



Laboratoire GIPSA-lab
Département Images-Signal
Domaine Universitaire, BP 46
38402, Saint Martin d'Hères cedex



Groupe Grenoble INP
Ecole doctorale EEATS
46, avenue Félix Viallet
38031 Grenoble cedex 1

Rapport de Stage
M2R Signal Image, Parole, Telecoms

Identification robuste de nombreux gestes de la main pour l'interaction muscle-machine.

Lefrançois Maxime

ENS-Cachan DGM – Normalien 4e Année – Lauréat de l'agrégation externe de mécanique 2008
INPG EEATS – M2R Signal Image, Parole, Telecoms
UPMF ICCA – M1P Ingénierie de la Communication Personne-Système

Date de soutenance : 30 juin 2009

Responsables de stage :

Christian JUTTEN, Professeur des Universités, membre de l'Institut Universitaire de France.
Responsable du département Images et Signal.

Franck QUAINÉ, Maître de conférences.

Responsable de l'équipe Systèmes BioMécaniques du département Automatique.

Remerciements

Je tiens tout d'abord à remercier très chaleureusement messieurs Christian JUTTEN et Franck QUAINÉ. Qu'ils soient assurés de ma gratitude pour leur aide à la définition de ce sujet de ce stage, leur accueil au laboratoire GIPSA-lab, leur disponibilité, leur encadrement, et toutes les discussions éclairées.

Toute ma reconnaissance va aussi :

- à monsieur Florent PACLET du département Automatique, pour ses conseils et pour m'avoir aidé à mettre en place la partie expérimentale de ce stage.
- à monsieur Coriandre VILAIN du département Parole et Cognition d'avoir accepté de nous prêter leur système de mesure de signaux EMGs lors des premières expérimentations de ce stage.
- à madame Lucia BOUFFARD-TOCAT, secrétaire du département Images et Signal, pour son accueil et pour son aide à la gestion administrative.
- aux sujets des expérimentations réalisées lors de ce stage : Merci pour votre patience !

Je tiens aussi à remercier Yann LAURILLAU, de l'équipe d'ingénierie de l'interaction homme-machine du laboratoire d'informatique de Grenoble pour son aide : avant de me centrer exclusivement sur le traitement du signal, ce sujet avait deux facettes complémentaires. Nous avons donc envisagé d'utiliser un prototype d'interface muscle-machine pour naviguer dans des interfaces zoomables, et montrer sur cet exemple que les interfaces muscles-machine pouvaient apporter quelque chose de plus que les dispositifs d'interaction classique.

Je tiens également à remercier toutes les personnes que j'ai pu côtoyer au sein du laboratoire GIPSA-lab : leur sympathie a rendu ce stage très agréable : mesdames Violaine CAHOUE et Annick MONTANVERT, et messieurs Florent PACLET, Adolfo INZA, Guillaume LIO, et Damien BEGUE.

Finalement, un merci tout particulier à mademoiselle Rachel MARTIN de m'avoir supporté et encouragé pendant les moments difficiles de ce stage.

Merci enfin aux montagnes où il est si agréable de se ressourcer, et sur lesquelles les levés et couchés de soleil sont si grandioses.

Résumé

Les avancées récentes dans le domaine du traitement du signal pour l'électromyographie de surface (EMGs) ouvrent la voie vers un nouveau type d'interaction homme-machine, récemment dénommé interaction muscle-machine. Beaucoup de recherches se sont concentrées sur la reconnaissance des mouvements des bras ou des mouvements simples de la main. Mais peu d'articles proposent une différenciation d'un nombre élevé de mouvements fins.

Cette étude a deux objectifs principaux : déterminer une méthode efficace permettant l'identification d'un ensemble riche de gestes du poignet et des doigts, et proposer une solution pour préserver les performances du système de reconnaissance après repositionnement du système de 8 électrodes (SysE).

L'expérience menée consiste à recueillir des données EMGs des muscles de l'avant-bras du sujet pendant qu'il répète un même geste, pour 31 mouvements. Elle est répétée pour un décalage angulaire de 12° du SysE.

Nous avons évalué les performances de la classification des gestes pour différents ensembles de caractéristiques des signaux, avec ou sans pré-traitement des données (par séparation aveugle de source (SAS), et/ou transformation non-linéaire des caractéristiques), avec ou sans post-traitement des décisions (par procédure de vote majoritaire), et pour des fenêtres de classification de différentes longueurs. Les meilleures performances en classification continue sont de l'ordre de $98.9 \pm 0.5\%$ de précision et $65.6 \pm 1.2\%$ de stabilité de classification.

Pour répondre au second objectif, nous avons introduit des méthodes d'estimations de la position angulaire du SysE et d'adaptation du classifieur à une nouvelle position, toutes deux basées sur des techniques de SAS et de localisation. Les résultats de ces méthodes sont moyens, à cause du petit nombre de capteurs utilisés et du caractère localisé de la contribution d'une source au potentiel EMGs global. Nous avons également évalué la robustesse des classifieurs au décalage angulaire. Les meilleurs résultats montrent une précision de $67.4 \pm 1.9\%$ et une stabilité de $55.5 \pm 1.7\%$ pour la classification continue. Cette étude se conclue par une ouverture vers une méthode qui devrait assurer une borne inférieure aux performances de la classification, quelque soit le décalage angulaire du SysE.

Mots clés : électromyographie de surface (EMGs), interfaces muscle-machine (ImuM), séparation aveugle de sources (SAS), analyse en composantes indépendantes (ACI), classification continue, localisation de sources, interaction homme-machine (IHM).

Abstract

Recent progress of signal processing for surface electromyography (sEMG) pave the way for new human-computer interaction, recently named muscle-computer interaction. Much researchs focused on arm movements or gross hand movements. Therefore, no much papers study classification of numerous fine movements.

This study has two main objectives : to determine a efficient approach to identify a manifold set of wrist and fingers gestures, and to put forward a solution to preserve the system recognition efficiency when the 8-electrodes system (eSys) is replaced.

The experiment led consists in collecting (sEMG) data from the subject's forearm muscles while he repeats one gesture, for 31 movements. It is repeated for a 12° angular shift of the eSys.

Results of the gestures classification were assessed for manifold data features sets. Datas were pre-processed or not (by Blind Source Separation (BSS), and/or non-linear features transformation). Decisions were post-processed or not (majority vote procedure). Different lengths were tested for classification windows. Best results for continuous classification were $98.9 \pm 0.5\%$ and $65.6 \pm 1.2\%$ for classification accuracy and stability, respectively.

To answer the second objective, we introduced an estimator of the eSys angular position, and an method to accomodate the classifier to a new position. These methods are based on BSS and localization techniques. Results of these methods were pour, because of fact that the number of sensors is limited, and that a source has a very localized impact on the global sEMG potential. The classifiers robustness in respect to the angular shift was also assessed. The best results were $67.4 \pm 1.9\%$ and $55.5 \pm 1.7\%$ for classification accuracy and stability, respectively. This study is ended by an overture towards a method that should assure a lower bound to classification accuracies, whatever the eSys angular shift is.

Keywords : surface electromyography (sEMG), muscle-computer interfaces (muCIs), blind source separation (BSS), independent component analysis (ICA), continuous classificatoin, sources localization, human-computer interaction (HCI)

Table des matières

Introduction	4
1 L'électromyographie pour l'interaction homme-machine	6
1.1 Origine physiologique du signal électromyographique de surface	6
1.2 Applications à l'interaction homme-machine	8
2 Classification de signaux électromyographiques	9
2.1 Les ensembles de mouvements à classifier	9
2.1.1 Catégorisations des mouvements	9
2.1.2 Résultats de la recherche en classification des mouvements des doigts	9
2.1.3 Définition des mouvements considérés dans cette étude	10
2.2 Les caractéristiques de la classification	10
2.2.1 La détection de mouvements et la fenêtre de classification	10
2.2.2 Les ensembles de caractéristiques	11
2.2.3 La classification	14
2.2.4 Post-traitement pour la classification continue	14
3 Utilisation des méthodes de séparation aveugle de source	15
3.1 Formulation mathématique et méthodes retenues	15
3.1.1 Introduction à la séparation aveugle de source	15
3.1.2 Identification aveugle du second ordre	16
3.1.3 Analyse en composantes indépendantes	17
3.2 La recherche en séparation aveugle de source appliquée aux signaux électromyographiques	19
3.3 Application des techniques de séparation aveugle de source pour l'interaction muscle-machine	20
3.3.1 Ensembles de caractéristiques pour la classification	20
3.3.2 Localisation et applications	20
4 Description des méthodes	23
4.1 Protocole expérimental	23
4.2 Rappel des choix adoptés	24
5 Evaluation des ensembles de classification	28
5.1 Entraînement et test des classifieurs	28
5.2 Classification continue	30
6 Evaluation de la robustesse vis-à-vis d'un décalage angulaire du système d'électrodes	36
6.1 Localisation et applications	36
6.2 Etude des performances de classification sans prise en compte du décalage angulaire du système d'électrodes	40
Conclusion	42
Bibliographie	44
Annexes	46

Introduction

Claquer des doigts pour répondre à son téléphone, se déplacer dans un monde virtuel en bougeant son poignet comme si on tenait un joystick, tapoter des doigts sur la table pour naviguer dans un album photo ou parmi des pages web... Ces actions peuvent être à la base de scénarios qui aspirent à rendre l'informatique ubiquitaire et l'interaction entre l'homme et la machine intuitive et naturelle.

Aujourd'hui, la plupart des interactions homme-machines utilise l'intermédiaire de capteurs physiques comme les souris, claviers, stylets, cadrans, et surfaces tactiles. Bien que ces outils permettent une interaction puissante en tirant profit des compétences de l'homme à manipuler des objets physiques, ils lient l'interaction à des objets physiques qui doivent être à la portée de l'utilisateur.

Comme l'informatique s'intègre de plus en plus dans notre environnement et est utilisée dans des situations où l'utilisateur n'est pas toujours concentré sur la tâche informatique, il est important de considérer des mécanismes pour acquérir des commandes des utilisateurs qui ne nécessitent pas de manipulation directe d'instruments physiques.

Jusqu'ici, la plupart des efforts pour permettre une interaction sans instrument se sont concentrés sur la parole et la vision, qui ont avancé à grand pas ces dernières années mais sont toujours sujets aux problèmes de l'environnement bruité et nécessitent que l'utilisateur fasse des mouvements ou des sons qui puissent être perçus extérieurement et qui par définition ne peuvent pas être dissimulés des autres personnes autour de lui.

Le traitement des signaux électromyographiques de surface (noté EMGs), qui sont une mesure du potentiel électrique en provenance des cellules neuro-musculaires, semble être un domaine de recherche prometteur pour l'interaction homme-machine (IHM). Ce domaine à la frontière entre deux disciplines, apporte potentiellement l'opportunité sans précédent à un utilisateur d'interagir directement par son activité musculaire : il a récemment été nommé interaction muscle-machine (ImuM) par Saponas et al. [42].

Les interfaces muscle-machine répondent à des besoins très différents de ceux exprimés classiquement pour les applications de l'électromyographie de surface, comme les applications cliniques ou le sport de haut niveau :

- La différence principale avec ces applications est que le traitement des données doit être effectué en temps réel. L'utilisateur ne doit pas être incommodé par le temps de réponse, sous peine de rejet du système. Le temps de réponse du système ne doit pas dépasser 300 ms [15, 39] ;
- Ensuite, on doit considérer le fait que l'utilisateur n'a pas le niveau d'expertise requis pour mettre en place les électrodes avec précision, ce qui signifie que le système doit être robuste vis-à-vis de son positionnement ;
- Enfin, l'utilisateur ne doit pas avoir à passer trop de temps à régler une interface muscle-machine. Il est envisageable de lui demander d'effectuer une heure de réglage une fois, mais ceci ne peut pas être répété avant chaque utilisation !

Dans cette étude on a fait l'hypothèse qu'un tel dispositif se composerait d'un ensemble de capteurs EMGs situés dans une étroite brassard autour de l'avant-bras. Nous nous plaçons ainsi dans le sillage de Saponas et al., qui envisagent que les capteurs ImuM pourront être portés sur le corps, tout comme une montre ou des bijoux (*cf* figure 1). D'après les auteurs, ces dispositifs représenteraient ainsi une technologie d'interaction toujours accessible et très personnalisable. Ce niveau d'accessibilité pour envoyer un flot de commandes à un ordinateur sera probablement intéressant à mesure que les tâches informatiques seront effectuées avec une variété croissante d'environnements pour lesquels les dispositifs de commande peuvent ne pas être facilement accessibles.

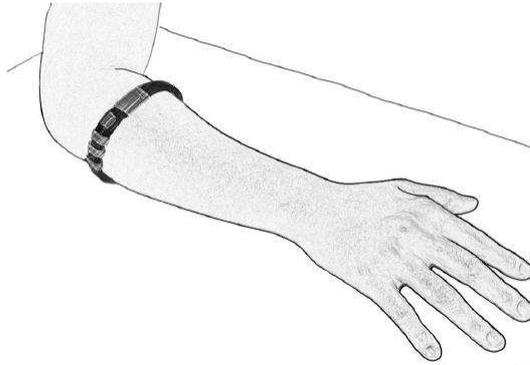


FIG. 1 – Vue d’artiste d’un brassard pour avant-bras avec des capteurs EMG qui pourrait être utilisé comme interface muscle-machine

Beaucoup de recherches se sont concentrées sur la reconnaissance des mouvements des bras ou des mouvements simples de la main. En revanche, il semble que reconnaître un ensemble riche de gestes d’une manière non-obstrusive reste une application peu exploitée des EMG. Ceci est dû en partie à la complexité des mouvements de la main et à l’enchevêtrement des muscles dans l’avant-bras qui rend l’identification des mouvements fins très difficile.

On se propose donc pour cette étude de se concentrer sur deux objectifs :

- Un système myoélectrique de commande performant doit identifier les mouvements avec précision, stabilité (aussi longtemps que le geste est maintenu), et dans un temps acceptable. Le premier objectif est donc d’évaluer la précision et la stabilité de différentes méthodes pour identifier un ensemble riche de gestes du poignet et des doigts. Nous évaluerons donc plusieurs ensembles de caractéristiques extraites des signaux EMGs, avec ou sans pré-traitement des données (par séparation aveugle de source (SAS), et/ou transformation non-linéaire des caractéristiques), avec ou sans post-traitement des décisions (par procédure de vote majoritaire), et pour des fenêtres de classification de différentes longueurs.
- Pour éviter à l’utilisateur une longue séance d’entraînement du classifieur à chaque nouvelle utilisation de l’interface muscle-machine, le système de reconnaissance doit s’adapter, ou être robuste, à un décalage angulaire du système d’électrodes. Nous nous proposons donc comme deuxième objectif d’évaluer une méthodes pour que cette condition soit remplie. Deux possibilités sont envisagées :

A) Le système peut évaluer la nouvelle position des électrodes et adapter le classifieur à cette nouvelle position. Pour étudier cette première option, nous introduirons des méthodes d’estimations de la position angulaire du système d’électrodes et d’adaptation du classifieur à une nouvelle position, toutes deux basées sur des techniques de séparation aveugle de source et de localisation.

B) Le système est robuste à un décalage angulaire du système d’électrodes. Pour cette seconde option, nous évaluerons la robustesse au décalage angulaire de la classification basée sur les ensembles de caractéristiques sélectionnés, pré-traités ou non.

Chapitre 1

L'électromyographie pour l'interaction homme-machine

Ce premier chapitre est l'occasion de se familiariser avec les signaux électromyographiques, au coeur de notre étude. Nous proposerons une brève description de leur origine physiologique, ainsi que des méthodes de détection et des des muscles de l'avant-bras. Puis nous proposerons ensuite un aperçu des applications de l'électromyographie dans le domaine de l'interaction homme-machine.

1.1 Origine physiologique du signal électromyographique de surface

Origine physiologique du signal EMGs. Les muscles squelettiques humains sont faits de fibres musculaires attachées aux os avec des tendons. Pour contracter un muscle, un signal électrique en provenance du système nerveux central est envoyé au motoneurone α par l'intermédiaire du centre nerveux. Ces motoneurones α transmettent alors les impulsions électriques du nom de *potentiel d'action* dans un certain nombre de fibres motoneuronales, provoquant la contraction des fibres musculaires associées. L'*unité motrice* (UM) représente le motoneurone α et l'ensemble des fibres musculaires qu'il innerve. L'ensemble des neurones moteurs innervant un muscle est nommé population de motoneurones. Chaque muscle comporte plusieurs unités motrices (*cf* figure 1.1). Lors de la contraction musculaire, un sous-ensemble des UM est activé. La somme de toutes les activités électriques d'une UM est nommée un *potentiel d'action d'unité motrice* (PAUM).

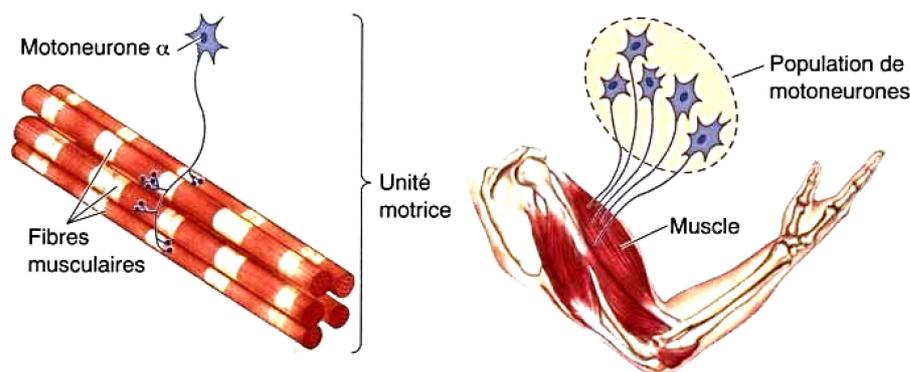


FIG. 1.1 – L'unité motrice représente le motoneurone α et l'ensemble des fibres musculaires qu'il innerve. L'ensemble des neurones moteurs innervant un muscle est nommée population de motoneurones. Chaque muscle comporte plusieurs unités motrices.

La manifestation électrique d'un PAUM est accompagnée d'un soubressaut de contraction sur la fibre musculaire de type impulsif. Pour maintenir une contraction musculaire, l'activation de l'unité motrice doit être répétée. La séquence résultante des PAUM est nommée *train de potentiels d'action d'unité motrice* (TPAUM). De plus, lorsque l'effort à développer augmente, deux mécanismes se mettent en place pour augmenter la force de contraction du muscle : les *intervalles inter-pics* (IIP) des TPAUMs diminuent, et/ou d'autres unités motrices sont recrutées.

Pour plus d'informations sur les signaux EMG et leurs applications, le lecteur peut se référer à [12, 29].

Mesure des signaux EMGs. L'électromyographie (EMG) mesure le TPAUM comme un potentiel électrique variant au cours du temps, à partir de deux électrodes [27]. On peut mesurer le signal directement à l'intérieur du muscle (méthode invasive) à l'aide d'aiguilles, ou sur la peau au dessus du muscle (EMG de surface, ou EMGs).

La méthode invasive est très précise pour capter l'activation de certaines UM, mais elle est douloureuse, et son application nécessite de déposer un dossier au comité de protection des personnes (CCP), et une mise en oeuvre dans un cadre clinique. Elle représente ainsi des contraintes qui font que **la grande majorité des recherches dans le domaine de l'interface homme-machine utilise l'EMGs**. Les signaux EMGs sont quant à eux moins précis puisque le signal se charge de bruit à mesure qu'il traverse les différents tissus jusqu'à la surface (autres muscles, graisse, vaisseaux sanguin, peau).

Volume de détection et phénomène de d'interférence. Il est admis que l'électrode a ce qu'on appelle un *volume de détection* qui lui est propre, qui dépend de la surface en contact avec la peau, et de la distance inter-électrodes. Pour simplifier, le volume est une demi sphère centrée entre les deux électrodes, et dont le diamètre est égal à la distance inter-électrodes. Au niveau de l'avant-bras, certains muscles sont très profonds et leur activité est donc difficilement observable. Cette remarque nous poussera à choisir des électrodes de relativement gros diamètre, et une distance inter-électrodes assez importante : 2.5 cm. Lorsque les volumes de détection de différentes électrodes se recoupent, où lorsqu'un muscle traverse deux volumes de détection, on peut observer un phénomène d'*interférence* entre les électrodes. Cela signifie que la même activité EMG peut contribuer à différents niveaux aux signaux EMGs observés par les deux électrodes. Ce phénomène d'interférence, longtemps redouté des chercheurs, justifie l'utilisation des techniques de séparation aveugle de source pour retrouver la contribution de chaque muscle aux signaux EMGs observés, et pour ensuite appliquer des algorithmes de localisation. De plus, aux vues des grandes vitesses de propagation des ondes dans les tissus mous par rapport aux vitesses de propagation dans les fibres musculaires, on pourra considérer que **le signal EMGs est un mélange linéaire instantané de TPAUM**.

Et pour les mouvements de la main ? Ce qui rend complexe la détection des mouvements de la main est que les muscles des doigts et du poignet sont pour la plupart enchevêtrés dans l'avant-bras, et qu'**il n'y a pas d'association simple entre les muscles et les mouvements** : un mouvement requiert en général la contraction de plusieurs muscles, et ces muscles peuvent être sollicités pour d'autres mouvements. Le fait qu'ils soient pour la plupart localisés dans l'avant-bras est néanmoins une opportunité, puisqu'il est ainsi théoriquement possible d'y détecter une activité EMGs correspondant aux mouvement des doigts.

Type d'électrodes et filtrage spatial. La technique de mesure d'EMGs la plus couramment utilisée consiste à utiliser la différence de potentiel entre une deux électrodes (électrode bi-polaire, ou mono-différentielle), mais il est aussi possible d'utiliser un filtrage spatial sur un nombre plus grand d'électrodes [27, 28]. On peut ainsi utiliser un filtrage laplacien 1D sur trois électrodes (électrode tripolaire, ou bi-différentielle), ou 2D à partir d'une matrice d'électrodes (filtrage laplacien 2D ou autre). Dans tous les cas, on utilise le terme *électrode* au singulier pour désigner le groupe d'électrodes plus le filtrage spatial. Dans le cadre de Notre étude, sauf indication contraire, le terme électrode désignera une électrode bi-polaire, ou mono-différentielle.

1.2 Applications à l'interaction homme-machine

L'application d'un dispositif électromyographique à l'interaction homme-machine est un domaine récent de la recherche, récemment nommé interaction muscle-machine (ImuM – muscle-computer interface – muCI) [42].

D'après Saponas et al. [42], les ImuM comptent sur la perception d'activités musculaires relativement subtiles, qui mènent des mouvements à la limite de la perception extérieure. Les ImuM pourraient ainsi permettre des formes d'interaction homme-machine plus fines et implicites que celles qui dépendent de flots de données traditionnellement captés ou utilisés par les hommes pour manipuler leur environnement ou communiquer entre eux. De plus, les auteurs envisagent que les capteurs ImuM pourront être portés sur le corps, à la façon d'une montre ou d'un bijou (*cf* figure 1). D'après eux, ils représenteraient ainsi une technologie d'interaction toujours accessible. Ce niveau d'accessibilité pour envoyer un flot de commandes à un ordinateur sera probablement intéressant à mesure que les tâches informatiques seront effectuées avec une variété croissante d'environnements pour lesquels les dispositifs de commande peuvent ne pas être accessibles.

Constanza et al. [8–10] ont plus particulièrement étudié l'intérêt ergonomique et social d'interfaces discrètes à base d'EMG. Les auteurs imaginent que cette technologie permettrait à un utilisateur de naviguer dans les menus d'une messagerie vocale d'un téléphone portable en contractant l'un ou l'autre des biceps. Les auteurs montrent qu'un point fort de cette technologie est que les utilisateurs pourraient utiliser leur système pour interagir discrètement avec un appareil sans que cela puisse être perçu extérieurement.

Au centre Arms Research Center de la NASA, Wheeler et al. [48, 49] ont réussi à utiliser les EMGs afin de contrôler un joystick virtuel, ou d'entrer du texte sur un clavier virtuel. Pour valoriser leurs recherches, ils ont utilisé les ImuM pour contrôler un avion de ligne d'un simulateur de vol de hautement fidèle.

Naik et al. [32, 34, 35] ont évalué différentes techniques de séparation aveugle de sources et de classification pour identifier les mouvements du poignet, des doigts, et leurs combinaisons. Ils utilisent plusieurs capteurs à différents endroits de l'avant-bras.

Arjunan et al. [2] ont travaillé sur les ImuM pour des applications telles que la reconnaissance des gestes faciaux et des gestes de la main. Leurs résultats montrent qu'il y a de très fortes variations inter-sujet des caractéristiques. Ainsi, un système de classification serait beaucoup plus performant si il est entraîné et testé par le même utilisateur. Les applications en IHM envisagées sont : permettre aux personnes handicapées de donner des commandes simples aux ordinateurs ; utiliser la classification des signaux EMGs pour des systèmes d'interaction homme-machine.

Zhang et al. [50] ont proposé l'utilisation conjointe d'une ImuM et d'accéléromètres, pour contrôler un jeu vidéo de combat. Pour cette interface homme-machine, l'électromyographie sert simplement à lier la force de fermeture de la main à la puissance du coup de poing, le type de coup est déterminé par l'accéléromètre (droit, crochet, uppercut).

Chapitre 2

Classification de signaux électromyographiques

Que ce soit pour le contrôle myo-électrique de prothèses ou plus récemment pour l'interaction muscle-machine, la reconnaissance de schémas a fait l'objet de nombreuses recherches. En particulier, un grand nombre de méthodes différentes d'extraction de caractéristiques et de classification a été testé. Des méthodes complémentaires, comme la réduction de dimension [6, 14–16, 38] des ensembles de caractéristiques et le post-traitement par vote majoritaire ont été utilisées [14, 15]. Pour les recherches récentes, des taux de classification de plus de 90% sont monnaie courante pour les mouvements du bras, du poignet et des mouvements grossiers de la main. Ce chapitre est l'objet d'une importante étude de Mitra et al. [31].

2.1 Les ensembles de mouvements à classifier

Pour notre étude, la plupart des recherches en classification de signaux électromyographiques recensées se base sur des données mesurées pendant des mouvements de la main, de l'avant-bras ou du bras. En général, les données électromyographiques sont mesurées sur des sujets sains, avec quelques exceptions où les données sont mesurées sur des sujets amputés, ou simulées [18].

2.1.1 Catégorisations des mouvements

Les mouvements sont soit statiques (steady-state), soit dynamiques (transient). Un mouvement statique peut être maintenu en une position constante pendant un certain temps (ex : saisir un objet). On parle alors de contraction isométrique. Au contraire, un mouvement dynamique est une transition brève entre deux états statiques (ex : taper d'un doigt sur une table) qui correspond à une contraction dite anisométrique. Il est également possible de catégoriser les mouvements par rapport aux articulations qu'ils sollicitent :

- Mouvements au niveau du coude : *flexion/extension au niveau du coude, pronation et supination de l'avant-bras* ;
- Mouvements au niveau du poignet : *flexion/extension, inclinaison ulnaire/radiale* ;
- Mouvements grossiers de la main : *ouverture/fermeture, prise de petits/gros objets* ;
- Mouvements des doigts : mouvements statiques (*flexion de l'index/majeur, flexion/abduction/extension du pouce*) / mouvements dynamiques (*taper/lever/fermer/tendre (d'un doigt)*) ;
- Autres : *données électromyographiques simulées*.

2.1.2 Résultats de la recherche en classification des mouvements des doigts

Les mouvements des doigts font l'objet d'un complexe équilibre biomécanique. En effet, le nombre de muscles est plus important que le nombre de degrés de liberté du système, de sorte qu'un muscle peut participer à plusieurs mouvements et qu'opérer un mouvement nécessite bien souvent de recruter plusieurs muscles [43]. De ce fait, les recherches sur la classification des mouvements des doigts sont assez récentes, et les résultats sont moins bons que pour des mouvements plus simples.

Uchida *et al.* [46] ont obtenu une précision de classification de 86% pour les mouvements de flexion du pouce, de l'index, du majeur, de tous les doigts, et la relaxation de la main. L'entraînement et le test de la classification ont été faits à partir d'un ensemble de 6 fois chaque mouvement. La détection était effectuée sur deux voies à l'aide d'électrodes de surface placées au-dessus du muscle *flexor digitorum superficialis*.

Tsenov *et al.* [45] ont obtenu 93% de précision avec deux électrodes bi-polaires et 98% avec quatre électrodes bi-polaires pour les mouvements : flexion du pouce, de l'index, du majeur, et fermeture de la main. Ils ont utilisé un ensemble de 25 fois chaque mouvement pour l'entraînement et le test de la classification. Pour le cas deux voies, les électrodes ont été placées au-dessus des muscles *palmaris longus* et *extensor digitorum*.

Par contre, dans ces deux articles [45,46], la durée des mouvements n'est pas définie, or la méthode optimale dépend fortement de la durée du mouvement [14]. De plus, les deux études portaient sur un seul sujet et le nombre de mouvements classifiés est petit par rapport à ceux dans les études qui portent sur les mouvements dynamiques du bras, du poignet et de la fermeture de la main [6, 13–15, 25, 38]. Ces deux facteurs ont une incidence sur la généralisation des résultats.

Saponas *et al.* [42] sont parvenus à classifier avec 84% de précision un ensemble de 20 mouvements des doigts : lever et taper d'un des cinq doigts, tendre ou plier l'index et le majeur, et appuyer avec une faible et moyenne intensité du bout de l'index et du majeur. Huit capteurs bi-différentiels ont été placés régulièrement autour de l'avant-bras avec une distance inter-électrode d'environ 2.5 cm. Treize sujets sains ont répété 45 fois chaque mouvement pour l'entraînement et 5 fois chaque mouvement pour le test de la classification. Les auteurs ont choisi d'extraire trois ensembles de caractéristiques et d'utiliser une version non-modifiée d'un algorithme de classification d'un logiciel de data-mining [47], et la règle de vote majoritaire pour déterminer le mouvement effectué. D'après les auteurs, ce choix très simple de traitement des données doit permettre de trouver une borne inférieure à la précision de classification et de rendre leur technique accessible à d'autres chercheurs. Cependant, les auteurs envisagent à terme la commercialisation d'un brassard fin (*cf* figure 1), qui impliquerait une distance inter-électrodes réduite, et du même coup, un volume de détection restreint qui ne permettrait pas forcément de mesurer l'activité électromyographique des muscles profonds, impliquant une détérioration de la précision de classification.

Andrews [1] a testé sur 12 sujets toute une batterie de classifieurs sur deux ensembles de mouvements dynamiques qui consistaient à appuyer sur une touche d'ordinateur. Huit électrodes ont été utilisées dans cette étude, régulièrement espacées autour de l'avant-bras avec une distance inter-électrode d'environ 2cm. Pour chaque sujet, Andrews a déterminé le taux optimal de classification. Ce taux est en moyenne de 92,8% pour un ensemble de 4 mouvements (appui sur les doigts index à auriculaire), et 93,6% pour l'appui sur le pouce et l'index.

2.1.3 Définition des mouvements considérés dans cette étude

Dans le cadre de l'expérimentation de cette étude, nous avons choisi d'utiliser de la même manière huit électrodes bi-différentiels et une distance inter-électrodes de 2.5 cm. Nous pourrions donc potentiellement classifier les mouvements du poignet et des doigts, ainsi que la pronation et la supination de l'avant-bras. En effet, les muscles qui commandent la flexion et l'extension des doigts sont situés dans l'avant-bras, quoique assez proche du poignet pour certains mouvements du pouce. De même, les muscles qui commandent flexion, extension, inclinaisons ulnaire et radiale du poignet sont situés dans l'avant-bras. Pour le cas particulier de la pronation et de la supination, les muscles qui commandent ces mouvements sont en partie dans le bras, et en partie dans l'avant-bras.

Nous avons donc choisi de tester la classification sur un ensemble composé de 30 mouvements :

- pour l'un des 5 doigts, et tous les doigts sauf le pouce :
 - l'extension (6 mouvements)
 - la flexion avec une faible intensité (6 mouvements)
 - la flexion avec une moyenne intensité (6 mouvements)
- pour le poignet :
 - l'extension et la flexion avec une faible et une moyenne intensité (4 mouvements)
 - l'inclinaison ulnaire et radiale avec une faible et une moyenne intensité (4 mouvements)
 - la pronation et la supination avec une faible et une moyenne intensité (4 mouvements)

2.2 Les caractéristiques de la classification

2.2.1 La détection de mouvements et la fenêtre de classification

Que ce soit pour la classification en direct ou en différé, l'étape précédent la classification est de déterminer à quelles parties du signal électromyographique correspond un mouvement. Pour les articles où la classification se fait en différé, les méthodes de détection peuvent être classées de la manière suivante : détection automatique [5, 16, 21, 30], détection continue [6, 13–15, 38, 46] ou détection manuelle.

La détection automatique nécessite l'utilisation d'un seuil : c'est-à-dire que lorsqu'un test mathématique sur le signal est vrai, on admet qu'un mouvement est initié, et on déclenche la classification. Les fonctions mathématiques utilisées dans la littérature sont par exemple la différence d'énergie entre deux fenêtres

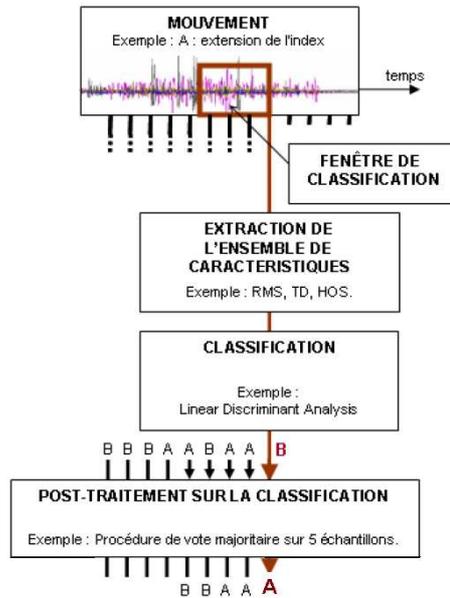


FIG. 2.1 – Composantes des méthodes de classification dans le cas de la classification continue. L'extraction de caractéristiques puis la classification est effectuée régulièrement sur une courte fenêtre de signal. En cas de post-traitement, le processus de décision tient en compte les décisions précédentes

consécutives, des caractéristiques d'amplitude dans une fenêtre glissante par rapport à une ligne moyenne [5,16], le maximum des transformées en ondelettes à un instant donné [30].

Pour la détection continue, on classe des mouvements à intervalles réguliers d'après le signal contenu dans des fenêtres qui peuvent se superposer. Dans ce cas, on peut se passer de l'utilisation d'un seuil de détection, mais on doit prévoir en contrepartie d'ajouter le mouvement "relaxé" à l'ensemble des mouvements à classifier.

La détection manuelle n'est pas utilisable pour la classification en direct, elle se base sur la reconnaissance des bouffées de signaux électromyographiques par l'expérimentateur.

Dans notre cas, nous utiliserons une détection semi-automatique et une détection continue. La détection semi-automatique permettra d'extraire de courts enregistrements nécessaires à l'entraînement et au test du classifieur, et on procédera à une détection continue sur des enregistrements plus longs.

Dans le cas du contrôle de prothèses, il existe un risque de rejet par le patient si le retard entre l'intention d'un mouvement et l'action par la prothèse est perçu. Il est admis que ce retard ne doit pas dépasser 300 ms [15, 39].

Dans le cas des interface muscles-machine pour l'interaction homme-machine, le risque encouru en cas de dépassement des 300 ms n'est pas aussi important, nous nous limiteront tout de même à une longueur de fenêtre de classification de 240 ms, ce qui laisse 60 ms de marge pour le temps de calcul. De plus, nous nous proposons d'étudier l'influence qu'aurait une fenêtre plus courte sur les performances du classifieur. Nous testerons donc trois longueurs de fenêtre de classification : 160, 200 et 240 ms.

2.2.2 Les ensembles de caractéristiques

Il serait trop lourd d'utiliser directement les échantillons du signal brut, d'une part car le signal brut comporte beaucoup de redondances, et d'autre part, le signal EMGs est dit pseudo-aléatoire, ce qui signifie que la probabilité que deux réalisations du même geste soient identiques est nulle. Dès lors, le choix de l'ensemble de caractéristiques à extraire des signaux *cf* : figure (2.1) est primordial. En effet, il a été montré que le choix des caractéristiques est plus influent que le choix du classifieur sur les résultats de la classification.

Les ensembles de caractéristiques utilisées dans cette étude sont listées ci-dessous et détaillées dans les paragraphes suivantes.

- Valeur Quadratique Moyenne (Root Mean Square : RMS)
- Caractéristiques temporelles de Hudgins (Hudgins' time-domain features : TD)
- Auto-corrélation et inter-corrélation (Auto-correlation and cross-correlation coefficients : CV)
- Amplitudes des puissances spectrales (Spectral power magnitudes : SPMs)
- Statistiques d'ordre supérieur (Higher Order Statistics : HOS)

Nous y rajouterons trois ensembles dérivés des algorithmes de séparation aveugle de source :

- Caractéristiques dérivées de l’algorithme SOBI (Second Order Blind Identification)
- Caractéristiques dérivées de l’algorithme EFICA (Efficient variant of FastICA)
- Caractéristiques dérivées de l’algorithme UNICA (Unified Classification Algorithm)

Et ces mêmes algorithmes seront utilisés comme pré-traitement sur les signaux, avant d’appliquer les caractéristiques RMS, TD, CV, SPMs et HOS citées ci-dessus.

Pour finir, nous proposerons un pré-traitement ”puissance un quart” de toutes les caractéristiques ainsi obtenues, qui consiste à élever les caractéristiques à cette puissance. Dans ce cas, tout se passe comme si on changeait d’espace de représentation des caractéristiques par une transformation non-linéaire, comprimant les grandes valeurs et dilatant les petites. On verra que ce pré-traitement augmente considérablement les taux de classification. Nous ne proposerons pas d’étude théorique à son propos, cependant il serait intéressant de vérifier dans quelle mesure les variations des petites valeurs de caractéristiques sont plus discriminantes que les variations des grandes valeurs.

Valeur Quadratique Moyenne (RMS) L’ensemble de caractéristiques RMS est composé des valeurs RMS de chaque voie dans la fenêtre de classification. Sa simplicité justifie son inclusion dans cette étude. Pour chaque voie i et pour la fenêtre de classification située en $t = t_k$ de longueur N échantillons, la valeur RMS ($RMS_i(t_k)$) est définie par :

$$RMS_i(t_k) = \frac{1}{N} \cdot \sqrt{\sum_{q=0}^{N-1} x_i(t_{k+q})^2} \quad (2.2.1)$$

Caractéristiques temporelles de Hudgins (TD) Introduit en 1993 dans [21], cet ensemble de caractéristiques temporelles dénommé Hudgins’ time-domain feature set (TD) a été utilisé plusieurs études [13–16]. A l’origine, l’ensemble comporte cinq caractéristiques différentes pour chaque voie et pour une fenêtre de classification divisée en six segments de longueurs égales. quatre caractéristiques sont calculées pour chaque segment, et une caractéristique est définie comme une différence entre les caractéristiques de deux segments voisins. On a donc au total $4 \times 6 + 5 = 29$ caractéristiques par voie. Les caractéristiques sont :

- la valeur absolue moyenne (*6 caractéristiques*)
- le nombre de passages par zéro (*6 caractéristiques*)
- le nombre de changement de signe de la pente (*6 caractéristiques*)
- la longueur de la forme d’onde (*6 caractéristiques*)
- la différence entre deux valeurs absolues moyennes, ou pente de valeur absolue moyenne (*5 caractéristiques*)

Pour être rigoureusement définies, les caractéristiques 2 et 3 nécessitent l’introduction d’un seuil pour prendre en compte que certains événements sont causés par le bruit dans lequel baigne le signal. Dans certaines études qui utilisent cet ensemble de caractéristiques, certaines de ces caractéristiques n’ont pas été utilisées. En particulier, Chan *et al.* [5] ont montré que l’effet de l’utilisation du nombre de changement de signe de la pente sur la classification est soit négatif soit négligeable.

L’ensemble de caractéristiques TD est très efficace pour la classification de contractions isostatiques, avec une précision de classification de 99.5% pour quatre mouvements et quatre voies [15]. Néanmoins, certains autres ensembles de caractéristiques sont plus performants pour les mouvements transitoires [14–16].

L’implémentation de cet ensemble de caractéristiques pour le domaine de la classification des données électromyographiques a permis de classer avec précision plusieurs mouvements [21]. Son utilisation commune et ses bonnes performances justifient l’inclusion de l’ensemble TD dans cette étude. Nous nous limitons à l’utilisation de la valeur absolue moyenne $MAV_i(t_k)$ et de la longueur de la forme d’onde $WL_i(t_k)$.

En gardant les notations de la sous-section précédente, ces caractéristiques sont définies par :

$$\begin{aligned} MAV_i(t_k) &= \frac{1}{N} \cdot \sum_{q=0}^{N-1} |x_i(t_{k+q})| \\ WL_i(t_k) &= \sum_{q=1}^{N-1} |x_i(t_{k+q}) - x_i(t_{k+q-1})| \end{aligned} \quad (2.2.2)$$

Auto-corrélation et inter-corrélation (ACCC) ou variation de corrélation (CV) L’utilisation des auto-corrélations et des inter-corrélations comme ensemble de caractéristiques a été proposée par Leowinata

et al. en 1998 [25]. Leur motivation a été de supposer que le phénomène d’interférence entre les électrodes comporte beaucoup d’information utile.

D’abord testé avec succès sur des données simulées, cet ensemble de caractéristiques a été utilisé par Englehart *et al.* [15] pour classifier des données électromyographiques avec quatre mouvements transitoires et quatre voies. Dans ce cas, la précision de classification (97%) fut un peu moins bonne que celle obtenue avec l’ensemble de caractéristiques TD.

Dans notre étude, les données électromyographiques ont été mesurées à partir de huit électrodes mono-différentielles autour de l’avant-bras, qui ont chacune un relativement grand volume de détection. On est ainsi assuré qu’il y aura des interférences entre les électrodes, et cela justifie l’utilisation de l’ensemble CV pour cette étude.

Nous utiliserons en fait une variante de cet ensemble : l’ensemble des variations de corrélation (CV), moins gourmand en temps de calcul, qui est composé de la RMS de chaque voie (*cf* equation 2.2.1) et de l’angle entre les voies :

$$A_{(i,j)}(t_k) = \frac{\sum_{q=0}^{N-1} x_i(t_{k+q}) \cdot x_j(t_{k+q})}{\sqrt{RMS_i(t_k) \cdot RMS_j(t_k)}}, i < j$$

Amplitudes des puissances spectrale (SPMs) Cet ensemble de caractéristiques se compose de l’amplitude moyenne des puissances du signal contenues dans des bandes de fréquences disjointes. C’est une mesure simple du contenu spectral du signal qui a été testée comme ensemble de caractéristiques dans plusieurs études [20, 46]. Il est nécessaire dans un premier temps de calculer le spectre de puissance en opérant une transformée rapide de Fourier (FFT) du signal dans la fenêtre de classification.

Hiraiwa *et al.* [46] et Uchida *et al.* [46] ont utilisé dix bandes de fréquences disjointes entre 63 et 500 Hz pour former l’ensemble SPMs, ils l’ont ensuite testé pour la classification de mouvements des doigts. Les fréquences centrales ont été précisées dans la seconde étude et sont : 63, 80, 100, 125, 160, 200, 250, 315, 400, et 500 Hz [46]. Cela peut être justifié par le fait que la plupart de l’énergie du signal électromyographique est comprise entre 40 et 600 Hz [?]. La précision de classification fut de 67% avec une seule voie [46] et 86% avec deux [46].

Dans notre étude, nous utiliseront dix bandes de largeur 20 Hz centrées autour des fréquences citées ci-dessus.

Statistiques d’ordre supérieur (HOS) Testé pour la première fois par Nazarpour *et al.* [38] comme ensemble de caractéristiques pour la classification de signaux électromyographiques, l’utilisation des statistiques d’ordre supérieur est justifiée par la non-Gaussianité des signaux électromyographiques pour des faibles contractions [38]. Les signaux non-Gaussiens comportent en effet de l’information dans les statistiques d’ordre supérieur à deux comme les cumulants.

Nazarpour *et al.* en particulier ont testé un ensemble de 19 caractéristiques par voie, comprenant des statistiques d’ordre 2 (variance), 3 (asymétrie) et 4 (kurtosis). Les données ont été orthonormalisées dans un premier temps de telle sorte que leur moyenne et que leur variance soient respectivement égales à 0 et 1 (*cf* équation 2.2.3), puis les cumulants d’ordre 2, 3, et 4 ont été calculés avec des décalages temporels de 0, 1, et 2 échantillons, ce qui aboutit à 19 caractéristiques.

$$x'(t) = \frac{x(t) - \bar{x}}{\sigma} \quad (2.2.3)$$

Par une procédure pas-à-pas, Nazarpour *et al.* ont sélectionné seulement 2, puis 3 caractéristiques parmi les 19 de telle sorte que les résultats de classification restent très bon. Pour ce faire ils ont testé l’ensemble des paires et des triplets de cumulants pour classifier quatre mouvements transitoires du bras avec deux voies, sur plusieurs sujets. Les ensembles de cumulants qui donnent les meilleurs résultats de classification sont $[C_2(0), C_4(0, 0, 0)]$ et $[C_2(0), C_2(1), C_4(0, 0, 0)]$, où $C_n(\{\tau_i\}_{1 \leq i < n})$ représente le cumulants d’ordre n calculé avec les retards $\{\tau_i\}_{1 \leq i < n}$. La précision de la classification qu’ils ont obtenue en utilisant le triplet de cumulants et un classifieur \bar{K} -plus-proche voisins (\bar{K} -nearest neighbour) fut 93.2%, à comparer avec les 94.1% obtenus en utilisant les 19 cumulants.

Bien que cet ensemble de caractéristiques soit un de ceux qui a reçu le moins d’attention dans la littérature, sa simplicité et sa petite dimension nous ont poussé à le sélectionner pour cette étude.

Nous utiliseront donc le triplet de cumulants $[C_2(0), C_2(1), C_4(0, 0, 0)]$, où :

$$\begin{aligned}
C_2(0) &= E[x'(t_k)^2] = \frac{1}{N} \cdot \sum_{q=0}^{N-1} x'(t_{k+q})^2 \\
C_2(1) &= E[x'(t_k) \cdot x'(t_{k+1})] = \frac{1}{N-1} \cdot \sum_{q=0}^{N-2} x'(t_{k+q}) \cdot x'(t_{k+q+1}) \\
C_4(0,0,0) &= E[x'(t_k)^4] - 3 \cdot C_2(0) = \frac{1}{N} \cdot \sum_{q=0}^{N-1} x'(t_{k+q})^4 - 3 \cdot \frac{1}{N} \cdot \sum_{q=0}^{N-1} x'(t_{k+q})^2
\end{aligned} \tag{2.2.4}$$

2.2.3 La classification

Les classifieurs communément utilisés dans la littérature [39, 41] sont les réseaux de neurones formels [14, 20, 46], les classifieurs Linear Discriminant Analysis [13, 15], les systèmes de logique floue [25, 39], les chaînes cachées de Markov [31, 48, 50]. Le classifieur le plus efficace parmi ceux qui utilisent les réseaux de neurones formels est le Perceptron Multi-couches (Multilayer Perceptron MLP) [14].

Nous avons choisi de concentrer notre étude sur le choix de l'ensemble de caractéristiques, et avons donc choisi de sélectionner un seul classifieur. Nous nous sommes donc basés sur l'étude d'Andrews [1] qui avait comparé les classifieurs Linear Discriminant Analysis (LDA), Multilayer Perceptron (MLP), et Statistical Classifier (SC) sur deux ensembles de 2 et 4 mouvements, et nous avons fait le choix de sélectionner le classifieur LDA pour l'ensemble de l'étude.

2.2.4 Post-traitement pour la classification continue

Dans le domaine du contrôle myoélectrique, les chercheurs se sont penchés sur un certain nombre de techniques de post-traitement de la classification pour la prise de décision. L'idée générale est de prendre en compte d'autres paramètres que la sortie actuelle du classifieur pour décider si tel ou tel mouvement a été effectué.

Une technique consiste à prendre en compte les décisions antérieures pour moduler la décision. La procédure de vote majoritaire [14, 15] en est une des plus simples. Dans l'ensemble { décisions antérieures \cup la sortie actuelle du classifieur }, cette technique consiste à prendre la décision de la classe la plus représentée. En cas d'égalité, on doit choisir l'une ou l'autre des options suivantes : soit prendre les deux décisions ; soit ne prendre aucune décision ; soit choisir le geste qui est prioritaire. Cette dernière option nécessite d'établir des règles de priorité entre les gestes.

En utilisant la logique floue, on peut définir une variante de la procédure de vote majoritaire, qui consisterait, pour la décision, à donner plus de poids à la sortie actuelle du classifieur qu'aux décisions récentes, et plus de poids aux décisions précédentes qu'aux décisions plus anciennes.

La seconde technique que nous décrivons se base sur l'utilisation des chaînes cachées de Markov [31, 48, 50]. Dans le cas d'une chaîne d'ordre 1, on doit au préalable définir expérimentalement les probabilités de passage d'une classe à l'autre. Une fois la matrice de probabilité de transition définie, il est alors possible d'estimer le geste le plus probable en fonction des gestes précédents pour rendre la décision. Même une chaîne de Markov d'ordre 1 fait qu'on prend en compte (en théorie, et par récurrence) une infinité de décisions antérieures.

Dans cette étude, nous nous proposons d'utiliser le post-traitement par procédure de vote majoritaire pour la prise de décision. Nous étudierons l'effet du nombre de prise de décision antérieures (d'échantillons) pris en compte pour le vote, sur les performances de la classification continue. Par contre, en cas d'égalité, nous nous garderons de donner la priorité à l'un ou l'autre des mouvements. Pour les calculs des performances de la classification, nous considérerons que la décision est partagée entre les mouvements à égalité. Par exemple, en cas d'égalité entre le geste A et le geste B, et si le geste réel est le geste A, le geste A sera considéré comme 1/2 bien classifié.

Chapitre 3

Utilisation des méthodes de séparation aveugle de source

Les signaux observés sont en réalité un mélange de différents signaux sources émis au niveau des muscles. Le mélange entre ces sources qui s'effectue pendant leur propagation dans l'avant-bras est inconnu a priori. Pourtant, savoir quels muscles sont sollicités et avec quelle intensité serait un atout majeur pour la reconnaissance des mouvements, puisque efforts et mouvements sont très intimement liés par la biomécanique. Pour accéder à ces informations reflétant la commande gestuelle, il existe en traitement du signal des méthodes dites de séparation aveugle de source.

Nous exposerons dans ce chapitre les formulations de deux méthodes de séparation aveugle de source retenues pour cette étude : une par second ordre et une par analyse en composantes indépendantes, et la prudence qui est de rigueur vis-à-vis des hypothèses sur lesquelles reposent ces méthodes.

Nous exposerons ensuite quelques applications aux signaux électromyographiques.

Enfin, nous décrirons l'utilisation que nous ferons de ces méthodes dans le cadre de notre étude, en particulier les ensembles de caractéristiques que nous dériverons de ces techniques. Puis, en se basant sur la résolution du problème de séparation aveugle de source et des modélisations du signal EMG et du milieu de propagation, nous proposerons un algorithme de localisation des muscles. Cet algorithme sera à la base de l'estimation d'un décalage angulaire du système d'électrodes, et d'une méthode de reconstruction du signal. C'est sur ces bases que nous nous proposons d'évaluer dans quelle mesure il est possible de rendre la classification robuste à un tel décalage angulaire.

3.1 Formulation mathématique et méthodes retenues

La séparation aveugle de source a fait l'objet d'une multitude d'études ces dernières années. On peut en expliquer le principe de la manière suivante :

D'un système de mélange et de filtrage MIMO (multiple-input/multiple-output) inconnu, on observe pour les instants discrets $t_k, k = 1, \dots, N$ les signaux enregistrés par les capteurs $\mathbf{x}(t_k) = [x_1(t_k), \dots, x_m(t_k)]^T$, où $(\cdot)^T$ est la fonction transposée. L'objectif est de trouver un système de reconstruction adaptatif, s'il existe et est stable, dans le but d'estimer les signaux des sources originales $\mathbf{s}(t_k) = [s_1(t_k), \dots, s_n(t_k)]^T$. Cette estimation est effectuée sur la seule base des signaux de sorties $\hat{\mathbf{s}}(t_k) = [\hat{s}_1(t_k), \dots, \hat{s}_n(t_k)]^T$, et des observations.

Il existe plusieurs type de mélanges, mais nous ne nous intéresserons qu'au mélange linéaire instantané, hypothèse validée pour les signaux EMG au niveau de l'avant-bras [17].

3.1.1 Introduction à la séparation aveugle de source

Formulation mathématique : On peut écrire sous forme matricielle :

$$\mathbf{x} = \mathcal{A}\mathbf{s}$$

où $\mathbf{x} = [\mathbf{x}(t_1), \dots, \mathbf{x}(t_N)] \in \mathbb{R}^{m \times N}$ est la matrice des observations, $\mathbf{s} = [\mathbf{s}(t_1), \dots, \mathbf{s}(t_N)] \in \mathbb{R}^{n \times N}$ est celle des sources et $\mathcal{A} \in \mathbb{R}^{m \times n}$ est la matrice inconnue de mélange.

La séparation aveugle de sources consiste à estimer les sources à partir des mélanges et d'hypothèses statistiques sur les sources. L'adjectif aveugle signifie que les sources ne sont pas observées et que l'on ne possède aucune information sur le mélange a priori. Ce problème, dû au manque d'informations *à priori*, est sans solution si l'on ne rajoute pas certaines hypothèses sur les sources \mathbf{s}_i .

Il nous faut donc estimer les sources \mathbf{s} à partir des seules observations \mathbf{x} et des hypothèses par l'intermédiaire d'une matrice de séparation $\mathcal{B} \in \mathbb{R}^{n \times m}$.

$$\hat{\mathbf{s}} = \mathcal{B}\mathbf{x}$$

Cette estimation des sources se fera donc en choisissant la matrice de mélange \mathcal{B} de telle sorte que $\hat{\mathbf{s}}$ satisfasse au mieux (selon un critère) les hypothèses formulées.

Indéterminations inhérentes au problème de séparation aveugle de source : Le problème tel qu'il est posé ne permet pas l'identification complète de \mathcal{A} , car l'échange d'un facteur scalaire entre le signal source et le vecteur colonne de \mathcal{A} n'affecte pas les signaux observés. Ainsi, on peut supposer sans aucune restriction que les signaux sources sont de variance unité. De même, on remarquera que la numérotation des signaux sources est arbitraire. Il en est donc de même pour les vecteurs colonnes de \mathcal{A} .

Ainsi, \mathcal{A} est identifiable au mieux à une permutation et à des facteurs scalaires près.

3.1.2 Identification aveugle du second ordre

Belouchrani et al. [3] ont utilisé les hypothèses que les signaux sources sont stationnaires au second ordre et mutuellement décorrélés pour développer un algorithme d'identification aveugle du second ordre (second order blind identification – SOBI). Les auteurs montrent qu'après blanchiment des observations, une diagonalisation conjointe des matrices en question permet d'estimer le mélange aux indéterminations classiques de la séparation aveugle de source près. L'algorithme était initialement présenté pour des signaux complexes et additivement bruités par un bruit spatialement et temporellement blanc, et décorrélé des signaux sources. Nous présenterons ici l'algorithme sur des signaux réels et non bruités.

L'analyse en composantes principales des observations exploite la matrice d'autocovariance $\mathcal{C}_{\hat{\mathbf{s}}}(0)$ de ces dernières afin d'assurer l'annulation de la covariance $E[\hat{\mathbf{s}}_i(t)\hat{\mathbf{s}}_j(t)], \forall i \neq j$. Il s'agit de trouver une matrice \mathcal{W} de telle sorte que le processus $\mathbf{y}(t) = \mathcal{W}\mathbf{x}(t)$ soit spatialement décorrélé. On impose, en outre, à la matrice \mathcal{W} de normaliser le problème de séparation, on parlera usuellement de blanchiment des signaux captés. Puisque l'on peut toujours considérer les sources de puissance unité, la condition de blanchiment s'écrit alors :

$$\begin{aligned} \mathcal{I}_n &= E[(\mathcal{W}\mathbf{x}(t))(\mathcal{W}\mathbf{x}(t))^T], \\ &= E[\mathcal{W}\mathcal{A}\mathbf{s}(t)\mathbf{s}(t)^T\mathcal{A}^T\mathcal{W}^T], \\ &= (\mathcal{W}\mathcal{A})(\mathcal{W}\mathcal{A})^T. \end{aligned} \tag{3.1.1}$$

Posons :

$$\mathcal{U} = \mathcal{W}\mathcal{A} \tag{3.1.2}$$

L'équation (3.1.1) montre que la matrice \mathcal{U} est unitaire. Le filtre blanchisseur \mathcal{W} décorrèle les observations et ramène le mélange des sources à un mélange unitaire.

La condition de décorrélation entre les composantes de $\mathbf{y}(t)$ est donc nécessaire mais non suffisante, elle ne permet d'identifier les sources $\mathbf{s}(t)$ qu'à une matrice unitaire \mathcal{U} près. Pour que la séparation de sources puisse être achevée, il faut identifier la rotation manquante \mathcal{U} .

Les matrices $\mathcal{C}_{\mathbf{y}}(\tau)$ des observations blanchies s'écrivent par définition :

$$\forall \tau \neq 0, \mathcal{C}_{\mathbf{y}}(\tau) = \mathcal{W}\mathcal{C}_{\mathbf{x}}(\tau)\mathcal{W}^T$$

D'après 3.1.2, on obtient la relation :

$$\forall \tau \neq 0, \mathcal{C}_{\mathbf{y}}(\tau) = \mathcal{W}\mathcal{A}\mathcal{C}_{\mathbf{s}}(\tau)\mathcal{A}^T\mathcal{W}^T = \mathcal{U}\mathcal{C}_{\mathbf{s}}(\tau)\mathcal{U}^T$$

Les matrices d'intercovariance $\mathcal{C}_{\mathbf{s}}(\tau)$ des sources colorées étant diagonales, \mathcal{U} est donc une base propre pour toutes les matrices $\mathcal{C}_{\mathbf{y}}(\tau), \forall \tau$. La matrice \mathcal{U} peut être déterminée de manière unique dans le cas où il est possible de trouver une valeur particulière τ_p de τ telle que la matrice $\mathcal{C}_{\mathbf{s}}(\tau_p)$ ne possède pas de valeurs propres multiples.

Si les fonctions d'autocorrélation des sources normalisées en puissance sont différentes, il est fort probable d'atteindre une valeur τ_p assurant la non dégénérescence des valeurs propres. Toutefois l'obtention de cette valeur n'est pas assurée.

Si on se limitait à la diagonalisation d'une seule matrice d'inter-corrélation $\mathcal{C}_{\mathbf{y}}(\tau)$, cela reviendrait à fixer $n(n+1)/2$ coefficients sur n^2 qu'impose l'indépendance dans le cas où l'on a n capteurs et n sources. Ce résultat n'est pas surprenant puisque nous ne nous sommes fixés qu'un critère du second ordre : la décorrélation au lieu de l'indépendance.

L'algorithme de séparation de source SOBI consiste à diagonaliser conjointement dans une même base \mathcal{U} , un ensemble de matrices $\{\mathcal{C}_y(\tau_i) | i = 1 \dots K\}$ pour différentes valeurs de τ choisies a priori.

La technique de diagonalisation conjointe de matrices normales a été introduite dans [19], sous forme d'une généralisation de la méthode de JACOBI de diagonalisation d'une seule matrice hermitienne. On recherche une transformation unitaire diagonalisant au mieux (au sens d'un critère quadratique) un ensemble de matrices normales.

Après détermination de \mathcal{U} , les sources sont ensuite restaurées en calculant le produit :

$$\hat{\mathbf{s}}(t) = \mathcal{U}^T \mathbf{y}(t) = \mathcal{U}^T \mathcal{W} \mathbf{x}(t)$$

Donc la matrice de séparation s'écrit :

$$\mathcal{B} = \mathcal{U}^T \mathcal{W}$$

3.1.3 Analyse en composantes indépendantes

L'analyse en composantes indépendantes introduite par C. Jutten au milieu des années 80 permet aussi de déterminer les $n(n-1)/2$ dernières conditions qu'impose l'indépendance. Pour cela, à partir des estimées décorrélatées \mathbf{x} , redéfinissons une matrice \mathcal{U} qui permette d'obtenir l'indépendance :

$$\hat{\mathbf{s}} = \mathbf{z} = \mathcal{U}^T \mathbf{y} = \mathcal{U}^T \mathcal{W} \mathbf{x} \quad (3.1.3)$$

Il vient alors, pour conserver la décorrélation, que \mathcal{U} est une matrice orthogonale donc de rotation puisque

$$\mathcal{C}_z = \mathcal{U}^T \mathcal{C}_y \mathcal{U} = \mathcal{U}^T \mathcal{U} = \mathcal{I}_n$$

Comment déterminer alors cette matrice \mathcal{U} ? Pour cela, nous devons nous rappeler de la définition de l'indépendance statistique : des variables aléatoires $\{z_i\}_i$ sont indépendantes si et seulement si la densité de probabilité conjointe $p_{\mathbf{z}}(z_1, \dots, z_N)$ est égale au produit des densités marginales $p_{Z_i}(z_i)$

$$z_1, \dots, z_N \text{ indépendantes} \iff p_{\mathbf{z}}(z_1, \dots, z_N) = \prod_{i=1}^N p_{Z_i}(z_i) \quad (3.1.4)$$

Une façon de mesurer l'indépendance est donc de quantifier l'écart entre les deux densités de probabilité $p_{\mathbf{z}}(z_1, \dots, z_N)$ et $\prod_i p_{Z_i}(z_i)$ à l'aide de la divergence de Kullback

$$I(z_1, \dots, z_N) = \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} p_{\mathbf{z}}(z_1, \dots, z_N) \ln \frac{p_{\mathbf{z}}(z_1, \dots, z_N)}{\prod_{i=1}^N p_{Z_i}(z_i)} dz_1 \dots dz_N \quad (3.1.5)$$

Cette divergence peut en effet servir de critère d'indépendance puisque

$$\forall (z_1, \dots, z_N), \quad I(z_1, \dots, z_N) \geq 0$$

avec égalité si et seulement si z_1, \dots, z_N sont indépendantes. Réécrivons la divergence de Kullback (3.1.5), que l'on appelle alors information mutuelle, à l'aide des entropies,

$$I(z_1, \dots, z_N) = \sum_{i=1}^N h(z_i) - h(\mathbf{z}) \quad (3.1.6)$$

où $h(\cdot)$ est l'entropie définie par

$$\begin{cases} h(z_i) &= -\int p_{Z_i}(z_i) \ln p_{Z_i}(z_i) dz_i &= -E \{ \ln p_{Z_i}(z_i) \} \\ h(\mathbf{z}) &= -\int \dots \int p_{\mathbf{z}}(\mathbf{z}) \ln p_{\mathbf{z}}(\mathbf{z}) d\mathbf{z} &= -E \{ \ln p_{\mathbf{z}}(\mathbf{z}) \} \end{cases}$$

Or on a

$$h(\mathbf{z}) = h(\mathbf{x}) + \ln |\det(\mathcal{U})| = h(\mathbf{x})$$

puisque \mathcal{U} est une matrice orthogonale. Donc le critère à minimiser pour obtenir la matrice de rotation \mathcal{U} est

$$J(z_1, \dots, z_N) = \sum_{i=1}^N h(z_i) \quad (3.1.7)$$

ce qui permet de nous ramener à N problèmes simples à 1 dimension : minimiser les $\{h(z_i)\}_{1 \leq i \leq n}$, au lieu d'un problème complexe à N dimensions : minimiser $I(\mathbf{z})$. La minimisation des entropies marginales $h(z_i)$ peut être effectuée par des méthodes de gradient qui font appel au calcul de $\partial h(z_i)/\partial \mathcal{U}$ nécessitant l'introduction des fonctions score marginales [22] définies par

$$\psi_{Z_i}(z_i) = -\frac{p'_{Z_i}(z_i)}{p_{Z_i}}(z_i) \quad (3.1.8)$$

puisque le gradient par rapport à un coefficient $\mathcal{U}_{i,k}$ vaut

$$\frac{\partial h(z_i)}{\partial \mathcal{U}_{i,k}} = -E \left\{ \frac{\partial \ln(p_{Z_i}(z_i))}{\partial \mathcal{U}_{i,k}} \right\} = E \left\{ \psi_{Z_i}(z_i) \frac{\partial z_i}{\partial \mathcal{U}_{i,k}} \right\}$$

Diverses méthodes [22] existent pour l'estimation des densités de probabilité marginales $p_{Z_i}(z_i)$ et des fonctions score marginales $\psi_{Z_i}(z_i)$. Même si cette estimation reste d'un coût acceptable, on se contente parfois d'utiliser des critères [4, 7] (comme dans les algorithmes Jade ou ICA) faisant intervenir les statistiques d'ordre supérieur tels que les cumulants d'ordre 4. Tout comme les moments sont définis par les coefficients du développement de Taylor de la première fonction caractéristique, les cumulants [23] sont quant à eux les coefficients du développement de Taylor de la seconde fonction caractéristique. Ces critères annulent par exemple tous les cumulants croisés d'ordre 4 ce qui permet de fixer les $n(n-1)/2$ dernières conditions définissant la matrice \mathcal{U} en complétant ainsi le problème de l'estimation d'une matrice de séparation $\mathcal{B} = \mathcal{U}^T \mathcal{W}$. Les sources sont alors estimées par

$$\hat{\mathbf{s}} = \mathcal{U}^T \mathcal{W} \mathbf{y} \quad (3.1.9)$$

FastICA est un des algorithmes les plus populaires pour l'analyse en composantes indépendantes développé par Hyvärinen et Oja. Cet algorithme estime les composantes indépendantes au moyen d'une mesure de non gaussianité après normalisation et décorrélacion. En effet, le théorème central limite stipule que la somme de variables indépendantes tend asymptotiquement vers une distribution normale. Dans le cas considéré, les estimations des sources $\hat{\mathbf{s}}$ sont une somme de variables indépendantes et tendent donc vers une distribution gaussienne. En cherchant à maximiser la non gaussianité des sources reconstituées $\hat{\mathbf{s}}$, chacune de ses composantes tendra vers une estimation des sources indépendantes (aux deux indéterminations près).

Plusieurs mesures de non-gaussianité ont été proposées, la plus usitée étant la néguentropie qui est la différence entre l'entropie d'une variable gaussienne et l'entropie du vecteur mesuré. Hyvärinen a proposé différentes approximations de cette mesure permettant une mise en œuvre algorithmique du principe exposé. L'algorithme FastICA se base sur le cumulants d'ordre quatre, ou kurtosis.

Le blanchiment préalable est nécessaire pour éviter que toutes les estimations ne convergent vers la même source. Deux méthodes existent pour imposer cette orthogonalité. La version dite par déflation estime itérativement les sources et orthogonalise chaque estimation au moyen d'une procédure de Gram-Schmidt. La version symétrique orthogonalise simultanément toutes les estimations.

Efficient variant of FastICA – EFICA Koldovský, Tichavský and Oja [44] ont développé une variante de la version symétrique de FastICA, nommée EFICA (efficient variant of FastICA). Cette variante est asymptotiquement efficace, c'est-à-dire que la précision calculée à partir de l'erreur quadratique résiduelle atteint asymptotiquement la borne inférieure de Cramér-Rao : borne inférieure sur la variance d'un estimateur sans biais, basée sur l'Information de Fisher. L'algorithme comporte deux phases : (1) application de l'algorithme FastICA symétrique avec test de point selle (pour éviter la convergence vers un minimum local de l'erreur [40]); (2) raffinement qui utilise une non linéarité choisie sur la base du moment d'ordre quatre des sources estimées.

Unbiased quasi Newton algorithm for ICA – UNICA Généralisation de l'algorithme FastICA, l'algorithme UNICA a été développé par Cruces, Cichocki et Castedo [11] et est utilisé pour extraire un nombre spécifié de composantes indépendantes en présence de bruit gaussien corrélé. Pour l'estimation de la matrice de mixage, l'algorithme utilise une itération de quasi-Newton pour minimiser la distorsion de la variance. L'utilisation de ce critère permet de minimiser l'interférence entre les sources estimées et le bruit.

3.2 La recherche en séparation aveugle de source appliquée aux signaux électromyographiques

Bien que la recherche en séparation aveugle de source appliquée aux signaux électromyographiques soit un domaine assez récent du traitement du signal, il a reçu un engouement assez rapide et les publications qui s’y rapportent sont nombreuses.

De nombreux efforts ont été fournis pour utiliser les méthodes de séparation de source existantes à différentes fins, ou pour développer de nouvelles méthodes plus spécifiques aux signaux EMGs.

Par exemple, Farina et al. [17] ont développé une méthode nommée TFBSS pour identifier l’activité EMGs de deux muscles très proches à partir de trois électrodes au dessus de ces sources. Pour plus d’observations que de capteurs, on parle de problème sur-déterminé. L’efficacité de la séparation a été vérifiée sur des signaux simulés ainsi que sur des signaux réels : les muscles identifiés étaient acteurs de la pronation et de la flexion du poignet.

L’utilisation des algorithmes de séparation aveugle de source pour les signaux électromyographiques se heurte à deux problèmes :

- D’une part, il peut y avoir plus de sources que d’observations, en particulier si l’on considère que chaque unité motrice est une source : il peut y avoir une centaine d’unités motrices pour un seul muscle. Une estimation de source regroupera donc de toute évidence un certain nombre d’unités motrices.
- D’autre part, l’hypothèse généralement admise d’indépendance des sources n’est pas forcément vérifiée dans le cas des signaux physiologiques. En effet, il existe parfois une certaine synchronisation entre les commandes des unités motrices. Cela n’a pas de conséquence fâcheuse si les unités motrices appartiennent au même muscle. Cependant, pour des mouvements aussi complexes que ceux de la main, il arrive que plusieurs muscles agonistes soient sollicités en même temps, et parfois même des muscles antagonistes si l’intensité du mouvement est importante, ou pour des mouvements pour lesquels il n’existe pas de muscle spécifiquement associé (lever l’annulaire par exemple). Pour des fenêtres de classification assez courtes, et si des unités motrices sont synchronisées, on risque alors de confondre deux sources.

Des considérations physiologiques de cet ordre ont poussé les chercheurs à se pencher sur les problèmes de séparation aveugle de sources lorsque les sources sont plus nombreuses que les observations, ou lorsque l’indépendance statistique entre les sources n’est pas vérifiée.

Pour prendre en compte le fait que les sources ne répondent pas aux exigences de l’analyse en composante indépendantes, les chercheurs ont montré que l’hypothèse d’indépendance statistique des sources peut néanmoins être valide dans des petites bandes de fréquence. Les méthodes de décomposition sous-bandes consistent à procéder à plusieurs séparation aveugle de sources après filtrage des observations par une banque de filtres passe bande de bande passante assez étroite. Pour mesurer la qualité de la séparation, on analyse les estimées des matrices de séparation $\{\mathcal{B}_i\}_{1 \leq i \leq n}$. Si les estimées de sources sont mutuellement indépendantes sur au moins deux sous-bandes, ou de manière plus générale deux sous-ensembles de sources (exemple : p et q), alors la matrice globale $\mathcal{G}_{pq} = \mathcal{W}_p \cdot \mathcal{W}_q^{-1}$ sera une matrice de permutation généralisée (un élément prépondérant pour chaque ligne et chaque colonne).

Une équipe de chercheurs s’est plus particulièrement concentrée sur cette méthode pour déterminer le nombre de sources indépendantes recrutées pour des gestes complexes de la main (Naik et al. [36]), puis pour identifier des gestes de la main (Naik et al. [32, 33, 35, 37]). Contrairement à ce que nous utiliserons dans cette étude, Naik et al. ont déterminé une seule matrice de séparation, et l’utilisent pour chaque fenêtre de classification. Sur un problème à quatre mouvements et quatre voies (les capteurs sont placés à différents endroits de l’avant-bras), et un classifieur basé sur la RMS des estimations des sources, le taux de classification atteint 97% en moyenne.

D’autres méthodes permettent en théorie de procéder à une séparation aveugle de sources dans le cas des problèmes sous-déterminés (avec plus de sources que de capteurs) [24, 26]. On citera simplement :

- les méthodes d’analyse en composantes parcimonieuses, qui assurent une séparation de plus de sources que de capteurs à la condition qu’à chaque instant, le nombre de sources actives soit inférieur au nombre de capteurs.
- les méthodes d’analyse par représentation en base sur-complète : on cherche dans ce cas une représentation des données dans une base sur-complète (pour une telle base, il existe une infinité de représentations pour les données) qui maximise la non gaussianité de chaque composante.

3.3 Application des techniques de séparation aveugle de source pour l'interaction muscle-machine

3.3.1 Ensembles de caractéristiques pour la classification

Dans le cadre de notre étude, nous ne cherchons pas à extraire les sources des signaux électromyographiques à tout prix, nous nous efforçons seulement d'obtenir une signature fiable des mouvements. Ainsi, une source composée de muscles antagonistes serait une signature fiable d'un mouvement intense, ou d'un mouvement pour lequel il n'existe pas de muscle spécifique associé (lever l'annulaire par exemple). En gardant en considération les écarts aux modèles décrits ci-dessus, nous nous proposons d'appliquer l'un des algorithmes SOBI, EFICA ou UNICA à chaque fenêtre de classification :

- pour composer des ensembles de caractéristiques pour la classification. Pour ce faire, nous devons transformer la matrice de mélange \mathcal{A} évaluée en un vecteur de caractéristiques. le $i^{\text{ème}}$ vecteur colonne \mathbf{a}_i de $\mathcal{A} = [\mathbf{a}_1 \cdots \mathbf{a}_n]$ représente la contribution d'une source aux différentes observations. On serait donc tenté d'utiliser le vecteur $[\mathbf{a}_1^T \cdots \mathbf{a}_n^T]$ comme ensemble de caractéristiques ;
- comme prétraitement avant d'extraire les caractéristiques décrites section 2.2.2. L'avantage de cette méthode réside dans le fait que les sources sont estimées de sorte que leur distribution soit la moins gaussienne possible, et que c'est donc en théorie plus facile de choisir des seuils pour la classification. Pour cela, on doit redonner aux sources l'information de leur puissance. On les multipliera donc par le maximum en valeur absolue de la colonne correspondante dans la matrice de mélange \mathcal{A} . Enfin, on n'utilisera pas le prétraitement par l'algorithme SOBI sur les caractéristiques CV dérivées de l'auto-corrélation et de l'inter-corrélation, puisque comme l'inter-corrélation entre les sources est nulle, cet ensemble de caractéristiques reviendrait à la seule mesure de l'auto-corrélation, qui est en l'occurrence identique aux caractéristiques RMS.

Dans les deux cas, il ne faut pas perdre de vue l'indétermination inhérente au problème de séparation aveugle de sources : la numérotation des signaux sources est arbitraire !

Algorithme de renumérotation des sources Pour s'assurer que les sources les plus ressemblantes soient toujours placées à la même place dans le vecteur de caractéristiques, nous proposons les règles suivantes :

- pour chaque vecteur colonne de la matrice \mathcal{A} , le terme de plus grande valeur absolue doit être positif.
- si le $j^{\text{ème}}$ terme du $i^{\text{ème}}$ vecteur colonne est le maximum de sa ligne et de sa colonne, le $i^{\text{ème}}$ vecteur colonne sera placé en priorité à la $j^{\text{ème}}$ place.
- si d'autres vecteurs colonnes ont pour maximum leur $j^{\text{ème}}$ terme, ils seront classés par ordre décroissant de maximum, et insérés dans les places non encore pourvues.

Ces règles ont mené au développement de l'algorithme présenté en Annexe A. Les permutations sont effectuées à la fois pour les colonnes de la matrice de mélange \mathcal{A} et pour les lignes des estimées des sources $\hat{\mathbf{s}}$.

3.3.2 Localisation et applications

Après séparation aveugle de sources, on obtient une estimation de la contribution de chaque source identifiée (supposée de puissance unitaire) à l'observation de chaque capteur. On a de ce fait la possibilité d'évaluer la position de la source par rapport aux capteurs.

Modèle du signal EMG et du milieu de propagation Tout processus de localisation de sources implique une modélisation du problème direct avant la résolution du problème inverse. Dans cette étude, le problème direct consiste à modéliser l'atténuation du signal source lors de son trajet jusqu'au capteur.

Certains chercheurs se sont efforcés de modéliser l'onde de base des signaux EMG (le potentiel d'action d'unité motrice) et comment elle se propage à travers les tissus humains. Ces recherches ont abouties à la conception de logiciels de simulation d'EMGs [18]. Cependant, ces modélisations ne conviennent pas à cette étude puisqu'elles nécessitent un nombre important de paramètres sujet-dépendant, à déterminer expérimentalement.

Dans cette étude, nous avons choisi d'utiliser l'hypothèse très simple que les sources sont contenues dans le plan qui passe par les capteurs, et que l'avant-bras, de section supposée circulaire, est un milieu linéaire, homogène et isotrope. Nous utiliserons de plus le fait que le signal EMG est une somme de potentiels d'action d'unité motrice, modélisés par la propagation d'un dipôle de courant à travers chaque fibre musculaire de l'unité motrice. Le champ de potentiel d'un dipôle de courant a pour expression simplifiée $\mathbf{x}(t) = k d^{-3/2} \mathbf{s}(t)$, où $\mathbf{s}(t)$ est le signal source, $\mathbf{x}(t)$ est celui observé par le capteur, k est un paramètre qui dépend du milieu de propagation (constant quelque soit le couple source/capteur), et d est la distance entre la source et le capteur.

Lors de la résolution du problème de séparation aveugle de source, la source \mathbf{s} est supposée de puissance unitaire. La constante k intègre donc l'information de la puissance réelle de la source \mathbf{s} .

Nous avons vu que pour des mouvements aussi complexes de ceux des doigts, chaque source estimée pourrait être la résultante de la contribution de plusieurs sources élémentaires dépendantes entre elles, du fait d'une apparente synchronisation de la commande. Pour prendre en compte la possibilité que les sources élémentaires soient situées à des endroits très différents dans la section de l'avant-bras, tout en ayant le même ordre de grandeur de puissance, on utilisera deux modèles différents basés sur des sources ponctuelles de dipôles de courant :

- à une source correspond un dipôle de courant,
- chaque source est la résultante de la contribution de deux dipôles de courant

La figure (3.1) représente en coordonnées polaires le rapport d'amplitude simulé autour d'une section de rayon $r = 1$. La figure de gauche simule l'effet d'un seul dipôle avec un coefficient $k = 1$, pour différentes positions. On remarque que le phénomène est très localisé au dessus de la source. La figure de droite simule deux dipôles positionnés sur le même cercle et avec un angle de 120° entre eux. Le premier ayant un coefficient $k_1 = 1$, et le second ayant des coefficients $k_2 \in \{-0.5; -0.1; 0.1; 0.5\}$. Des coefficients de dipôles opposés signifient que les signaux émis par les dipôles sont globalement en opposition de phase.

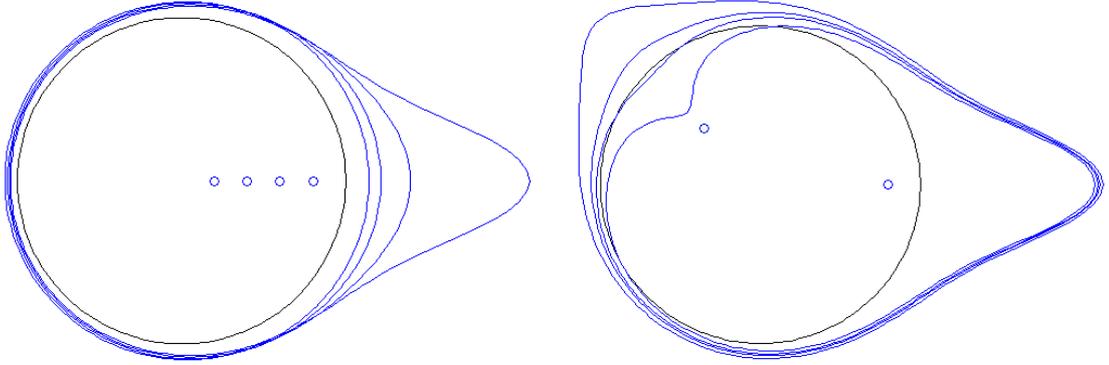


FIG. 3.1 – Représentation du rapport d'amplitude autour d'une section de rayon $r = 1$. A gauche, $k = 1; y = 0; x \in \{0.2; 0.4; 0.6; 0.8\}$. A droite, $x_1 = 0.8; y_1 = 0; k_1 = 1$ pour le dipôle 1, et $x_1 = -0.8 \cdot \sqrt{2}/2; y_1 = 0.8 \cdot \sqrt{2}/2; k_1 \in \{-0.5; -0.1; 0.1; 0.5\}$ pour le dipôle 2.

Algorithme de localisation A partir des coefficients X_{obs} d'une colonne de la matrice \mathcal{A} évaluée par séparation aveugle de source, la résolution du problème inverse en terme d'identification de la puissance et de la position du dipôle (triplet $\{k, x, y\}$), est fondée sur une minimisation d'une fonction de coût avec contrainte d'inégalité pour que les dipôles soient bien à l'intérieur de la section considérée. La fonction coût a pour expression :

$$e = \sum_{i=1}^n (X_{obs,i} - X_{cal,i}(k, x, y))^2 \quad (3.3.1)$$

où $X_{cal,i}(k, x, y) = k d_i(x, y)^{-3/2}$ et $d_{i+1}(x, y) = ((x - r \cos(i 2\pi/n))^2 + (y - r \sin(i 2\pi/n))^2)^{1/2}$. Posons :

$$A_i(k, x, y) = \frac{X_{obs,i} - \frac{k}{((x - r \cos(i 2\pi/n))^2 + (y - r \sin(i 2\pi/n))^2)^{-3/4}}}{((x - r \cos(i 2\pi/n))^2 + (y - r \sin(i 2\pi/n))^2)^{-3/4}}$$

L'équation du gradient de coût associé a pour expression :

$$\nabla e = \begin{bmatrix} \frac{\partial e}{\partial k} \\ \frac{\partial e}{\partial x} \\ \frac{\partial e}{\partial y} \end{bmatrix} = \sum_{i=0}^{n-1} A_i(k, x, y) \begin{bmatrix} -2 \\ 3 \frac{k(x - r \cos(i 2\pi/n))}{(x - r \cos(i 2\pi/n))^2 + (y - r \sin(i 2\pi/n))^2} \\ 3 \frac{k(y - r \sin(i 2\pi/n))}{(x - r \cos(i 2\pi/n))^2 + (y - r \sin(i 2\pi/n))^2} \end{bmatrix} \quad (3.3.2)$$

La fonction coût étant convexe, nous avons choisi d'utiliser un algorithme de descente du gradient avec gain adaptatif, et vérification de la contrainte $x^2 + y^2 < (0.9r)^2$. L'algorithme utilisé est décrit en Annexe B.

Application pour l'interaction muscle-machine Il serait trop coûteux en temps de calcul de procéder à n localisations pour chaque fenêtre de classification, et d'ainsi utiliser n triplets $\{k_i, x_i, y_i\}$ comme ensemble de caractéristiques.

Cependant, dans le cas de l'utilisation d'un dispositif d'interaction muscle-machine sous la forme d'un brassard possédant n électrodes également espacées, il serait important que l'utilisateur n'ait pas à se soucier de placer le brassard avec précision, ni de refaire une longue série de gestes pour entraîner le classifieur. La localisation des sources offre potentiellement la possibilité d'estimer le décalage angulaire entre les positions du brassard lors de l'entraînement et après repositionnement, puis d'utiliser cette estimation pour modifier le classifieur.

Dans un premier temps nous testerons la robustesse des méthodes de classification choisies par rapport à un décalage angulaire (sans le prendre en compte), et dans un deuxième temps, nous testerons une méthode pour prendre en compte le décalage angulaire. Cette méthode se base sur la remarque qu'une colonne i de la matrice \mathcal{A} obtenue après séparation aveugle de source représente la contribution de la source i à l'observation de chaque capteur. Nous nous proposons donc d'estimer ce que seraient ces contributions si les électrodes étaient décalées d'un certain angle lors de la phase d'entraînement.

Pour ce faire, une première possibilité serait de procéder à une interpolation (par spline par exemple) des contributions de la source. La figure (3.2) représente l'interpolation par splines à partir de différentes positions d'un système de huit capteurs, pour des coefficients arbitraires de dipôle. Cette méthode ne prend pas du tout en compte l'origine physiologique des signaux, et on observe de grands écarts entre les contributions théoriques et les contributions estimées par interpolation.

On choisira donc plutôt de reconstruire les contributions à partir de l'estimation des paramètres de la localisation. Sur le même problème élémentaire (*cf* : fig.3.2), la méthode par reconstruction est beaucoup plus précise que celle par interpolation.

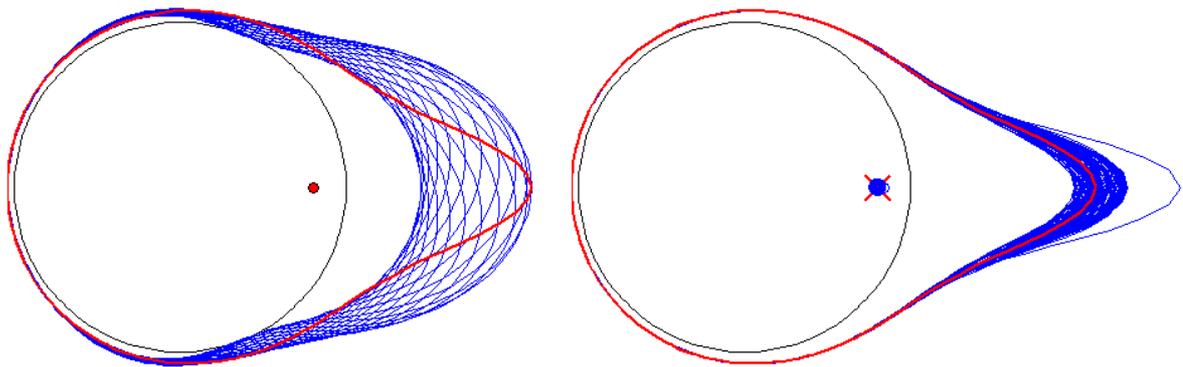


FIG. 3.2 – Représentation des deux méthodes d'interpolation des contributions des sources aux signaux EMGs. Interpolation par spline (figure de gauche), et reconstruction du champ de potentiel à partir de l'estimation de la localisation (figure de droite).

Chapitre 4

Description des méthodes

Quelques expériences ont été menées sur plusieurs sujets à l'aide d'un premier système de mesure, avec six électrodes bipolaires. Après acquisition par le département d'automatique d'un nouveau système plus adapté, l'expérience a été renouvelée sur un seul sujet, avec un protocole expérimental légèrement différent. C'est cette expérience que nous décrirons dans la première section de ce chapitre, et ce sont les résultats de cette expérience qui seront présentés dans les chapitres suivants.

La seconde section est un rappel des choix adoptés pour répondre aux problématiques de cette étude : mouvements à classifier, caractéristiques de la classification, et utilisation des techniques de séparation aveugle de sources.

4.1 Protocole expérimental

Le sujet Le sujet repose dans une position confortable, la main posée sur une table et le coude surélevé de sorte que les électrodes ne touchent pas la table *cf* : figure (4.1). La main et les doigts du sujet sont liés à la table à l'aide de colliers en plastique. Ce choix permet de s'assurer :

- que le sujet ne fasse pas travailler ses muscles pour revenir en position de repos. On a ainsi l'assurance que pendant la durée de la bouffée d'EMGs, seul l'effort demandé est fourni, et pas son contraire.
- que le sujet puisse doser facilement l'intensité avec laquelle il exécute l'effort demandé.

Préparation de l'expérimentation Tout d'abord, la longueur de l'avant-bras du sujet est mesurée entre le pli du coude et le second pli de la main. A environ 1/4 de cette longueur par rapport au pli du coude. La circonférence de l'avant-bras est alors mesurée, puis la peau est rasée sur une bande d'environ 5 cm. La peau est alors nettoyée avec un alcool pour diminuer son impédance de façon à ce que le signal EMGs soit bien détecté par les électrodes. Huit électrodes mono-différentielles (composées de deux électrodes patch Biopac EL503, Ag-AgCl de 10 mm de diamètre) sont alors positionnées régulièrement espacées autour de l'avant-bras, avec une distance inter-électrodes d'environ 2.5 cm, et de telle sorte que la surface de détection soit perpendiculaire à la plupart des fibres des muscles de l'avant-bras. Une électrode supplémentaire est placée au dessus de la tête cubitale près du poignet pour donner une référence stable commune aux voies.

Système d'acquisition Pour l'acquisition des signaux EMGs, le potentiel capté par chaque électrode est amplifié à l'aide d'un système d'amplification Biopac EMG100C, puis les données sont transférées à l'ordinateur par le biais d'un système d'acquisition des données Biopac MP150. C'est à l'aide du logiciel Biopac AcqKnowledge que l'on impose les paramètres de l'acquisition, et que l'on lance l'acquisition. Le logiciel permet d'enregistrer automatiquement les données après chaque acquisition.

Collection des données Contrairement aux sessions de pré-test lors desquelles le sujet devait effectuer des mouvements qui lui étaient présentés dans un ordre aléatoire, pour l'expérience finale il était simplement demandé au sujet de répéter un même mouvement plusieurs fois. Cela se justifie :

- d'une part puisqu'il est très difficile pour le sujet de rester concentré pendant toute la durée de l'expérience, il était ainsi impossible d'éviter des erreurs sur les mouvements, ce qui biaise les résultats de la classification. Pour permettre au sujet de se concentrer afin de limiter ces erreurs, l'exécution des gestes devait être plus espacée dans le temps, l'expérimentation était donc plus longue et fatigante pour le sujet.

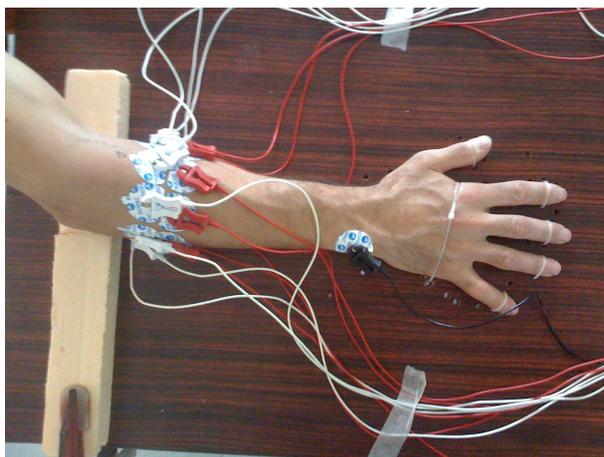


FIG. 4.1 – Le sujet a la main posée dans une position reposante, le coude surélevé. La main et les doigts sont attachés à la table. Les électrodes bi-polaires sont disposées régulièrement espacées sur l'avant-bras, près du coude, avec une distance inter-électrodes de 2.5 cm. Une électrode de référence est placée au dessus de la tête cubitale.

- d'autre part, lors des sessions de pré-test, on a observé que les mouvements exécutés étaient variés beaucoup en fonction du mouvement précédent. Répéter un mouvement permet donc au sujet de standardiser son mouvement et de mieux différencier les mouvements qui ne diffèrent que par leur degré d'intensité.
- finalement, en l'absence de feedback de la classification, la répétition de mouvements serait probablement le meilleur moyen pour un utilisateur potentiel d'automatiser les gestes à effectuer.

L'expérimentation comporte donc autant de phases que de mouvements à classifier.

Lors d'une phase, le sujet répète un certain nombre de fois un même geste avec 1.5 s entre deux gestes, pendant que les signaux EMGs sont enregistrés. Des stimuli auditif (bips) et visuels ("wait" et "go") sont utilisés pour l'aider dans cette tâche. Ainsi, une phase dure environ 50 s pour 30 répétitions d'un même geste, ce qui fait dans cas un total d'environ 30 minutes d'expérimentation pour les 31 phases.

Essais Notre étude a deux buts :

- évaluer les ensembles de caractéristiques pour la classification
- évaluer la robustesse de la classification vis-à-vis d'un décalage angulaire du système d'électrodes

Ainsi, nous avons pratiqué deux essais de 31 phases chacun. Pour le premier essai nous avons choisi d'enregistrer 30 répétitions de chaque mouvement : la moitié des données servira à entraîner le classifieur, et l'autre moitié à le tester. Entre les deux essais, le système d'électrodes fut décalé de 12° , ce qui correspond à un quart de l'angle entre deux électrodes. Nous avons choisi cet angle pour qu'il y ait un impact suffisamment important sur les données, et pour rester loin du cas extrême où l'écart angulaire serait égal à la moitié de l'angle entre deux électrodes. Pour cet essai, nous enregistrons 15 répétitions de chaque mouvement, et l'ensemble des données servira à évaluer la robustesse de la classification.

4.2 Rappel des choix adoptés

Mouvements à classifier On a trois catégories de mouvements à classifier : 18 mouvements des doigts, 12 mouvements du poignet, et la relaxe de la main. Ce qui fait un total de 31 gestes :

- pour l'un des 5 doigts, et tous les doigts sauf le pouce :
 - l'extension (*6 mouvements*)
 - la flexion avec une faible intensité (*6 mouvements*)
 - la flexion avec une moyenne intensité (*6 mouvements*)
- pour le poignet :
 - l'extension et la flexion avec une faible et une moyenne intensité (*4 mouvements*)
 - l'inclinaison ulnaire et radiale avec une faible et une moyenne intensité (*4 mouvements*)
 - la pronation et la supination avec une faible et une moyenne intensité (*4 mouvements*)
- relaxe de la main.

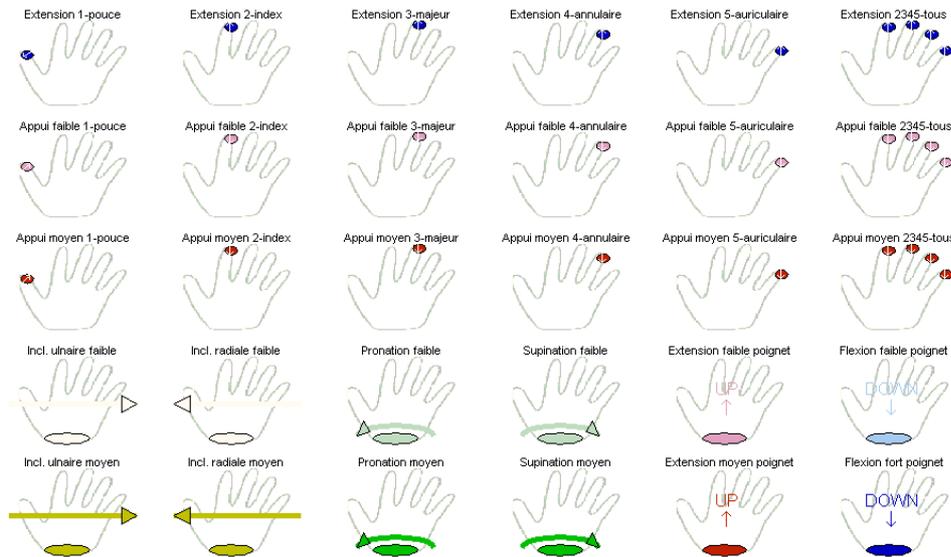


FIG. 4.2 – Ensemble des 31 gestes que le sujet devait répéter (le geste **relaxe** n'est pas représenté). Des stimuli visuels et auditifs l'aident à respecter le timing.

Fenêtre de classification La longueur totale de la classification ne doit pas excéder 300 ms pour que la classification en-ligne soit la plus transparente possible aux yeux de l'utilisateur. Nous nous limitons à une longueur de 240 ms, et étudierons l'influence d'une longueur plus courte sur les résultats de la classification. Nous testerons ainsi trois longueurs de fenêtres de classification : 160, 200 et 240ms.

Evaluation des classifieurs L'évaluation se fait en deux phases :

- Phase **Train_Test** : Nous sélectionnerons trois fenêtres de classification (une de chaque longueur) par répétition de mouvement par une technique semi-automatisée de détection de mouvements. Ces ensembles de bouts d'enregistrement serviront à entraîner le classifieur et à le tester. L'entraînement se fera à partir de la première position angulaire du système d'électrodes (ensemble **training**), et le test se fera pour chaque position angulaire du système d'électrodes (ensembles **test0deg** : évaluation des ensembles de caractéristiques; et **test12deg** : évaluation de la robustesse par rapport à un décalage angulaire des électrodes). Chacun des trois ensembles représente 15 répétitions \times 31 mouvements = 465 fenêtres de classification.
- Phase **Cont_Test** : Pour la seconde phase de test en classification continue, la classification se fera sur un ensemble de fenêtres partiellement superposées toutes les 25 ms. Aucune détection de mouvement ne sera nécessaire, mais nous sélectionnerons de façon semi-automatisée 1 s d'enregistrement. Sur 1 s de signal et pour des fenêtres de classification de 160, 200 et 240 ms, on aura donc 33, 32 et 30 classifications respectivement. De la même manière, le test fera fait pour chaque position angulaire du système d'électrodes (ensemble **Ctest0deg** : évaluation des ensembles de caractéristiques; et **Ctest12deg** : évaluation de la robustesse par rapport à un décalage angulaire des électrodes). Chacun des trois ensembles représente 15 répétitions \times 31 mouvements \times n_{fen} fenêtres soit respectivement 15345, 14880 et 13950 fenêtres de classification.

Pour éviter que le choix des fichiers utilisés pour l'entraînement des classifieurs ait une influence sur les résultats, nous répéterons les deux phases 20 fois avec des fichiers différents choisis au hasard.

Découpage hors-ligne des enregistrements La première étape du traitement des données est de découper l'enregistrement d'une phase en morceaux de 1.5s de données contenant chacun une répétition du mouvement de la phase (cf : fig. 4.2 gauche). Ensuite, pour chaque répétition de mouvement, on extrait :

- trois fichiers contenant 160, 200 et 240 ms d'enregistrements pour l'entraînement et le test du classifieur ;
- un fichier contenant 1 s d'enregistrement pour la classification continue.

Cette étape d'extraction des données est semi-automatisée (cf : fig. 4.2 droite). Pour chaque morceau de 1.5s de données,

- la puissance quadratique moyenne est calculée en chaque point pour une fenêtre rectangulaire de 20 ms centrée sur ce point ;

- les différentes fenêtres sont alors automatiquement centrées là où la puissance maximale est détecté ;
- l’expérimentateur peut alors valider, ou modifier manuellement la position des fenêtre. Une fois les positions validées, les différents fichiers sont extraits.

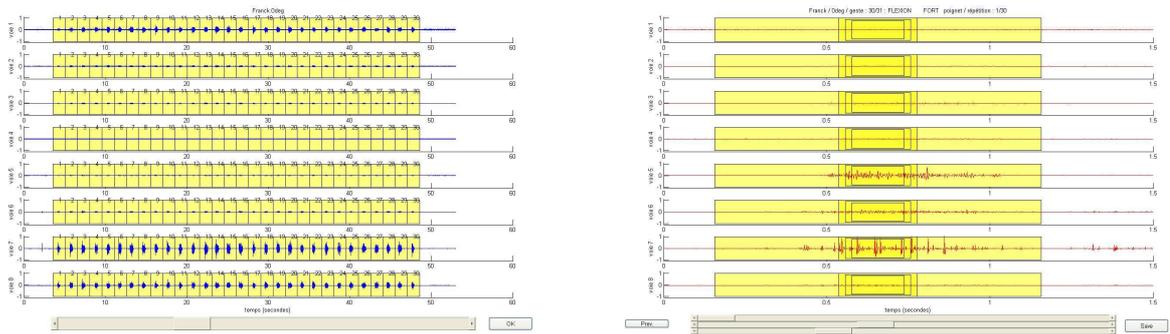


FIG. 4.3 – Figure de gauche : extraction manuelle des différentes répétitions d’un même geste pour une phase. Figure de droite : extraction semi-automatisée des différentes longueurs d’enregistrement (160, 200 et 240 ms pour l’entraînement et le test du classifieur, et 1 s pour la classification continue).

Extraction des ensembles de caractéristiques La seconde étape du traitement des données est l’extraction des ensembles de caractéristiques. Les ensembles de caractéristiques évaluées pour la classification sont :

- *Sans prétraitement des données, extraction des ensembles de caractéristiques :*
 - RMS : Valeur Quadratique Moyenne
 - TD : Caractéristiques temporelles de Hudgins
 - CV : Caractéristiques dérivées des auto- et inter-corrélations
 - SPMs : Amplitudes des puissances spectrale
 - HOS : Statistiques d’ordre supérieur
 - *Avec prétraitement des données par un algorithme de séparation aveugle de source SOBI, EFICA ou UNICA, à partir des estimations des sources renumérotées et multipliées par le maximum de la colonne de \mathcal{A} correspondante, extraction des ensembles de caractéristiques :*
 - SOBI_RMS ; EFICA_RMS ; UNICA_RMS : Valeur Quadratique Moyenne
 - SOBI_TD ; EFICA_TD ; UNICA_TD : Caractéristiques temporelles de Hudgins
 - EFICA_CV ; UNICA_CV : Caractéristiques dérivées des auto- et inter-corrélation
 - SOBI_SPMs ; EFICA_SPMs ; UNICA_SPMs : Amplitudes des puissances spectrale
 - SOBI_HOS ; EFICA_HOS ; UNICA_HOS : Statistiques d’ordre supérieur
 - *A partir de l’estimation de la matrice de mixage \mathcal{A} obtenu par l’algorithme SOBI, EFICA ou UNICA, après renumérotation des colonnes de \mathcal{A} :*
 - SOBI ; EFICA ; UNICA.
 - *Avec prétraitement non-linéaire ”puissance un quart”*
 - RMS_p ; TD_p ; SPMs_p ;
 - SOBI_RMS_p ; EFICA_RMS_p ;
 - UNICA_RMS_p ; SOBI_TD_p ;
 - EFICA_TD_p ; UNICA_TD_p ; SOBI_SPMs_p ; EFICA_SPMs_p ; UNICA_SPMs_p
- Ce qui fait un total de 34 ensembles de caractéristiques.

Post-traitement pour la classification continue On utilisera une des règles les plus simples de post-traitement : la règle du vote majoritaire. En cas d’égalité, nous utiliserons une logique floue pour ne favoriser aucun mouvement : après application du vote, on peut choisir à 1/2 le geste i et à 1/2 le geste j par exemple, et le si le mouvement réel est le mouvement i , alors il sera considéré comme 1/2 bien classifié.

Localisation et application On estime position et puissance d’un et de deux dipôles à partir des vecteurs colonnes de la matrice de mixage \mathcal{A} estimée par les algorithmes d’identification aveugle de source EFICA et UNICA. On obtient quatre structures de résultats : Loc1sEFICA ; Loc1sUNICA ; Loc2sEFICA ; Loc2sUNICA. On appliquera la localisation à tous les fichiers de 160, 200 et 240ms d’enregistrement, pour des deux essais (deux positions angulaires du système d’électrodes).

A partir des résultats de la localisation, on reconstruit les contributions des sources entre les électrodes, on

procède ainsi à une interpolation des coefficients des colonnes des matrices de mixage \mathcal{A} qui prend en compte l'origine physiologique des signaux.
On évaluera donc la classification des ensembles `test12deg` et `Ctest12deg` à partir de l'interpolation des ensembles de caractéristiques `EFICA` et `UNICA`.

Chapitre 5

Evaluation des ensembles de classification

5.1 Entraînement et test des classifieurs

Produit scalaire entre les vecteurs caractéristiques Une première façon de vérifier la discriminabilité de l'ensemble de caractéristiques choisi est de représenter un produit scalaire entre les vecteurs caractéristiques des fenêtres de classification. Le produit scalaire $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$ utilisé est définie sur \mathbb{R}^n par :

$$\langle \mathbf{x}_i, \mathbf{x}_j \rangle = \frac{\sum_{k=1}^n (\mathbf{x}_i(k) \cdot \mathbf{x}_j(k))}{\sqrt{\sum_{k=1}^n \mathbf{x}_i(k)^2 \cdot \sum_{k=1}^n \mathbf{x}_j(k)^2}} \quad (5.1.1)$$

L'idéal pour une classification parfaite est que ce produit scalaire soit égal à 1 entre deux vecteurs caractéristiques du même geste, et égal à 0 pour deux vecteurs caractéristiques de gestes différents.

La figure (5.1) ci-dessous représente les produits scalaires $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$ calculés entre les vecteurs caractéristiques des fenêtres de classification ($L = 240ms$) d'un ensemble $\{\mathbf{training} \cup \mathbf{test0deg}\}$ pour l'ensemble de caractéristiques RMS.

On remarque que les caractéristiques de certains mouvements se ressemblent beaucoup, ces mouvements auront donc plus de chance d'être confondus. Par contre, les caractéristiques peuvent avoir de grandes différences de norme, bien qu'ayant des direction similaires. Le produit scalaire $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$ tel qu'il est défini ne rend pas compte de cela, comme pour les extension faibles et moyennes du poignet par exemple.

Précision de la classification L'évaluation des classificateurs a été menée 20 fois avec des fichiers différents choisis au hasard pour éviter que le choix des fichiers utilisés à l'entraînement des classifieurs ait une trop grande influence sur les résultats. Tous les résultats présentés ici sont moyennés sur ces 20 essais, et présentés sous la forme *moyenne*±*textit*cart-type. La figure (5.1) représente la précision de classification obtenue sur les ensembles $\mathbf{training}$ et $\mathbf{test0deg}$, pour les trois longueurs de fenêtre, pour les ensembles de caractéristiques qui n'ont pas subi le prétraitement "puissance un quart".

Interprétation des performances des ensembles de caractéristiques Pour une longueur de fenêtre de 240ms, les résultats des ensembles de caractéristiques les plus performants sur l'ensemble $\mathbf{training}$ sont très élevés, et assez proches : SPMS : $97.7 \pm 0.5\%$, UNICA.SPMS : $96.9 \pm 0.7\%$, UNICA : $96.0 \pm 0.5\%$. CV : $95.4 \pm 0.9\%$, TD : $94.7 \pm 0.8\%$. Les plus hautes valeurs s'expliquent par le nombre important de caractéristiques (80) dans les ensembles SPMS et UNICA.SPMS.

Sur l'ensemble $\mathbf{test0deg}$, la classification optimale est obtenue pour l'ensemble de caractéristique TD, avec $92.7 \pm 1.1\%$ de précision de classification, juste devant UNICA.TD : $91.4 \pm 1.1\%$, CV : $89.4 \pm 1.4\%$.

L'ensemble de caractéristiques dérivé de l'algorithme SOBI : SOBI, et ceux qui utilisent un prétraitement par l'algorithme SOBI : SOBI_RMS, SOBI_TD, SOBI_SPMS, SOBI_HOS, sont parmi les moins performants. Cela montre que l'algorithme SOBI n'est pas très adapté à la séparation aveugle de sources pour les signaux électromyographiques. Il est possible aussi que l'algorithme de renumérotation des sources soit mal adapté à SOBI.

L'ensemble EFICA.CV et UNICA.CV sont les moins performants après prétraitement par les algorithmes d'analyse en composantes indépendantes. Cela tient du fait que les signaux sources sont cherchés le plus indépendants

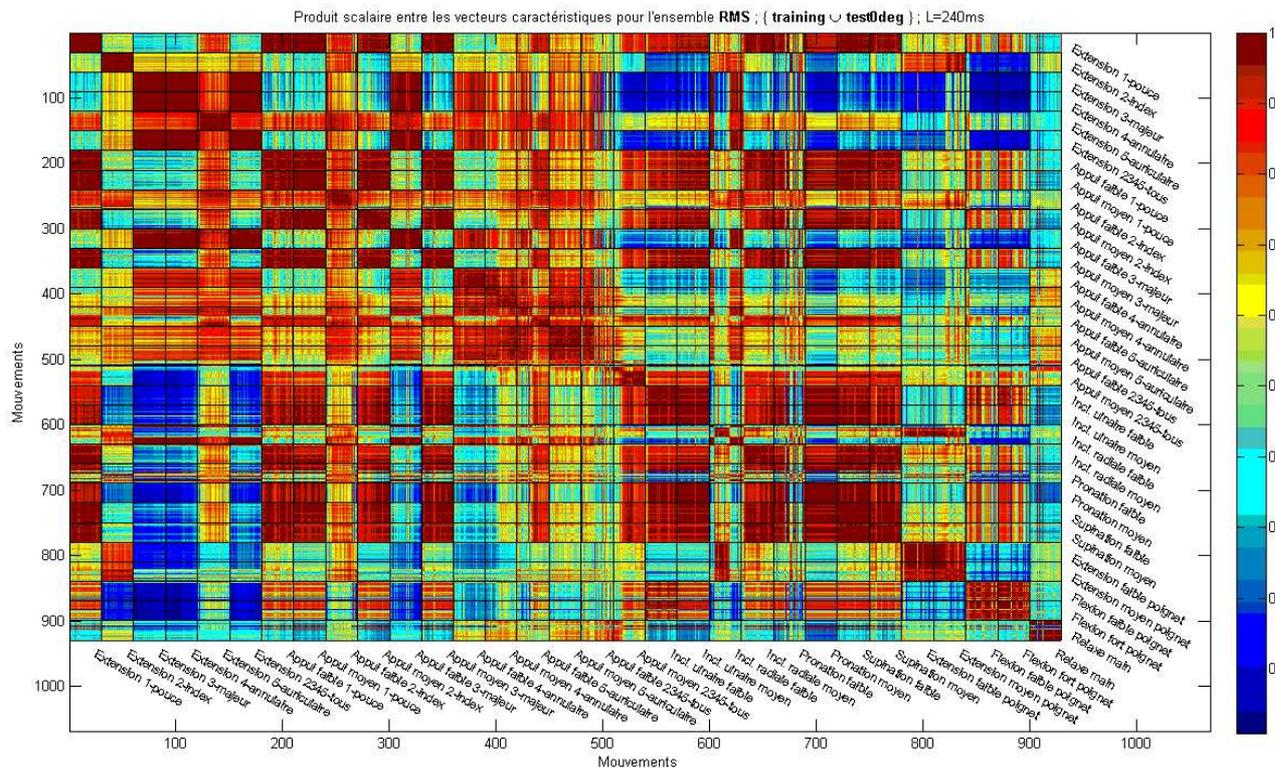


FIG. 5.1 – Produit scalaire entre les caractéristiques RMS extraites des fenêtres de 240 ms pour l’ensemble

possible, et ils sont donc très peut inter-corrélés. Ces ensembles s’approchent donc des ensembles RMS pour l’auto-corrélation, à un terme multiplicatif et une puissance 2 près. On s’attendrait alors à ce que leurs performances soient très proches. Or, l’écart est important. Après vérification, il s’avère que la différence vient du fait qu’ils ont un grand nombre de caractéristiques proches de 0, ce qui réduit fortement les performances de ces ensembles. Pour un même ensemble `training` aléatoirement choisi, et une longueur de fenêtre de classification de 240 ms, on obtient ainsi 72.2%, 55.4%, et 61.64% pour les ensemble `UNICA_RMS`, `UNICA_CV`, et `UNICA_CV-`, respectivement. `UNICA_CV-` étant obtenu à partir de l’ensemble de caractéristique `UNICA_CV` en supprimant les lignes correspondant aux termes d’inter-corrélation.

Influence de la longueur de la fenêtre de classification La diminution de la longueur de la fenêtre de classification s’accompagne d’une diminution sensible des résultats pour la plupart des ensembles de caractéristiques. Cependant l’importance de cette diminution dépend fortement de l’ensemble de caractéristique. L’ensemble de caractéristiques pour lequel la précision sur l’ensemble `test0deg` reste au dessus de 75% et qui est le plus influencé par la longueur de la fenêtre de classification est l’ensemble `UNICA_SPMs`, avec une précision de $83.3 \pm 1.7\%$ pour une fenêtre de 240 ms, qui baisse à $76.6 \pm 2.2\%$ pour une fenêtre de 160 ms.

L’ensemble TD, le plus performant pour la classification du groupe `test0deg`, est aussi le moins sensible aux effets d’un raccourcissement de la fenêtre de classification ($91.8 \pm 1.2\%$ pour 160 ms et $92.7 \pm 1.1\%$ pour 240 ms). Cela le rend très avantageux puisqu’il allie un temps de calcul très court, à de très bonnes performances même dans le cas d’une très courte fenêtre de classification. Il serait donc un bon candidat pour appliquer des algorithmes de post-traitement sur plusieurs fenêtres en classification continue, comme les procédures dérivées du vote majoritaire ou l’utilisation des chaînes de Markov.

Résultats avec le prétraitement ”puissance un quart” La figure (5.1) ci-dessous représente les taux de classification avec et sans prétraitement ”puissance un quart” des ensembles de caractéristiques, pour une fenêtre de classification de 240 ms.

Les performances sont beaucoup plus élevées lorsque le prétraitement ”puissance un quart” est appliqué. Pour l’ensemble de caractéristiques optimal sur l’ensemble `test0deg` : `TD_p`, on arrive ainsi à des précisions qui atteignent $98.0 \pm 0.6\%$ pour l’ensemble `training`, et $96.4 \pm 0.5\%$ pour l’ensemble `test0deg`.

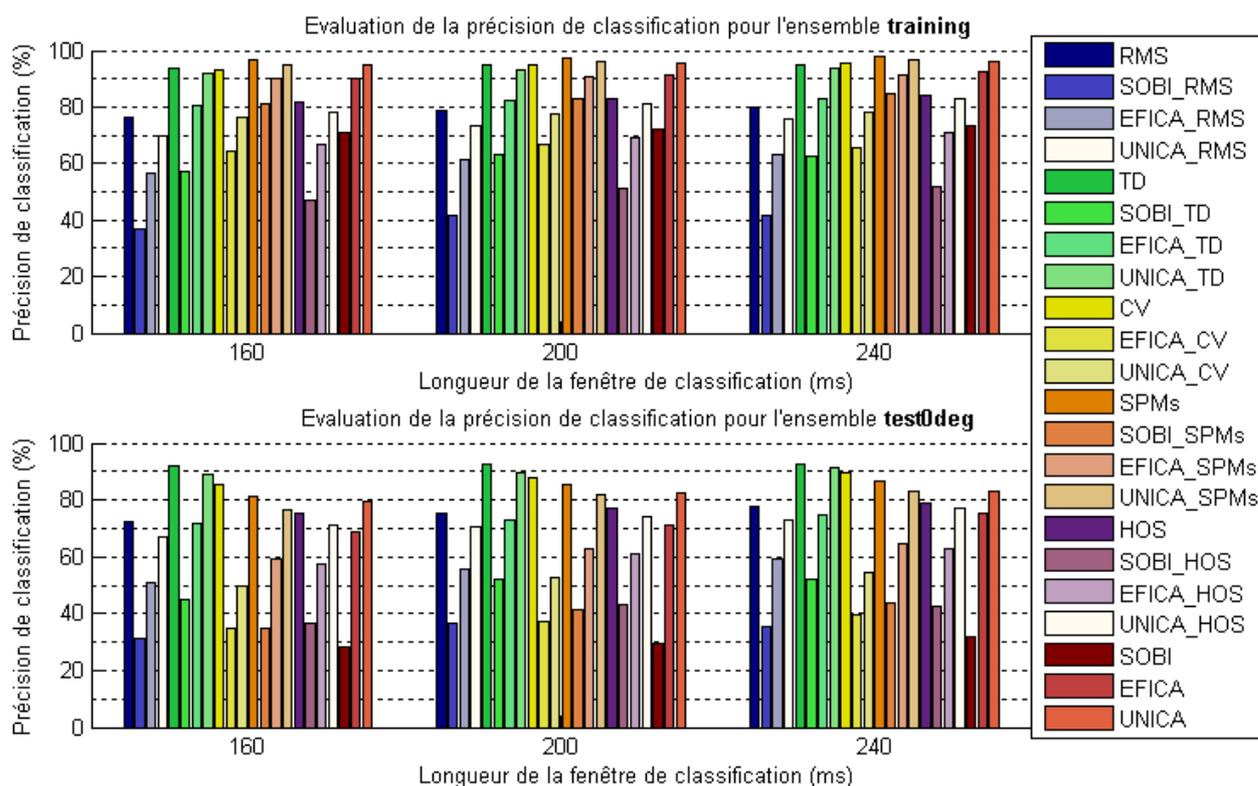


FIG. 5.2 – Taux de classification obtenus pour l’entraînement et le test du classifieur, sans prétraitement ”puissance un quart”, et pour des différentes longueurs de fenêtres de classification.

En appliquant une puissance inférieure à un aux ensembles de caractéristiques, on applique en fait une fonction non-linéaire pour changer d’espace de représentation et de classification des caractéristiques : les grandes valeurs de caractéristiques sont fortement comprimées, et les petites fortement dilatées. Les variations des petites caractéristiques prennent ainsi d’avantage de poids dans la classification.

Comme nous l’avons dit section 2.2.2, nous ne proposerons pas d’étude théorique à son propos, cependant il serait intéressant de vérifier dans quelle mesure les variations des petites valeurs de caractéristiques sont plus discriminantes que les variations des grandes valeurs.

Les algorithmes de classification par ”Support Vector Machine” (SVM) ont justement pour objectif de choisir un espace optimal de représentation des caractéristiques pour la classification. Pour cette étude, le prétraitement ”puissance un quart” a été déterminé expérimentalement, mais dans le cas d’un algorithme de classification SVM, l’espace adapté est recherché par récurrence. Un tel algorithme mènerait donc probablement à de très bonnes performances.

5.2 Classification continue

Définition des indices de performances Pour la classification continue, la classification est effectuée pour environ 30 fenêtres de classification pendant la seconde de signal. Nous définirons deux critères d’évaluation pour la classification continue :

- **la précision, ou taux** : La précision, ou taux, est le pourcentage de fichiers d’1 s d’EMGs pour lesquels le bon geste a été détecté dans au moins une fenêtre de classification.
- **la stabilité** : c’est la moyenne pour l’ensemble des fichiers où le bon geste a été détecté dans au moins une fenêtre de classification, des rapports entre le nombre de bonne classification et le nombre de classification autre que ”relaxe”

La figure (5.2) ci-dessous est une illustration qui permet de bien comprendre ces deux indices de performance. Elle représente la classification continue sur un enregistrement d’1 s du geste **Flexion moyenne du poignet**, pour une longueur de fenêtre de 240 ms et pour l’ensemble de caractéristiques TD.

Sur les 31 classifications, les mouvement **Relaxe de la main**, **Flexion faible du poignet**, et **Flexion moyenne du poignet** on été identifiés 7, 8 et 16 fois, respectivement.

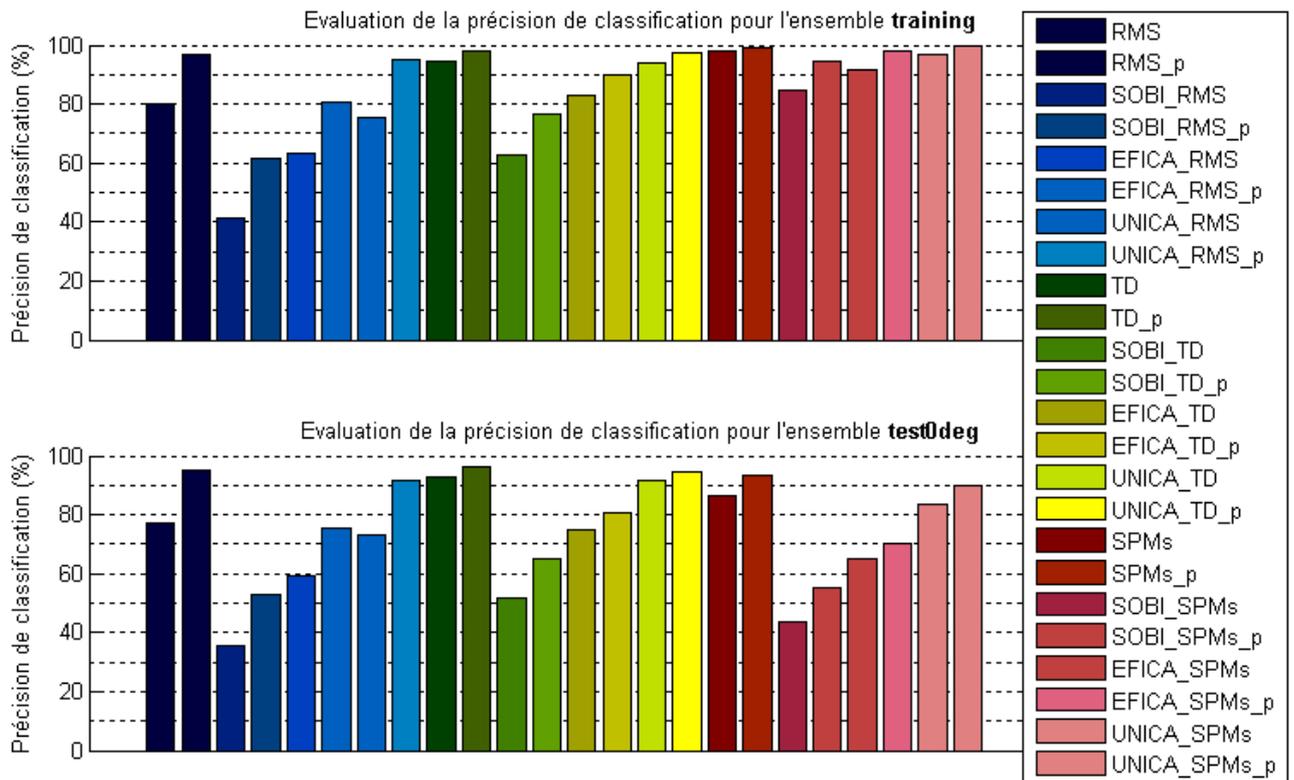


FIG. 5.3 – Taux de classification obtenus pour l’entraînement et le test du classifieur, avec et sans prétraitement ”puissance un quart”.

- Le bon geste a été trouvé au moins une fois, donc on compte $+1/(le\ nombre\ total\ d’enregistrements)$ pour l’indice de précision, et cet enregistrement contribuera à l’indice de stabilité global (calculé sur l’ensemble des enregistrements possédant au moins une classification correcte).
- Le nombre de classifications correctes vaut 16, et le nombre de classifications pour lesquels un geste autre que **Relaxe de la main** a été identifié vaut 24. On compte donc $16/24 = 66\%$ pour l’indice de stabilité sur ce fichier, et la stabilité globale est la moyenne des stabilités pour l’ensemble des enregistrements qui possèdent au moins une classification correcte.

Analyse des résultats La figure (5.2) ci-dessous représente les résultats de la classification continue sans prétraitement ”puissance un quart” , et sans post-traitement par vote majoritaire.

Pour des fenêtres de classification de 240ms, Les ensembles de caractéristiques CV, SPMs et TD mènent aux meilleures précisions avec des précisions de $98.0\pm 0.5\%$, $96.6\pm 0.7\%$ et $96.5\pm 0.8\%$ respectivement. Les ensembles EFICA et UNICA arrivent juste derrière, avec tous deux $96.1\pm 1.0\%$ de précision.

D’une manière générale, la précision est bien meilleure en classification continue que lors du test du classifieur. La méthode de sélection des fenêtres de classification peut fournir une explication à cela. En effet, pour un mouvement de moyenne intensité, et comme les fenêtres sont parfois prises au début ou à la fin du mouvement, la sélection peut parfois être considérée comme un mouvement de faible intensité. On peut aussi raisonner en considérant une classification aléatoire : pour environ 31 fenêtres de classification et 31 classes de mouvements, la probabilité que le bon geste soit détecté au moins une fois lors de la classification continue est de 100%.

Pour la stabilité, l’ensemble le plus performant est TD, avec $62.3\pm 1.6\%$, suivi par l’ensemble CV : $59.3\pm 1.1\%$. Il serait en fait difficile d’atteindre des valeurs beaucoup plus grandes, en partie à cause du fait que l’on essaye dans cette étude de classifier des mouvements avec différents degrés d’intensité. Ainsi, lorsque la fenêtre de classification est à cheval entre un signal EMGs plat et le début de la bouffée d’EMGs, il est très probable que la classification privilégie un geste de plus faible intensité.

Influence de la longueur de la fenêtre de classification Sur la précision, l’influence de la longueur de la fenêtre de classification est la même que lors du test du classifieur. La stabilité est quand à elle très influencée

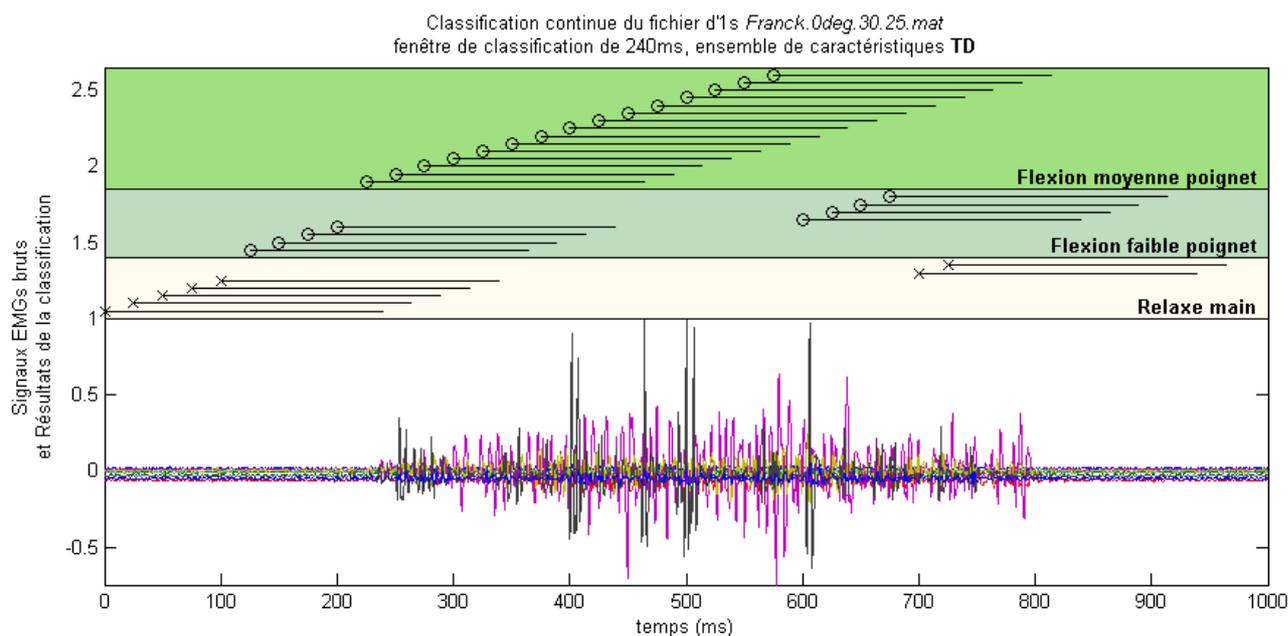


FIG. 5.4 – Classification continue du geste **Flexion moyenne poignet** obtenue avec entraînement du classifieur sur des fenêtres de classification de 240 ms par l'ensemble de caractéristiques TD.

par ce paramètre.

L'ensemble de caractéristiques TD est encore l'ensemble qui semble le moins influencé par le raccourcissement de la fenêtre de classification, autant du point de vue de la précision que de du point de vue de la stabilité. Cette remarque et les bonnes performances de cet ensemble de caractéristiques confirme le fait que l'ensemble TD serait un bon candidat pour l'interaction muscle-machine.

Résultats avec le prétraitement "puissance un quart" La figure (5.2) ci-dessous représente les résultats de la classification continue avec et sans pré-traitement "puissance un quart". Les résultats sont considérablement améliorés lorsqu'on applique ce pré-traitement, aussi bien pour la précision que pour la stabilité.

Un certain nombre d'ensembles de caractéristiques dépasse la barre des 98% de précision : $99.0 \pm 0.5\%$ pour UNICA_SPMs_p, $99.0 \pm 0.4\%$ pour SPMs_p, $98.9 \pm 0.5\%$ pour TD_p, $98.2 \pm 0.8\%$ pour RMS_p, juste devant l'ensemble CV.

Pour la stabilité encore, un certain nombre d'ensembles de caractéristiques passe la barre des 60% de stabilité. L'ensemble de caractéristiques optimal au niveau de la stabilité est encore l'ensemble TD_p, avec $65.6 \pm 1.2\%$ de stabilité.

Post-traitement par vote majoritaire La figure (5.2) représente les performances de la classification continue pour une longueur de fenêtre de 240 ms et les ensembles de caractéristiques avec post-traitement par procédure de vote majoritaire sur 1, 5 et 10 échantillons.

On remarque que la précision diminue avec le nombre d'échantillons pour le vote majoritaire, tandis que la stabilité augmente. Pourtant, sur un enregistrement tel que celui de la figure (5.2) où les classifications sont stables par paliers, un vote majoritaire sur 5 échantillons ne modifie aucune classification.

Pour expliquer ce phénomène, imaginons la configuration très simple où une classification **geste B** est isolée au milieu d'un palier de classification où le **geste A** est détecté 20 fois de suite par exemple. On détecte donc 10 fois **geste A**, puis 1 fois **geste B**, et de nouveau 10 fois **geste A**. Lors de l'application du post-traitement par vote majoritaire, la classification isolée **geste B** sera gommée, et on aura simplement 21 fois **geste A**. Les deux cas suivant peuvent se produire :

- si le mouvement réel est **geste A**, cet enregistrement participe toujours à la précision de l'ensemble, par contre la stabilité est accrue.
- au contraire, si le mouvement réel est **geste B**, il n'est plus détecté, et cet enregistrement ne participe plus à la précision de l'ensemble.

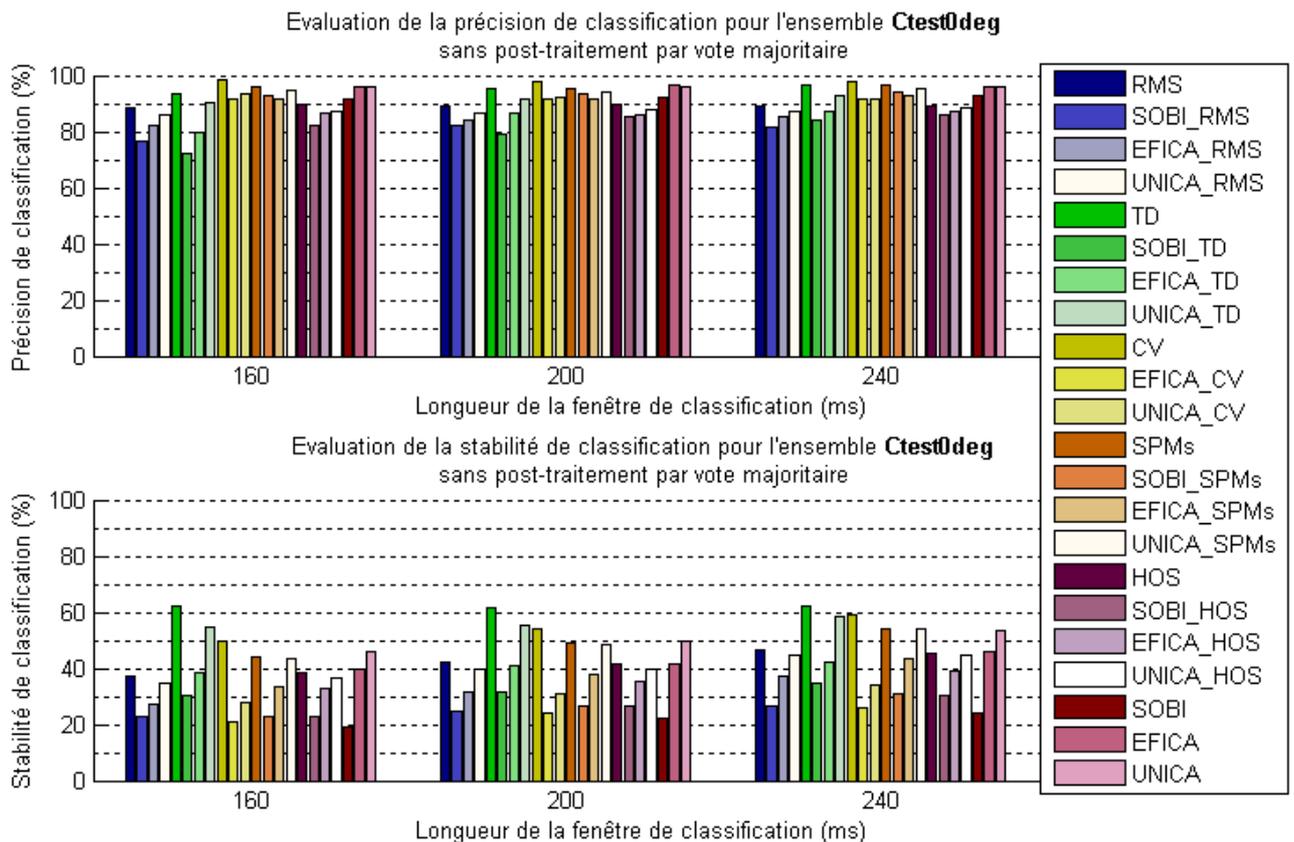


FIG. 5.5 – Résultats de la classification continue sans prétraitement "puissance un quart", et pour différentes longueurs de fenêtres de classification.

Ainsi, après application d'un tel post-traitement, la précision ne peut que diminuer, alors que la stabilité a plutôt tendance à augmenter.

Matrice de confusion Pour bien se rendre compte des mouvements qui sont confondus, la matrice de confusion, notée \mathcal{C} est un outil de représentation très adapté.

Par rapport à la définition de la stabilité, on fait le choix de calculer la matrice de confusion sans prendre en compte le geste **relaxe main**.

L'élément C_{ij} de la matrice de confusion est alors le rapport en pourcents entre le nombre de fenêtres où le mouvement j a été détecté et que le mouvement réel est i , et le nombre total de fenêtres pour lesquelles le mouvement réel est le mouvement i (hormis celles où le geste détecté est **relaxe main**). La somme des éléments de chaque colonne vaut donc 1, et on retrouve dans la diagonale la participation de chaque mouvement à la stabilité globale.

Après 20 entraînements du classifieur sur l'ensemble **training**, la figure (5.2) ci-dessous représente la matrice de confusion moyenne de la classification continue de l'ensemble **Ctest0deg** pour l'ensemble de caractéristiques optimal **TD_p**, une fenêtre de classification de 240 ms, et aucun post-traitement.

On remarque que les confusions se font souvent avec un mouvement de faible à très faible intensité, variable selon les types de mouvements. ainsi, les mouvements de faible intensité avec lesquels les mouvements réels sont souvent confondus sont :

- **Extension 1-pouce** pour les mouvements d'extension d'un ou plusieurs doigts
- **Appui faible 3-majeur** et **Appui faible 3-majeur** pour les mouvements d'appui sur un ou plusieurs doigts
- **Appui faible 1-pouce** pour les mouvements du poignet.

Cette confusion se fait très probablement au début ou à la fin du mouvement, lorsque la fenêtre de classification est à cheval entre un EMGs plat et une bouffée d'EMGs. Grâce à cela, on peut comprendre que les probabilités de transition (ou plus précisément probabilités de confusion ici) entre les mouvements peuvent ainsi être déterminées expérimentalement, ce qui serait très utile pour renseigner un algorithme à base de chaîne

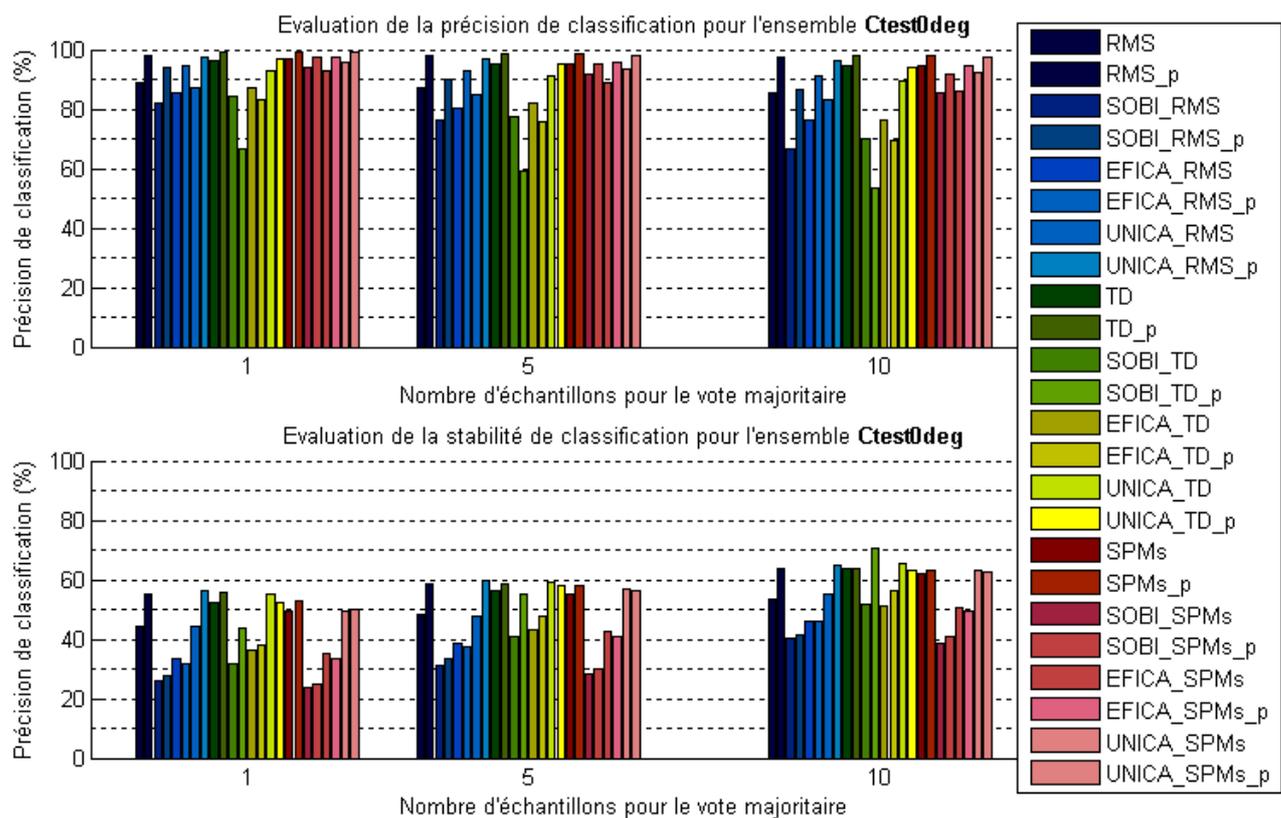


FIG. 5.6 – Résultats de la classification continue, avec et sans pré-traitement "puissance un quart", et pour un post-traitement par processus de vote majoritaire sur différents nombres de décisions

de Markov pour le post-traitement de la classification. Une décision serait alors prise en fonction de la sortie actuelle du classifieur, et des sorties antérieures.

Lorsque pour un mouvement de moyenne intensité la fenêtre de classification observe plus de bouffée d'EMGs que de signal plat, on a dit au paragraphe de la figure (5.2) qu'il pourrait y avoir une confusion avec le même mouvement mais de plus faible intensité. On peut vérifier cette supposition à partir de la matrice de confusion.

On peut aussi utiliser la matrice de confusion pour se rendre compte des mouvements qui se ressemblent beaucoup, et qui sont donc souvent confondus. Ces renseignements devraient permettre de mieux sélectionner les mouvements pour une application en interaction muscles-machine. Ainsi, le mouvement **appui moyen 1234-tous** est plus souvent pris pour le mouvement **appui moyen 3-majeur**. On confond aussi très souvent la **supination faible** avec l'**appui moyen 1-pouce**

Enfin, On peut considérer qu'une partie de ces confusions peut être expliquée par les stratégies de mouvement du sujet, en particulier à cause du fait que la main du sujet est attachée à la table. on peut ainsi expliquer le fait que l'**inclinaison radiale faible** soit parfois confondue avec la **pronation faible**,

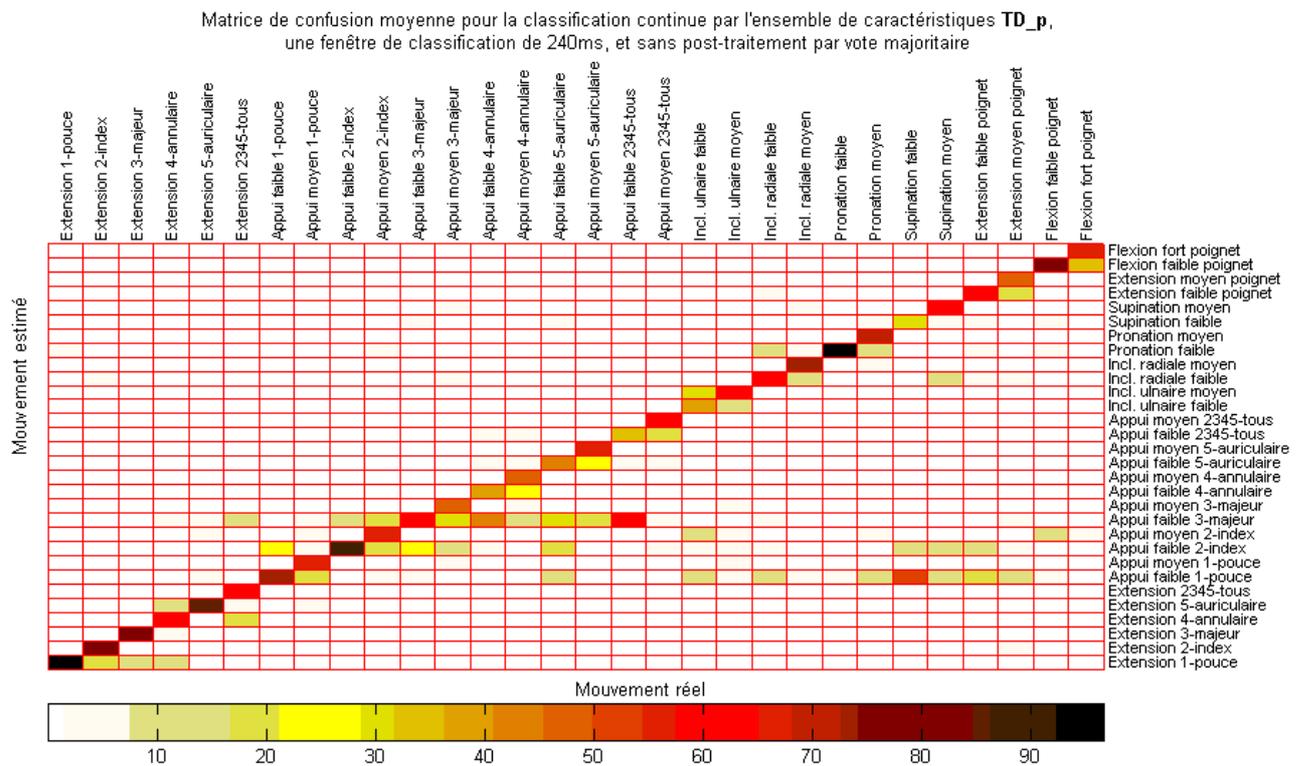


FIG. 5.7 – Matrice de confusion moyennée sur 20 classifications continues avec entraînement du classifieur sur des ensembles différents, L'ensemble de caractéristiques est TD_p

Chapitre 6

Evaluation de la robustesse vis-à-vis d'un décalage angulaire du système d'électrodes

6.1 Localisation et applications

Résultats de la localisation Les algorithmes de séparation aveugle de sources par analyse en composantes indépendantes permettent de déterminer à la fois des estimations des sources indépendantes, et la visibilité de ces sources pour chaque capteur. Dans notre cas, les huit capteurs sont également répartis autour d'une section de l'avant-bras. On se propose d'utiliser un modèle des sources des signaux EMGs, et un modèle du milieu de propagation, pour estimer à la fois la localisation des huit sources, et leur puissance. La figure (6.1) ci-dessous représente l'estimation de la localisation des source pour le mouvement **Extension 2-index** sous l'hypothèse qu'à une estimation de source correspond un seul dipôle. Sur l'ensemble des figures représentant la section du bras, l'orientation est telle que la main est derrière le dessin, avec la paume à gauche et le pouce en haut.

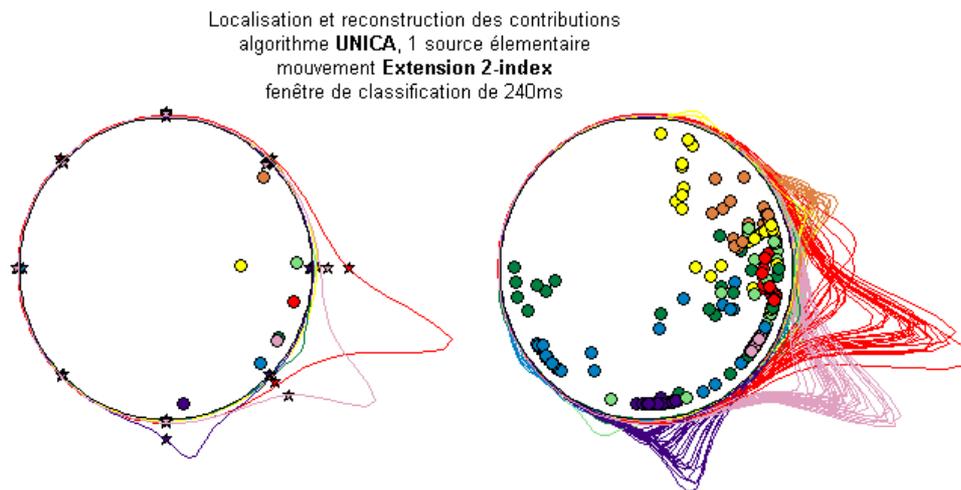


FIG. 6.1 – Estimation de la localisation des sources et reconstruction des contributions autour de la section pour une répétition (figure de gauche) et l'ensemble des répétitions (figure de droite) d'un mouvement particulier.

La figure (6.1 gauche) représente une répétition particulière du geste, l'estimation de la localisation des huit sources représentées par des ronds, les contributions des sources au niveau des capteurs représentées par les étoiles, et l'interpolation de la participation de chaque source au potentiel observable tout autour de la section. La figure (6.1 droite) représente les résultats de la localisation pour l'ensemble répétitions du geste. Même si les contributions des sources sont assez bien regroupées au niveau des capteurs, on observe de grandes variations de reconstruction de la participation entre les capteurs. L'algorithme de réordonnement des sources semble être efficace sur ce geste, puisque les sources de même couleur (identiquement numérotées) sont visiblement concentrées dans les mêmes zones, tout au moins en ce qui concerne les sources les plus puissantes.

Malgré cette grande variabilité, les résultats de la localisation permettent de retrouver de manière grossière la position des muscles utilisés pour chaque mouvement, ainsi que certaines stratégies du contrôle neuromusculaire. La figure (6.1) ci-dessous représente l'estimation de la localisation des source pour 4 mouvements : deux mouvements contraires et deux intensités différentes, toujours sous l'hypothèse qu'à une estimation de source correspond une source élémentaire.

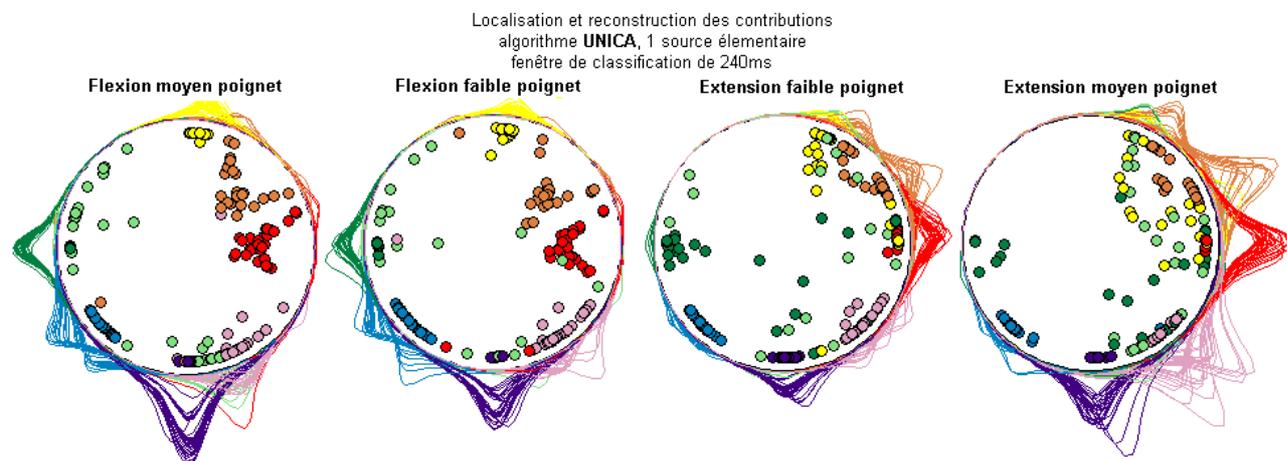


FIG. 6.2 – Estimation de la localisation et reconstruction des contributions pour l'ensemble des répétitions de quatre mouvements du poignet

Ces quatre figures permettent de mettre cela en évidence :

- la contribution de chaque source au potentiel capté par les électrodes augmente avec l'intensité du mouvement ;
- les positions des sources les plus puissantes sont globalement opposées pour la flexion et pour l'extension du poignet. D'un point de vue physiologique, les fléchisseurs sont effectivement plutôt du côté paume et les extenseurs plutôt du côté dos de la main ;
- les figures représentant les mouvements de flexion montrent une activité musculaire intense du côté du petit doigt, et une faible du côté du pouce. Ceci est signe d'un recrutement de muscles antagonistes qui peuvent participer à l'équilibre global de la main par exemple.

Mise en garde Compte tenu de ces résultats préliminaires et du caractère très localisé de la contribution d'une source autour d'une section de l'avant-bras, on peut d'ors et déjà affirmer que l'échantillonnage réalisé par l'ensemble des capteurs autour du bras est trop grossier pour que l'on obtienne une estimation précise de la localisation et de la puissance des sources. Cette remarque est l'occasion d'avertir le lecteur que les résultats qui suivent sont vraisemblablement fortement pénalisés par cet échantillonnage trop grossier, et que si on pouvait recommencer l'expérience avec plus de capteurs, les conclusions de cette étude seraient probablement plus optimistes quand à l'utilisation d'algorithmes d'analyse en composantes indépendantes et de localisation pour assurer l'adaptation du classifieur à un décalage angulaire du système d'électrodes.

Estimation du décalage angulaire des électrodes On se propose d'utiliser un estimateur du décalage angulaire du système d'électrodes, défini comme la différence entre les position angulaire moyennes des barycentres des positions des sources pondérées par leur amplitude.

La figure (6.1 gauche) illustre la recherche de l'estimation du décalage angulaire du système d'électrodes. Chaque courbe est la somme des contributions de chaque source pour une répétition particulière, interpolées autour de la section. Les points ronds dans la section correspondent aux estimations des positions des sources, et leur surface est proportionnelle au facteur k d'amplitude des sources. Chaque étoile correspond au barycentre des positions des sources pondérées par leur amplitude. Le rouge correspond à la première position angulaire du système d'électrodes, et le bleu correspond au système décalé angulairement. L'angle entre les deux droites est l'estimateur du décalage angulaire du système d'électrodes.

La figure (6.1 droite) montre le calcul de l'estimateur sur chaque mouvement, et en moyenne sur tous les mouvements, pour l'algorithme d'analyse en composantes indépendantes UNICA, et une source élémentaire

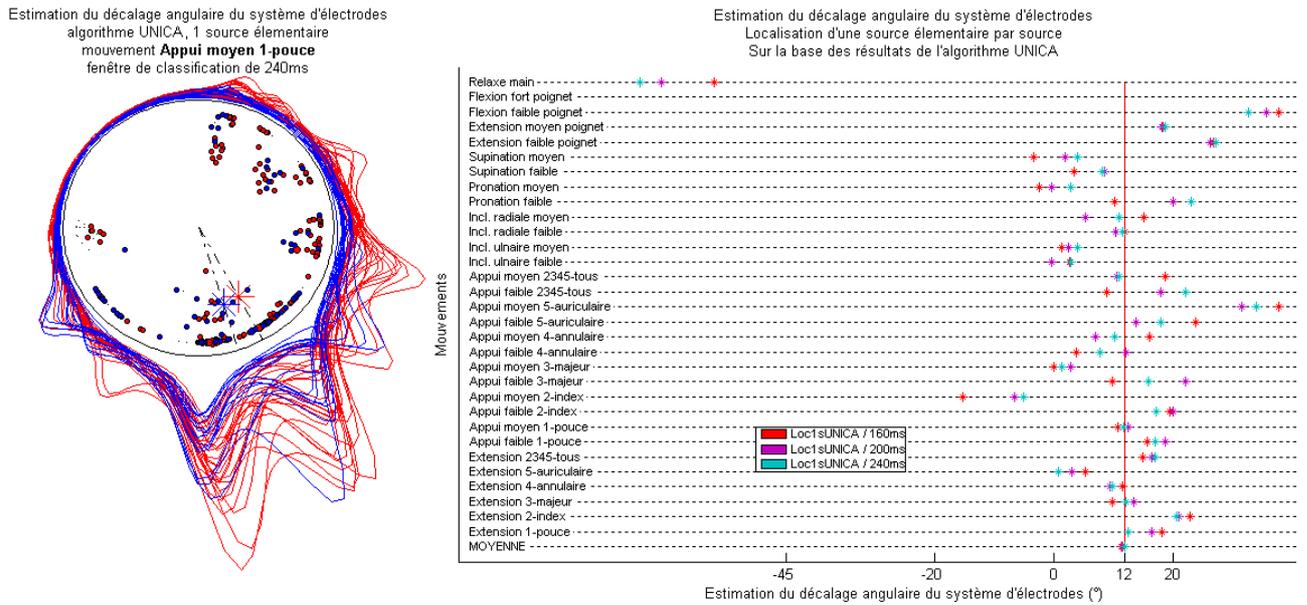


FIG. 6.3 – Estimation du décalage angulaire du système d'électrodes pour un mouvement particulier (figure de gauche), et pour chaque mouvement (figure de droite).

par source, et pour les trois longueurs de fenêtre de classification. Comme on peut le voir, l'estimateur semble proche de la valeur réelle de l'écart angulaire (12°) pour certains mouvements. Même si dans ce cas là la moyenne sur tous les mouvement est très proche de 12° pour chaque longueur de fenêtre de classification. Les résultats basés sur l'algorithme EFICA et ceux basés sur une localisation de deux sources élémentaires par source donnent des résultats similaires, mais la moyenne sur tous les mouvements varie entre -6° et 13°. Enfin, les écarts-type sont très importants pour chacun des quatre cas. On gardera donc un avis très réservé sur la qualité de cet estimateur.

Les valeurs très importantes de l'estimateur pour des gestes comme **appui moyen 5-auriculaire**, ou **flexion faible poignet** et **flexion moyen poignet** peuvent s'expliquer par le fait que ces mouvements utilisent un grand nombre de muscles, parfois en des positions opposés dans la section de l'avant-bras. Le barycentre est de ce fait assez proche du centre de la section. A précision égale de positionnement du barycentre, cela affecte beaucoup la précision de la position angulaire du barycentre.

En utilisant un échantillonnage plus fin des capteurs autour de la section, il est probable que cet estimateur soit plus efficace sur certains mouvements bien choisis où les muscles sollicités sont bien localisés dans une partie ou une autre de l'avant-bras. Si cette intuition devait se confirmer, il serait donc possible à partir de quelques répétitions d'un même geste, d'avoir une estimation du décalage angulaire du système d'électrodes entre la position où l'entraînement du classifieur a été réalisée, et celle obtenue après repositionnement (le jour suivant par exemple).

Etude des performances de la classification pour les ensembles de caractéristiques reconstruits après localisation De la même manière que pour les ensembles **training** et **test0deg** d'entraînement et de test des classifieurs, et pour l'ensemble **Ctest0deg** de classification continue, on a extrait les ensembles de caractéristiques des signaux mesurés après repositionnement du système d'électrodes, et ainsi obtenu les ensembles **test12deg** et **Ctest12deg**.

Après l'estimation de la localisation des sources sur l'ensemble **training**, on a procédé à la reconstruction des participations des différentes sources (simples ou doubles) aux potentiels mesurés par les capteurs, en prenant en compte un décalage angulaire du système d'électrodes. Les ensembles de caractéristiques ainsi obtenus sont **Loc1sEFICA**, **Loc1sEFICA_p**, **Loc1sUNICA**, **Loc1sUNICA_p**, **Loc2sEFICA**, **Loc2sEFICA_p**, **Loc2sUNICA**, et **Loc2sUNICA_p**.

La figure (6.1) ci-dessous montre les performances de cette méthode sur la classification. Les figures de gauche représentent le taux de classification obtenue sur les ensembles **training** en haut et **test12deg** en bas. A droite, c'est les performances de la classification continue sur l'ensemble **Ctest12deg** qui sont représentées,

avec précision en haut et stabilité en bas. La longueur de la fenêtre de classification est de 240ms, et aucun post-traitement par vote majoritaire n'a été appliqué.

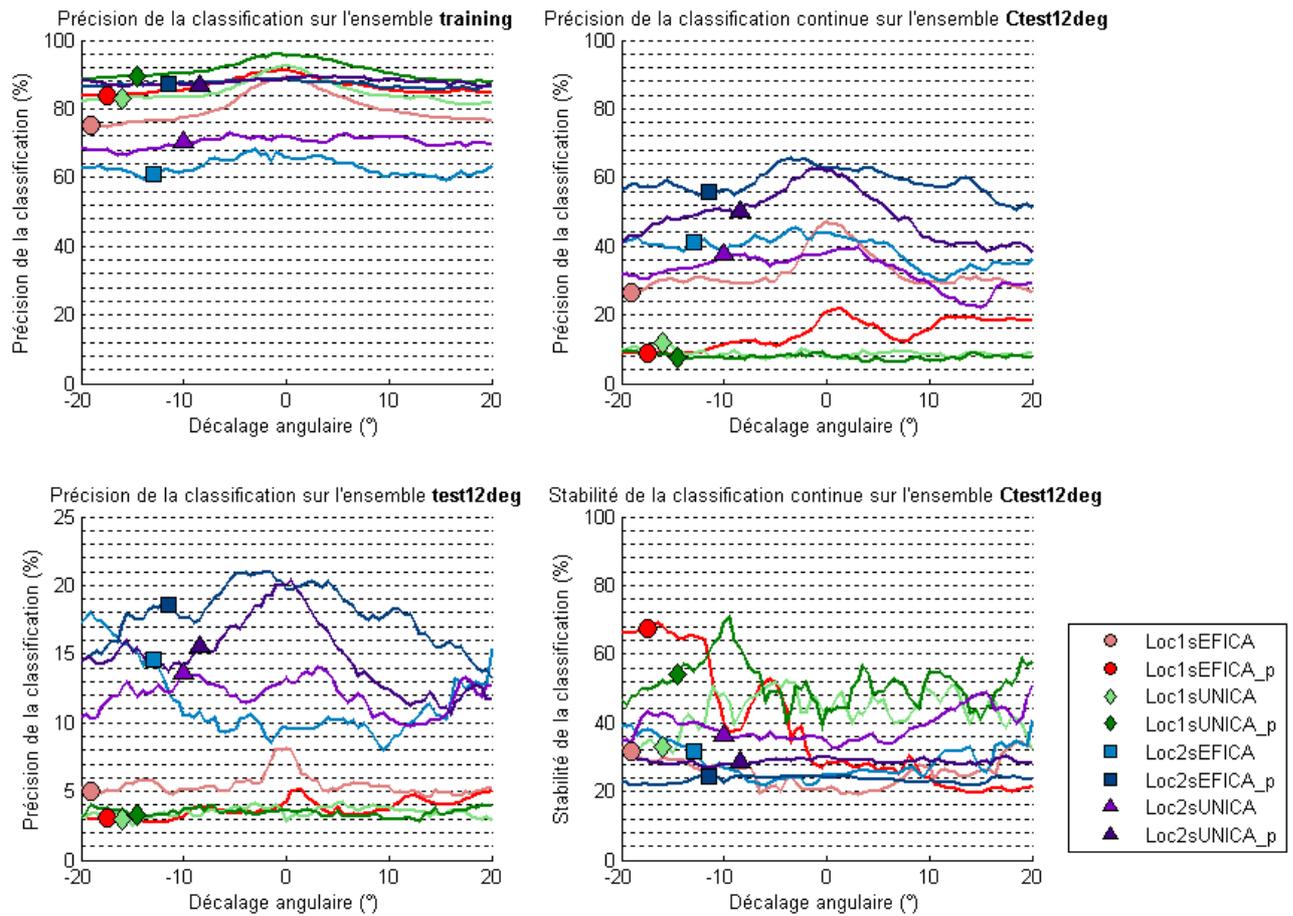


FIG. 6.4 – Résultats de la classification après modification du classifieur afin de prendre en compte un décalage angulaire.

La figure (6.1 en haut à gauche) qui représente le taux de classification sur l'ensemble **training** montre que la recherche d'un seul dipôle par estimée de source rend la classification moins précise lorsque l'écart angulaire augmente. Ceci est une implication directe du fait que les interpolations entre les électrodes varient beaucoup d'un geste à l'autre. Au contraire, la précision de classification est pratiquement constante lorsque deux dipôles sont pris en compte par estimée de source. L'hypothèse de sources multiples semble donc d'ors et déjà la plus appropriée pour assurer une adaptation du classifieur à un décalage angulaire des électrodes.

Cette remarque est confirmée pour l'ensemble **test12deg** (6.1 en bas à gauche) : la précision apportée par les ensembles de caractéristiques **Loc1s-** ne dépasse pas les 8%. On retrouve par ailleurs un pic dans la précision autour de 0 de décalage angulaire. Les ensembles **Loc2s-** atteignent des taux de classification un peu plus élevés, bien que toujours très faibles (21% au maximum pour l'ensemble **Loc2sEFICA_p**). Pour les deux ensembles les plus performants, **Loc2sEFICA_p** et **Loc2sUNICA_p**, le taux de classification chute lorsque le décalage angulaire augmente. D'une manière générale, on est bien loin des attentes que l'on pouvait avoir : la classification n'atteint pas de maximum autour de 12.

La classification continue (6.1 droite) de l'ensemble **Ctest12deg** montre que l'ensemble **Loc2sEFICA_p** qui présentait le plus grand plateau autour de 0, est encore l'ensemble dont le taux de classification continue est le moins dégradé lorsque le décalage angulaire augmente. Le groupe le plus performant du point de vue du taux de classification est **Loc2s_p** (environ 64% de précision autour de 0). Vient ensuite le groupe **Loc2s-** (autour de 40%), puis les autres loin derrière. On retrouve la dualité précision/stabilité : les ensembles de caractéristiques les moins précis sont aussi les plus stables.

Conclusions sur l'application des méthodes de localisation Finalement, les résultats ne répondent pas aux attentes que l'on avait sur l'adaptation du classifieur à un décalage angulaire des électrodes. L'étude de

l'estimateur du décalage angulaire ne permet pas de conclure sur sa pertinence pour l'un ou l'autre des gestes avant de pouvoir comparer les résultats à ceux d'autres expériences sur différents sujets, différents décalages angulaires des électrodes et différentes positions initiales des électrodes autour de l'avant-bras. Pour ce qui est de la classification, les performances décroissent rapidement lorsque le décalage augmente, et on ne retrouve pas de maximum autour de 12° comme on l'avait espéré.

Néanmoins, restons optimiste : il est probable que le nombre trop faible de capteurs autour de l'avant-bras soit le principal responsable des mauvais résultats exposés dans cette section. En effet un plus grand nombre de capteurs devrait vraisemblablement provoquer une réaction en chaîne : une meilleure séparation de sources, une localisation plus précise, une interpolation moins variable, et donc une classification plus performante. Il serait donc très intéressant de vérifier ces suppositions avec plus de capteurs.

6.2 Etude des performances de classification sans prise en compte du décalage angulaire du système d'électrodes

Nous évaluons ici la robustesse à proprement parler des performances de la classification par rapport à un décalage angulaire du système d'électrodes. Pour cela, nous appliquons tout simplement les classificateurs utilisés dans le chapitre précédent, aux signaux enregistrés après repositionnement des électrodes.

Performances de la classification La figure (6.2) ci-dessous montre l'influence du décalage angulaire sur les performances de la classification, pour une fenêtre de classification de 240 ms, et sans post-traitement par vote majoritaire pour le cas de la classification continue.

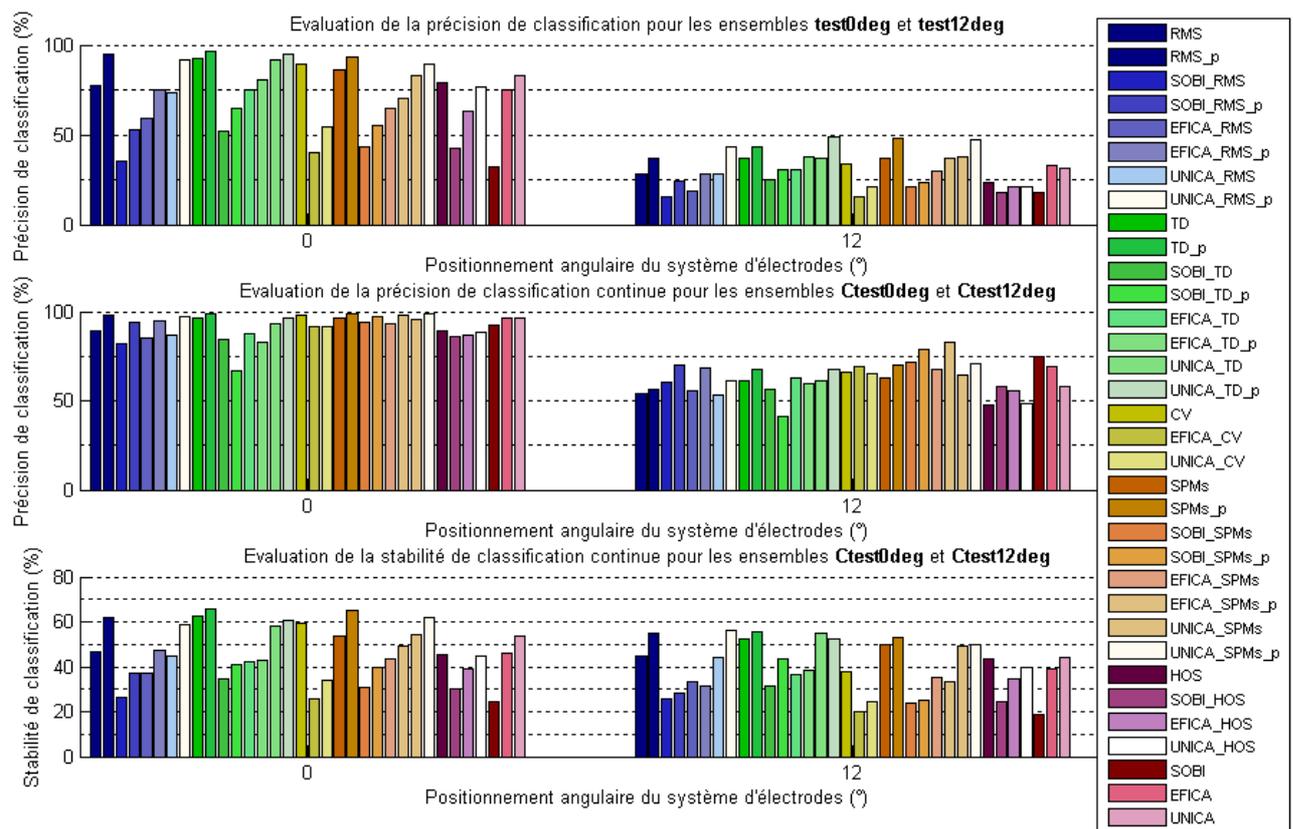


FIG. 6.5 – Résultats de la robustesse de la classification au décalage angulaire du système d'électrodes pour les 34 ensembles de caractéristiques : le classifieur n'est pas modifié pour prendre en compte le décalage angulaire.

On remarque tout de suite que les résultats sont bien meilleurs que ceux de la section précédente, en particulier du point de vue du taux de classification continue. On a tout de même une forte baisse des performances, plus prononcée pour le taux de classification du groupe de test du classifieur que pour le taux de classification continue. On retrouve ici encore une dualité précision/stabilité, peut-être plus importante encore que pour la section précédente.

Malgré tout, certains ensembles de caractéristiques donnent de très bon résultats, autant au niveau de la précision que de la stabilité de la classification continue. L'ensemble de caractéristiques TD_p, qui était considéré comme optimal pour le chapitre précédent avec (98.9±0.5%; 65.6±1.2%) de (précision; stabilité), affiche sur l'ensemble CtestOdeg les performances (67.4±1.9%; 55.5±1.7%). Ses performances sont tout à fait similaires à celles de l'ensemble SPms_p (70.0±2.1%; 53.0±1.7%).

Si l'on considère que la somme *précision+stabilité* est un bon critère pour juger des performances obtenues par les ensembles de caractéristiques, les trois premiers ont gardé la même place que pour le chapitre précédent : les deux ensembles précédemment cités arrivent premiers ex æquo, et on retrouve juste derrière les ensembles pré-traités par l'algorithme de séparation aveugle de source UNICA : UNICA.SPms_p (70.8±2.4%; 50.0±1.6%); UNICA.TD_p (67.7±2.7%; 52.2±1.0%); UNICA.RMS_p (61.0±1.6%; 56.4±1.6%); et UNICA.TD (60.9±2.2%; 55.0±2.3%).

Par cette remarque, on peut considérer que le pré-traitement par séparation aveugle de source est un bon moyen d'assurer la robustesse des performances de classification vis-à-vis d'un décalage angulaire du système d'électrodes. Le fait que les ensembles pré-traités restent juste derrière les ensembles SPms_p et TD_p est peut être le signe que l'algorithme UNICA n'est pas le meilleur candidat pour la séparation aveugle de source des signaux EMGs, c'est-à-dire que les hypothèses statistiques des signaux sources sur lesquelles reposent cet algorithme ne sont pas très justifiées pour les signaux EMGs. Cela peut aussi venir du fait que l'algorithme de renumérotation des signaux sources n'est pas optimal, et peut encore être amélioré.

Ouvertures Comme certains ensembles de caractéristiques semblent somme-toute présenter une assez bonne robustesse au décalage angulaire du système d'électrodes, il serait envisageable de ne pas reconstruire les signaux à l'aide des techniques de localisation. Dans le cas où le dispositif d'interaction muscle-machine intégrerait l'informatique nécessaire à la classification et à la prise de décision, une telle méthode serait avantageuse puisqu'elle permettrait d'économiser beaucoup de calculs. Pour assurer la robustesse à n'importe quel décalage angulaire des électrodes, deux méthodes sont envisageables :

Soit le système aide l'utilisateur à placer le système d'électrodes aussi proche que possible de la position initiale, en lui donnant un feedback par rapport à ce qu'il détecte. Pour cela, l'utilisateur devrait exécuter un mouvement convenu d'avance. L'avantage de cette méthode est que le décalage angulaire du système d'électrode pourrait être minimal. L'inconvénient est que l'utilisateur devrait exécuter un mouvement avec une excellente constance pour que l'estimation de l'écart angulaire soit fiable.

La seconde méthode consisterait à déterminer une permutation circulaire des signaux de telle sorte que l'électrode renumérotée 1 soit la plus proche de là où était l'électrode n 1 lors de l'entraînement du classifieur. Cette méthode semble être la plus prometteuse puisque l'estimation de la permutation circulaire pourrait être fait par un classifieur auxiliaire, entraîné à comparer les caractéristiques d'un mouvement à celles du même mouvement si les électrodes avaient subies une permutation circulaire. L'ensemble de gestes répétés lors de l'entraînement initial du classifieur suffiraient donc à mettre au point le système de classification auxiliaire

Par cette deuxième méthode, le profil du taux de classification en fonction du décalage angulaire des électrodes devrait ressembler à la courbe de la figure (6.2), et une augmentation du nombre d'électrodes permettrait du même coup d'augmenter la borne inférieure des performances du système d'interaction muscle-machine.

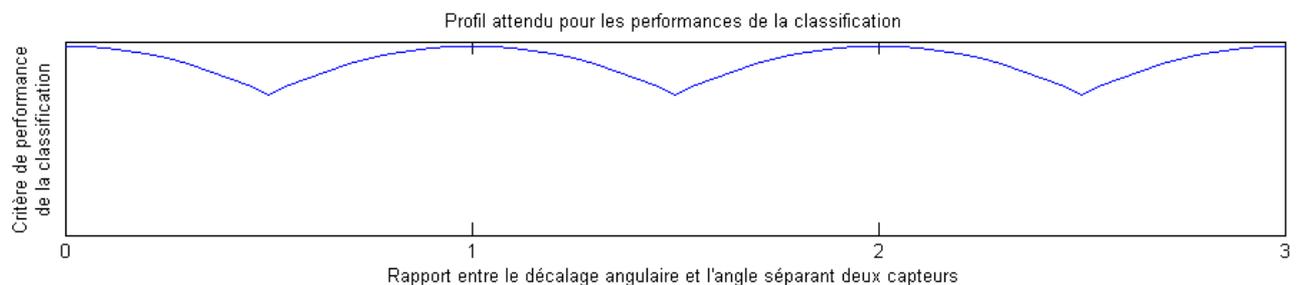


FIG. 6.6 – Les performances de classification pourraient avoir un profil périodique en fonction du décalage angulaire du système d'électrodes, assurant ainsi une borne inférieure aux performances de la classification

Conclusion

Motivations L'interaction muscle-machine est une promesse d'interaction sans instrument physique, intuitive et naturelle avec l'informatique qui nous entoure. Les travaux de recherche dans ce domaine sont récents et s'inspirent des domaines de l'électromyographie, du traitement du signal, et de l'interaction homme-machine. Un tel système d'interaction, sous l'aspect physique d'un brassard à placer autour de l'avant bras pour ce qui concerne cette étude, doit répondre à un certain nombre de besoins d'un utilisateur potentiel.

Les deux besoins principaux que l'on a identifié pour l'application des signaux électromyographiques de surface à l'interaction muscle-machine peuvent être exprimés de la manière suivante :

- d'une part, le système doit pouvoir reconnaître autant de mouvements différents que possible, avec fiabilité et robustesse ;
- d'autre part, l'utilisateur doit pouvoir entraîner le système à reconnaître ses mouvements une fois pour toute, de sorte qu'à la deuxième utilisation, le système soit opérationnel le plus rapidement possible.

Dans le cadre de cette étude, nous nous sommes donc fixés deux objectifs principaux pour tenter de répondre à ces besoins :

- déterminer une méthode efficace permettant l'identification d'un ensemble riche de gestes du poignet et des doigts ;
- évaluer dans quelles mesures les performances de la classification peuvent être robustes à un repositionnement du brassard.

Performances de la classification Pour répondre au premier objectif que l'on s'était fixé, nous avons testé la classification de 30 gestes du poignet et des doigts sur un ensemble de courts enregistrements et en classification continue, pour un certain nombre d'ensembles de caractéristiques.

Pour une fenêtre de classification de 240ms et sans post-traitement par vote-majoritaire, les meilleures performances ont été atteintes pour TD_p : l'ensemble de caractéristiques temporelles de Hudgins avec changement d'espace de classification par prétraitement non-linéaire "puissance un quart". Cet ensemble atteint une précision de $96.4 \pm 0.5\%$ pour le test du classifieur, et $98.2 \pm 0.8\%$ et $65.6 \pm 1.2\%$ de précision et de stabilité pour la classification continue.

Globalement, les ensemble de caractéristiques sont assez sensibles à la diminution de la longueur de la fenêtre de classification, surtout du point de vue de la stabilité.

Enfin, la méthode de post-traitement par vote majoritaire utilisée permet de choisir un compromis entre précision et stabilité.

Adaptation du classifieur à un repositionnement du système d'électrodes Pour cette partie, nous avons tout d'abord introduit un estimateur du décalage angulaire du système d'électrodes. Ensuite, nous avons proposé une méthode pour adapter le classifieur à un tel décalage angulaire.

Ces deux méthodes sont basées sur l'application d'algorithmes de séparation aveugle de sources par analyse en composantes indépendantes et l'estimation de la localisation des sources.

Malheureusement, les résultats de cette étude sont plutôt décevants, mais cela peut s'expliquer partiellement :

- par le grand écart entre les électrodes de mesure et le caractère très localisé des signaux à observer ;

- par un mauvais choix des algorithmes de séparation aveugle de sources, pas suffisamment bien adaptés à la séparation des signaux électromyographiques de surface.

Robustesse de la classification par rapport à un repositionnement du système d'électrodes En terme de robustesse pure, sans adapter le classifieur à la nouvelle position du système d'électrodes, les résultats sont plus satisfaisants.

Pour le classifieur optimal de la première partie (qui utilise l'ensemble de caractéristiques TD_p), un décalage angulaire de 12° du système d'électrodes abaisse les performances de la classification continue de $98.9 \pm 0.5\%$ à $67.4 \pm 1.9\%$ pour le taux de classification, et de $65.6 \pm 1.2\%$ à $55.5 \pm 1.7\%$ pour la stabilité.

Perspectives Les résultats de la première partie de cette étude sont très encourageants, et permettent de définir de nouveaux objectifs et de rentrer un peu plus dans les détails du choix des caractéristiques de la classification. Il serait ainsi intéressant :

- de choisir un prétraitement des données par un algorithme de séparation aveugle de source plus adapté aux signaux électromyographiques de surface ;
- de tester d'autres classifieurs, en particulier le SVM puisqu'on a vu qu'une transformation non-linéaire élémentaire amélioreraient considérablement les résultats ;
- d'appliquer un algorithme de post-traitement plus puissant comme les chaînes de Markov, pour augmenter encore la stabilité de la classification et ainsi atteindre les critères d'exigence des applications en interface muscle-machine

Pour le second objectif, Cette étude s'intéressait à un problème qui ne semble pas avoir été abordé dans la recherche auparavant : la robustesse de la classification par rapport à un décalage angulaire du système d'électrodes.

Nous avons proposé une méthode d'adaptation du classifieur au décalage angulaire du système d'électrodes qui mériterait d'être testée avec un nombre plus élevé d'électrodes, et peut-être pour des algorithmes de séparation aveugle de source plus adaptés aux signaux électromyographiques de surface. Une orientation possible serait de décomposer dans un premier temps le signal en ses composants élémentaires : les trains de potentiels d'actions d'unités motrices.

Enfin, les résultats de robustesse du classifieur sont très encourageants, et permettent d'envisager une méthode pour garantir une minoration de la précision et de la stabilité de la classification, même pour des décalages angulaires importants.

Bibliographie

- [1] A. J. Andrews. Finger Movement classification using forearm EMG signals. Master's thesis, Queen's University, Kingston, Ontario, Canada, October 2008.
- [2] Sridhar Arjunan and Dinesh K. Kumar. Recognition of facial movements and hand gestures using surface electromyogram(semg) for HCI based applications. *Digital Image Computing Techniques and Applications, 9th Biennial Conference of the Australian Pattern Recognition Society on*, pages 1–6, Dec. 2007.
- [3] A. Belouchrani, K. A. Meraim, J. F. Cardoso, and E. Moulines. A blind source separation technique using second-order statistics. *IEEE Transactions on Signal Processing*, 45(2), 1997.
- [4] J. F. Cardoso. Blind signal separation : statistical principles. *Proceedings of the IEEE*, 86(10) :2009–2025, 1998.
- [5] F. H. Y. Chan, Y.-S. Yang, F. K. Lam, Y.-T. Zhang, and P. A. Parker. Fuzzy EMG classification for prosthesis control. *IEEE Transactions on Rehabilitation Engineering*, 8(3) :305–311, 2000.
- [6] J.U. Chu, I. Moon, and M. Mun. A real-time pattern recognition for multifunction myoelectric hand control. In *International conference on control, automation and systems*, June 2005.
- [7] P. Comon. Independent component analysis, a new concept? *Signal Process.*, 36(3) :287–314, 1994.
- [8] Enrico Costanza. *Subtle, Intimate Interfaces for Mobile Human Computer Interaction*. PhD thesis, Massachusetts Institute of Technology, Sept. 2003.
- [9] Enrico Costanza, Samuel A. Inverso, and Rebecca Allen. Toward subtle intimate interfaces for mobile devices using an EMG controller. In *CHI '05 : Proceedings of the SIGCHI conference on Human factors in computing systems*, pages 481–489, 2005.
- [10] Enrico Costanza, Samuel A. Inverso, Rebecca Allen, and Pattie Maes. Intimate interfaces in action : assessing the usability and subtlety of emg-based motionless gestures. In *CHI '07 : Proceedings of the SIGCHI conference on Human factors in computing systems*, pages 819–828, 2007.
- [11] S. Cruces, L. Cichocki, and L. Castedo. Blind source extraction in gaussian noise. In *In proceedings of the 2nd International Workshop on Independent Component Analysis and Blind Signal Separation (ICA'2000)*, pages 63–48, June 2000.
- [12] Carlo J. De Luca. Physiology and mathematics of myoelectric signals. *Biomedical Engineering, IEEE Transactions on*, 26(6) :313–325, June 1979.
- [13] K. Englehart and B. Hudgin. A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 50(7) :848–854, 2003.
- [14] K. Englehart, B. Hudgin, and A. D. C. Chan. Continuous multifunction myoelectric control using pattern recognition. *Technology and Disability*, 15(2) :95–103, 2003.
- [15] K. Englehart, B. Hudgin, and P. A. Parker. A wavelet-based continuous classification scheme for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 48(3) :302–311, 2001.
- [16] K. Englehart, B. Hudgins, and P. A. Parker. Classification of the myoelectric signal using time-frequency based representations. *Medical Engineering and Physics*, 21(6-7) :431–438, Jul. 1999.
- [17] D. Farina, C. Fevotte, C. Doncarli, and R. Merletti. Blind separation of linear instantaneous mixtures of nonstationary surface myoelectric signals. *Biomedical Engineering, IEEE Transactions on*, 51(9) :1555–1567, Sept. 2004.
- [18] D. Farina and R. Merletti. A novel approach for precise simulation of the EMG signal detected by surface electrodes. *Biomedical Engineering, IEEE Transactions on*, 48(6) :637–646, Jun 2001.
- [19] H. H. Goldstein and P. Horwitz. A procedure for the diagonalization of normal matrices. *Journal of the Association for Computing Machinery*, 6 :176–195, 1959.
- [20] A. Hiraiwa, K. Shimohara, and Y. Tokunaga. EMG pattern analysis and classification by neural network. In *Proc. Int. Conf. IEEE Systems, Man and Cybernetics*, volume 3, pages 1113–1115, 1989.

- [21] B. Hudgins, P. A. Parker, and R. Scott. A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 40(1) :82–94, Jan. 1993.
- [22] C. Jutten. Algorithmes fondés sur l’information mutuelle. In *École de printemps de Villard-de-Lans : de la s’eparation de sources à l’analyse en composantes indépendantes*, pages 145–176, mai 2001.
- [23] J. L. Lacoume, P. O. Amblard, and Comon. P. *Statistiques d’ordre supérieur pour le traitement du signal*. Masson, 1997.
- [24] Te-Won Lee, M.S. Lewicki, M. Girolami, and T.J. Sejnowski. Blind source separation of more sources than mixtures using overcomplete representations. *Signal Processing Letters, IEEE*, 6(4) :87–90, Apr 1999.
- [25] S. Leowinata, B. Hudgins, and P. A. Parker. A multi function myoelectric control strategy using an array of electrodes. In *19th Annual Congress of the international Society Electrophysiology and Kinesiology*, 1998.
- [26] M. S. Lewicki and T. J. Sejnowski. Learning overcomplete representations. *Neural Comput*, 12(2) :337–365, February 2000.
- [27] R. Merletti, A. Botter, A. Troiano, E. Merlo, and M. A. Minetto. Technology and instrumentation for detection and conditioning of the surface electromyographic signal : State of the art. *Journal of Clinical biomechanics*, 24(2), 2009.
- [28] R. Merletti, A. Holobar, and D. Farina. Analysis of motor units with high-density surface electromyography. *Journal of Electromyography and Kinesiology*, 18(6) :879–890, Dec 2008.
- [29] R. Merletti and P.A. Parker. *Electromyography : Physiology, engineering, and noninvasive applications*. John Wiley & Sons : Hoboken, New Jersey, 2004.
- [30] A. Merlo, D. Farina, and R. Merletti. A fast and reliable technique for muscle activity detection from surface EMG signals. *Biomedical Engineering, IEEE Transactions on*, 50(3) :316–323, March 2003.
- [31] S. Mitra and T. Acharya. Gesture recognition : A survey. *Systems, Man, and Cybernetics, Part C : Applications and Reviews, IEEE Transactions on*, 37(3) :311–324, May 2007.
- [32] G. R. Naik, H. Weghorn, D. K. Kumar, V. P. Singh, and M. Palaniswami. Real-time hand gesture identification for human computer interaction based on ICA of surface electromyogram. In *IADIS International Conference Interfaces and Human Computer Interaction*, 2007.
- [33] Ganesh R. Naik, Dinesh K. Kumar, and Sridhar P. Arjunan. Multi modal gesture identification for HCI using surface EMG. In *MindTrek ’08 : Proceedings of the 12th international conference on Entertainment and media in the ubiquitous era*, pages 90–94, 2008.
- [34] Ganesh R. Naik, Dinesh K. Kumar, Sridhar P. Arjunan, Hans Weghorn, and Marimuthu Palaniswami. Limitations and applications of ICA in facial sEMG and hand gesture sEMG for human computer interaction. *Digital Image Computing Techniques and Applications, 9th Biennial Conference of the Australian Pattern Recognition Society on*, pages 15–22, Dec. 2007.
- [35] Ganesh R. Naik, Dinesh K. Kumar, and Marimuthu Palaniswami. Surface EMG based hand gesture identification using semi blind ICA : Validation of ICA matrix analysis. *Electromyography and clinical neurophysiology*, 48(3-4) :169–180, 2008.
- [36] G.R. Naik, D.K. Kumar, and H. Weghorn. Ica based identification of sources in sEMG. *Intelligent Sensors, Sensor Networks and Information, 2007. ISSNIP 2007. 3rd International Conference on*, pages 619–624, Dec. 2007.
- [37] G.R. Naik, D.K. Kumar, and H. Weghorn. Performance comparison of ICA algorithms for isometric hand gesture identification using surface EMG. *Intelligent Sensors, Sensor Networks and Information, 2007. ISSNIP 2007. 3rd International Conference on*, pages 613–618, Dec. 2007.
- [38] K. Nazarpour, A. R. Sharafat, and S. P. M. Firoozabadi. Application of higher order statistics to surface electromyogram signal classification. *IEEE Transactions on Biomedical Engineering*, 54(10) :1762–1769, October 2007.
- [39] M.A. Oskoei and H. Hu. Myoelectric control systems - a survey. *Biomedical Signal Processing and Control*, 2(4) :275–294, Oct. 2007.
- [40] Z. P. Tichavský, P. Tichavský, and E. Oja. Asymptotic Performance Analysis of the Fixed-Point Algorithm (Fast-ICA) for Independent Component Analysis. In *SSP*, 2005.
- [41] M. B. Raez, M. S. Hussain, and Mohd F. Yasin. Techniques of EMG signal analysis : detection, processing, classification and applications. *Biological procedures online*, 8 :11–35, 2006.
- [42] T Scott Saponas, Desney S. Tan, Dan Morris, and Ravin Balakrishnan. Demonstrating the feasibility of using forearm electromyography for muscle-computer interfaces. In *CHI ’08 : Proceeding of the twenty-sixth annual SIGCHI conference on Human factors in computing systems*, pages 515–524, 2008.

- [43] MH Schieber. Muscular production of individuated finger movements : the roles of extrinsic finger muscles. *J. Neurosci.*, 15(1) :284–297, 1995.
- [44] P. Tichavský, Z. Koldovský, and E. Oja. Efficient variant of algorithm FastICA for independent component analysis attaining the Cramer-Rao lower bound. *IEEE Trans. on Neural Networks*, 17(5) :1265–1277, Sept. 2006.
- [45] G. Tsenov, A. H. Zeghib, F. Palis, N. Shoylev, and V. Mladenov. Neural networks for online classification of hand and finger movements using surface emg signals. In *Neural Network Applications in Electrical Engineering, 2006. NEUREL 2006. 8th Seminar on*, pages 167–171, 2006.
- [46] N. Uchida, A. Hiraiwa, N. Sonehara, and K. Shimohara. EMG pattern recognition by neural networks of multi fingers control. In *Proc. Ann. Int. Conf. IEEE Eng. Med. Biol. Soc.*, volume 3, pages 1016–1018, 1992.
- [47] Data mining software in java. <http://www.cs.waikato.ac.nz/ml/weka>.
- [48] K.R. Wheeler, M.H. Chang, and K.H. Knuth. Gesture-based control and EMG decomposition. *Systems, Man, and Cybernetics, Part C : Applications and Reviews, IEEE Transactions on*, 36(4) :503–514, July 2006.
- [49] K.R. Wheeler and C.C. Jorgensen. Gestures as input : neuroelectric joysticks and keyboards. *Pervasive Computing, IEEE*, 2(2) :56–61, April-June 2003.
- [50] Xu Zhang, Xiang Chen, Wen-hui Wang, Ji-hai Yang, Vuokko Lantz, and Kong-qiao Wang. Hand gesture recognition and virtual game control based on 3D accelerometer and EMG sensors. In *IUI '09 : Proceedings of the 13th international conference on Intelligent user interfaces*, pages 401–406, 2008. alamaison.

Annexe A

Algorithm 1 Algorithme d'extraction de caractéristiques à partir du résultat d'une séparation aveugle de sources

```
A = A * diag(sign(sum(minmax(A'), 2)')); — s'assurer que le maximum de chaque colonne est positif
B ← []; — la matrice aux colonnes ordonnée
C ← []; — une matrice temporaire
iB ← []; — la liste des places pourvues dans B
[mA, iL] = max(A); — trouver les maximums de chaque colonnes et leur emplacement(=ligne) dans la
colonne
for i = 1...n do
    iC1 = find(iL == i); — trouver les colonnes qui ont leur maximum à la ligne i
    if length(iC1) > 0 — s'il en existe then
        [tmp, iC2] = sort(mA(iC1), 'descend'); — les trier par ordre décroissant de maximum de colonnes
        iC = iC1(iC2);
        B(:, i) = A(:, iC(1)); — placer celle au plus grand maximum à la place i de B
        iB = [iB, i]; — noter que i est une place pourvue dans B
        C = [C, A(:, iC(2 : length(iC)))]); — placer les autres à la suite de C, toujours en ordre décroissant
    end if
end for
iiB = setdiff(1 : n, iB); — noter les places qui ne sont pas encore pourvues dans B
B(:, iiB) = C; — y placer les colonnes de B
X = B(:); — X est le vecteur de caractéristiques
```

AnnexeB

Algorithm 2 Algorithme de localisation de la source

```
 $X_{obs}^{rms} = rms(X_{obs});$   
choisir le meilleur triplet initial  $\{k, x, y\}$  parmi 16 ( $k = 0.01$  et position sur un cercle de rayon  $r/2$ )  
 $e = coût(X_{obs}, k, x, y);$   
 $i = 0$   
 $arret = 0$   
while  $arret = 0$  do  
   $i = i + 1;$   
   $adapt = 1;$   
   $[e_{,k}, e_{,x}, e_{,y}] = gradient(X_{obs}, k, x, y);$   
   $i' = 0;$   
  while  $arret' = 0$  do  
     $i' = i' + 1;$   
    if  $e_{,k} \neq 0$  then  
       $k' = k - adapt \cdot e/e_{,k};$   
    end if  
    if  $e_{,x} \neq 0$  then  
       $x' = x - adapt \cdot e/e_{,x};$   
    end if  
    if  $e_{,y} \neq 0$  then  
       $y' = y - adapt \cdot e/e_{,y};$   
    end if  
     $tmp = \sqrt{x'^2 + y'^2}/r$   
    if  $tmp > 1$  then  
       $x' = x'/(1.1 \cdot tmp);$   
       $y' = y'/(1.1 \cdot tmp);$   
    end if  
     $e' = coût(X_{obs}, k', x', y');$   
    if  $e' < e$  then  
       $de = e - e';$   
       $e = e';$   
       $k = k';$   
       $x = x';$   
       $y = y';$   
       $arret' = 1;$   
    else  
       $adapt = 0.7 \cdot adapt;$   
    end if  
  end while  
   $arret = 100e/X_{obs}^{rms} < 0.1$  ou  $de/X_{obs}^{rms} < 10^{-8}$  ou  $i > 200$  ou  $arret' = 0;$   
end while
```
