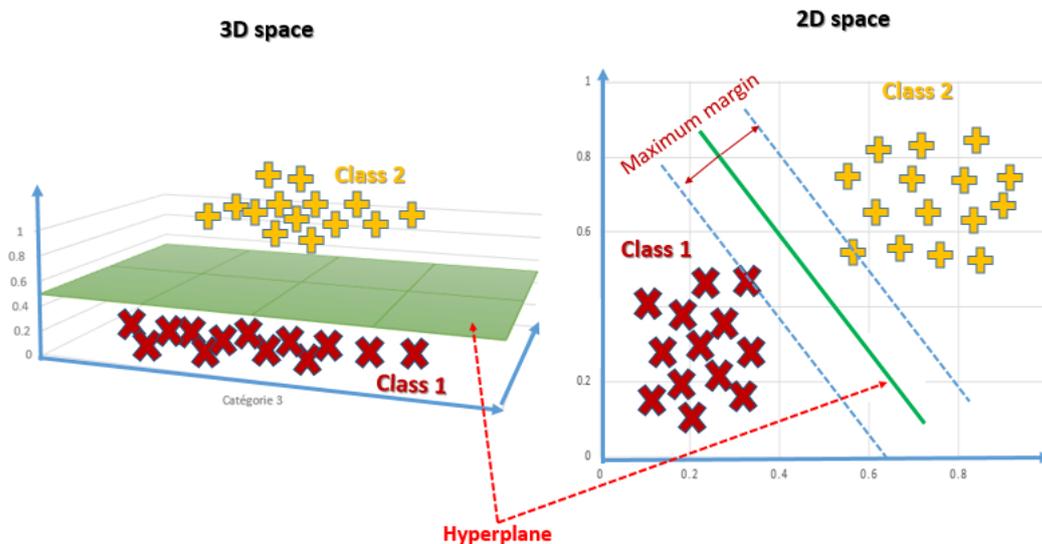


FIG. 2.6 : Principe du SVM

²Une frontière linéaire qui sépare l'espace des données en deux régions distinctes

- **k-Nearest Neighbors (k-NN) :**

C'est un algorithme de classification qui attribue une étiquette de classe à une instance en fonction de la classe majoritaire des k instances les plus proches dans l'espace de données. La proximité est généralement mesurée en utilisant une mesure de distance telle que la distance euclidienne. k-NN est facile à comprendre et à implémenter, mais peut être coûteux en temps de calcul pour les ensembles de données volumineux.

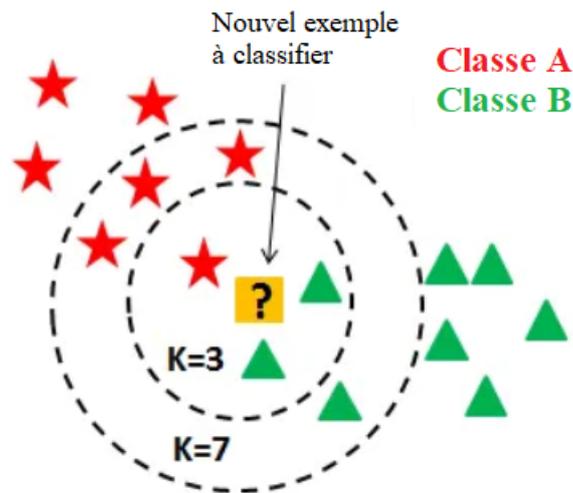


FIG. 2.7 : Principe du k-NN

Le choix du nombre de voisins est crucial pour la qualité de la classification, comme démontré dans cet exemple illustré dans la figure 2.7. Lorsqu'on considère un nombre de voisins égal à 3, un nouvel élément à classer (représenté en jaune) sera assigné à la classe A, tandis qu'avec un nombre de voisins égal à 7, la classe majoritaire sera la classe B.

- **Random Forest (RF) :**

C'est un algorithme d'apprentissage supervisé qui utilise plusieurs arbres de décision pour effectuer la classification. Chaque arbre est construit en utilisant un sous-ensemble aléatoire des données et un sous-ensemble aléatoire des fonctionnalités. La prédiction est obtenue en assemblant les prédictions de chaque arbre comme illustré dans la figure 2.8. Cet algorithme peut traiter des ensembles de données volumineux avec des milliers de fonctionnalités.

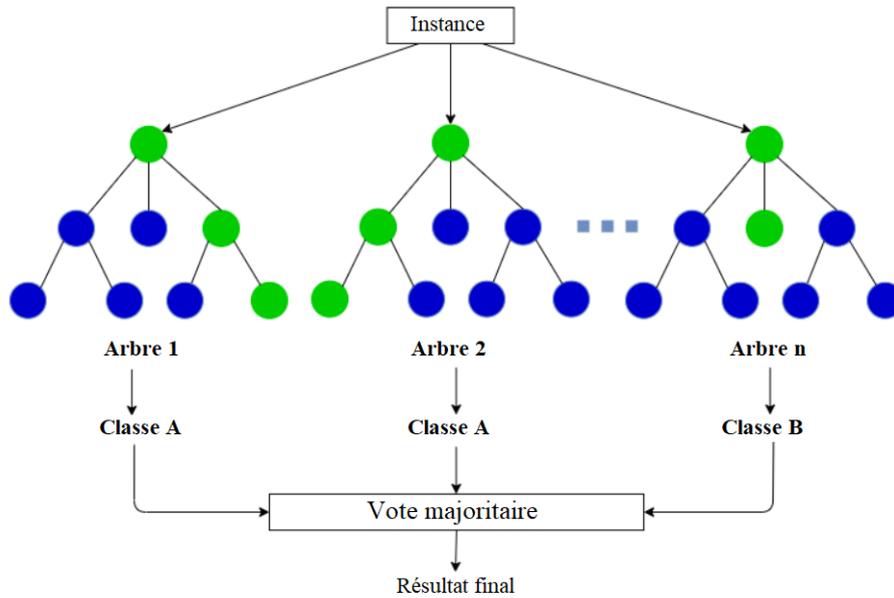


FIG. 2.8 : Principe du RF

- **Linear Discriminant Analysis (LDA) :**

LDA est un algorithme de classification linéaire qui cherche à projeter les données dans un espace de dimension inférieure tout en maximisant la séparation entre les classes. Il suppose que les classes sont linéairement séparables et utilise la variance interclasse et la variance intraclasse pour trouver la projection optimale. Ce modèle peut être utilisé pour traiter des ensembles de données de petite à moyenne taille. La figure ci-dessous 2.9 illustre le principe de fonctionnement de l'algorithme LDA

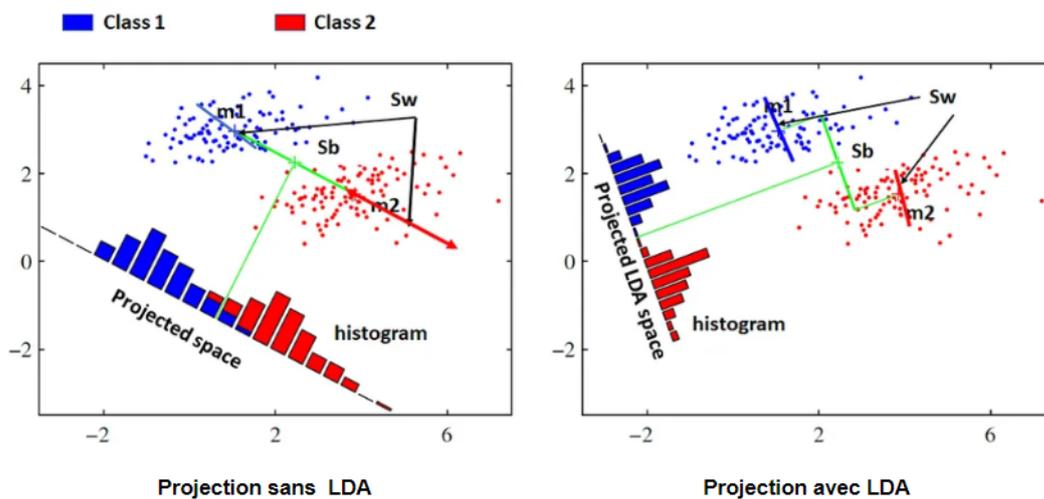


FIG. 2.9 : Principe du LDA

Avec S_w représente la covariance intra-classe et S_b représente covariance inter-classes.

- **Logistic Regression :**

La régression logistique est un algorithme de classification linéaire qui utilise une fonction logistique pour prédire la probabilité d'appartenance à une classe. La fonction logistique est une courbe en forme de S qui sature aux valeurs de 0 et 1 comme montré dans la figure 2.10. Si la valeur prédite dépasse un certain seuil (généralement il est pris comme valant 0.5), il y a une probabilité que l'événement se produise, tandis que si cette valeur est inférieure au seuil, il y a une probabilité qu'il ne se produise pas. Ce classifieur peut être utilisé pour traiter des problèmes de classification binaire et multiclassé.

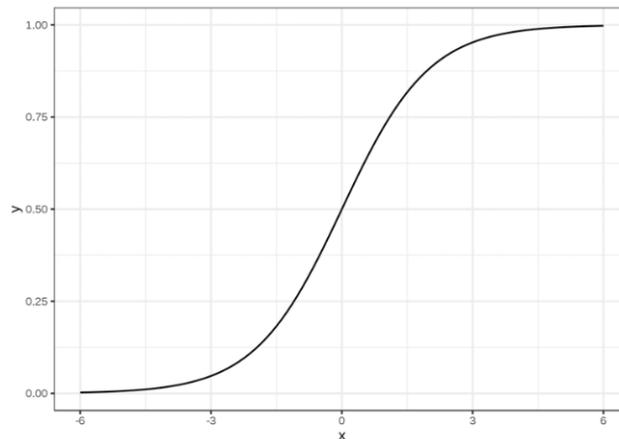


FIG. 2.10 : La fonction logistique

2.6.2 GridSearchCV

Pour sélectionner les paramètres optimaux de chaque classifieur, nous avons utilisé la validation croisée avec la recherche par grille. La recherche par grille est un processus permettant d'ajuster les hyperparamètres afin de trouver les valeurs optimales pour un modèle donné. La performance d'un modèle dépend considérablement des hyperparamètres. Il est important de noter qu'il n'existe aucun moyen de connaître à l'avance les meilleures valeurs pour ces hyperparamètres. Par conséquent, idéalement, nous devons essayer toutes les valeurs possibles pour déterminer celles qui sont optimales. Cependant, effectuer cette tâche manuellement peut être très chronophage et nécessiter de nombreuses ressources. C'est pourquoi nous utilisons GridSearchCV pour automatiser le processus d'ajustement des hyperparamètres.

En spécifiant les hyperparamètres à évaluer, tels que le nombre de voisins pour le k-NN :

$$k \in \{1, 3, 5, 7, 9, 11, 13, 15, 17, 19\} \quad (2.24)$$

ainsi que les méthodes de calculs de distances choisies, comme la distance euclidienne :

$$D_{\text{Euclidienne}}(a, b) = \sqrt{\sum_{i=1}^n |a_i - b_i|^2} \quad (2.25)$$

GridSearchCV explore toutes les combinaisons de valeurs fournies et évalue le modèle pour chaque combinaison en utilisant la validation croisée. Par conséquent, après avoir utilisé cette méthode, nous obtenons la précision associée à chaque combinaison d’hyperparamètres, ce qui nous permet de sélectionner celle qui offre la meilleure performance.

Dans notre projet, il est observé que cette fonction ne produit pas les mêmes hyperparamètres pour chaque individu. Cette situation est due à notre décision d’adopter un modèle individuel lors de la classification des signaux EMG. Les raisons de ce choix seront expliquées dans la section suivante 2.7.

Le tableau 2.2 résume les différentes caractéristiques ainsi que les classifieurs couramment mentionnés dans la littérature.

| Auteurs | Capteur utilisé | Caractéristiques | Classifieurs |
|--------------------------|----------------------------|---------------------------------|-----------------------------------|
| Wan-Ting Shi et al. [19] | MA300 | MAV ou WL | k-NN |
| Motoche et al. [14] | Myo armband | MAV, RMS, WL, SSC et HJP | ANN |
| Yang et al. [23] | Homemade | MAV, WL, ZC et SSC | NI |
| Malesevic et al. [24] | Homemade | MAV | LDA, QDA, k-NN, SVM, NB, RF et DT |
| Das et al. [22] | Homemade | MAV, VAR, et SKEW | SVM et k-NN |
| Raurale et al. [20] | Myo armband | iEMG, VAR et RSS | RBF |
| Pancholi et al. [21] | Analog Front End (ADS1298) | RMS, WL, ZC et SSC | LDA |
| Liang et al. [25] | Homemade | SKEW, TTP, MNF, MDF, MNP et PKF | k-NN et SVM |

NI : Non Indiqué

TAB. 2.2 : Résumé des caractéristiques et classifieurs utilisés dans la littérature

2.7 Modèles individuels Vs Modèles généraux

Dans le schéma général d’un système de reconnaissance des mouvements à partir des signaux EMG, nous avons identifié deux types de modèles : les modèles individuels et les modèles généraux. Les modèles individuels sont entraînés en se basant sur les gestes (données) d’une personne spécifique et reconnaissent les gestes de cette même personne. Les modèles généraux sont entraînés avec les données de plusieurs personnes et reconnaissent les gestes de n’importe quelle personne. Afin de dresser un tableau comparatif des avantages et inconvénients de chaque modèle, il est intéressant de se pencher sur les différentes caractéristiques qui influencent les signaux EMG, nous présenterons également les spécificités matérielles liées à une classification de signaux EMG.

D’abord, les signaux EMG peuvent être influencés par plusieurs facteurs externes (qui ont été mentionnés dans le chapitre 1, section ”signaux EMG”), ainsi que par des facteurs intrinsèques propres à l’utilisateur, tels que l’âge, le sexe, la corpulence ou encore la masse

musculaire.

- Une étude menée par Olga et al. [40] a examiné l'influence de l'âge et du sexe sur les signaux EMG. Cette étude avait pour objectif de déterminer si les contractions enregistrées dans les signaux EMG pendant une journée type de 8 heures différaient entre les hommes et les femmes jeunes et âgés. L'activité musculaire a été enregistrée chez 16 adultes jeunes et 15 adultes âgés, en utilisant des électromyogrammes portables. Les résultats ont montré que les muscles de ces derniers présentaient des contractions plus fréquentes (16-27% du temps) par rapport aux muscles des jeunes adultes (5-9% du temps), avec des amplitudes moyennes plus élevées tout au long de la journée. De plus, les muscles des femmes ont manifesté des contractions plus fréquentes et de plus longue durée que ceux des hommes.

Ensuite, lors du développement d'une application portable pour un système embarqué, plusieurs spécificités matérielles doivent être prises en compte. Ces spécificités concernent principalement les caractéristiques du dispositif sur lequel l'application sera exécutée.

- La gestion de la consommation de mémoire est un aspect crucial à prendre en compte lors du développement d'une application. Il est essentiel de considérer l'espace de stockage nécessaire pour enregistrer la base de données ainsi que les différents paramètres entraînés.
- Le temps de calcul joue un rôle crucial dans les applications embarquées nécessitant des résultats en temps réel. Selon Hudgins et al. [41], il est généralement préférable que le temps de calcul soit inférieur à 300 millisecondes. Il est donc important de prendre en considération cette contrainte lors du choix des filtres, des caractéristiques extraites et des classifieurs utilisés dans le système. Par exemple, dans le cas du choix d'un filtre, opter pour un filtre d'ordre inférieur peut être plus approprié pour une application en temps réel. Cela est dû au fait que les filtres d'ordre inférieur nécessitent moins de calculs, ce qui permet de réduire le temps de traitement des signaux EMG et de respecter ainsi la contrainte de temps réel.

Finalement, en consultant la littérature existante, il est possible de comparer la fréquence d'utilisation des modèles individuels et généraux.

Jaramillo-Yáñez et al. [5] ont examiné 65 articles de journaux, de revues et d'autres sources, mettant en évidence que 44 parmi eux étaient des modèles individuels et 21 étaient des modèles généraux. Cependant, parmi ces 21 modèles généraux, dix n'étaient pas des modèles en temps réel.

En s'aidant des différents points cités précédemment, nous avons pu établir le tableau 2.3 des avantages et inconvénients des modèles cités ci-dessous :

Chapitre 2. Système de détection de mouvements de la main à partir des signaux EMG

| Modèle | Avantages | Inconvénients |
|----------------------------|--|---|
| Modèles individuels | <ul style="list-style-type: none"> - Adaptation aux caractéristiques individuelles : age, sexe, corpulence et masse musculaire - Réduction des données à stocker - Temps de traitement court - Consommation énergétique réduite | <ul style="list-style-type: none"> - Nécessitent un entraînement spécifique pour chaque individu - Besoin de recalibration en cas de changements chez l'individu (perte/gain de poids, blessures, fatigue musculaire.) |
| Modèles généraux | <ul style="list-style-type: none"> - Ne nécessite pas de réentraînement pour chaque individu. - Scalabilité : Les modèles généraux peuvent être utilisés pour un grand nombre de personnes (avec la condition d'une plage d'âge restreinte) - Possibilité de généralisation : Les modèles généraux peuvent capturer les tendances et les caractéristiques communes à un groupe de personnes | <ul style="list-style-type: none"> - Risque de moins bonne performance pour certains individus - La base de données collectée doit inclure des personnes avec une plage d'âge réduite, et elle doit inclure les deux sexes - Temps de calcul plus lent - Nécessite un espace mémoire plus large |

TAB. 2.3 : Avantages et inconvénients des modèles individuels et généraux

2.8 Conclusion

Dans ce chapitre, nous avons abordé les différentes étapes clés du traitement d'un système de reconnaissance de mouvement à partir des signaux EMG qui est constitué de différentes étapes. D'abord, nous avons examiné l'acquisition des données EMG. Ensuite, nous avons exploré les méthodes de prétraitement pour améliorer la qualité des signaux enregistrés. De plus, nous avons étudié les étapes de fenêtrage et d'extraction des caractéristiques temporelles et fréquentielles pour obtenir des informations pertinentes sur les motifs d'activité musculaire. Ensuite, nous avons discuté de l'importance de la réduction de la dimensionnalité. Enfin nous avons expliqué également la différence entre les modèles individuels et les modèles généraux ainsi que les différents classifieurs utilisés.

Dans le prochain chapitre, nous aborderons le matériel et les logiciels utilisés pour mettre en œuvre notre système de reconnaissance des mouvements. Nous présenterons les capteurs EMG et le microcontrôleur choisis, ainsi que notre modèle proposé. De plus, nous illustrerons les différentes étapes de notre modèle à l'aide d'une interface graphique.

Chapitre 3

Méthodologie et implémentation

3.1 Introduction

Ce chapitre est dédié à l'explication de la méthodologie de travail ainsi qu'au choix du matériel hardware concernant les capteurs utilisés et le microcontrôleur. En ce qui concerne la méthodologie, nous examinerons les différentes étapes suivies pour le développement de ce projet. La méthodologie adoptée est le fruit d'une réflexion approfondie et vise à garantir une approche systématique et efficace tout au long du processus de développement.

En ce qui concerne le choix du matériel hardware, une attention particulière a été portée aux capteurs utilisés et au microcontrôleur sélectionné. Les capteurs jouent un rôle essentiel dans la collecte des données nécessaires au bon fonctionnement du système. De plus, le microcontrôleur a été sélectionné en fonction de ses fonctionnalités clés, de sa performance de programmation et de sa capacité à gérer les capteurs choisis. Ces décisions matérielles sont cruciales pour garantir des performances optimales et une intégration harmonieuse du système dans son environnement.

Ce chapitre se concentrera donc sur l'explication détaillée de la méthodologie de travail utilisée tout au long du projet, ainsi que sur les raisons et les considérations qui ont conduit au choix du matériel hardware, en mettant en évidence les capteurs utilisés et le microcontrôleur sélectionné.

3.2 Logiciels, librairies et matériels

3.2.1 Logiciels, librairies

Python

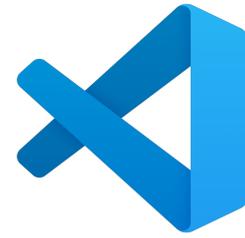
Python est un langage de programmation interprété, orienté objet et de haut niveau qui se distingue par sa sémantique dynamique, sa syntaxe simple et lisible, ainsi que sa capacité à manipuler des structures de données intégrées de haut niveau. Il est largement utilisé pour le développement rapide d'applications et peut servir de langage de script ou de collage pour connecter des composants existants. Python prend également en charge des modules et des *packages* pour faciliter la modularité des programmes et la réutilisation du code. Enfin, il est disponible gratuitement sous forme de source ou binaire pour toutes les plates-formes, ce qui en fait un choix populaire pour de nombreux projets de développement logiciel [42].



Visual studio code

Visual Studio Code est un éditeur de code open-source léger et puissant, disponible sur Windows, macOS et Linux. Il est principalement destiné aux développeurs de logiciels et offre une prise en charge intégrée de plusieurs langages de programmation tels que JavaScript, TypeScript et Node.js. Il dispose également d'une riche communauté de développeurs qui ont créé des extensions pour d'autres langages et environnements d'exécution, comme C++, C#, Java, Python, PHP, Go et .NET.

En somme, Visual Studio Code est un éditeur de code gratuit, léger et puissant, idéal pour les développeurs travaillant sur des projets de machine learning et de Python, mais également adapté à une grande variété de langages et d'écosystème de développement [43].



Scikit-learn

Scikit-learn est une bibliothèque Python, qui est généralement utilisée dans les projets d'apprentissage automatique, elle se concentre sur les outils classiques de Machine Learning, tels que KNN, SVM, RF... ainsi que sur l'implémentation de réseaux de neurones. Elle offre des fonctionnalités pour développer et appliquer des modèles basés sur des méthodes statistiques fondamentales. En tant qu'outil gratuit, Scikit-learn est d'une importance considérable dans de nombreux types de développement d'algorithmes pour l'apprentissage automatique et les technologies connexes [44].



Stmcubeide

STM32CubeIDE est un outil de développement multi-OS (multi-Operating System) tout-en-un, qui fait partie de l'écosystème logiciel STM32Cube. C'est une plateforme de développement C/C++ avancée avec des fonctions de configuration de périphériques, de génération de code, de compilation de code et de débogage pour les microcontrôleurs et microprocesseurs STM32. Il intègre la configuration STM32 et les fonctionnalités de création de projet de STM32CubeMX pour offrir une expérience d'outil tout-en-un et économiser du temps d'installation et de développement. Après la sélection d'un MCU ou MPU STM32 vide, ou d'un microcontrôleur ou microprocesseur préconfiguré à partir de la sélection d'une carte ou d'un exemple, le projet est créé et le code d'initialisation généré. A tout moment du développement, l'utilisateur peut revenir à l'initialisation et à la configuration des périphériques ou du middleware et régénérer le code d'initialisation sans impact sur le code utilisateur. STM32CubeIDE inclut des analyseurs de compilation



et de pile qui fournissent à l'utilisateur des informations utiles sur l'état du projet et les besoins en mémoire. Il comprend également des fonctions de débogage standard et avancées, y compris des vues des registres du cœur du CPU, des mémoires et des registres de périphériques, ainsi que la surveillance des variables en direct, l'interface Serial Wire Viewer, ou l'analyseur de fautes [45].

Tkinter

Tkinter est une bibliothèque Python qui permet aux développeurs de créer des interfaces graphiques utilisateur (GUIs - Graphical User Interfaces) pour leurs applications. Elle offre une gamme d'éléments pré-construits tels que des boutons, des menus et des zones de texte, qui peuvent être organisés et agencés pour concevoir des interfaces interactives et esthétiquement attrayantes. Tkinter simplifie la gestion des entrées utilisateur et des événements, facilitant ainsi la création de programmes pilotés par les événements. Elle est compatible avec plusieurs plateformes, ce qui permet aux applications de s'exécuter sur plusieurs systèmes d'exploitation sans modifications majeures [46].



3.3 Schéma général

Dans cette partie, nous présenterons les différents aspects de notre projet, ainsi que leur mise en œuvre. Plus spécifiquement, nous aborderons la collecte et l'acquisition des données en utilisant les capteurs EMG et le microcontrôleur STM32F103C8T6. D'autre part nous présenterons le fonctionnement du convertisseur analogique-numérique et la communication UART entre le microcontrôleur et l'ordinateur. De plus, nous mettrons en pratique la classification en utilisant les classifieurs mentionnés dans le chapitre 2 afin de classifier les différents types de mouvements. La figure 3.1 présente le schéma général de notre projet.

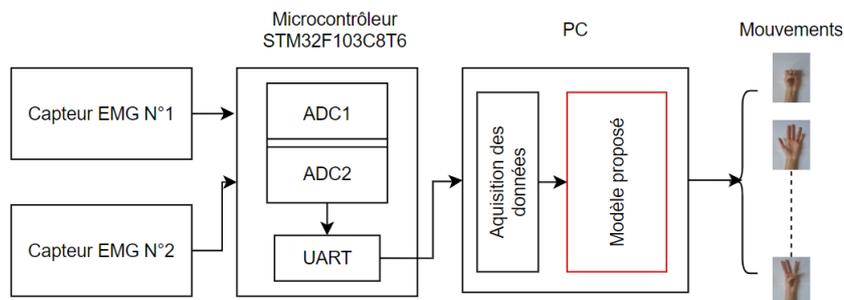


FIG. 3.1 : Schéma-bloc du système de détection des mouvements de la main

3.4 Capteurs EMG

Le capteur utilisé est un capteur musculaire de *Advancer Technologies*. Le capteur amplifie et traite l'activité électrique d'un muscle, la convertissant en un signal analogique qui peut être facilement reçu par n'importe quel microcontrôleur doté d'un convertisseur analogique-numérique (CAN). Le capteur EMG existe en plusieurs versions qui peuvent être divisés en deux catégories : ceux où les électrodes sont directement appliquées sur la peau (3.2a)(3.2b), et ceux qui sont équipés de câbles où l'on place les électrodes sEMG géliifiées (3.2c)(3.2d).

Dans le cadre de ce travail, nous utiliserons les capteurs EMG de la version 3.

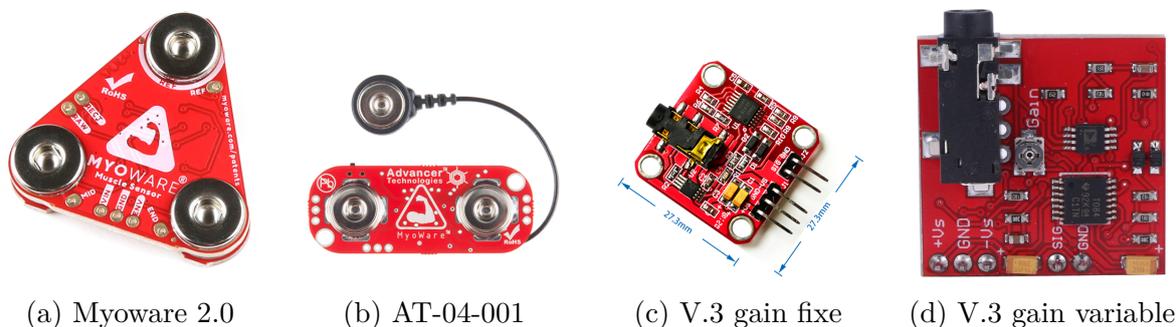


FIG. 3.2 : Les différentes versions des capteurs EMG

Lorsque le groupe musculaire ciblé se contracte, la tension de sortie du capteur augmente. La relation précise entre la tension de sortie et l'activité musculaire peut être ajustée avec précision à l'aide d'un potentiomètre de gain intégré. Sur le marché, on trouve deux versions de ce capteur : une version équipée d'un potentiomètre permettant de régler le gain d'amplification, et une autre avec un gain fixe. Pour notre travail, nous utiliserons les capteurs dotés d'un gain fixe en raison de leur disponibilité. Le calcul de ce gain est facile : il suffit de lire la valeur de la résistance située à la sortie de l'amplificateur TL084 (voir le circuit schématique en annexe A 4.10) et de le calculer en utilisant la formule (3.1) mentionnée dans le Manuel d'utilisation du fournisseur [47].

$$Gain = 207 * (X/1k) \tag{3.1}$$

Avec X représentant la valeur de la résistance utilisée.

Un câble pour connecter trois électrodes à la carte du capteur musculaire est utilisé. L'une des extrémités du câble est dotée d'un connecteur audio jack de 3,5 mm qui peut être branché directement sur la carte. L'autre extrémité est équipée de trois connecteurs à pression (*snap-on*) qui facilitent la fixation et le détachement des électrodes. On peut trouver différentes combinaisons de couleurs pour les trois connecteurs (vert-jaune-rouge) ou bien (bleu-noir-rouge). Dans le circuit schématisé du capteur, les trois connecteurs sont désignés comme suit : MID, END et GND. "MID" signifie "middle" (milieu) et correspond à l'électrode qui doit être positionnée au milieu du muscle que l'on souhaite étudier, "END" signifie "final" (extrémité) et indique que l'électrode doit être placée à l'extrémité du muscle étudié et "GND" représente notre électrode de référence. Les différentes connexions de ces câbles n'étant pas citées dans le datasheet, il suffit d'utiliser un multimètre en mode de continuité (mode de test de continuité) afin de correspondre les différentes couleurs au trois désignations (MID, END et GND).

Dans notre configuration, le câble de référence "GND" est identifié par la couleur verte, tandis que les deux autres câbles, de couleur rouge et jaune, représentent respectivement les câbles "MID" et "END".



3.4.1 Composants internes des capteurs EMG

Comme présenté dans le chapitre 2 section 2.3.2, les capteurs EMG sont dotés de composants électroniques qui sont utilisés afin de filtrer, amplifier et rectifier le signal. Nous détaillerons dans cette section les différents composants utilisés et leur utilité dans l'acquisition et le prétraitement des signaux EMG. Le diagramme ci-dessous (Fig :3.3) résume les différentes étapes et composants internes utilisés pour amplifier, rectifier et filtrer le signal EMG.

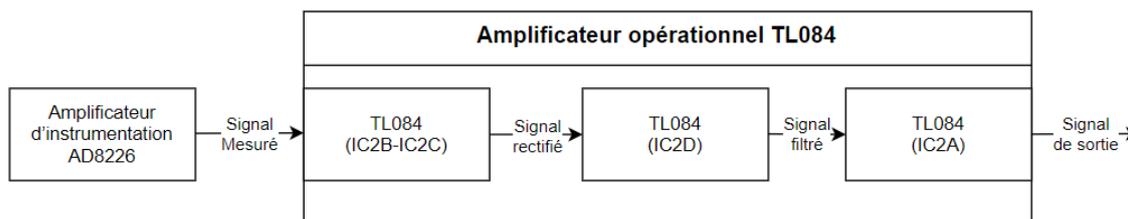
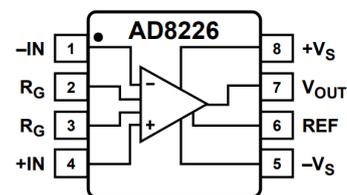


FIG. 3.3 : Composants internes des capteurs EMG

Amplificateur d'instrumentation AD8226:

Le capteur EMG utilise l'AD8226 qui est un amplificateur d'instrumentation à large plage d'alimentation. Il ne nécessite qu'une seule résistance externe pour régler le gain entre 1 et 1000.

L'amplificateur AD8226 du capteur nécessite une tension de référence positive et négative en raison de sa configuration à double alimentation. Cette configuration permet à l'amplificateur de traiter des signaux à la fois positifs et négatifs. Deux piles, $+V_s$ et $-V_s$, fournissent les tensions de référence positive et négative nécessaires. Cela permet à l'amplificateur de traiter avec précision les signaux alternatifs ou bipolaires, tels que ceux rencontrés dans les applications d'électromyographie (EMG). Bien que la tension de fonctionnement maximale soit de ± 18 V, il est recommandé d'utiliser une tension plus faible, par exemple ± 9 V, afin de minimiser le risque de choc électrique. Cependant, même des tensions d'alimentation plus faibles, comme $\pm 3,7$ V, peuvent encore donner des résultats satisfaisants d'après les résultats pratiques.



Amplificateur opérationnel TL084:

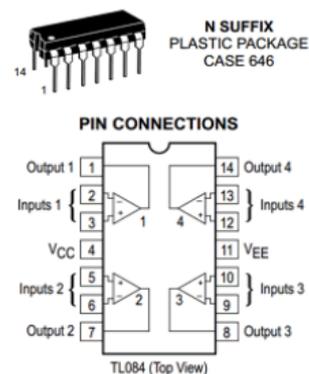
Dans le schéma, le signal de sortie de l'AD8226 est étiqueté "Signal mesuré" et est utilisé comme entrée du TL084, qui est un amplificateur opérationnel quadruple.

Pour faciliter l'explication des circuits, nous supposerons l'hypothèse suivante :

- Tous les amplificateurs opérationnels sont considérés comme idéaux, sauf indication contraire. Cela signifie que les courants d'entrée i^+ et i^- sont nuls (impédance d'entrée de l'AOP infinie) et que leurs caractéristiques ne varient pas en fonction de la fréquence.

Afin de ne pas encombrer le schéma nous prendrons en compte ce qui suit :

- L'alimentation symétrique des amplificateurs opérationnels ne sera pas représentée dans les schémas pour alléger leur complexité.
- Les schémas présentés sont des schémas théoriques. Aucune valeur de composant n'est donnée. Les valeurs des composants et le schéma complet se trouvent en annexe 4.10.



Dans le circuit schématique du capteur emg utilisant le TL084 (annexe 4.10), IC2A, IC2B et IC2C font référence à des amplificateurs opérationnels spécifiques dans le circuit intégré TL084. Les lettres "IC" devant le numéro indiquent qu'il s'agit d'un circuit intégré (Integrated circuit). Les amplificateurs opérationnels IC2B et IC2C sont utilisés dans le schéma pour rectifier le signal mesuré en utilisant des diodes.

- **IC2B** agit comme un redresseur de demi-onde précis, permettant de ne laisser passer que les demi-cycles positifs du signal mesuré grâce à une diode connectée entre la borne inverseuse et la sortie de l'amplificateur opérationnel.
- **IC2C** agit comme un redresseur de pleine onde précis, permettant de laisser passer à la fois les demi-cycles positifs et négatifs du signal mesuré grâce à une autre diode connectée entre la borne inverseuse et la sortie de l'amplificateur opérationnel. Cela signifie que les signaux négatifs sont inversés en signaux positifs et ajoutés aux signaux positifs.

Afin d'expliquer plus en détail comment nous obtenons le signal rectifié, nous allons étudier le circuit utilisé dans le capteur.

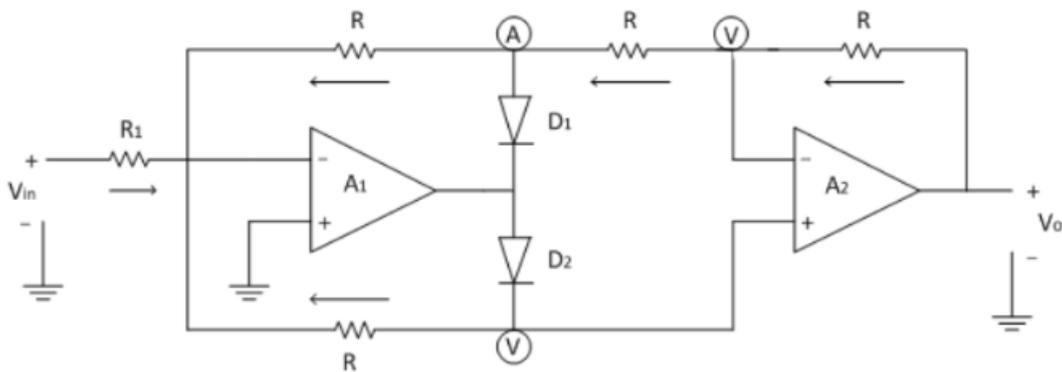


FIG. 3.4 : Circuit de rectification du signal (Annexe 4.10)

- **Dans le demi-cycle positif** du signal d'entrée alternatif appliqué, la sortie de l'amplificateur op. 1 est négative, ce qui signifie que la diode D2 est polarisée de manière inversée.

L'amplificateur op. A1 fonctionne donc comme un amplificateur inverseur avec un gain $(-R/R1)$

Par conséquent, la tension au point "A" (sortie de l'amplificateur op. A1) est donnée comme suit :

$$V_A = \frac{-R}{R1} \times V_{in}$$

La borne non inverseuse de l'amplificateur op. A2 est virtuellement mise à terre, de sorte que l'amplificateur op. A2 fonctionne également comme un amplificateur inverseur. Par conséquent, la tension de sortie V_o est donnée par :

$$V_o = \frac{-R}{R} \left[\frac{-R}{R1} \times V_{in} \right]$$

$$V_o = \frac{R}{R1} \times V_{in}$$

- **Dans le demi-cycle négatif** du signal d'entrée alternatif appliqué, la sortie de l'amplificateur op. A1 est positive, la diode D2 est donc polarisée dans le sens direct et la diode D1 est polarisée en inverse. L'amplificateur op-amp A1 fonctionne donc comme un amplificateur inverseur.

Soit V la sortie de l'amplificateur opérationnel A1.

Le courant circulant dans le circuit de rétroaction de l'amplificateur opératif A2 et A1 est donné par la formule suivante :

$$\begin{aligned} \frac{(V_o - V)}{R} &= \frac{(V - 0)}{2R} \\ V_o &= \frac{V}{2 + V} \\ V &= \frac{2}{3} \times V_o \end{aligned} \tag{3.2}$$

En appliquant la loi de Kirchhoff au nœud présent à la borne d'inversion de l'amplificateur op. A1, on obtient :

$$\begin{aligned} \frac{(V_{in} - 0)}{R1} + \frac{(V - 0)}{R} + \frac{(V - 0)}{2R} &= 0 \\ \frac{V_{in}}{R1} + V \left[\frac{1}{R} + \frac{1}{2R} \right] &= 0 \end{aligned}$$

En substituant l'équation 3.2 dans l'équation ci-dessus, on obtient ce qui suit :

$$\begin{aligned} \frac{V_{in}}{R1} + \frac{2}{3} V_o \left[\frac{2R + R}{(2R)R} \right] &= 0 \\ \frac{V_{in}}{R1} + \frac{V_o}{R} &= 0 \\ V_o &= -\frac{R}{R1} V_{in} \end{aligned}$$

Mais dans le demi-cycle négatif, l'amplitude de l'entrée est négative et nous obtenons donc :

$$\begin{aligned} V_o &= -\left(\frac{R}{R1}\right)(-V_{in}) \\ V_o &= \frac{R}{R1} V_{in} \end{aligned}$$

Ainsi, dans les deux demi-cycles du signal d'entrée alternatif appliqué, la sortie reste la même avec le gain (R/R1).

Par la suite, l'amplificateur opérationnel IC2D est utilisé en tant que filtre passe-bas. Le filtre passe-bas permet de filtrer le signal rectifié en atténuant les composantes à haute fréquence et en ne laissant passer que les composantes à basse fréquence.

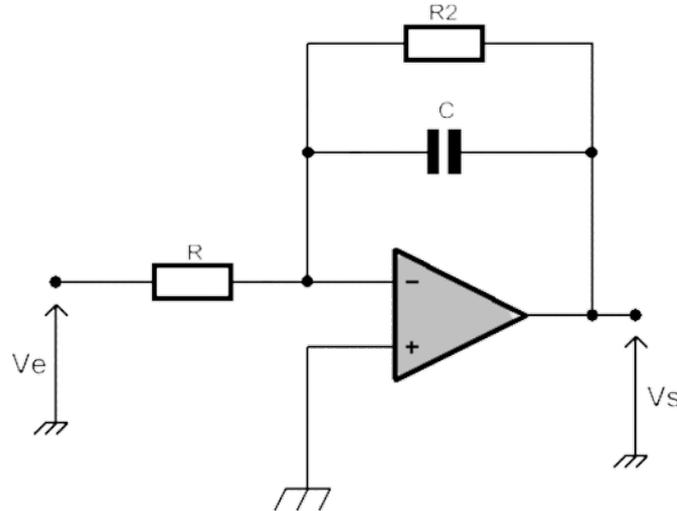


FIG. 3.5 : Filtre actif passe-bas du 1er ordre

Le circuit de la figure 3.5 est un circuit de filtre passe bas, considérons tout d'abord l'impédance globale Z , résultat de la mise en parallèle de C et de R_2

$$Z = R_2 // Z_C = \frac{\frac{R_2}{jCw}}{R_2 + \frac{1}{jCw}} = \frac{R_2}{1 + jR_2Cw} \quad (3.3)$$

Ensuite, il suffit de reconnaître que la structure est identique à un montage amplificateur inverseur pour déterminer la fonction de transfert $H(jw)$

$$H(jw) = - \left(\frac{Z}{R} \right) = - \frac{R_2}{R + jRR_2Cw} = - \frac{R_2}{R} \cdot \frac{1}{1 + jR_2Cw}$$

$$H(jw) = A_0 \cdot \frac{1}{1 + j \frac{w}{w_0}} \text{ avec } A_0 = - \frac{R_2}{R} \text{ et } w_0 = \frac{1}{R_2C}$$

Fréquence de coupure :

$$f_c = \frac{1}{2\pi R_2 C}$$

Nous obtenons la fonction de transfert caractéristique d'un filtre passe-bas du 1er ordre, elle-même multipliée par un gain fixé par les valeurs R_2 et R .

Physiquement, l'impédance du condensateur diminuant avec la fréquence, plus celle-ci augmente, plus la boucle de contre-réaction se rapproche d'un simple fil (court-circuit de R_2). De ce fait, malgré le gain R_2/R et puisque l'AOP fonctionne en régime linéaire, on obtient $V_+ = V_- = 0$ V et donc la sortie se rapproche aussi de 0V.

Finalement, l'amplificateur opérationnel IC2A est utilisé en configuration d'un amplificateur inverseur. La sortie de l'amplificateur IC2D étant négative, ce dernier étage est utilisé afin de rectifier la polarité du signal filtré.

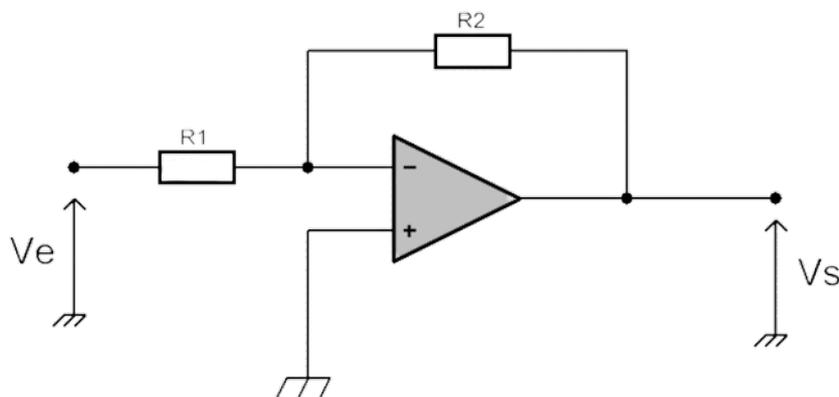


FIG. 3.6 : Amplificateur inverseur

Le courant circulant dans R1 est le même que celui dans R2 puisque $i_- = 0$ (voir figure 3.6). La loi d'Ohm appliquée à ces deux résistances donne :

$$\begin{aligned} \frac{V_e}{R_1} &= -\frac{V_s}{R_2} \\ \Leftrightarrow \frac{V_s}{V_e} &= -\frac{R_2}{R_1} \\ \Rightarrow V_s &= -\left(\frac{R_2}{R_1}\right) V_e \end{aligned}$$

Nous obtenons finalement le signal rectifié et filtré à la sortie de ce dernier amplificateur.

Comme mentionné dans la section 2.3 du chapitre précédent, nous avons fourni une explication détaillée des étapes d'amplification, de rectification et de filtrage analogique utilisés dans notre capteur. Ces étapes sont essentielles pour conditionner le signal avant qu'il ne soit traité par le convertisseur analogique-numérique (CAN) de notre microcontrôleur.

3.5 Choix du microcontrôleur

Dans le cadre de notre application, il est impératif de disposer d'un microcontrôleur adapté à nos besoins. Il existe divers microcontrôleurs parmi lesquels notre choix sera guidé par plusieurs caractéristiques, telles que la disponibilité, la présence du protocole de communication UART, la résolution adéquate du convertisseur analogique-numérique, la fréquence d'horloge, ainsi que la petite dimension de la carte de développement. Après

avoir comparé différents microcontrôleurs, nous avons opté pour le STM32F103C8T6 (STM32 Blue Pill), car il satisfait les caractéristiques attendues. La STM32 Blue Pill se distingue par sa disponibilité sur le marché, sa prise en charge du protocole de communication UART (plusieurs), sa résolution du convertisseur analogique-numérique 12 bits de haute qualité, sa fréquence d'horloge de maximum 72MHz optimale, et en plus de cela, elle présente une petite taille qui répond à nos contraintes d'espaces qui sont limitées.

Dans cette partie, nous allons présenter la carte de développement STM32 Blue Pill ainsi que ses spécifications :

3.5.1 STM32 Blue Pill

La STM32 Blue Pill 3.7est une carte de développement qui utilise le microcontrôleur STM32F103C8T6 de ST-Microelectronics. Ce microcontrôleur est un processeur 32 bits basé sur l'architecture ARM Cortex-M3, fonctionnant jusqu'à une vitesse maximale de 72 MHz. Il est disponible dans un boîtier compact à faible quadrillage LQFP (Low Quad Flat Package) comportant 48 broches, ce qui facilite son intégration dans des applications nécessitant une utilisation d'espace restreinte. Parmi ses caractéristiques, on peut citer :

- Microcontrôleur ARM 32-bit Cortex™ M3 STM32F103C8T6 CPU Core
- Taux d'échantillonnage : jusqu'à 1 million d'échantillons par seconde
- Mémoire Flash : 64 Ko
- Mémoire SRAM : 20 Ko
- Périphériques : 7 x Timers, 2 x SPI, 2 x I²C, 3 x USART, USB, 2 x CAN
- Contrôleur DMA 7 canaux
- Nombre GPIOs : 37 (LQFP-48)
- CAN : Convertisseur Analogique Numérique de 12 bits (10 broches analogiques)
- Tension de fonctionnement (VCC) : 2V à 3,6V
- Tension sur les broches : -0.3V à 5,5V (pour $2V < VCC < 3,6V$)
- Gamme de température ambiante de -40°C à 85°C

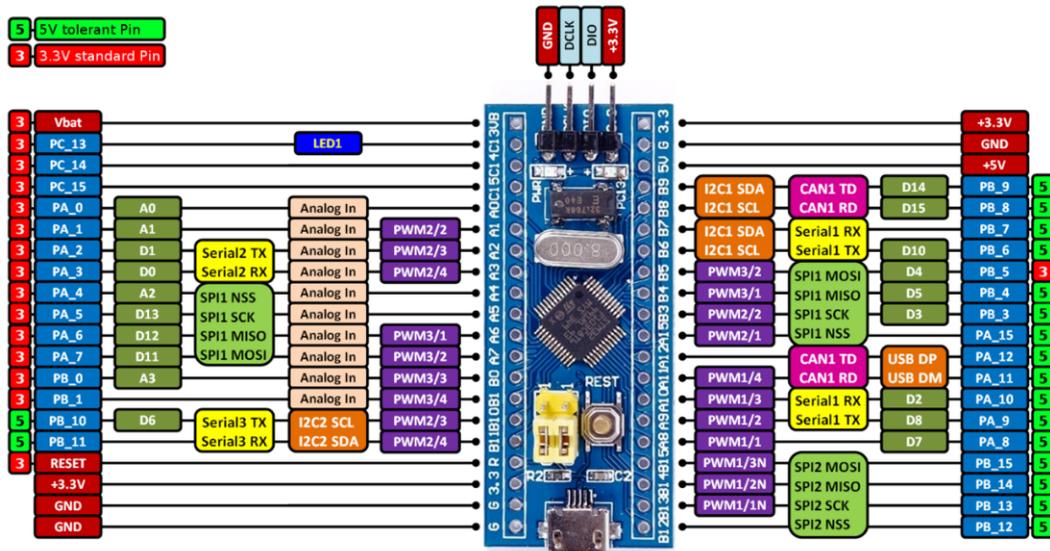


FIG. 3.7 : STM32 Blue Pill Pinout

3.5.2 ST-LINK V2

Le STLINK V2 est un outil de programmation et de débogage utilisé avec la carte de développement STM32 Blue Pill. Il permet de connecter un ordinateur à la Blue Pill et de téléverser du code sur celle-ci, ainsi que de surveiller et de déboguer le microcontrôleur STM32 qui se trouve sur la carte. Pour utiliser le STLINK V2 avec la Blue Pill, il est nécessaire de modifier les cavaliers (jumpers) de mode 0 et de mode 1 sur la carte. Le mode 0 (programming mode) est utilisé pour activer le mode de programmation du microcontrôleur, permettant au STLINK V2 de téléverser le code sur la Blue Pill. Le mode 1 (operational mode), quant à lui, permet au microcontrôleur de démarrer normalement à partir de sa mémoire flash principale. Cela signifie que le programme chargé dans la mémoire flash sera exécuté après la mise sous tension. En modifiant les cavaliers de mode 0 et de mode 1, une communication appropriée peut être établie entre le STLINK V2 et le microcontrôleur STM32, facilitant ainsi la programmation et le débogage de la Blue Pill.

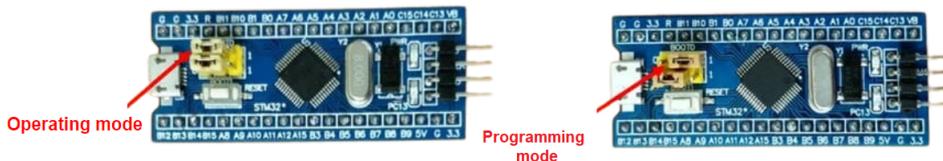


FIG. 3.8 : Boot mode

3.5.3 Timer

Le timer est une fonctionnalité essentielle de la STM32 Blue Pill qui permet de mesurer et de contrôler le temps avec précision. Il est doté de 7 timers intégrés qui offrent une flexibilité maximale dans la gestion des tâches temporelles. Les timers sont des compteurs électroniques qui peuvent être utilisés pour générer des signaux d'horloge, mesurer des intervalles de temps, déclencher des événements périodiques, etc. Chaque timer de la STM32 Blue Pill est composé d'un compteur et d'un prescaler. Le compteur est un registre qui est incrémenté à chaque impulsion d'horloge interne du microcontrôleur. Le prescaler permet de diviser la fréquence de l'horloge interne pour ajuster la précision et la plage de mesure du timer.

En ce qui concerne la configuration de l'horloge, la STM32 Blue Pill dispose d'une horloge système interne (HSI) qui fournit une fréquence d'horloge par défaut de 8 MHz. Cependant, il est possible d'utiliser une horloge système externe (HSE) en connectant un oscillateur externe à la carte de développement pour obtenir une meilleure précision. La vitesse maximale de fonctionnement de la STM32 Blue Pill est de 72 MHz, ce qui permet des performances optimales pour de nombreuses applications.

Dans le cadre de notre étude, nous avons employé un timer dans notre application afin de réguler la cadence du CAN, permettant ainsi d'échantillonner le signal à une fréquence de 1000 Hz.

3.5.4 Convertisseur analogique-numérique (CAN)

Un convertisseur analogique-numérique est un dispositif électronique utilisé pour convertir des signaux analogiques en signaux numériques. Il s'agit d'un composant essentiel dans de nombreux systèmes électroniques, tels que les systèmes de contrôle, les équipements audio, les capteurs, les instruments de mesure, etc.

Le CAN est l'un des composants électroniques les plus précieux, surtout lorsqu'il offre un taux d'échantillonnage élevé et une résolution élevée. Cependant, sa présence dans les microcontrôleurs implique des coûts significatifs. Pour exploiter au mieux cette ressource essentielle, les fabricants de microcontrôleurs fournissent donc aux ingénieurs en microprogrammation différentes caractéristiques .

Le STM32F103C8T6 (Blue Pill) est doté d'un CAN de 12 bits, qui est un convertisseur analogique-numérique à approximations successives¹. Il dispose de 18 canaux multiplexés, ce qui lui permet de mesurer des signaux provenant de seize sources externes et deux sources internes. Le résultat de la conversion A/N est stocké dans un registre de données de 16 bits, aligné à gauche ou à droite. La fonction de surveillance analogique (watchdog) permet à l'application de détecter si la tension d'entrée dépasse les seuils haut ou bas

¹Le convertisseur effectue une série d'approximations successives pour déterminer la valeur numérique correspondant à la tension analogique d'entrée

définis par l'utilisateur.

Dans le cadre de notre projet, nous avons utilisé un mode de lecture du CAN qui permet de lire les 2 CAN disponibles dans le microcontrôleur de façon simultanée. Le CAN du microcontrôleur offre la possibilité de lecture en mode indépendant et en deux modes. Dans le cas de l'utilisation de deux électrodes, nous utilisons le mode "Double mode régulier simultané" illustré dans la figure (3.9), ce mode permet d'effectuer deux conversions simultanément grâce à la synchronisation des CAN1 et CAN2. Chaque CAN convertit une séquence de canaux (avec le scan activé et le séquenceur de chaque CAN configuré) ou convertit un seul canal (scan désactivé).

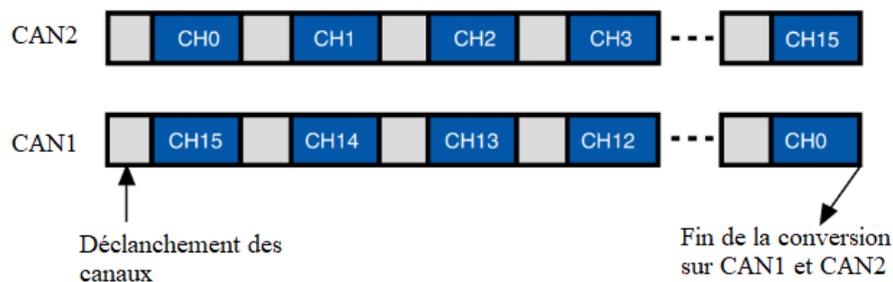


FIG. 3.9 : Fonctionnement du double mode régulier simultané

Différentes méthodes pour lire le CAN sur STM32

Dans cette section, nous allons détailler les trois modes d'utilisation du CAN de la carte STM32 Blue Pill. Nous aborderons les méthodes de lecture du CAN en utilisant le sondage, l'interruption et l'Accès Direct Mémoire (DMA). Ces trois modes offrent différentes approches pour lire les valeurs analogiques à partir de la carte STM32 Blue Pill.

Méthode du sondage (Polling) :

C'est la méthode la plus simple pour effectuer une conversion analogique-numérique en utilisant le CAN sur un canal d'entrée analogique. Cependant, ce n'est pas toujours une méthode efficace car elle est considérée comme bloquante. Dans cette méthode, nous lançons la conversion A/N et attendons que le CAN termine la conversion afin que le CPU puisse reprendre le traitement du code principal.

Méthode par interruption (Interrupt) :

La méthode par interruption est une façon efficace d'effectuer une conversion A/N de manière non bloquante. Ainsi, le CPU peut reprendre l'exécution du code principal jusqu'à ce que le CAN termine la conversion et déclenche une interruption. Le CPU peut alors passer au contexte de l'ISR (Routine de Service d'Interruption) et enregistrer les résultats de la conversion pour un traitement ultérieur. Cependant, lorsque l'on travaille avec plusieurs canaux en mode circulaire, par exemple, on peut avoir des interruptions périodiques du CAN qui sont trop nombreuses pour que le CPU les gère. Cela peut entraî-

ner l'injection de gigue², une latence d'interruption et divers problèmes de synchronisation dans le système. Cela peut être évité en utilisant le DMA.

Méthode par DMA (Direct Memory Access) :

Enfin, la méthode par accès mémoire direct DMA est la plus efficace pour convertir plusieurs canaux du CAN à des taux très élevés et transférer les résultats en mémoire sans intervention du CPU. Il s'agit d'une technique très pratique qui permet de gagner du temps.

La méthode du CAN avec DMA a été utilisée pour décharger le CPU des tâches de conversion analogique-numérique, permettant ainsi de libérer des ressources pour effectuer d'autres calculs et faciliter les développements futurs de l'application. Cela permet une gestion plus efficace des transferts de données entre le CAN et la mémoire, minimisant ainsi la charge de travail du processeur et offrant une meilleure flexibilité pour les fonctionnalités et les améliorations ultérieures de l'application.

3.5.5 Protocole de communication UART

Le protocole de communication UART (Universal Asynchronous Receiver/Transmitter) est une méthode de communication série largement utilisée pour la transmission de données entre des périphériques électroniques. Il est couramment utilisé dans les systèmes embarqués, les microcontrôleurs et d'autres applications nécessitant une communication série simple et fiable. Voici les principales caractéristiques et le fonctionnement du protocole de communication UART :

- **Transmission asynchrone** : Contrairement aux protocoles synchrones tels que le SPI ou l'I²C, l'UART est asynchrone, ce qui signifie qu'il n'utilise pas de signal d'horloge commun entre les périphériques pour synchroniser la transmission des données. Au lieu de cela, il utilise des bits de démarrage (start bit) et des bits d'arrêt (stop bit) pour délimiter chaque octet de données.
- **Configuration des paramètres** : Avant la communication, les périphériques UART doivent être configurés avec des paramètres spécifiques tels que la vitesse de transmission (bauds), le nombre de bits de données, le nombre de bits de parité (facultatif) et le nombre de bits d'arrêt. Les deux périphériques doivent être configurés avec les mêmes paramètres pour une communication réussie.
- **Format des trames de données** : Une trame de données typique à l'UART comprend les éléments suivants :
 - Bit de démarrage (start bit) : Un niveau logique bas (0) indiquant le début de la trame.
 - Bits de données : Les bits de données (généralement 7 ou 8 bits) représentant les informations à transmettre.

²Désigne l'introduction de variations aléatoires ou de fluctuations dans la synchronisation temporelle des événements au sein d'un système

- Bit de parité : Un bit facultatif utilisé pour la détection d'erreurs. Il peut être pair, impair ou absent.
- Bits d'arrêt (stop bit) : C'est un bit à niveau logique haut (1) indiquant la fin de la trame.

La trame de données typique à l'UART est illustrée dans la Figure 3.10.

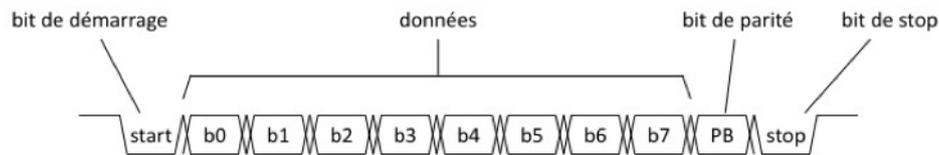


FIG. 3.10 : Trame de données en UART

- **Transmission et réception des données** : L'émetteur UART envoie les trames de données bit par bit, en commençant par le bit de démarrage, puis les bits de données, le bit de parité et enfin les bits d'arrêt. Le récepteur UART détecte le bit de démarrage, lit les bits de données, vérifie la parité et les bits d'arrêt pour recevoir correctement la trame de données.
- **Débit binaire** : Le débit binaire (baud rate) est la vitesse à laquelle les données sont transmises en UART. Il est mesuré en bauds (symboles par seconde) et peut varier en fonction des exigences du système. Les débits binaires courants incluent 9600, 19200, 115200 bauds, etc.

En résumé, le protocole de communication UART est un protocole simple et largement utilisé pour la transmission de données série. Il utilise une transmission asynchrone, des bits de démarrage et d'arrêt, et permet la configuration de divers paramètres pour une communication fiable entre les périphériques.

Le tableau 3.1 récapitule les diverses configurations de l'UART choisies dans notre application afin d'assurer le transfert de données vers l'ordinateur :

| | |
|---------------------|---------------|
| Le débit binaire | 115200 Bits/s |
| Longueur du message | 8 Bits |
| Bit de parité | None |
| Bit d'arrêt | 1 |

TAB. 3.1 : Configuration de l'UART

3.5.6 Convertisseur USB-TTL

Le convertisseur USB-TTL est généralement utilisé pour établir une connexion UART (Universal Asynchronous Receiver Transmitter) avec la carte de développement STM32 Blue Pill. C'est un dispositif électronique utilisé pour convertir les signaux de communication série entre un port USB et une interface de niveau logique TTL (Transistor-Transistor Logic).



3.5.7 Programmation du microcontrôleur

Dans notre projet, nous avons utilisé la couche d'abstraction matérielle (*Hardware Abstraction Layer* "HAL") fournie par STMicroelectronics pour programmer le microcontrôleur. HAL simplifie le processus de développement en offrant une interface standardisée pour interagir avec les périphériques matériels du microcontrôleur STM32.

En utilisant HAL, nous avons pu écrire un code portable et indépendant de la variante spécifique du microcontrôleur que nous utilisons. HAL a abstrait les détails matériels de bas niveau, tels que les GPIO, les UART, les SPI et les timers, en fournissant des fonctions et des pilotes faciles à utiliser. Cela nous a permis de nous concentrer sur la logique et la fonctionnalité de l'application de plus haut niveau, plutôt que de devoir gérer des configurations matérielles complexes.

Les bibliothèques HAL fournies par STMicroelectronics encapsulent les opérations et les configurations au niveau des registres nécessaires pour interagir avec les périphériques du microcontrôleur. Nous pouvons simplement utiliser les fonctions HAL fournies pour initialiser et contrôler les différents composants matériels de notre projet.

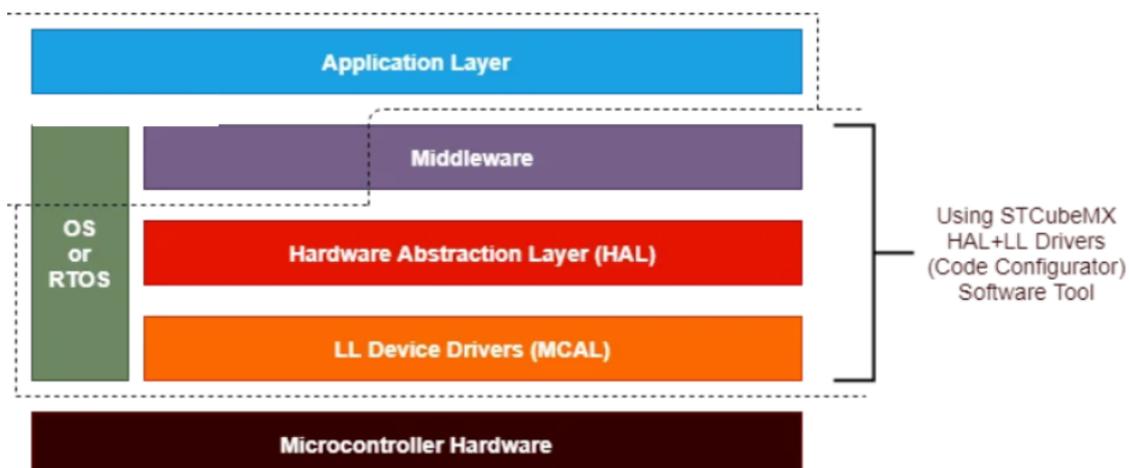


FIG. 3.11 : Couche d'abstraction de StmCubeide [48]

L'utilisation de la HAL et de l'IDE STM32Cube présente plusieurs avantages pour la programmation des cartes STM32 :

Abstraction de haut niveau : La HAL fournit une interface de programmation de haut niveau qui simplifie l'interaction avec les périphériques matériels .

Portabilité : La HAL est conçue pour être portable entre les différents microcontrôleurs STM32. Cela signifie qu'on peut développer une application avec la HAL sur une carte STM32 spécifique, puis la porter facilement vers une autre carte STM32 sans avoir à modifier de manière significative le code.

Gain de temps : L'IDE STM32Cube intègre le STM32CubeMX, un outil graphique de configuration qui permet de générer automatiquement du code d'initialisation. Cela permet de configurer rapidement les broches, les périphériques et les fonctionnalités de la carte STM32.

Documentation complète : La HAL et l'IDE STM32Cube sont fournis avec une documentation complète comprenant des manuels de référence, des exemples de code et des tutoriels. Ces ressources détaillées sont conçues pour aider à comprendre et à utiliser efficacement les fonctionnalités offertes par la HAL et l'IDE.

Conformité et fiabilité : Le code source de la HAL est développé en langage C strictement conforme à la norme ANSI-C³, ce qui le rend indépendant des outils de développement. De plus, il est entièrement documenté et est conforme à la norme MISRA-C 2004, qui définit des directives pour produire un code robuste et fiable.

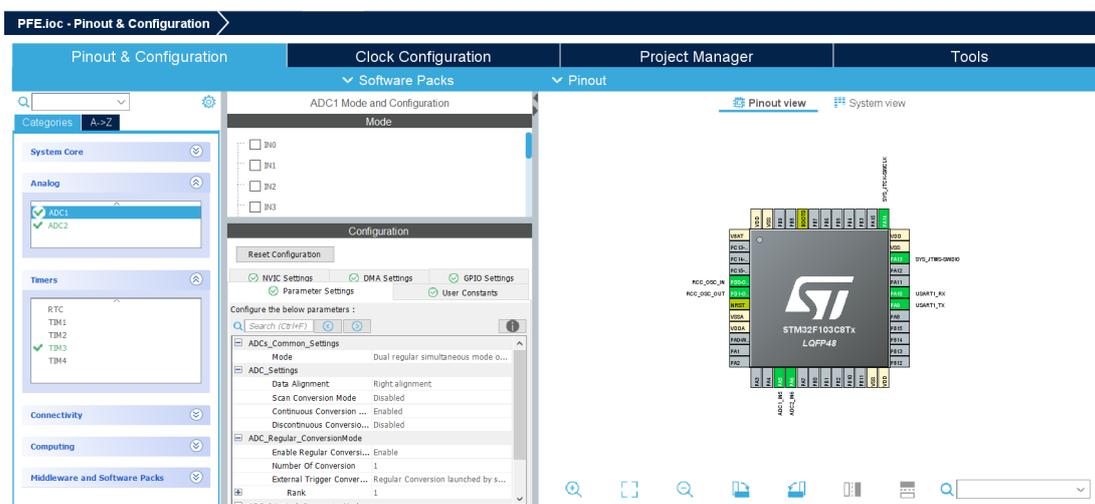


FIG. 3.12 : Ecran de configuration du microcontrôleur

³La norme C ANSI est une spécification du langage C adoptée en 1989 par l'institut national américain de normalisation (ANSI) . Également appelée C ISO , c'est cette spécification qui va amener à une standardisation complète du langage afin d'éviter des problèmes de compilation, assez commun à l'époque.

3.6 Modèle Proposé

Dans cette section, nous présentons notre modèle pour la classification des données, tel qu'illustré dans la figure 3.13. Ce modèle comprend plusieurs étapes clés, allant de la capture initiale des signaux bruts à l'utilisation de classificateurs pour attribuer des étiquettes aux données. Ces étapes comprennent un prétraitement des signaux, l'extraction de caractéristiques, la réduction de la dimension, et enfin, l'application de différents classificateurs.

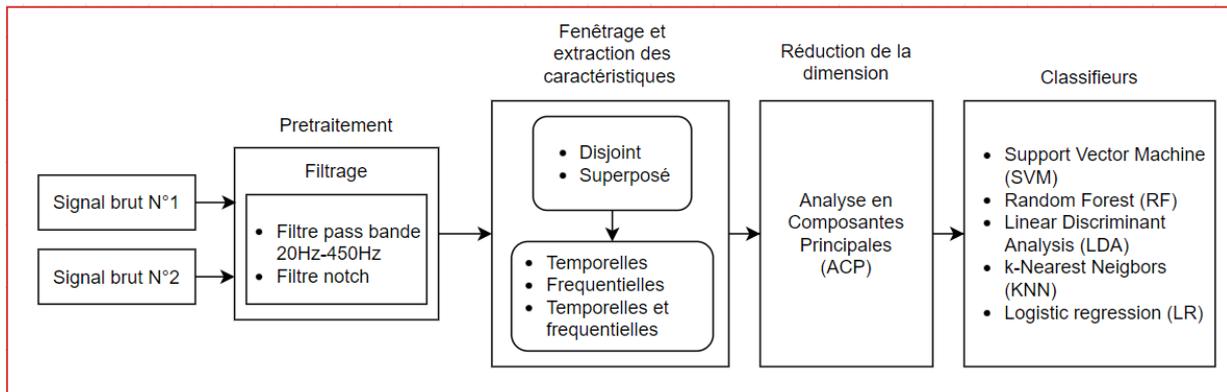


FIG. 3.13 : Schéma synoptique du modèle proposé

Après l'enregistrement des signaux bruts EMG, une série d'étapes de pré-traitement, de fenêtrage et de classification sont appliquées. La première étape essentielle consiste en un filtrage visant à éliminer les bruits indésirables. À cet effet, un filtre passe-bande est utilisé avec une plage de fréquence allant de 20 Hz à 450 Hz. De plus, un filtre notch est employé pour éliminer les interférences potentielles du réseau électrique à 50 Hz.

Ensuite, les caractéristiques sont extraites. Cette étape implique le calcul de plusieurs caractéristiques en utilisant des fenêtrages adjacents ou avec chevauchement (plus de data) dans le domaine temporel, comprenant l'IEMG, MAV, SSI, RMS, WL, ACC, DASDV, ZC, MYOP, WAMP, SSC et les paramètres de hjorth HJP (l'Activité, la Complexité et la Mobilité), ainsi que des caractéristiques dans le domaine fréquentiel telles que le MNP, PKF, TTP, MDF, MNP, et la combinaison des caractéristiques temporelles et fréquentielles. Toutes ces caractéristiques ont été présentées dans le chapitre 2.

Après avoir extrait toutes les caractéristiques pertinentes mentionnées précédemment, nous sommes souvent confrontés à un nombre élevé de dimensions ce qui peut rendre l'analyse complexe et coûteuse en termes de temps de calcul. C'est là que la réduction de dimension en utilisant l'ACP intervient pour simplifier le problème. En appliquant cette technique, nous pouvons projeter nos données sur un sous-espace de dimensions réduites, en conservant les composantes qui expliquent le mieux la variance totale des données. Cela nous permet d'éliminer les dimensions moins significatives et de ne conserver que les principales composantes, ce qui réduit considérablement la complexité de l'analyse tout en préservant l'essence des données originales.

Enfin, la dernière étape consiste à classer les données. Pour cela, différents classifieurs sont utilisés, tels que le Support Vector Machine (SVM), le Random Forest, le Linear Discriminant Analysis (LDA), le K-Nearest Neighbors (KNN) et la régression logistique. Ces classifieurs sont appliqués pour classer les différents mouvements identifiés à partir des signaux EMG traités.

Pour évaluer la performance de notre classification, plusieurs métriques de classification seront utilisées. Cela inclut l'exactitude (Accuracy), la matrice de confusion qui fournit des informations sur les vrais positifs, les vrais négatifs, les faux positifs et les faux négatifs, ainsi que différentes mesures de performance telles que la sensibilité, le F1 score et la précision. Ces métriques nous permettront d'évaluer la précision et la fiabilité de notre modèle de classification EMG dans la reconnaissance des différents mouvements musculaires. Ces évaluations seront présentées dans le chapitre 4.

3.6.1 Pseudo-Code

Dans le cadre de notre projet, nous fournissons un pseudocode illustrant chaque étape, de l'acquisition du signal (programmation du microcontrôleur) à la classification des signaux EMG en différents mouvements de la main.

Les fichiers sources et les fichiers d'en-tête (.c et .h) décrivant les configurations spécifiques de l'UART, de l'ADC, du timer et du DMA sont disponibles en annexe 4.10. De plus, le fichier main.c, qui est décrit dans le pseudocode ci-dessous, se trouve également en annexe 4.10. Cette approche vise à faciliter la compréhension du code implémenté et permet aux utilisateurs de consulter les détails de configuration spécifiques dans les fichiers fournis.

La création de la base de données s'effectue à l'aide d'une interface graphique que l'on présentera en section 4.10. Afin de ne pas alourdir le pseudocode et de faciliter sa compréhension, nous ne détaillerons pas la programmation de cette interface, qui est disponible en annexe 4.10. Le pseudocode ci-dessous présente la création d'une base de données pour un individu.

Algorithm 1 Lecture des ADC 1 et ADC 2 avec DMA et transmission via UART

Require : ADC 1, ADC 2 configurés en mode double régulier simultané

Ensure : Valeurs des ADC 1 et ADC 2 transmises via UART

Configurer les ADC en mode double régulier simultané

Configurer la méthode DMA pour la récupération des données des ADC

Configurer l'UART pour la transmission des données

Configurer un timer à une fréquence spécifique (1000 HZ)

while vrai **do**

 Attendre le déclenchement de l'interruption du timer

 Lire les valeurs de l'ADC 1 et de l'ADC 2 depuis le tampon DMA

 Transmettre les valeurs lues via UART

 Réinitialiser le tampon DMA pour la prochaine acquisition

end while

Algorithm 2 Création d'une base de données

Require : Individu (pseudo ou chiffre), Temps de mouvement (5-8 s), Temps de pause (1-3 s), Nombre de mouvements (2-7), Nombre de répétitions

Ensure : Base de données créée

```
1: Initialiser la base de données pour l'individu
2: for chaque mouvement dans la liste des mouvements do
3:   Créer un dossier pour le mouvement dans la base de données
4:   for chaque répétition dans la plage des répétitions do
5:     Créer un fichier CSV pour le mouvement_répétition_i
6:     for chaque échantillon dans la plage des échantillons do
7:       Collecter les données de l'échantillon
8:       Insérer les données dans l'entrée de la répétition
9:     end for
10:    Attendre le temps de pause
11:  end for
12:  Attendre le temps de mouvement
13: end for
14: Afficher un message indiquant la fin de la création de la base de données
```

Le pseudo-code présenté ci-dessous décrit le modèle proposé pour la classification des signaux EMG. Ce modèle englobe les différentes étapes du processus, à savoir le prétraitement des signaux, leur fenêtrage, l'extraction des caractéristiques, la réduction de la dimensionnalité, ainsi que la phase de classification des mouvements.

Algorithm 3 Modèle proposé

```
1: freqSignal ← 1000 /*frequencySignal*/
2: tailleSignal ← 5000
3: tailleFenetre ← 200
4: increment ← 20
5: nombreFenetres ← (tailleSignal – tailleFenetre)/incrementFenetre + 1
6:
7: donnees, mouvementMains ← chargerBaseDeDonnees()
8: signalf ← appliquerFiltres(donnees)
9: /* Initialiser les vecteurs des caractéristiques /
10: cTemps ← [] / Caractéristiques temporelles /
11: cFreq ← [] / Caractéristiques fréquentielles */
12: for i ← 0 à tailleSignal – 1 do
13:
14:   segment ← extraireSegment(signalf, tailleFenetre, increment, freqSignal)
15:   for j ← 0 à tailleFenetre – 1 do
16:     ct ← calculerCaracteristiquesTemporelles(segment)
17:     cf ← calculerCaracteristiquesFrequeincielles(segment)
18:     ajouter(caracteristiquesTemps, ct)
19:     ajouter(caracteristiquesFreq, cf)
20:   end for
21: end for
22:
23: classes ← repeter(nombreFenetres, mouvementMains)
24: ensembleDonnees ← preparerEnsembleDonnees(csTemps, cesFreq, classes)
25: classifieur ← Classifier()
26: classifieur.entrainer(ensembleDonnees)
27:
28: resultatsClassification ← []
29: metriques ← calculerMetriques(resultatsClassification, etiquettesReelles)
30: afficher(resultatsClassification)
31: afficher(metriques)
```

3.7 Interface Graphique

Afin de faciliter les différentes étapes de ce projet, des interfaces graphiques ont été développées pour les trois principaux axes de travail : la collecte des données (base de données), la classification des signaux EMG et la classification en temps réel des signaux EMG. Il est important de noter que cette interface a été conçue de manière à être simple d'utilisation. De plus, elle peut être utilisée pour d'autres applications et d'autres signaux physiologiques, à condition de modifier le code backend des classifieurs et les méthodes de sélection et de choix des caractéristiques. Les autres fonctionnalités restent inchangées, ce qui rend cette interface polyvalente. Dans cette section, chaque interface sera présentée, accompagnée de détails supplémentaires sur les fonctionnalités des boutons, des menus.

3.7.1 Interface Base de données

Cette interface permet la collecte des signaux EMG et la création d'une base de données personnalisée pour le sujet. Elle est divisée en trois sections distinctes, chacune jouant un rôle spécifique dans le processus de collecte et d'enregistrement des signaux EMG, afin de faciliter le processus de classification.

Section paramètres

Dans la section des paramètres, l'âge du sujet ainsi que son nom est inscrit (l'utilisateur peut choisir de mentionner le nom du sujet ou d'inscrire un nombre pour garder l'anonymat du sujet). L'utilisateur peut choisir le nombre de mouvements à enregistrer ainsi que le nombre de répétitions de chaque mouvement (un nombre supérieur à 5 répétitions est conseillé afin d'avoir une bonne classification). L'utilisateur peut aussi choisir le temps d'enregistrement et de pause de chaque mouvement. Ces informations sont importantes et conditionnent l'affichage de l'état d'acquisition et la création des différents dossiers et fichiers CSV en backend.

Section affichage

Cette section est dédiée à l'affichage des signaux EMG en utilisant la communication UART. Elle offre la possibilité d'afficher à la fois le signal EMG brut ainsi que le signal filtré, permettant ainsi une visualisation claire et détaillée des données recueillies. L'utilisateur peut donc arrêter l'acquisition des signaux s'il remarque une anomalie lors de l'affichage du signal brut ou filtré. L'utilisateur peut choisir le mode d'affichage des signaux, le nombre de signaux affichés ainsi que les filtres utilisés.

Section Etat de l'acquisition

Cette section est dédiée au contrôle de l'état de l'acquisition des signaux EMG. L'utilisateur a la possibilité d'arrêter et de reprendre l'acquisition à tout moment. Il peut choisir en s'aidant du bouton "browse" le répertoire où il souhaite enregistrer sa base de données. Une assistance visuelle est fournie pour guider l'utilisateur dans l'exécution des différents mouvements requis, ainsi que pour afficher le nombre de répétitions prévues, le tout en respectant un *timing* précis. La figure 3.14 ci-dessous présente l'interface graphique avant le début de l'acquisition

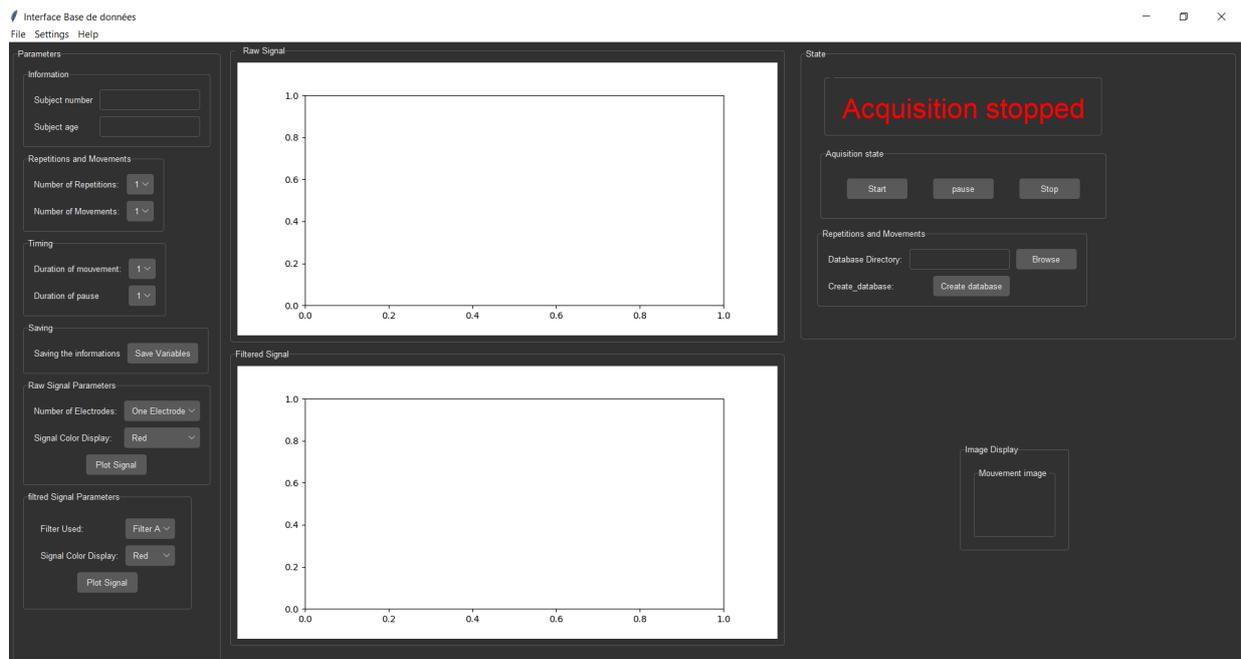


FIG. 3.14 : Interface de Base de données

3.7.2 Interface Classification

Cette interface est utilisée pour classifier les différents signaux collectés à travers l'interface de base de données présentée précédemment. Elle est également divisée en trois grandes sections. La première section "Paramètres" comprend un bouton permettant de sélectionner le dossier de la base de données du sujet que l'on souhaite classifier. La deuxième section d'affichage des signaux est identique à celle présentée dans l'interface de collecte de la base de données. En ce qui concerne la section "Classification", en appuyant sur un bouton, on génère les résultats de classification pour l'ensemble d'entraînement et l'ensemble de test pour tous les classifieurs. La section suivante est la section "Métriques", où l'on peut visualiser les différentes matrices de confusion. La figure 3.15 ci-dessous illustre l'interface lors de la classification d'un ensemble de données (les matrices de confusion n'ont pas encore été affichées dans cette capture d'écran).

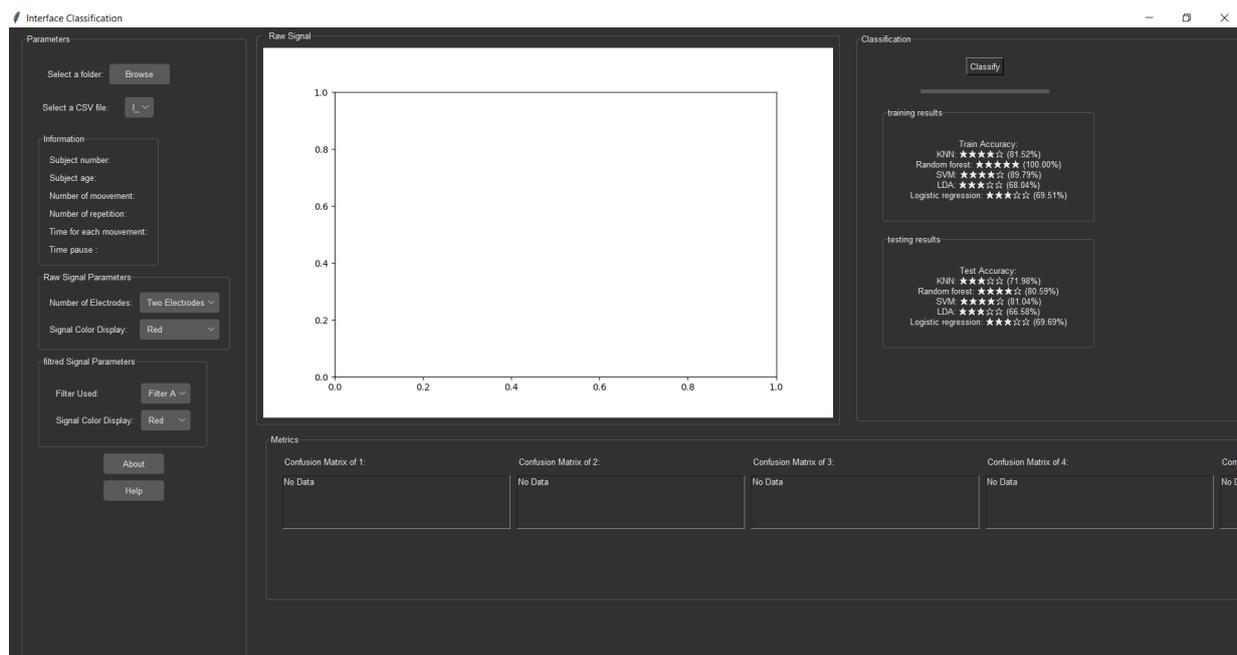


FIG. 3.15 : Interface de classification

3.8 Conclusion

Dans ce chapitre, notre choix s'est porté sur le microcontrôleur STM32F103C8T6 en raison de ses caractéristiques avantageuses. Ce microcontrôleur présente plusieurs fonctionnalités essentielles pour notre projet, telles que le CAN, le timer et l'UART. Ces fonctionnalités nous permettent d'interfacer efficacement avec les capteurs EMG et d'établir une communication fiable. De plus, nous avons approfondi notre compréhension de l'architecture des capteurs EMG et du fonctionnement précis de leurs circuits intégrés.

Dans le chapitre suivant, nous aborderons les résultats expérimentaux obtenus au cours de notre étude, ainsi que les différentes analyses et études réalisées. Nous évaluerons la performance du système dans des conditions variées et analyserons les données collectées. En examinant ces résultats, nous pourrions évaluer l'efficacité de notre solution et en tirer des conclusions significatives. De plus, nous discuterons des implications pratiques et des éventuelles améliorations à apporter.

Chapitre 4

Résultats et évaluation expérimentale

4.1 Introduction

Dans ce chapitre, nous allons présenter et discuter des résultats de nos expérimentations. Notre objectif principal était d'évaluer l'efficacité des différentes approches présentées dans le chapitre 2. Pour cela, nous avons effectué une série de tests comprenant l'utilisation de différentes méthodes de fenêtrage, l'exploration des caractéristiques temporelles et fréquentielles, l'application d'une méthode de réduction de la dimensionnalité, ainsi que des essais avec différents classifieurs. Nous avons également varié le nombre d'électrodes et de mouvements étudiés, et nous avons évalué les performances de notre approche en effectuant des tests sur plusieurs individus.

Le but de cette section est de présenter de manière détaillée les résultats obtenus pour chaque test afin de déterminer les paramètres optimaux qui rendront notre modèle plus robuste et performant

4.2 Ensemble de données

Lors de notre étude sur l'acquisition de données, nous avons rassemblé un groupe de 20 individus, composé d'hommes et de femmes (11 hommes et 9 femmes) âgés entre 18 et 24 ans. Notre objectif était de collecter des informations précises sur les mouvements effectués par ces individus en utilisant des capteurs EMG placés sur l'avant-bras. Nous avons sélectionné sept mouvements spécifiques à étudier qui sont illustrés dans le tableau 4.1, et pour chaque mouvement, nous avons demandé aux participants de réaliser dix répétitions de cinq secondes chacune, avec un temps de repos de trois secondes entre chaque répétition.

Il convient de noter que la préparation et l'enregistrement des données pour chaque individu prenaient généralement entre 15 et 20 minutes. Cette approche méthodique, combinant l'utilisation de capteurs EMG et un protocole précis, nous a permis de recueillir des données significatifs sur chaque mouvement des participants. La figure 4.1 illustre une personne sur qui nous avons collecté ses données, mettant en évidence l'utilisation des capteurs EMG sur l'avant-bras.

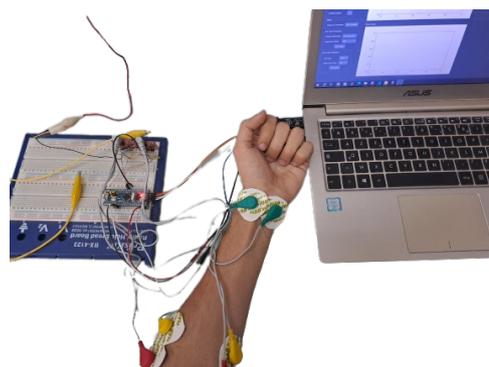




FIG. 4.1 : Exemple de collecte de données

| Mouvements | Main fermée | Main ouverte | Pouce fléchi | Index fléchi | Majeur fléchi | Annulaire fléchi | Auriculaire fléchi |
|------------|---|---|---|---|--|---|---|
| Images |  |  |  |  |  |  |  |

TAB. 4.1 : Les différents mouvements de la main

4.2.1 Répartition des données

Lors de la collecte des données, nous avons recueilli 5000 échantillons pour chaque électrode ($f_s = 1000Hz$). Nous avons répété la procédure 10 fois pour chaque mouvement, chaque répétition durait 5 secondes avec des pauses de 3 secondes.

Étant donné que notre base de données est équilibrée¹, et que nous avons choisi d'utiliser une technique de fenêtrage superposé pour une taille de fenêtre de 200 et un incrément de 20 (le choix de ces derniers est justifié à la section 4.5), il est nécessaire de calculer le nouveau nombre d'échantillons générés par cette méthode avant de procéder à la subdivision de nos données par la formule citée dans la section 2.4.

¹C'est à dire que chaque mouvement a le même nombre d'échantillons

$$N_{FS} = \frac{5000 - 200}{20} + 1 = 241$$

Pour déterminer l'ensemble de données généré, nous devons multiplier le nouveau nombre d'échantillons générés par le nombre de mouvements (7) et par le nombre de répétitions (10) pour chaque mouvement, a savoir $241 \times 7 \times 10 = 16870$ échantillons pour chaque individu.

Ainsi, notre ensemble de données est composé de 16870 échantillons. Pour la répartition de cet ensemble, nous avons choisi d'allouer 80% pour la phase d'entraînement et 20% pour la phase de test. Le tableau 4.2 résume la répartition de notre ensemble de données.

| Ensemble | Pourcentage (%) | Nombre d'échantillons |
|--------------|-----------------|-----------------------|
| Entraînement | 80 | 13496 |
| Test | 20 | 3374 |

TAB. 4.2 : Répartition de notre ensemble de données

4.3 Métriques d'évaluations utilisées

La qualité d'un modèle se mesure par sa capacité à généraliser son apprentissage à de nouvelles données et à produire des résultats précis et pertinents. Les mesures d'évaluation sont des indicateurs quantitatifs utilisés pour évaluer la qualité d'un modèle en fonction de ses performances sur des données d'entraînement et de test.

Dans ce qui suit, nous suggérons l'utilisation de diverses métriques d'évaluation énumérées ci-dessous.

4.3.1 La précision (Accuracy)

C'est la mesure du nombre de prédictions correctes par rapport au nombre total de prédictions effectuées pour un ensemble de données. Cette métrique peut être trompeuse si les classes sont déséquilibrées.

$$\text{Précision (\%)} = \frac{\text{Nombre de prédictions correctes}}{\text{Nombre total de prédictions effectuées}} \times 100 \quad (4.1)$$

4.3.2 Matrice de confusion

La matrice de confusion est une représentation tabulaire qui permet d'évaluer la performance d'un modèle de classification en comparant les prédictions du modèle avec les valeurs réelles des données. Elle est utilisée pour analyser la qualité des résultats de classification obtenus.

Elle est généralement constituée de deux axes : l'axe des prédictions (les classes prédites par le modèle) et l'axe des valeurs réelles (les classes réelles des données). Elle est divisée en plusieurs cellules qui contiennent des informations sur les prédictions effectuées par le modèle.

Dans une matrice de confusion typique 2×2 comme montré dans la figure 14, les cellules sont réparties en quatre catégories principales :

| | | Classes réelles | |
|------------------|---------|----------------------|----------------------|
| | | Positif | Négatif |
| Classes prédites | Positif | VP Vrais Positifs | FP Faux Positifs |
| | Négatif | FN Faux Négatifs | VN Vrais Négatifs |

FIG. 4.2 : Matrice de confusion

- **Les vrais positifs (VP)** : Il s'agit des cas où le modèle a correctement prédit une classe positive. Cela signifie que le modèle a prédit correctement qu'une instance appartient à une classe donnée et que cette prédiction correspond à la vérité terrain.
- **Les vrais négatifs (VN)** : Il s'agit des cas où le modèle a correctement prédit une classe négative. Cela signifie que le modèle a prédit correctement qu'une instance n'appartient pas à une classe donnée et que cette prédiction correspond à la vérité terrain.
- **Les faux positifs (FP)** : Il s'agit des cas où le modèle a incorrectement prédit une classe positive. Cela signifie que le modèle a prédit à tort qu'une instance appartient à une classe donnée alors qu'en réalité, elle n'appartient pas à cette classe.
- **Les faux négatifs (FN)** : Il s'agit des cas où le modèle a incorrectement prédit une classe négative. Cela signifie que le modèle a prédit à tort qu'une instance n'appartient pas à une classe donnée alors qu'en réalité, elle appartient à cette classe.

Dans un cas général, une matrice de confusion de taille $n \times n$ est utilisée pour évaluer un modèle de classification avec n classes différentes comme illustré dans la figure 4.3.

| | $C_0 \dots C_{k-1}$ | C_k | $C_{k+1} \dots C_n$ |
|---------------------|---------------------|-------|---------------------|
| $C_{k+1} \dots C_n$ | VN | FN | VN |
| C_k | FP | VP | FP |
| $C_0 \dots C_{k-1}$ | VP | FN | VN |

FIG. 4.3 : Matrice de confusion générale

- **Vrai Positif (VP)** : Le nombre d'observations de la classe réelle k qui ont été correctement prédites comme appartenant à la classe k .
- **Faux Positif (FP)** : Le nombre d'observations qui ont été incorrectement prédites comme appartenant à la classe k , alors qu'elles appartiennent réellement à une autre classe j ($j \neq k$).
- **Faux Négatif (FN)** : Le nombre d'observations de la classe réelle k qui ont été incorrectement prédites comme n'appartenant pas à la classe k .
- **Vrai Négatif (VN)** : Le nombre d'observations qui ont été correctement prédites comme n'appartenant pas à la classe k , lorsque la classe réelle est en effet une autre classe j ($j \neq k$).

La matrice de confusion permet de calculer plusieurs mesures de performance importantes, telles que le sensibilité et la spécificité.

La sensibilité

La sensibilité est défini comme le nombre de vrais positifs divisé par la somme des vrais positifs et des faux négatifs. Elle quantifie la proportion des instances positives réelles que le modèle parvient à identifier correctement. La formule peut être exprimée de la manière suivante :

$$\text{Sensibilité (\%)} = \frac{VP}{VP + FN} \times 100 \quad (4.2)$$

La spécificité

La spécificité peut être exprimée comme le rapport entre le nombre de vrais négatifs et la somme des vrais négatifs et des faux positifs. Elle mesure la proportion des exemples négatifs réels que le modèle parvient à détecter correctement. La formule est la suivante :

$$\text{Spécificité (\%)} = \frac{VN}{VN + FP} \times 100 \quad (4.3)$$

4.4 Variations du nombre d'électrodes utilisées

Le nombre de capteurs EMG utilisés peut varier en fonction des besoins spécifiques de l'application. Dans certaines littératures, un seul capteur EMG est utilisé et peut être suffisant pour obtenir des informations sur l'activité d'un muscle spécifique [49]. Cependant, dans des applications plus complexes, il peut être nécessaire d'utiliser plusieurs capteurs EMG pour obtenir des données sur plusieurs muscles simultanément [24][14][21]. Dans cette section nous verrons l'effet de la variation du nombre d'électrodes et du nombre de mouvements sur les résultats de classification en utilisant le même schéma de prétraitement, d'extraction de caractéristiques et de classification.

Il est important de souligner que nous avons pu identifier avec précision le meilleur emplacement des électrodes comme illustré dans la figure 4.4 grâce à l'aide de monsieur Shane Grubbs, chef des services cliniques chez *Procare Prosthetics and Orthotics* de l'Université du Texas *Southwestern*.



(a) Placement de la première électrode

(b) Placement de la deuxième électrode

FIG. 4.4 : Emplacement des électrodes

| Nombre d'électrodes | Nombre de mouvements | Taux de classification (%) | | | | |
|---------------------|----------------------|----------------------------|-------|-------|-------|-------|
| | | SVM | k-NN | LDA | LR | RF |
| 1 | 2 | 96.78 | 96.88 | 79.22 | 80.80 | 97.19 |
| | 3 | 95.47 | 94.44 | 72.80 | 78.84 | 95.98 |
| | 4 | 93.22 | 93.56 | 67.73 | 76.98 | 94.04 |
| | 5 | 91.97 | 91.64 | 64.01 | 74.55 | 93.19 |
| | 6 | 90.05 | 89.12 | 62.85 | 72.92 | 92.60 |
| | 7 | 89.90 | 88.39 | 60.40 | 70.72 | 92.10 |
| | 2 | 2 | 97.61 | 96.80 | 81.23 | 85.90 |
| 3 | | 96.33 | 95.60 | 79.15 | 82.75 | 97.63 |
| 4 | | 95.06 | 95.14 | 78.05 | 79.66 | 97.03 |
| 5 | | 94.14 | 94.85 | 75.33 | 78.37 | 96.88 |
| 6 | | 93.45 | 94.51 | 74.34 | 77.05 | 96.53 |
| 7 | | 92.59 | 93.69 | 73.88 | 76.45 | 96.03 |

TAB. 4.3 : Taux de classification des mouvements par variation des nombres d'électrodes et des mouvements

4.4.1 Discussion des résultats

Le taux de classification diminue avec l'augmentation du nombre de mouvements. L'utilisation de deux électrodes plutôt qu'une seule permet de capturer plus de contractions musculaires provenant de différentes zones de l'avant-bras, ce qui améliore le taux de classification. Avoir une plus grande diversité de signaux EMG grâce à deux électrodes permet au modèle de mieux représenter les actions effectuées par l'utilisateur. En revanche, une seule électrode limite la quantité d'informations disponibles et peut entraîner une diminution de précision dans la classification des mouvements.

4.5 Test du fenêtrage

Dans cette section, nous allons nous concentrer sur la deuxième étape de notre schéma de classification 3.13, à savoir le fenêtrage. Deux schémas de fenêtrage ont été utilisés : le fenêtrage disjoint et le fenêtrage superposé. Pour évaluer l'efficacité de ces deux schémas de fenêtrage dans la classification, nous avons effectué des expériences en utilisant l'enregistrement d'un seul individu choisi aléatoirement à partir de notre base de données. Les mêmes caractéristiques temporelles et fréquentielles ont été extraites à partir de chaque fenêtre, puis plusieurs classifieurs ont été entraînés et évalués sur ces caractéristiques. Nous examinerons les performances des différents schémas de fenêtrage, notamment la précision de classification en variant la taille de la fenêtre (TAB : 4.4) et de l'incrémenta-tion (TAB : 4.5) ainsi que le temps de calcul (TAB : 4.6) pour chaque schéma. De plus, nous analyserons l'effet du choix de la taille de la fenêtre et de l'incrémenta-tion sur la précision de classification.

| | Taille de la fenêtre - incrément | 200-20 | 180-18 | 160-16 | 140-14 | 120-12 | 100-10 |
|----------------|----------------------------------|--------------|--------|--------|--------|--------|--------|
| Classifieur(%) | SVM | 92.59 | 90.49 | 89.61 | 87.32 | 85.65 | 84.20 |
| | k-NN | 93.68 | 90.52 | 88.72 | 86.80 | 83.59 | 81.80 |
| | RF | 96.29 | 94.37 | 93.49 | 91.22 | 90.61 | 89.41 |
| | LR | 76.45 | 63.06 | 62.10 | 61.28 | 60.07 | 59.10 |
| | LDA | 73.88 | 64.35 | 62.63 | 61.41 | 59.69 | 58.45 |

TAB. 4.4 : Résultats de la précision par variation de la taille de la fenêtre

| | Increment (%) | 10 | 20 | 30 | 40 | 50 | 60 |
|-----------------|---------------|--------------|-------|-------|-------|-------|-------|
| Classifieur (%) | SVM | 92.59 | 88.48 | 87.12 | 87.23 | 84.40 | 81.27 |
| | k-NN | 93.68 | 83.70 | 79.36 | 75.52 | 74.48 | 70.73 |
| | RF | 96.29 | 91.26 | 87.83 | 87.58 | 87.02 | 86.98 |
| | LR | 76.45 | 74.00 | 73.31 | 73.28 | 72.18 | 72.02 |
| | LDA | 73.88 | 66.96 | 65.35 | 64.62 | 63.85 | 62.98 |

TAB. 4.5 : Résultats de la précision par variation du pourcentage d'incrementation (taille de la fenêtre fixe = 200)

Pour le test du temps calcul, nous avons choisi la taille de fenêtre et d'incrément ayant donné les meilleurs résultats.

| Type de fenêtrage | Temps de calcul (secondes) | Taille de la fenêtre | L'incrément |
|---------------------|----------------------------|----------------------|-------------|
| Fenêtrage disjoint | 0.082 | 200 | / |
| Fenêtrage superpose | 0.1530 | 200 | 20 |

TAB. 4.6 : Temps d'exécution de chaque type de fenêtrage

4.5.1 Discussion des résultats

Les résultats obtenus révèlent les avantages et les limites de chaque schéma de fenêtrage. Le schéma disjoint peut être efficace pour capturer des événements ou des motifs locaux, mais il peut manquer des informations contextuelles entre les fenêtres, ce qui explique les résultats de classification obtenus. En revanche, le schéma superposé peut mieux représenter les variations temporelles, mais il peut introduire une redondance d'informations et augmenter la complexité du traitement.

En termes de temps de calcul et de complexité, le schéma adjacent est plus avantageux. En générant moins de fenêtres, le nombre de données est plus faible par rapport à celui obtenu par chevauchement, ce qui réduit considérablement le temps de calcul. Un incrément égal à moins de 50% de la taille de la fenêtre choisie donne de bons résultats. En particulier, le choix de 10% a donné les meilleurs résultats, tous classifieurs confondus. Cependant, si l'on choisit plus de 50% de la fenêtre, les résultats diminuent mais restent acceptables. Sur la base des résultats obtenus, nous poursuivrons notre étude en utilisant un **fenêtrage superposé** avec une taille de fenêtre de **200** et un incrément de **20**.

4.6 Test des caractéristiques

Dans cette section de notre projet, nous entreprenons une étude comparative afin d'évaluer l'efficacité de trois méthodes d'extraction de caractéristiques sur la classification. Il convient de noter que ces caractéristiques ont été préalablement introduites dans le chapitre 2. Après chaque étape d'extraction, nous utilisons l'Analyse en Composantes Principales (ACP) pour réduire la dimensionnalité et préserver les informations pertinentes. La première partie se concentre sur l'extraction des caractéristiques temporelles (TAB : 4.7), tandis que la deuxième partie se penche sur l'extraction des caractéristiques fréquentielles (TAB : 4.8). Enfin, la troisième partie explore l'extraction simultanée des caractéristiques temporelles et fréquentielles (TAB : 4.9). En évaluant ces approches d'extraction et en analysant leurs effets sur la classification à l'aide de plusieurs classifieurs, nous pourrions déterminer leur efficacité respective.

| Mouvements | Taux de classification (%) | | | | |
|--------------------|------------------------------|--------------|--------------|--------------|--------------|
| | Caractéristiques temporelles | | | | |
| | SVM | k-NN | LDA | LR | RF |
| Main fermée | 95.19 | 94.61 | 75.49 | 77.73 | 96.62 |
| Main ouverte | 92.42 | 96.62 | 73.04 | 75.18 | 96.52 |
| Pouce fléchi | 79.61 | 82.72 | 74.48 | 71.73 | 93.22 |
| Index fléchi | 83.27 | 86.45 | 77.63 | 76.51 | 95.81 |
| Majeur fléchi | 92.57 | 94.30 | 71.60 | 71.78 | 97.46 |
| Annulaire fléchi | 81.47 | 80.90 | 65.64 | 68.67 | 93.24 |
| Auriculaire fléchi | 79.39 | 89.84 | 61.61 | 63.45 | 90.60 |
| La moyenne | 86.40 | 89.33 | 71.35 | 72.15 | 94.81 |

TAB. 4.7 : Performances atteintes sur chaque mouvement avec les caractéristiques temporelles

| Mouvements | Taux de classification (%) | | | | |
|--------------------|---------------------------------|--------------|--------------|--------------|--------------|
| | Caractéristiques fréquentielles | | | | |
| | SVM | kNN | LDA | LR | RF |
| Main fermée | 81.51 | 72.38 | 68.69 | 64.29 | 84.94 |
| Main ouverte | 69.12 | 64.78 | 57.22 | 65.82 | 75.50 |
| Pouce fléchi | 63.94 | 51.69 | 58.16 | 58.28 | 69.35 |
| Index fléchi | 59.47 | 57.80 | 57.99 | 69.32 | 73.31 |
| Majeur fléchi | 71.95 | 70.04 | 59.03 | 56.74 | 76.46 |
| Annulaire fléchi | 48.66 | 52.11 | 51.25 | 62.64 | 67.38 |
| Auriculaire fléchi | 47.18 | 52.26 | 57.59 | 50.61 | 69.14 |
| La moyenne | 62.54 | 60.61 | 58.56 | 61.10 | 73.72 |

TAB. 4.8 : Performances atteintes sur chaque mouvement avec les caractéristiques fréquentielles

| Mouvements | Taux de classification (%) | | | | |
|--------------------|--|--------------|--------------|--------------|--------------|
| | Caractéristiques temporelle et fréquentielles | | | | |
| | SVM | k-NN | LDA | LR | RF |
| Main fermée | 97.49 | 95.29 | 81.11 | 82.68 | 96.84 |
| Main ouverte | 97.92 | 97.46 | 73.49 | 73.01 | 96.93 |
| Pouce fléchi | 85.83 | 93.25 | 74.34 | 72.70 | 94.61 |
| Index fléchi | 91.83 | 89.78 | 69.54 | 72.01 | 96.81 |
| Mqjeur fléchi | 97.05 | 96.19 | 81.40 | 78.75 | 98.62 |
| Annulaire fléchi | 89.52 | 88.81 | 64.88 | 79.59 | 95.55 |
| Auriculaire fléchi | 88.25 | 95.24 | 72.40 | 76.44 | 92.70 |
| La moyenne | 92.59 | 93.69 | 73.88 | 76.45 | 96.03 |

TAB. 4.9 : Performances atteintes sur chaque mouvement avec les caractéristiques temporelles et fréquentielles

4.6.1 Discussion des résultats

Les résultats obtenus nous permettent de mener une étude comparative des différentes méthodes d'extraction des caractéristiques. Les performances obtenues varient considérablement entre les différentes approches.

Tout d'abord, l'extraction des caractéristiques fréquentielles a montré des résultats moins satisfaisants que les autres méthodes. Cela suggère que les informations liées à la dimension fréquentielle ne sont pas suffisantes pour une classification précise. Il est possible que ces caractéristiques ne capturent pas pleinement les motifs ou les relations nécessaires à la distinction des classes.

En revanche, l'extraction des caractéristiques temporelles a donné de meilleurs résultats, mais encore insuffisants pour atteindre une précision élevée dans la classification. Il est probable que ces caractéristiques soient plus discriminantes que les caractéristiques fréquentielles, mais qu'elles ne contiennent pas toutes les informations nécessaires pour une classification précise.

Cependant, l'extraction simultanée des caractéristiques temporelles et fréquentielles a montré de meilleures performances parmi les trois méthodes. Cette approche a permis de combiner les informations temporelles et fréquentielles, ce qui a conduit à une meilleure discrimination entre les classes et donc à une classification plus précise.

Ces résultats soulignent l'importance de prendre en compte à la fois les aspects temporels et fréquentiels lors de l'extraction de caractéristiques pour la classification.

Sur la base des résultats prometteurs de cette étude, nous envisageons d'utiliser l'extraction simultanée des caractéristiques temporelles et fréquentielles dans ce qui suit.

4.7 Test de la réduction de la dimension avec l'ACP

Dans cette section, nous nous intéressons à une étude comparative des performances de divers classifieurs, en examinant l'impact de l'analyse en composantes principales (ACP) sur ces performances par rapport à son absence. L'objectif principal de cette étude est d'évaluer l'effet de l'ACP sur les résultats de classification, afin de diminuer le nombre de caractéristiques utilisé. En d'autres termes, nous cherchons à déterminer si l'utilisation de l'ACP peut améliorer les performances de classification en réduisant le nombre de caractéristiques. Pour ce faire, nous comparerons les résultats obtenus par différents classifieurs lorsqu'ils sont appliqués aux données brutes et aux données transformées par l'ACP. Cette analyse comparative nous permettra de mieux comprendre l'impact de l'ACP sur la capacité des classifieurs à distinguer et à catégoriser les mouvements de manière précise et fiable. Le tableau 4.10 présente les performances obtenues dans les deux cas, c'est-à-dire avec et sans l'utilisation de l'ACP, ainsi que les temps de calcul associés, nous permettant ainsi de comparer les résultats dans les deux approches.

| Classifieurs | En appliquant l'ACP (22 composantes principales) | | Sans appliquer l'ACP (38 caractéristiques) | |
|--------------|---|-------------------------------|---|-------------------------------|
| | Taux de classifications (%) | Temps de calcul (secondes) | Taux de classifications (%) | Temps de calcul (secondes) |
| SVM | 92.59 | 18.2 | 90.42 | 22 |
| k-NN | 93.69 | 1.9 | 89.54 | 2.2 |
| LDA | 73.88 | 0.1 | 68.34 | 0.5 |
| LR | 76.45 | 1.6 | 70.64 | 3.9 |
| RF | 96.03 | 10.5 | 94.23 | 15.3 |

TAB. 4.10 : Comparaison des performances et des temps de calcul avec et sans utilisation de l'ACP

4.7.1 Discussion des résultats

Les résultats obtenus montrent clairement que l'utilisation de l'ACP a conduit à une amélioration des performances de classification. En conservant les informations pertinentes tout en réduisant la dimension des données (projection des caractéristiques), l'ACP a permis aux classifieurs d'accéder à des caractéristiques plus discriminantes et de mieux capturer les structures des données. L'ACP a été appliquée à un ensemble de données caractérisées par 38 variables (temporelles et fréquentielles) qui ont été réduits à 22 composantes principales, ce qui représente une réduction significative de la dimension des données. Cette réduction a permis de simplifier l'analyse tout en conservant une quantité importante d'informations. Les résultats obtenus confirment que cette réduction de dimension a été bénéfique, car les performances de classification se sont améliorées. De plus, il convient de souligner que la variance retenue pour ces 22 composantes principales est de 95%, ce qui indique que ces composantes représentent une grande partie de la va-

riabilité des données originales. Cela renforce la fiabilité et la pertinence de l'approche par ACP dans ce contexte spécifique. En outre, il est important de noter que le temps de calcul a été considérablement amélioré grâce à l'ACP, ce qui permet d'obtenir rapidement les résultats de classification.

4.8 Test sur la base de données

Afin d'évaluer les performances de notre modèle et montrer son efficacité, nous allons le tester sur différents enregistrements de chaque individu. La taille de la fenêtre, l'incrément et les caractéristiques utilisés sont ceux sélectionnés dans les sections 4.5 et 4.6. Nous avons recueilli les résultats de ces tests dans le tableau 4.11, accompagnés des différentes mesures de métriques illustrées dans le tableau 4.12.

Les résultats obtenus fournissent un aperçu de la précision de notre modèle pour la classification des individus. Nous examinerons attentivement ces résultats en vue d'une analyse approfondie et d'une discussion concernant l'efficacité et la fiabilité de notre approche de classification. Les diagrammes illustrés dans la section 4.9 fourniront une représentation visuelle des performances du modèle,

| Sujets | Taux de classification (%) | | | | |
|----------------|----------------------------|--------------|--------------|--------------|--------------|
| | k-NN | RF | SVM | LDA | LR |
| Sujet 1 | 89.03 | 93.44 | 76.61 | 63.27 | 81.41 |
| Sujet 2 | 69.20 | 80.58 | 59.86 | 61.43 | 62.27 |
| Sujet 3 | 85.06 | 87.61 | 73.77 | 65.76 | 76.82 |
| Sujet 4 | 75.69 | 79.57 | 67.16 | 71.42 | 68.26 |
| Sujet 5 | 91.37 | 93.83 | 91.58 | 79.09 | 81.30 |
| Sujet 6 | 93.96 | 96.03 | 92.59 | 76.08 | 80.26 |
| Sujet 7 | 94.45 | 96.97 | 92.50 | 86.47 | 88.59 |
| Sujet 8 | 95.10 | 93.33 | 94.04 | 83.69 | 87.61 |
| Sujet 9 | 91.52 | 91.05 | 92.97 | 81.68 | 90.00 |
| Sujet 10 | 51.65 | 62.47 | 54.44 | 46.94 | 57.67 |
| Sujet 11 | 84.94 | 88.29 | 84.35 | 76.46 | 82.51 |
| Sujet 12 | 64.31 | 72.82 | 59.09 | 51.00 | 59.54 |
| Sujet 13 | 88.14 | 91.10 | 88.76 | 84.16 | 84.47 |
| Sujet 14 | 70.21 | 80.91 | 72.91 | 69.08 | 79.90 |
| Sujet 15 | 91.46 | 91.10 | 90.84 | 77.32 | 84.76 |
| Sujet 16 | 63.30 | 70.95 | 53.46 | 53.84 | 52.87 |
| Sujet 17 | 72.91 | 76.49 | 62.89 | 63.30 | 57.94 |
| Sujet 18 | 85.74 | 83.52 | 85.68 | 77.26 | 80.91 |
| Sujet 19 | 89.89 | 92.41 | 88.05 | 80.28 | 79.28 |
| Sujet 20 | 47.27 | 67.75 | 50.50 | 50.32 | 55.84 |
| Moyenne | 79.76 | 84.51 | 76.60 | 69.94 | 74.61 |

TAB. 4.11 : Les performances atteintes sur chaque sujet

Discussion des résultats

D'après les résultats présentés dans le tableau 4.11, il est observé que certains classifieurs, tels que le RF avec un taux de classification moyen de 84.51%, le k-NN avec un taux de 79.76% et le SVM avec un taux de 76.60% montrent des performances de classification supérieures. En revanche, d'autres classifieurs, comme le LDA et le LR, affichent des résultats moins satisfaisants. Une explication plausible à ces différences de performance peut être attribuée aux principes intrinsèques des classifieurs.

Le RF et le SVM ont montré de bonnes performances en raison de leurs principes et fonctionnalités distincts. Random Forest utilise un ensemble d'arbres de décision, permettant de réduire les effets du bruit. D'autre part, SVM est capable de trouver un hyperplan d'optimisation qui sépare les échantillons de différentes classes dans un espace de plus haute dimension.

k-NN est capable d'obtenir de bons résultats en raison de sa capacité à gérer efficacement des frontières de décisions non linéaires. Cette propriété le rend particulièrement adapté pour résoudre des problèmes de classification complexes, où les classes peuvent se chevaucher ou présenter des relations non linéaires.

En revanche, le LDA est un algorithme qui cherche à trouver une projection linéaire des données dans un espace de plus basse dimension tout en maximisant la séparation entre les classes. LDA suppose que les classes sont linéairement séparables, ce qui peut limiter sa capacité à gérer des situations où les classes se chevauchent ou présentent des relations non linéaires, entraînant ainsi des performances de classification inférieures.

Ainsi, Le LR a montré des résultats un peu faibles. Cela peut être attribué à sa fonction logistique qui limite les prédictions entre 0 et 1. Lorsque les valeurs prédites se trouvent proches de 0,5, cela indique que le modèle est incertain quant à la classification. Par conséquent, les prédictions peuvent être moins précises et les performances du modèle peuvent être affaiblies.

| Sujets | k-NN (%) | | RF (%) | | SVM (%) | | LDA (%) | | LR (%) | |
|----------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| | SENS | SPEC |
| Sujet 1 | 87.53 | 86.32 | 92.74 | 92.04 | 75.71 | 75.06 | 63.20 | 62.17 | 80.14 | 80.86 |
| Sujet 2 | 68.90 | 68.45 | 80.20 | 79.42 | 59.50 | 59.10 | 60.34 | 59.65 | 62.00 | 62.03 |
| Sujet 3 | 84.23 | 84.67 | 86.11 | 83.19 | 72.22 | 72.67 | 63.54 | 64.09 | 75.99 | 76.01 |
| Sujet 4 | 73.55 | 74.58 | 78.00 | 77.33 | 65.10 | 64.32 | 70.66 | 70.35 | 67.78 | 67.62 |
| Sujet 5 | 91.12 | 90.77 | 90.12 | 91.38 | 90.34 | 89.44 | 77.88 | 78.24 | 80.88 | 80.40 |
| Sujet 6 | 93.60 | 93.15 | 95.32 | 95.16 | 92.00 | 92.07 | 75.76 | 75.38 | 79.63 | 79.99 |
| Sujet 7 | 92.84 | 93.62 | 93.42 | 92.55 | 91.84 | 92.00 | 85.95 | 85.33 | 87.88 | 88.05 |
| Sujet 8 | 94.18 | 94.70 | 92.22 | 92.90 | 93.40 | 91.14 | 83.50 | 83.29 | 86.80 | 86.73 |
| Sujet 9 | 91.21 | 90.72 | 90.97 | 89.77 | 90.51 | 91.06 | 80.86 | 79.33 | 89.54 | 89.69 |
| Sujet 10 | 51.05 | 49.65 | 62.04 | 60.88 | 52.95 | 53.00 | 45.53 | 45.11 | 57.12 | 57.26 |
| Sujet 11 | 83.85 | 84.24 | 86.62 | 85.34 | 82.53 | 83.08 | 76.24 | 76.19 | 81.59 | 81.92 |
| Sujet 12 | 63.91 | 63.43 | 70.20 | 71.68 | 59.00 | 58.90 | 50.98 | 50.77 | 59.10 | 59.09 |
| Sujet 13 | 87.10 | 87.59 | 90.10 | 89.73 | 85.40 | 83.90 | 83.39 | 83.84 | 83.74 | 84.00 |
| Sujet 14 | 70.02 | 69.34 | 80.30 | 80.25 | 71.19 | 70.66 | 68.74 | 68.80 | 78.12 | 78.37 |
| Sujet 15 | 91.35 | 90.46 | 91.02 | 90.78 | 89.77 | 89.20 | 76.63 | 76.94 | 83.84 | 83.98 |
| Sujet 16 | 62.60 | 62.44 | 70.88 | 68.40 | 53.06 | 53.14 | 52.73 | 52.90 | 52.47 | 52.30 |
| Sujet 17 | 71.47 | 72.07 | 74.36 | 75.47 | 61.70 | 61.50 | 63.04 | 63.84 | 57.01 | 56.30 |
| Sujet 18 | 84.55 | 80.23 | 82.96 | 82.19 | 83.80 | 84.73 | 75.64 | 76.09 | 80.83 | 80.50 |
| Sujet 19 | 87.63 | 88.83 | 90.14 | 91.67 | 87.60 | 84.33 | 79.83 | 80.00 | 78.15 | 78.36 |
| Sujet 20 | 47.09 | 46.52 | 67.00 | 67.09 | 50.00 | 48.22 | 49.23 | 49.56 | 54.52 | 54.90 |
| Moyenne | 78.89 | 78.59 | 83.24 | 82.86 | 75.38 | 74.88 | 69.18 | 69.09 | 73.86 | 73.92 |

SENS : Sensibilité ; **SPEC** : Spécificité

TAB. 4.12 : Résultats des métriques sur chaque sujet

Discussion des résultats

Les résultats obtenus pour les métriques de spécificité et de sensibilité sont extrêmement prometteurs, ce qui témoigne de la robustesse de notre modèle. Ces résultats indiquent que notre modèle est capable de classer avec précision les échantillons positifs et négatifs, en minimisant à la fois les faux positifs et les faux négatifs. Cette performance montre la fiabilité et la capacité de notre modèle à généraliser et à fournir des prédictions précises sur de nouveaux exemples. Ces résultats sont encourageants et renforcent la confiance dans notre approche et sa capacité à être appliquée à notre problème de classification.

On termine cette discussion en exposant les matrices de confusion des résultats du meilleur sujet des 5 classifieurs SVM, KNN, LDA, RF et LR, illustrées dans les figures 4.5 et 4.6. Il convient de noter que les classes HC, HO, I, M, P, R et T correspondent respectivement à la main fermée, la main ouverte, l'index fléchi, le majeur fléchi, l'auriculaire fléchi, l'annulaire fléchi et le pouce fléchi.

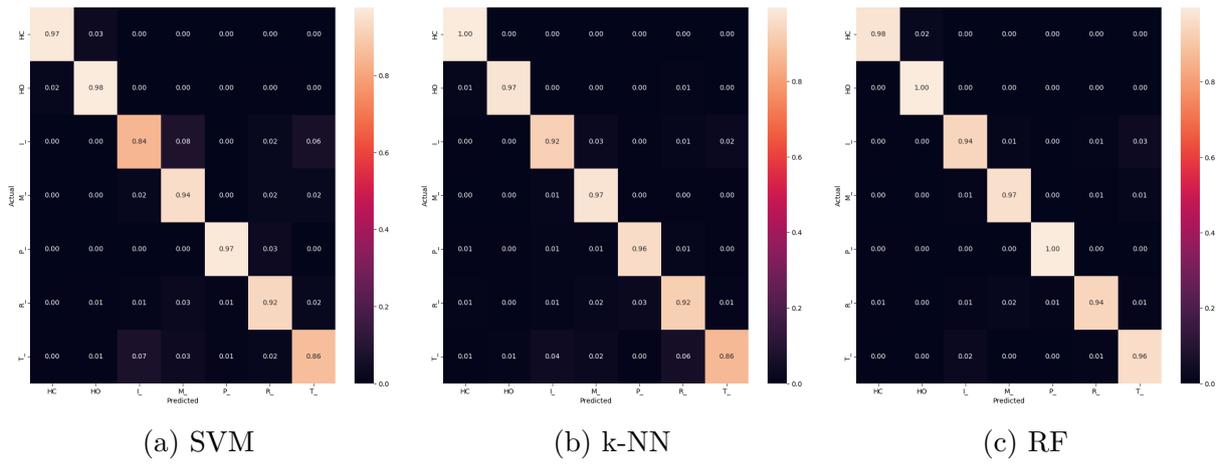


FIG. 4.5 : Matrices de confusion du meilleur sujet pour les classifieurs SVM, k-NN et RF

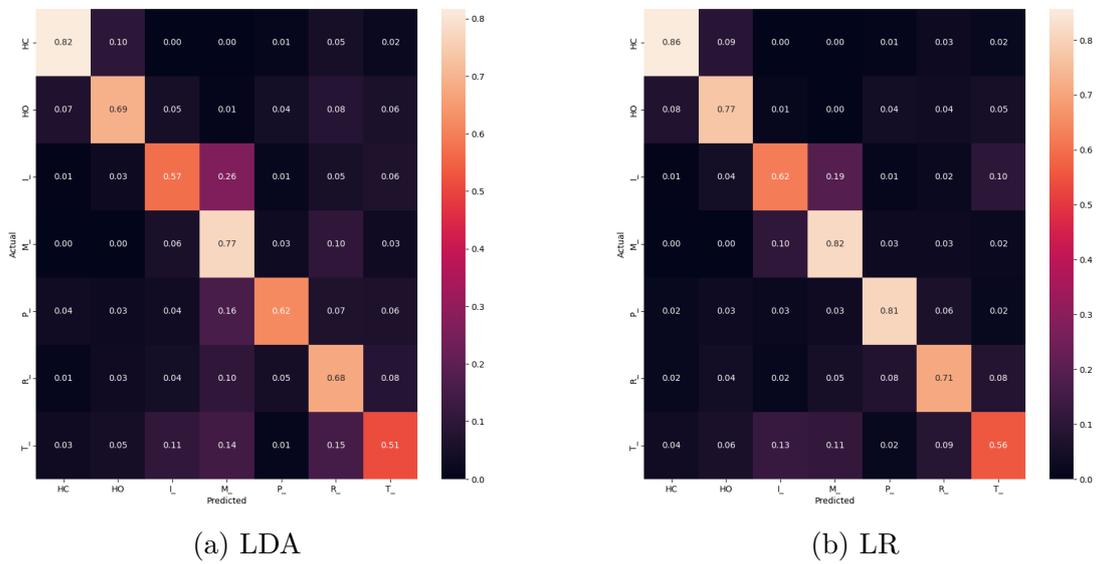


FIG. 4.6 : Matrices de confusion du meilleur sujet pour les classifieurs LDA et LR

4.9 Récapitulatif des résultats

Les figures 4.7 et 4.8 ci-dessous présentent un résumé des performances atteintes par les 20 sujets, tandis que la figure 4.9 illustre les performances moyennes atteintes par ces sujets. En outre, la figure 4.10 présente les moyennes des métriques de sensibilité et de spécificité pour les 20 sujets.

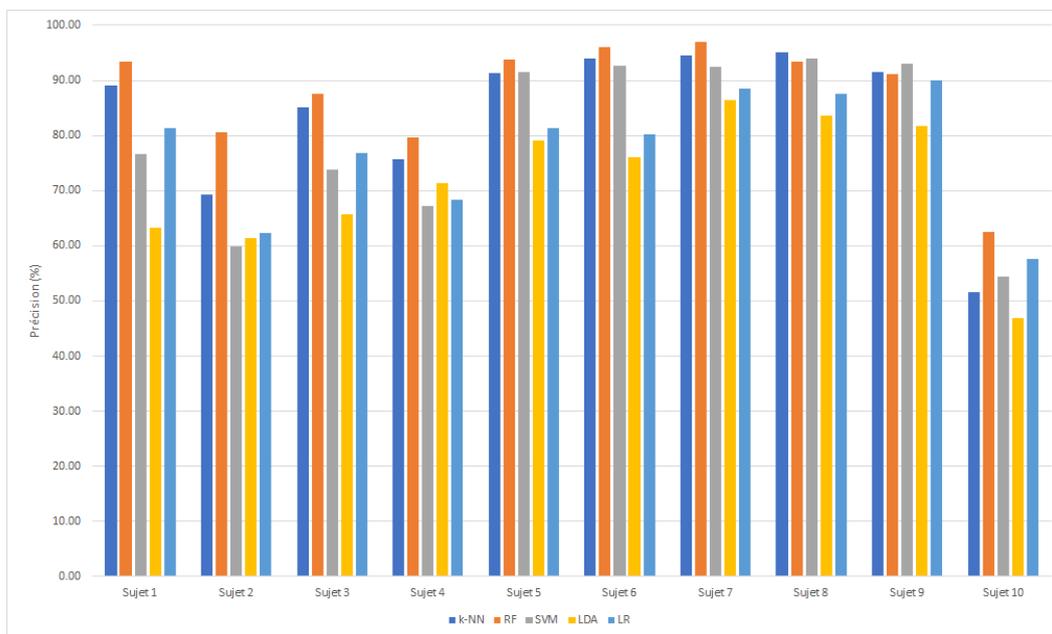


FIG. 4.7 : Les performances atteintes (Sujets 1 - 10)

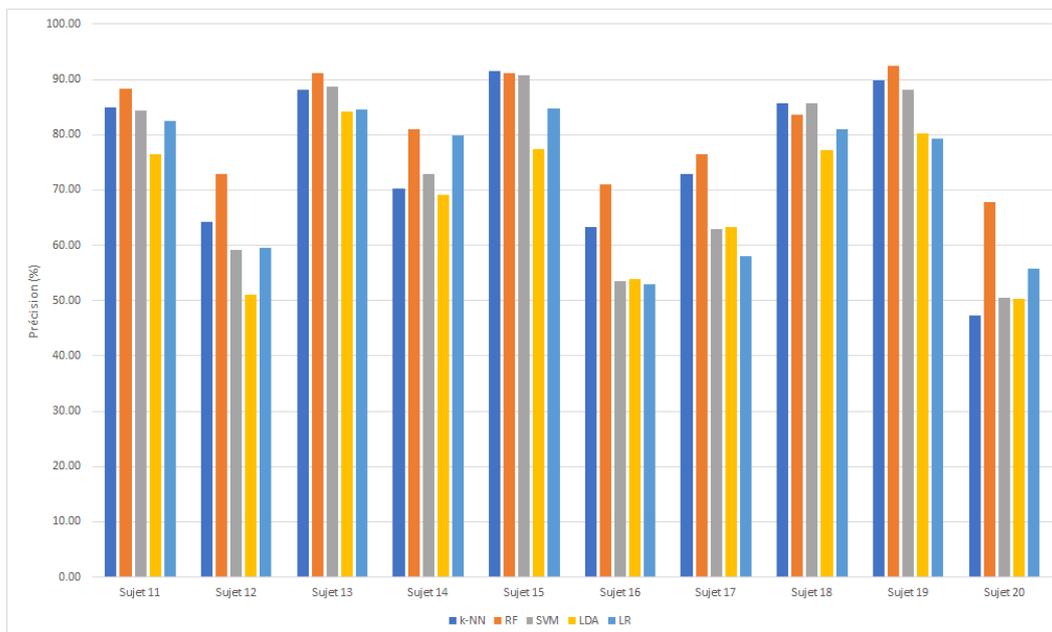


FIG. 4.8 : Les performances atteintes (Sujets 11 - 20)

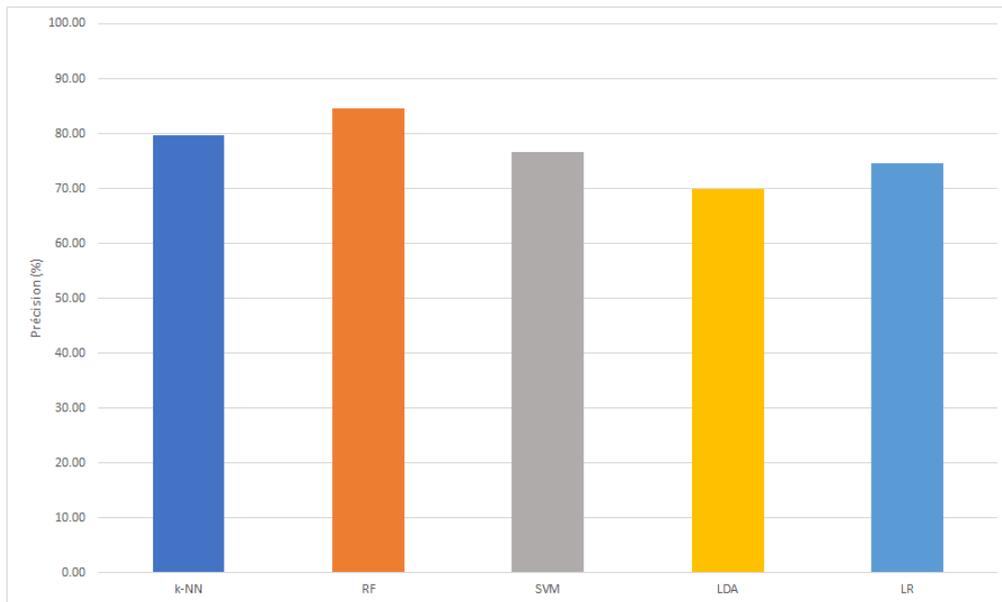


FIG. 4.9 : Performances moyennes atteintes des 20 sujets

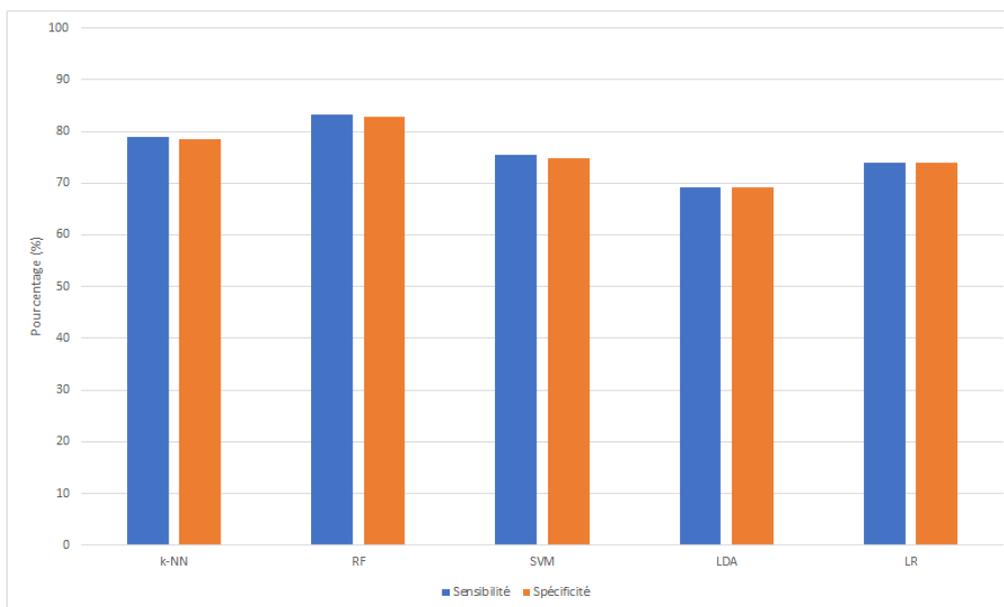


FIG. 4.10 : Moyennes de sensibilités et de spécificités des 20 sujets

4.10 Conclusion

En conclusion, après avoir comparé différentes méthodes et utilisé les résultats optimaux, nous avons pu obtenir des performances de classification très satisfaisantes, le tout en un temps réduit. De plus, nous avons utilisé des modèles à faible consommation mémoire, ce qui est un avantage significatif. Nos taux de classification approchent ceux rapportés dans la littérature, ce qui renforce la validité de notre approche. Ces résultats ouvrent la voie à de nombreuses possibilités et implications dans le domaine de la classification, en particulier pour les applications où la réduction du temps de calcul et l'utilisation efficace des ressources sont essentielles. De plus, nos travaux futurs pourraient se concentrer sur l'extension de notre approche à d'autres domaines ou sur l'amélioration de nos performances en explorant de nouvelles méthodes ou en affinant les paramètres existants.

Conclusion et perspectives

Conclusion et perspectives

En conclusion, cette étude présente une approche basée sur l'apprentissage automatique, visant à classifier les signaux EMG en gestes de la main de manière rapide et efficace, tout en optimisant l'utilisation des ressources. L'étude présente le processus de sélection des différentes méthodes et caractéristiques, mettant en évidence leur pertinence et leur impact sur les performances de classification. Les résultats obtenus sont extrêmement prometteurs, avec une moyenne de taux de classification de 84.51% pour le RF, 79.76% pour le k-NN, 76.60% pour le SVM, 74.61% pour le LR et 69.94% pour le LDA.

Ces performances montrent la robustesse et l'efficacité du modèle proposé, même en prenant en compte les contraintes des ressources matérielles utilisées. De plus, il est intéressant de souligner que ces résultats rivalisent avec ceux obtenus par des architectures complexes, telles que les réseaux de neurones convolutionnels (CNN). Cette constatation est significative, car elle suggère qu'un modèle léger et rapide peut obtenir des performances de classification comparables, ce qui représente un avantage considérable en termes d'efficacité de calcul et d'utilisation des ressources.

En résumé, cette étude apporte une contribution importante en proposant un modèle d'apprentissage automatique efficace pour la classification des signaux EMG en gestes de la main. Les résultats encourageants obtenus ouvrent de nouvelles perspectives pour le développement d'applications pratiques nécessitant des ressources réduites. Des recherches ultérieures pourraient se concentrer sur l'optimisation du modèle, l'exploration de nouvelles caractéristiques et l'évaluation des ensembles de données plus vastes, afin de consolider les résultats et de favoriser une adoption plus large de cette approche novatrice.

En répondant à la problématique du projet, nous avons accompli une étape importante. Cependant, il est important de noter qu'il existe toujours des possibilités d'améliorations futures à explorer. Dans la suite de cette section, nous allons mettre en évidence quelques pistes d'amélioration potentielles.

- Une amélioration potentielle pour réduire les interférences et le bruit ajouté aux signaux EMG et d'acquérir de meilleurs capteurs qui sont directement placés sur l'avant bras sans utiliser de câbles.
- L'utilisation d'un microcontrôleur ayant un CAN avec une meilleure résolution peut augmenter la précision de classification
- Ce modèle peut être directement implémenter sur une Raspberry Pi qui communi-

quera avec le microcontrôleur en utilisant un protocole SPI, cela permettrait d'avoir un système totalement embarqué.

- L'utilisation de la méthode DMA pour lire les valeurs du CAN offre la possibilité de rajouter des composants a ce potentiel système embarqué (scalabilité) tout en gardant l'efficacité de ce dernier , car le CPU n'est pas en charge de la conversion A/N, laissant ce dernier la possibilité de contrôler des moteurs par exemple
- Une application envisageable du modèle proposé consiste en la réhabilitation des patients présentant une altération de la motricité de leur main à la suite d'un accident vasculaire cérébral (AVC). L'utilisateur pourrait ainsi participer à des séances de rééducation structurées en deux étapes distinctes. Dans la première étape, des dispositifs mécaniques placés au niveau de la main seraient utilisés pour entraîner la main affectée, en tirant parti de l'utilisation de l'autre main grâce à des techniques de traitement d'image. Dans la deuxième étape, un système embarqué équipé d'électrodes EMG serait employé pour contrôler la main affectée, en s'appuyant toujours sur le dispositif mécanique, mais cette fois-ci, permettant des mouvements presque "naturels". À terme, grâce à ce système de réhabilitation, le patient retrouverait progressivement la mobilité de sa main. [Il est à noter que tous les patients atteints ne peuvent pas obtenir des résultats efficaces grâce à cette méthode de rééducation. L'efficacité de cette approche peut varier en fonction de la gravité de l'atteinte de la main chez chaque individu].
- L'intégration de l'interface proposée dans cette application simplifierait le suivi des patients par les professionnels de la santé en leur fournissant une interface intuitive. Celle-ci pourrait être utilisée comme un outil de suivi pour évaluer l'évolution de la condition du patient.

Bibliographie

1. SHI, Wan-Ting; LYU, Zong-Jhe; TANG, Shih-Tsang; CHIA, Tsorng-Lin; YANG, Chia-Yen. A bionic hand controlled by hand gesture recognition based on surface EMG signals : A preliminary study. *Biocybernetics and Biomedical Engineering*. 2018, t. 38, n° 1, p. 126-135.
2. ISLAM, Md Mohiminul; SIDDIQUA, Sarah; AFNAN, Jawata. Real time hand gesture recognition using different algorithms based on American sign language. In : *2017 IEEE international conference on imaging, vision & pattern recognition (icIVPR)*. IEEE, 2017, p. 1-6.
3. LI, Wen-Jeng; HSIEH, Chia-Yeh; LIN, Li-Fong; CHU, Woei-Chyn. Hand gesture recognition for post-stroke rehabilitation using leap motion. In : *2017 international conference on applied system innovation (ICASI)*. IEEE, 2017, p. 386-388.
4. BENALCÁZAR, Marco E.; MOTOCHÉ, Cristhian; ZEA, Jonathan A.; JARAMILLO, Andrés G.; ANCHUNDIA, Carlos E.; ZAMBRANO, Patricio; SEGURA, Marco; BENALCÁZAR PALACIOS, Freddy; PÉREZ, María. Real-time hand gesture recognition using the Myo armband and muscle activity detection. In : *2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM)*. 2017, p. 1-6. Disp. à l'adr. DOI : [10.1109/ETCM.2017.8247458](https://doi.org/10.1109/ETCM.2017.8247458).
5. JARAMILLO-YÁNEZ, Andrés; BENALCÁZAR, Marco E.; MENA-MALDONADO, Elisa. Real-Time Hand Gesture Recognition Using Surface Electromyography and Machine Learning : A Systematic Literature Review. *Sensors*. 2020, t. 20, n° 9, p. 2467. ISSN 1424-8220. Disp. à l'adr. DOI : [10.3390/s20092467](https://doi.org/10.3390/s20092467).
6. MCMANUS, Lara; DE VITO, Giuseppe; LOWERY, Madeleine M. Analysis and biophysics of surface EMG for physiotherapists and kinesiologists : toward a common language with rehabilitation engineers. *Frontiers in neurology*. 2020, t. 11, p. 576729.
7. CREPIN, Roxane; FALL, Cheikh Latyr; MASCRET, Quentin; GOSSELIN, Clement; CAMPEAU-LECOURS, Alexandre; GOSSELIN, Benoit. Real-time hand motion recognition using semg patterns classification. In : *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE, 2018, p. 2655-2658.
8. EBIED, Ahmed; AWADALLAH, Ahmed M; ABBASS, Mohamed A; EL-SHARKAWY, Yasser. Upper limb muscle fatigue analysis using multi-channel surface EMG. In : *2020 2nd Novel Intelligent and Leading Emerging Sciences Conference (NILES)*. IEEE, 2020, p. 423-427.

9. STANGO, Antonietta ; YAZDANDOOST, Kamya Yekeh ; FARINA, Dario. Wireless radio channel for intramuscular electrode implants in the control of upper limb prostheses. In : *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. 2015, p. 4085-4088. Disp. à l'adr. DOI : [10.1109/EMBC.2015.7319292](https://doi.org/10.1109/EMBC.2015.7319292).
10. HUG, François ; TUCKER, Kylie. Surface Electromyography to Study Muscle Coordination. In : 2017. ISBN 978-3-319-14417-7. Disp. à l'adr. DOI : [10.1007/978-3-319-30808-1_184-1](https://doi.org/10.1007/978-3-319-30808-1_184-1).
11. YEON, Seong Ho ; SHU, Tony ; ROGERS, Emily A. ; SONG, Hyungeun ; HSIEH, Tsung-Han ; FREED, Lisa E. ; HERR, Hugh M. Flexible Dry Electrodes for EMG Acquisition within Lower Extremity Prosthetic Sockets. In : *2020 8th IEEE RAS/EMBS International Conference for Biomedical Robotics and Biomechatronics (BioRob)*. 2020, p. 1088-1095. Disp. à l'adr. DOI : [10.1109/BioRob49111.2020.9224338](https://doi.org/10.1109/BioRob49111.2020.9224338).
12. CAMPBELL, Evan ; PHINYOMARK, Angkoon ; SCHEME, Erik. Current trends and confounding factors in myoelectric control : Limb position and contraction intensity. *Sensors*. 2020, t. 20, n° 6, p. 1613.
13. GHAPANCHIZADEH, Hossein ; AHMAD, Siti A. ; ISHAK, Asnor Juraiza. Recommended surface EMG electrode position for wrist extension and flexion. In : *2015 IEEE Student Symposium in Biomedical Engineering Sciences (ISSBES)*. 2015, p. 108-112. Disp. à l'adr. DOI : [10.1109/ISSBES.2015.7435877](https://doi.org/10.1109/ISSBES.2015.7435877).
14. MOTOCHÉ, Cristhian ; BENALCÁZAR, Marco E. Real-time hand gesture recognition based on electromyographic signals and artificial neural networks. In : *Artificial Neural Networks and Machine Learning—ICANN 2018: 27th International Conference on Artificial Neural Networks, Rhodes, Greece, October 4-7, 2018, Proceedings, Part I 27*. Springer, 2018, p. 352-361.
15. YANG, Zhongliang ; CHEN, Yumiao. Surface EMG-based sketching recognition using two analysis windows and gene expression programming. *Frontiers in neuroscience*. 2016, t. 10, p. 445.
16. TAM, Simon ; BOUKADOUM, Mounir ; CAMPEAU-LECOURS, Alexandre ; GOSSELIN, Benoit. A Fully Embedded Adaptive Real-Time Hand Gesture Classifier Leveraging HD-sEMG and Deep Learning. *IEEE Transactions on Biomedical Circuits and Systems*. 2019, t. PP, p. 1-1. Disp. à l'adr. DOI : [10.1109/TBCAS.2019.2955641](https://doi.org/10.1109/TBCAS.2019.2955641).
17. AL-AYYAD, Muhammad ; OWIDA, Hamza ; DE FAZIO, Roberto ; AL-NAAMI, Bassam ; VISCONTI, Paolo. Electromyography Monitoring Systems in Rehabilitation : A Review of Clinical Applications, Wearable Devices and Signal Acquisition Methodologies. *Electronics*. 2023, t. 12, p. 1-35.
18. FANG, Chaoming ; HE, Bowei ; WANG, Yixuan ; CAO, Jin ; GAO, Shuo. EMG-Centered Multisensory Based Technologies for Pattern Recognition in Rehabilitation : State of the Art and Challenges. *Biosensors*. 2020, t. 10, p. 85. Disp. à l'adr. DOI : [10.3390/bios10080085](https://doi.org/10.3390/bios10080085).

19. SHI, Wan-Ting; LYU, Zong-Jhe; TANG, Shih-Tsang; CHIA, Tsorng-Lin; YANG, Chia-Yen. A bionic hand controlled by hand gesture recognition based on surface EMG signals : A preliminary study. *Biocybernetics and Biomedical Engineering*. 2017, t. 38. Disp. à l'adr. DOI : [10.1016/j.bbe.2017.11.001](https://doi.org/10.1016/j.bbe.2017.11.001).
20. RAURALE, Sumit; MCALLISTER, John; RINCON, Jesus Martinez del. EMG Wrist-hand Motion Recognition System for Real-time Embedded Platform. In : *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2019, p. 1523-1527. Disp. à l'adr. DOI : [10.1109/ICASSP.2019.8683104](https://doi.org/10.1109/ICASSP.2019.8683104).
21. PANCHOLI, Sidharth; JOSHI, Amit M. Electromyography-Based Hand Gesture Recognition System for Upper Limb Amputees. *IEEE Sensors Letters*. 2019, t. 3, n° 3, p. 1-4. Disp. à l'adr. DOI : [10.1109/LENS.2019.2898257](https://doi.org/10.1109/LENS.2019.2898257).
22. DAS, Amal; LAXMI, Vijaya; KUMAR, Sanjeev. Hand Gesture Recognition and Classification Technique in Real-Time. In : 2019, p. 1-5. Disp. à l'adr. DOI : [10.1109/ViTECoN.2019.8899619](https://doi.org/10.1109/ViTECoN.2019.8899619).
23. YANG, Chun; LONG, Jinyi; URBIN, M. A.; FENG, Yanyun; SONG, Ge; WENG, Jian; LI, Zhijun. Real-Time Myocontrol of a Human-Computer Interface by Paretic Muscles After Stroke. *IEEE Transactions on Cognitive and Developmental Systems*. 2018, t. 10, n° 4, p. 1126-1132. Disp. à l'adr. DOI : [10.1109/TCDS.2018.2830388](https://doi.org/10.1109/TCDS.2018.2830388).
24. MALEŠEVIĆ, Nebojša; MARKOVIC, Dimitrije; KANITZ, Gunter; CONTROZZI, Marco; CIPRIANI, Christian; ANTFOLK, Christian. Vector Autoregressive Hierarchical Hidden Markov Models for Extracting Finger Movements Using Multichannel Surface EMG Signals. *Complexity*. 2018, t. 2018, p. 1-12. Disp. à l'adr. DOI : [10.1155/2018/9728264](https://doi.org/10.1155/2018/9728264).
25. LIANG, Shili; WU, Yansheng; CHEN, Jianfei; ZHANG, Ling; CHEN, Peipei; CHAI, Zongqian; CAO, Chunlei. Identification of Gesture Based on Combination of Raw sEMG and sEMG Envelope Using Supervised Learning and Univariate Feature Selection. *Journal of Bionic Engineering*. 2019, t. 16, p. 647-662. Disp. à l'adr. DOI : [10.1007/s42235-019-0052-1](https://doi.org/10.1007/s42235-019-0052-1).
26. AL OMARI, Firas; HUI, Jiang; MEI, Congli; LIU, Guohai. Pattern recognition of eight hand motions using feature extraction of forearm EMG signal. *Proceedings of the National Academy of Sciences, India Section A : Physical Sciences*. 2014, t. 84, p. 473-480.
27. LI, Guanglin; LI, Yaonan; ZHANG, Zhiyong; GENG, Yanjuan; ZHOU, Rui. Selection of sampling rate for EMG pattern recognition based prosthesis control. In : *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*. IEEE, 2010, p. 5058-5061.
28. TANKISI, Hatice; BURKE, David; CUI, Liying; CARVALHO, Mamede de; KUWABARA, Satoshi; NANDEDKAR, Sanjeev; RUTKOVE, Seward; STÅLBERG, Erik; PUTTEN, Michel van; FUGLSANG-FREDERIKSEN, Anders. Standards of instrumentation of EMG. *Clinical Neurophysiology*. 2019, t. 131. Disp. à l'adr. DOI : [10.1016/j.clinph.2019.07.025](https://doi.org/10.1016/j.clinph.2019.07.025).

29. KHUSHABA, Rami N ; KODAGODA, Sarath. Electromyogram (EMG) feature reduction using mutual components analysis for multifunction prosthetic fingers control. In : *2012 12th International Conference on Control Automation Robotics & Vision (ICARCV)*. IEEE, 2012, p. 1534-1539.
30. KHUSHABA, Rami N ; KODAGODA, Sarath ; TAKRURI, Maen ; DISSANAYAKE, Gamini. Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals. *Expert Systems with Applications*. 2012, t. 39, n° 12, p. 10731-10738.
31. TOLEDO PÉREZ, Diana ; RODRIGUEZ, Juvenal ; GÓMEZ LOENZO, Roberto ; JAUREGUI, Juan. Support Vector Machine-Based EMG Signal Classification Techniques : A Review. *Applied Sciences*. 2019, t. 9, p. 4402. Disp. à l'adr. DOI : [10.3390/app9204402](https://doi.org/10.3390/app9204402).
32. HALAKI, Mark ; GINN, Karen. Normalization of EMG Signals : To Normalize or Not to Normalize and What to Normalize to? In : 2012, p. 175-194. ISBN 978-953-51-0805-4. Disp. à l'adr. DOI : [10.5772/49957](https://doi.org/10.5772/49957).
33. BENATTI, Simone ; ROVERE, Giovanni ; BÖSSER, Jonathan ; MONTAGNA, Fabio ; FARELLA, Elisabetta ; GLASER, Horian ; SCHÖNLE, Philipp ; BURGER, Thomas ; FATEH, Schekeb ; HUANG, Qiuting ; BENINI, Luca. A sub-10mW real-time implementation for EMG hand gesture recognition based on a multi-core biomedical SoC. In : *2017 7th IEEE International Workshop on Advances in Sensors and Interfaces (IWASI)*. 2017, p. 139-144. Disp. à l'adr. DOI : [10.1109/IWASI.2017.7974234](https://doi.org/10.1109/IWASI.2017.7974234).
34. JIE, Jing ; LIU, Kairui ; ZHENG, Hui ; WANG, Beibei ; DAI, Rui. High dimensional feature data reduction of multichannel sEMG for gesture recognition based on double phases PSO. *Complex & Intelligent Systems*. 2021, t. 7, p. 1877-1893.
35. PHINYOMARK, Angkoon ; PHUKPATTARANONT, P. ; LIMSAKUL, Chusak. Feature Reduction and Selection for EMG Signal Classification. *Expert Systems with Applications*. 2012, t. 39, p. 7420-7431. Disp. à l'adr. DOI : [10.1016/j.eswa.2012.01.102](https://doi.org/10.1016/j.eswa.2012.01.102).
36. GALVÃO, Filipe ; MENESES ALARCÃO, Soraia ; FONSECA, Manuel J. Predicting Exact Valence and Arousal Values from EEG. *Sensors*. 2021, t. 21, p. 3414. Disp. à l'adr. DOI : [10.3390/s21103414](https://doi.org/10.3390/s21103414).
37. CAMPBELL, Evan ; PHINYOMARK, Angkoon ; SCHEME, Erik. Current trends and confounding factors in myoelectric control : Limb position and contraction intensity. *Sensors*. 2020, t. 20, n° 6, p. 1613.
38. ZHAO, Zhenyu ; ANAND, Radhika ; WANG, Mallory. Maximum Relevance and Minimum Redundancy Feature Selection Methods for a Marketing Machine Learning Platform. In : *2019 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*. 2019, p. 442-452. Disp. à l'adr. DOI : [10.1109/DSAA.2019.00059](https://doi.org/10.1109/DSAA.2019.00059).
39. JOURNAUX, Ludovic. *UNIVERSITE DE BOURGOGNE SCIENCES ET TECHNIQUES ANALYSE MULTISPECTRALE D'IMAGES SATELLITAIRES ET ANALYSE MULTI-TABLEAUX : APPLICATION A LA REPARTITION DES POPULATIONS D'OISEAUX ET A LA STRUCTURE DU PAYSAGE*. 2006. Disp. à l'adr. DOI : [10.13140/2.1.1542.4641](https://doi.org/10.13140/2.1.1542.4641). Thèse de doct.

40. THEOU, Olga ; EDWARDS, Darl ; JONES, Gareth R ; JAKOBI, Jennifer M. Age-related increase in electromyography burst activity in males and females. *Journal of aging research*. 2013, t. 2013.
41. HUDGINS, B. ; PARKER, P. ; SCOTT, R.N. A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*. 1993, t. 40, n° 1, p. 82-94. Disp. à l'adr. DOI : [10.1109/10.204774](https://doi.org/10.1109/10.204774).
49. MANE, SM ; KAMBLI, RA ; KAZI, FS ; SINGH, NM. Hand motion recognition from single channel surface EMG using wavelet & artificial neural network. *Procedia Computer Science*. 2015, t. 49, p. 58-65.
50. ZHAO, Zhenyu ; ANAND, Radhika ; WANG, Mallory. Maximum relevance and minimum redundancy feature selection methods for a marketing machine learning platform. In : *2019 IEEE international conference on data science and advanced analytics (DSAA)*. IEEE, 2019, p. 442-452.

Webographie

42. *What is Python? Executive Summary / Python.org* [<https://bit.ly/3ze7tUw>]. [s. d.].
43. *Visual Studio Code* [<https://bit.ly/3qxj3YB>]. [s. d.].
44. *Scikit-learn* [<https://bit.ly/3WVDpGP>]. [s. d.].
45. *STM32CubeIDE* [<https://bit.ly/43mWkNg>]. [s. d.].
46. *Tkinter - Interface Python* [<https://bit.ly/3WVrAR0>]. [s. d.].
47. *Manuel d'utilisation* [<https://bit.ly/3CGTVBn>]. [s. d.].
48. *STM32 HAL Library* [<https://bit.ly/46hjbvr>]. [s. d.].

Annexes

Définitions

MRMR (*Maximum Relevance — Minimum Redundancy*) :

C'est un algorithme de sélection de caractéristiques qui a gagné en popularité suite à la publication d'un article par un ingénieur d'Uber en 2019 [50].

Cet algorithme est utilisé pour choisir les caractéristiques les plus pertinentes et informatives parmi un ensemble de données. L'objectif de MRMR est de maximiser la pertinence entre chaque caractéristique et la variable cible, tout en minimisant la redondance entre les caractéristiques sélectionnées.

T-sne :

C'est une technique de réduction de dimension utilisée en exploration de données de grandes dimensions développée en 2008 par Geoffrey Hinton et Laurens van der Maaten. Comme pour l'ACP l'objectif est de déterminer un espace de plus petite dimension tout en préservant les distances entre les points.

SFS (*sequential forward selection*) :

La sélection séquentielle des caractéristiques est une technique utilisée en apprentissage automatique et en sélection de caractéristiques pour identifier et sélectionner un sous-ensemble de caractéristiques parmi un ensemble plus large de caractéristiques disponibles. Elle consiste à ajouter ou supprimer de manière itérative des caractéristiques en fonction de leur contribution individuelle ou combinée à la performance prédictive d'un modèle.

MCA (*Mutual Information-Based Feature Reduction*) :

C'est une technique utilisée dans le domaine de l'apprentissage automatique pour sélectionner les caractéristiques les plus pertinentes et informatives d'un ensemble de données. Elle se base sur le concept d'information mutuelle, qui mesure la dépendance statistique entre deux variables aléatoires.

Isomap :

C'est une technique de réduction de dimensionnalité qui vise à simplifier des données complexes en les représentant dans un espace de dimensions inférieures. Elle y parvient en combinant plusieurs algorithmes pour capturer la structure sous-jacente des données de manière non linéaire.

Codes

Voici une brève présentation de l'annexe code, qui inclut les différents liens GitHub des codes utilisés dans ce travail :

L'annexe code regroupe tous les codes sources développés pour ce projet, chacun ayant un rôle spécifique. Voici les différents liens GitHub correspondants :

- **Code STM32** : Ce code concerne la programmation du microcontrôleur STM32. Il comprend les fonctionnalités de contrôle et de communication nécessaires à l'interaction avec les capteurs et les périphériques externes.

[Code](#).

- **Code Acquisition des données par UART** : Ce code est responsable de l'enregistrement des données via l'interface UART. Il assure la communication entre le microcontrôleur et le dispositif d'acquisition de données.

[Code](#)

- **Code Backend du modèle proposé** : Ce code regroupe les fonctionnalités de backend nécessaires au fonctionnement du modèle de classification. Il comprend le prétraitement des données, l'extraction des caractéristiques, la réduction de la dimensionnalité et la classification elle-même. [Code](#)

- **Code Interface graphique - Classification** : Ce code correspond à l'interface graphique utilisée pour la classification des données en utilisant le modèle proposé. Il permet d'afficher les résultats de la classification .

[Code](#)

Ces différents codes représentent les piliers du projet, couvrant les aspects matériels, les interfaces utilisateur et le traitement des données. Les liens GitHub associés vous permettront d'accéder aux codes sources complets pour chaque aspect spécifique du projet.

Capteurs EMG

Dimensions et schéma électrique

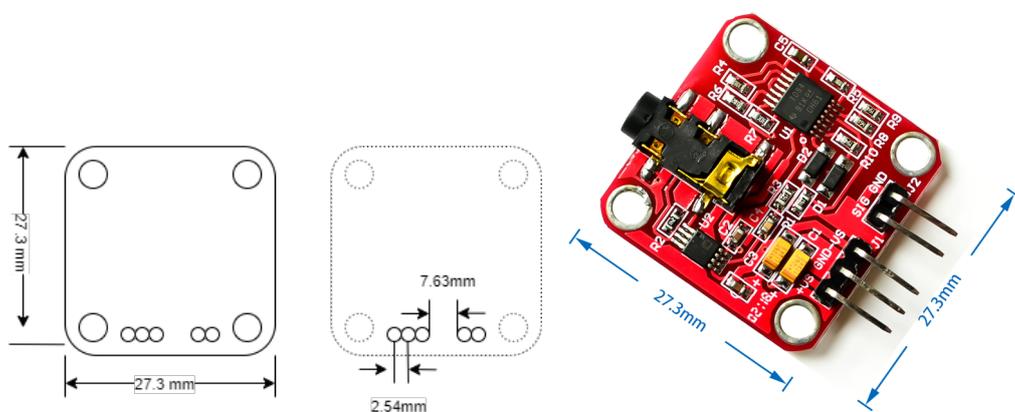


FIG. 11 : Dimensions du capteurs EMG

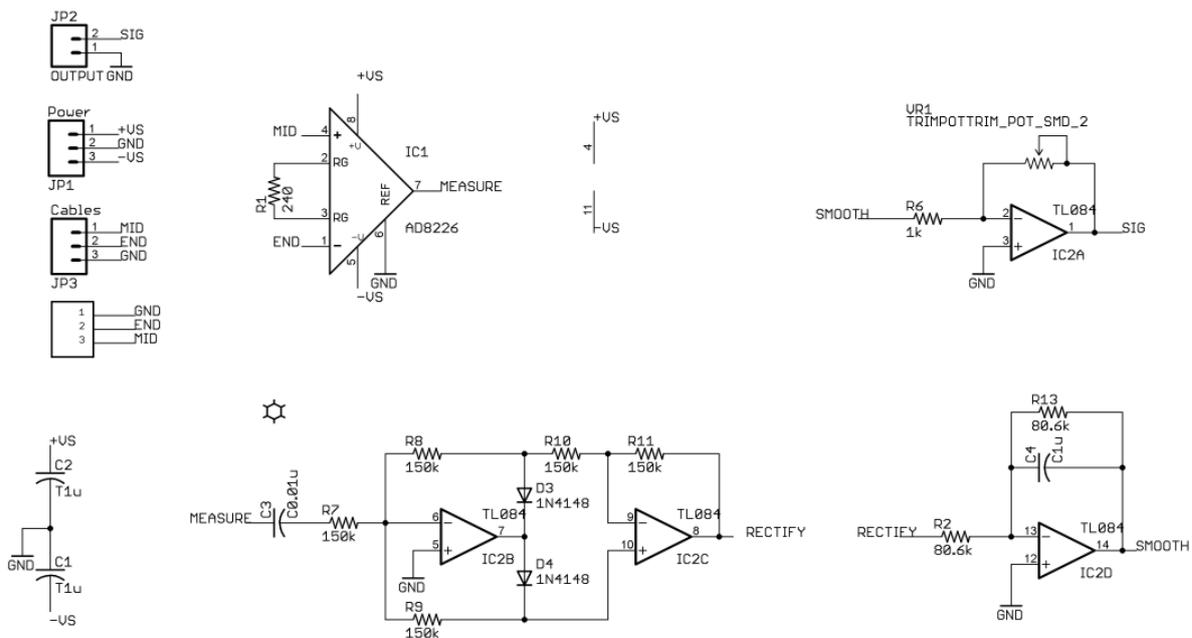


FIG. 12 : Schéma électrique du capteurs EMG

Interface graphique

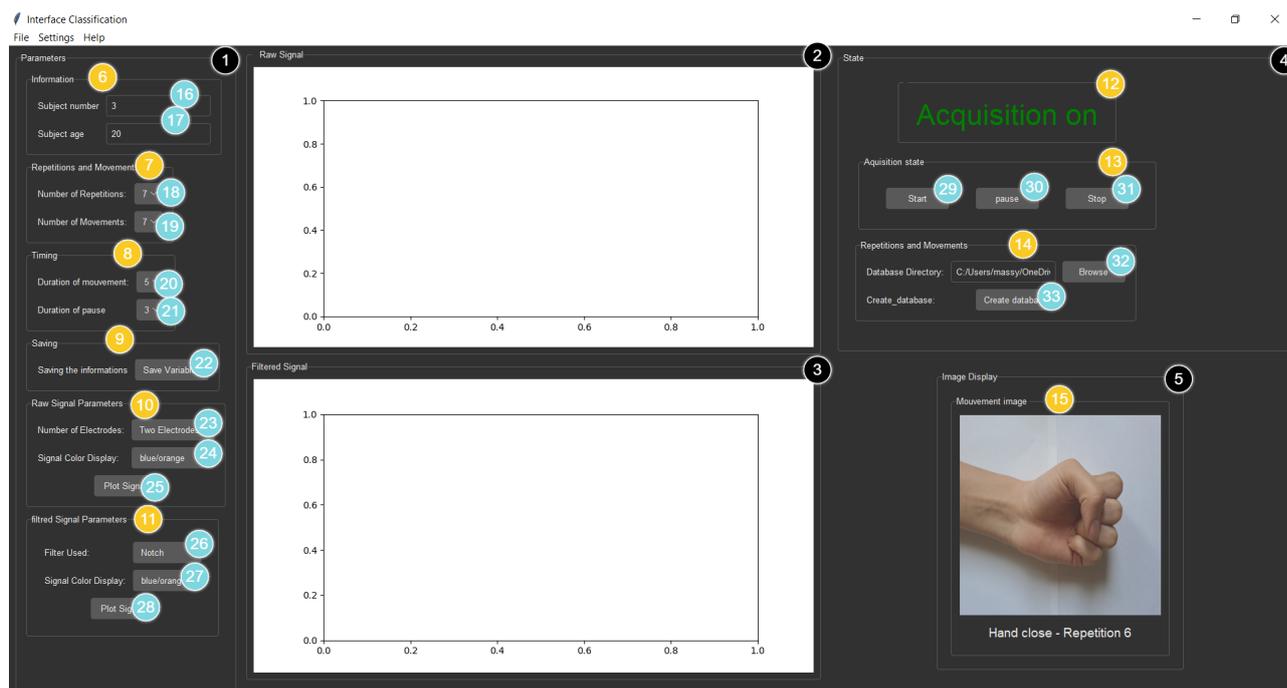


FIG. 13 : Fonctionnalités de base de l'interface graphique

- | | | |
|--------------------------------------|--|--|
| 1 Section paramètre | 10 Onglet des paramètres du signal brute | 18 Nombre de répétition par mouvement |
| 2 Section affichage du signal brute | 11 Onglet des paramètres du signal filtré | 19 Nombres de mouvements a réaliser |
| 3 Section affichage du signal filtré | 12 Affichage de l'état de l'aquisition | 20 Durée du mouvement |
| 4 Section état de l'acquisition | 13 Onglet de controle de l'état d'aquisition | 21 Durée de la pause |
| 5 Section Affichage des mouvements | 14 Onglet création de la base de donnée | 22 Bouton d'enregistrement des variables |
| 6 Onglet Information | 15 Onglet affichage du mouvement | 23 Choix du nombre d'électrode |
| 7 Onglet répétitions et mouvements | 16 Numéro du sujet | 24 Couleur(s) du/des signal(signaux) brute |
| 8 Onglet timing | 17 Age du sujet | 25 bouton pour tracer le signal brute |
| 9 Onglet Sauvegarde | | |

- | | | | | | |
|----|---|---------------|--------------|-------------|--|
| 26 | Choix du filtre | signal filtré | 31 | Bouton stop | |
| 27 | Couleur(s) du/des signal(signal) filtré | 29 | Bouton start | 32 | Bouton parcourir |
| 28 | bouton pour tracer le | 30 | Bouton pause | 33 | Bouton sauvegarde de la base de donnée |

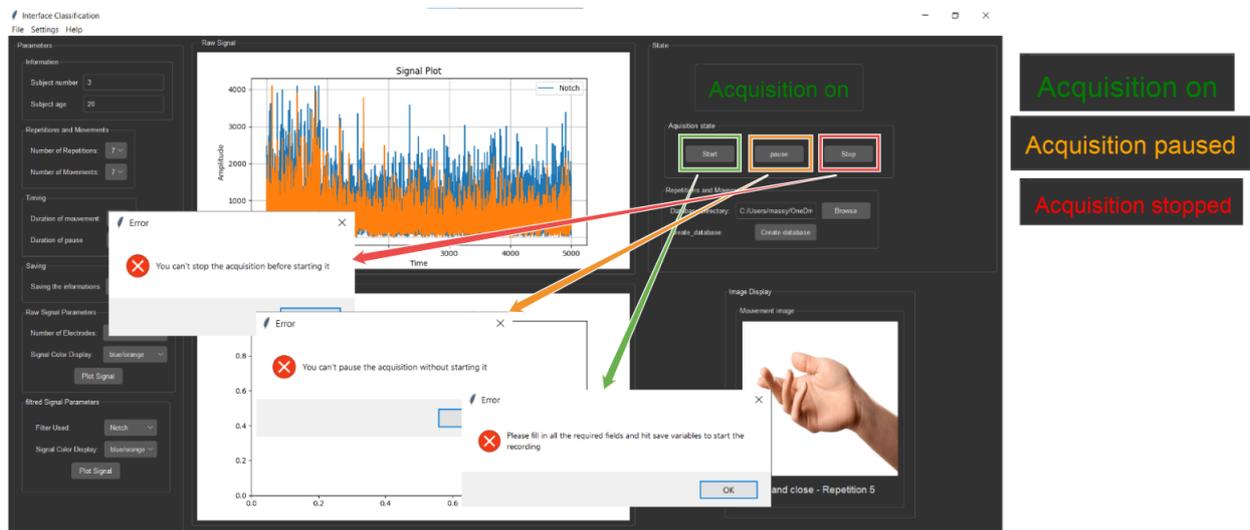


FIG. 14 : Exemples de messages d'erreurs courants et leur présentation dans l'interface

Lettre de Consentement

Cher participant,

Nous vous remercions de votre intérêt à participer à notre étude de recherche. Avant de poursuivre, nous aimerions vous présenter les détails importants de cette expérience, ainsi que les informations sur la manière dont les signaux collectés seront utilisés. Nous vous encourageons à lire attentivement cette lettre et à poser toutes les questions que vous pourriez avoir avant de donner votre consentement.

Titre de l'étude : Classification des mouvements de la main basée sur des modèles d'apprentissage automatique

Procédure de collecte des données : Au cours de cette étude, nous collecterons des signaux EMG à l'aide de capteurs placés à la surface de l'avant-bras. Les signaux seront enregistrés pendant une période définie avec des période de pause entre chaque mouvements réalisés.

Utilisation des signaux collectés : Les signaux collectés seront utilisés exclusivement à des fins de recherche scientifique. Ils seront analysés, traités et étudiés dans le but de les classifier en différents mouvements de la main.

Confidentialité et anonymat : Toutes les données collectées seront traitées de manière strictement confidentielle et anonyme. Votre identité personnelle sera protégée en tout temps. Les vidéos enregistrées lors de la collecte pourraient être utilisées à des fins de présentation dans un cadre spécifique, telles qu'une soutenance, un événement

scientifique ou autre. Avant toute utilisation ou diffusion de ces vidéos, votre accord sera demandé.

Consentement volontaire : Votre participation à cette étude est entièrement volontaire. Vous avez le droit de refuser de participer ou de retirer votre consentement à tout moment, sans aucune conséquence négative.

Droits du participant : En participant à cette étude, vous avez le droit d'être informé de tout développement important lié à l'étude. Vous avez également le droit d'accéder à vos propres données, dans les limites permises par les protocoles de confidentialité et les réglementations en vigueur.

Contact et questions : Si vous avez des questions ou des préoccupations concernant cette étude ou votre participation, veuillez contacter Mme Massyia KHELAFI ou M. Walid ZEGAOUI à l'adresse e-mail qui vous a été communiquée lors de la collecte des données.

En donnant votre consentement à cette étude, vous reconnaissez avoir lu et compris les informations présentées dans cette lettre. Vous comprenez les procédures de collecte des données, l'utilisation prévue des signaux collectés, ainsi que vos droits en tant que participant. Vous consentez librement à participer à cette étude et à fournir les signaux nécessaires à des fins de recherche.

Nous vous remercions sincèrement de votre participation. Votre contribution est extrêmement précieuse pour faire progresser la recherche dans notre domaine.

Cordialement,