

Classification de muscles profonds de la sangle abdominale à partir d'EMG de surface

Ines MOUDJARI^{1,2}, Caroline PAUTARD¹, Clément JOUANNEAU¹, Régine LE BOUQUIN JEANNES²

¹Blueback, 1137A Av. des Champs Blancs, 35510 Cesson-Sévigné, France

² Univ Rennes, Inserm, LTSI - UMR 1099, F-35000 Rennes, France

imoudjari@blueback.fr, cpautard@blueback.fr, cjouanneau@blueback.fr,
regine.le-bouquin-jeannes@univ-rennes1.fr

Résumé – L'électromyographie est une technique de mesure qui permet d'acquérir des signaux électriques produits par les muscles. Dans ce papier, nous proposons une méthode de classification supervisée permettant de distinguer le nombre de muscles contractés à partir de deux paires d'électrodes de surface. L'application présentée se base sur des signaux de la sangle abdominale, plus précisément des signaux contenant un mélange d'informations provenant de l'oblique interne et du muscle transverse abdominal. Les positions de ces deux muscles dans la sangle abdominale font qu'ils sont qualifiés de muscles profonds. Nos travaux visent à fournir une méthode permettant de connaître les synergies musculaires, afin de faciliter la pratique des kinésithérapeutes et d'améliorer la prise en charge des patients. La méthode de classification présentée ici est une machine à vecteurs de support à noyau linéaire, afin de répondre à un problème de discrimination à deux classes. Deux réalisations de cet algorithme sont proposées dans ce papier, conduisant à des valeurs de précision atteignant 96.6%, suite à une validation croisée sur 30 signaux réels.

Abstract – Electromyography is a measurement technique that acquires electrical signals produced by muscles. In this paper, we propose a supervised classification method to distinguish the number of contracted muscles from two pairs of surface electrodes. The application presented is based on signals from the abdominal wall, more precisely signals containing a mixture of information from the obliquus internus and the transversus abdominis muscle. The position of these muscles in the abdominal wall qualifies them as deep muscles. Our work consists in providing a solution to identify muscle synergies, in order to facilitate the practice of physiotherapists and to improve patient care. The classification method presented here is a support vector machine, in order to address a two-class discrimination problem. Two implementations of this algorithm are presented in this paper, leading to an accuracy rate up to 96.6%, following a cross validation on 30 real signals.

1 Introduction

Ces dernières décennies, l'étude des muscles de la sangle abdominale est devenue un sujet prédominant dans la compréhension de certaines pathologies observées en kinésithérapie et notamment celle du muscle transverse abdominal, qui, de par sa fonction et sa constitution, participe entre autres au maintien de la colonne vertébrale, à la respiration et à l'accouchement. Toutefois, il est complexe d'acquérir de l'information sur ce muscle, au vu de sa position en profondeur dans la sangle abdominale. En pratique clinique, l'information sur la contraction du muscle transverse est acquise par palpation. La spécificité de cette méthode est très dépendante de l'investigateur. En recherche, cette information est acquise soit par électromyographie intramusculaire soit par échographie. Ces deux méthodes nécessitent l'immobilité du sujet durant l'acquisition des mesures et ne peuvent donc pas être utilisées en pratique clinique. Toutefois, certaines équipes de recherche ont utilisé l'électromyographie de surface pour obtenir le signal du muscle transverse abdominal [2]. Cependant, il faut noter que ce signal est pollué par le signal du muscle oblique interne, qui se superpose au muscle transverse dans la sangle abdominale. D'autre part, ces dernières années ont

également connu l'essor de méthodes de classification supervisée, utilisées pour traiter des signaux électromyographiques (EMG). En effet, diverses méthodes telles que l'algorithme des k plus proches voisins (KNN), les machines à vecteurs de support (SVM) ou encore les réseaux de neurones convolutifs, ont été utilisées pour répondre à des problèmes de détection de maladies neuro-dégénératives [4] ou de classification de mouvements de la main [5, 3]. Toutes ces méthodes se basent sur l'acquisition de signaux EMG provenant de muscles de surface, à partir d'au moins deux électrodes. La méthode présentée dans ce papier cherche à répondre à un besoin clinique qui est de différencier la contraction du muscle transverse abdominal de celle de l'oblique interne, à l'aide de deux paires d'électrodes d'électromyographie de surface, le nombre d'électrodes étant délibérément réduit pour faciliter la pratique clinique. Dans ce but, nous avons mis en œuvre un algorithme de classification basé sur une méthode d'apprentissage supervisée. Ce type d'algorithme nécessite de labelliser chacun des signaux utilisés, ainsi que de construire une base d'apprentissage, constituée de caractéristiques extraites des signaux. Ce papier est structuré de la manière suivante : la section 2 présente la méthode développée, la section 3 illustre les résultats obtenus et la section 4 vient conclure ce travail et ouvrir sur des perspectives.

2 Matériels et Méthodes

2.1 Acquisition EMG et prétraitement

Les signaux acquis pour cette expérimentation sont des signaux réels provenant de trois participants sains et volontaires (2 hommes et 1 femme) qui ont effectué 9 exercices en décubitus dorsal et 7 exercices debout. Les exercices effectués sont des exercices de respiration, de flexion du tronc et de mouvement des membres. Un EMG portable (Blueback Physio® développé par la société Blueback) composé de deux paires d'électrodes bipolaires a été utilisé pour récupérer les signaux dits cibles dans cette analyse, positionnées suivant le repère anatomique des épines iliaques antéro-supérieures. Une échographie a permis de récupérer la vérité-terrain sur la contraction des muscles transverse abdominal et oblique interne, en fonction de leurs épaisseurs mesurées sur les images extraites des vidéos toutes les secondes. Le prétraitement des signaux se divise en trois étapes. La première consiste à ré-échantillonner les signaux initialement acquis à 500 Hz afin d'obtenir une fréquence d'échantillonnage de 1000 Hz. La deuxième étape se résume à filtrer les signaux avec un filtre passe-haut à réponse impulsionnelle finie possédant une fréquence de coupure à 30 Hz et 151 coefficients, afin de réduire le bruit. Enfin les signaux sont redressés en prenant la valeur absolue du signal temporel.

2.2 Indicateurs

Afin de créer une base initiale de caractéristiques exhaustive pour la classification des signaux, 23 indicateurs (dont 14 temporels, 3 fréquentiels et 6 temps-fréquence) ont été calculés sur les signaux EMG acquis. Une combinaison de tout ou partie de cette base a été utilisée en tant que base d'apprentissage de l'algorithme. Le choix des indicateurs retenus provient d'une recherche bibliographique sur l'existant dans le domaine de la classification EMG mais aussi dans d'autres domaines.

Pour chacun des indicateurs suivants faisons l'hypothèse que nous avons deux signaux x et y (correspondant aux signaux recueillis sur les deux électrodes à la fréquence d'échantillonnage f_e), chacun de durée N (entre 5s et 30s). Le périodogramme et la fréquence sont notés respectivement P et f .

2.2.1 Indicateurs temporels

Le premier indicateur correspond à la durée (exprimée en seconde) d'un burst de contraction (WL) obtenu à l'aide de l'équation suivante : $WL = t_1 - t_2$, avec t_1 le temps où la contraction musculaire commence, *i.e.* lorsque l'amplitude dépasse un seuil fixé au quart de la valeur maximale de la valeur absolue de l'amplitude et t_2 celui où elle se termine, *i.e.* lorsque l'amplitude descend en dessous de ce seuil. Le second indicateur représente la moyenne des amplitudes du signal temporel (MAV) [5]. Le troisième indicateur, dénommé Complexité, est issu des paramètres de Hjorth et permet de comparer le signal à une onde sinusoïdale :

$$Complexité = \frac{\frac{\sigma^2(x'')}{\sigma^2(x')}}{\frac{\sigma^2(x')}{\sigma^2(x)}} \quad (1)$$

avec x' la dérivée première de x , x'' sa dérivée seconde et σ^2 représente la variance du signal. Les indicateurs 4 à 7 sont des

estimateurs d'entropies classiques tels que l'entropie d'échantillon (SampEn) [5], l'entropie approximative (ApEn), l'entropie multi-échelle (MEn) et l'entropie de Shannon (SEn). La corrélation entre les deux voies de mesure a également été calculée (corr) :

$$corr = \frac{\sum_{k=1}^N [(x(k) - \bar{x}) \times (y(k) - \bar{y})]}{\sqrt{\sum_{k=1}^N (x(k) - \bar{x})^2} \times \sqrt{\sum_{k=1}^N (y(k) - \bar{y})^2}} \quad (2)$$

avec \bar{x} et \bar{y} les moyennes statistiques de x et y respectivement. Des indicateurs statistiques, tels que la moyenne, la médiane et la moyenne quadratique ont été extraits à partir des coefficients cepstraux (Cc) du signal :

$$Cc_k = \sum_{i=1}^M \log(E_i) \times \cos\left[\frac{\pi k}{M} \times (i - 0.5)\right] \quad (3)$$

avec $k = 1, \dots, d \leq M$, M étant le nombre de filtres composant le banc de filtres de Mel et E_i l'énergie du signal en sortie du banc de filtres de Mel.

2.2.2 Indicateurs fréquentiels

Les fréquences moyennes (fm) et médianes (fmd) sont calculées sur des périodogrammes obtenus avec la méthode de Welch (fenêtre rectangulaire de 256 points, un recouvrement de 50%, et un nombre de points en fréquence de N) [6]. De même nous avons calculé un indicateur représentant une fréquence f_p qui a été déterminée par la quantification de la puissance du spectre du signal par rapport à un seuil fixé (A), obtenu suite à une étude visuelle et différents tests :

$$\frac{\sum_{i=0}^{f_p} P(f_i)}{\sum_{i=0}^{f_e/2} P(f_i)} \times 100 > A \quad (4)$$

2.2.3 Indicateurs temps-fréquence

L'objectif de la décomposition en modes empiriques (EMD) est de décomposer un signal en mono-composantes appelées fonctions de mode intrinsèque (IMF). Une IMF est une fonction oscillante de moyenne nulle. Une EMD a été appliquée sur les signaux, selon la méthode présentée dans [1]. Les indicateurs extraits de cette EMD sont les fréquences médianes des 3 premières IMF. De plus, une transformée en ondelettes a été calculée sur chacun des signaux [3]. Trois indicateurs ont été extraits de cette représentation, à savoir le maximum d'amplitude (m) ainsi que la fréquence (f) et le temps (t) où ce maximum m a lieu.

2.3 Classifieurs

L'algorithme de classification utilisé dans cette étude est une machine à vecteurs de support (SVM) à noyau linéaire. Le principe de ce type d'algorithme est de projeter le vecteur de caractéristiques dans un espace de plus grande dimension afin de rendre les classes plus séparables. La fonction de décision pour un problème de classification binaire et linéaire peut être modélisée par un hyperplan. Nous avons choisi de ne présenter qu'un seul type de classifieur, l'idée étant ici de concevoir une preuve de concept. Nous avons toutefois étudié les avantages et les inconvénients de plusieurs techniques de classification. Le SVM à noyau linéaire est simple d'implémentation et moins coûteux en temps de calcul que des SVM utilisant d'autres noyaux ou encore que l'algorithme KNN.

3 Résultats

Trente signaux ont été utilisés dans les expérimentations suivantes, afin d’obtenir une base d’apprentissage homogène, soit quinze signaux par classe.

3.1 Critères de performance

La classification réalisée dans ce papier est linéaire et binaire. La classe 1 correspond à la contraction soit de l’oblique interne soit du muscle transverse et la classe 2 correspond à la contraction des deux muscles. L’étude des performances de l’algorithme de classification s’est faite par validation croisée de type k -fold avec 5 sous-ensembles homogènes, afin de compenser la taille de notre base d’apprentissage. Suite à cela, nous avons construit une matrice de confusion. Différents indices de performances ont été calculés à partir de cette matrice de confusion, tels que la sensibilité, la spécificité, la précision et l’indice ROC (Receiver Operating Characteristic). La sensibilité et la spécificité correspondent respectivement aux taux de vrais positifs et de vrais négatifs. La qualité d’un modèle dépend du compromis entre ces deux quantités et s’apprécie grâce à l’indice ROC. La précision correspond au rapport entre le nombre d’individus bien classés et le nombre total d’individus.

3.2 Classification EMG

Dans cette section, deux réalisations de notre algorithme sont présentées. La base d’apprentissage de la première réalisation est constituée de 7 variables présentées en section 2.2, tandis que celle de la deuxième réalisation consiste en une réduction de la première base. Cette démarche a été adoptée afin d’estimer la possibilité de réduire notre modèle initial en fonction des pertes de performance. Toutes les réductions de dimensions de base ont été effectuées à l’aide d’un algorithme de la société Blueback.

3.2.1 Résultats sur la Base 1

Le choix des indicateurs utilisés dans cette réalisation s’est effectué en deux étapes. La première a consisté en l’étude visuelle des répartitions des classes en fonction de chaque indicateur, suivie d’un test de Wilcoxon afin de vérifier le pouvoir discriminant des indicateurs de façon individuelle. Une combinaison optimale des variables a conduit à conserver les indicateurs suivants : la moyenne du premier coefficient cepstral, la complexité, les fréquences médianes des deux premières IMFs, l’entropie approximative, l’entropie multi-échelle et l’entropie de Shannon.




FIGURE 1 – Projection des individus dans l’espace de décision du classifieur 1

La Figure 1 représente la projection des individus et de leur vraie classe dans l’espace de décision du classifieur. On peut également y voir les individus moyens en vert (\bar{c}_1 et \bar{c}_2) et un individu mal classé (x_1) caractérisé par un cercle noir. Cette figure montre une distinction nette entre les deux classes. Après analyse, il s’avère que l’individu mal classé correspond à un signal acquis sur le côté droit de l’un des sujets, sachant que l’échographie (référence) a été réalisée à gauche et que le sujet a levé le bras droit durant la manipulation. Il est donc possible que son muscle oblique interne droit ait été contracté sans que l’expert n’ait pu le signaler.

TABLE 1 – Matrice de confusion avec la Base 1

		Prédiction	
		1	2
Vérité	1	14	1
	2	0	15

Les indicateurs de performances obtenus donnent de bons résultats pour cette réalisation. En effet, nous obtenons ici une précision de 96.67%, une sensibilité de 93%, une spécificité de 100%, ainsi qu’un indice ROC de 0.07. Ce dernier indice est très proche de zéro, ce qui signifie que ce classifieur conduit à un très bon compromis entre sensibilité et spécificité et qu’il est capable de reconnaître les individus appartenant à chacune des classes étudiées.

3.2.2 Résultats sur la Base 2

Après réduction de la Base 1, nous avons retenu une base à 4 variables composée de la moyenne du premier coefficient cepstral, de la complexité, de la fréquence médiane de la première IMF et de l’entropie de Shannon.




FIGURE 2 – Projection des individus dans l’espace de décision du classifieur 2

La Figure 2 montre une dissociation nette entre les deux classes. Trois individus sont mal classés (x_1 , x_2 et x_3). L’un des individus mal classés, noté x_1 , est le même que celui de la réalisation précédente. Nous pouvons expliquer ces erreurs de classification en regardant les individus moyens par classe (\bar{c}_1 et \bar{c}_2). On peut voir, sur la Figure 2, que les individus x_1 et x_3 sont plus proches de \bar{c}_2 , alors que l’individu x_2 est plus proche de \bar{c}_1 . Lors de l’acquisition des données, nous n’avons qu’une seule échographie à disposition, qui a été utilisée pour récupérer la vérité sur les muscles de gauche. Nous avons donc dû émettre des règles de classification pour les muscles contralatéraux à l’échographie. La première règle impose la contraction bilatérale du muscle transverse abdominal. La deuxième concerne la contraction des obliques internes, qui est unilatérale s’il y a une torsion du tronc et bilatérale autrement. Les trois indivi-

musculaires. Les travaux de Mishra *et al.* [1] et de Tepe *et al.* [6] ont quant à eux rapporté respectivement des précisions de 99.16% et 99.23%, pour des SVM qui identifient, pour le premier, la présence de sclérose latérale amyotrophique et, pour le second, des mouvements de la main. Si ces résultats s'avèrent supérieurs aux nôtres, il faut garder à l'esprit que leurs expérimentations portent sur l'analyse de muscles de surface. Nous sommes également conscients des limites actuelles de notre étude : le nombre de signaux utilisés pour valider notre approche est faible, tout comme le nombre de sujets. De plus, le type de sujet ayant participé aux tests est peu diversifié, que ce soit en termes d'âge ou de conditions physiques. Toutefois, cette étude préliminaire a permis de mettre en évidence la possibilité d'utiliser l'EMG de surface pour comptabiliser le nombre de muscles profonds contractés au même moment. Il serait intéressant pour la suite d'acquies plus de données, ainsi que de faire effectuer aux sujets d'autres exercices. De plus l'acquisition de données provenant de sujets pathologiques peut également être intéressante car le fonctionnement des muscles et les schémas de co-contractions musculaires diffèrent chez ces patients. Afin d'éviter toute confusion dans la classification expert, nous comptons rajouter une deuxième échographie lors d'une prochaine acquisition. L'essai de différents algorithmes d'apprentissage est également envisagé. Finalement, ce type d'algorithme pourrait améliorer la prise en charge thérapeutique dans le cadre de rééducation pour certaines pathologies, en permettant de travailler les muscles de manière isolée.

TABLE 2 – Matrice de confusion avec la Base 2

		Prédiction	
		1	2
Vérité	1	13	2
	2	1	14

Cette configuration a conduit à une valeur de précision de 90%, une sensibilité de 87%, une spécificité de 98%, ainsi qu'un indice ROC de 0.13. Notons que ces valeurs sont légèrement inférieures à celles obtenues pour la première réalisation. En effet, il existe une différence de 0.06 entre les deux indicateurs ROC, ce qui montre que la sensibilité et la spécificité du classifieur mis au point dans cette réalisation sont légèrement inférieures à celles de la première réalisation. De même, nous remarquons une diminution de 6% de la précision entre les deux réalisations. Toutefois ces baisses de performance doivent être nuancées par la réduction de la base d'apprentissage, passant de 7 à 4 variables, ainsi que par le faible nombre d'individus prédits.

4 Conclusion

Ce travail cherche à explorer l'information contenue dans un signal EMG. Les signaux acquis ont été classés en deux classes par un algorithme de classification supervisée de type SVM linéaire. Les résultats obtenus au cours de cette étude (précision de 96.67% et 90%) sont très acceptables. Nous pouvons notamment comparer nos résultats à ceux de Gozzia *et al.* [5], qui rapportent une précision de 91.72% pour classifier des mouvements de la main à partir de signaux EMG de surface ou encore ceux d' Ai *et al.* [4], qui affichent une précision entre 94% et 98% pour un SVM qui détecte la présence de la maladie de Parkinson à partir de signaux de tremblements

musculaires. Les travaux de Mishra *et al.* [1] et de Tepe *et al.* [6] ont quant à eux rapporté respectivement des précisions de 99.16% et 99.23%, pour des SVM qui identifient, pour le premier, la présence de sclérose latérale amyotrophique et, pour le second, des mouvements de la main. Si ces résultats s'avèrent supérieurs aux nôtres, il faut garder à l'esprit que leurs expérimentations portent sur l'analyse de muscles de surface. Nous sommes également conscients des limites actuelles de notre étude : le nombre de signaux utilisés pour valider notre approche est faible, tout comme le nombre de sujets. De plus, le type de sujet ayant participé aux tests est peu diversifié, que ce soit en termes d'âge ou de conditions physiques. Toutefois, cette étude préliminaire a permis de mettre en évidence la possibilité d'utiliser l'EMG de surface pour comptabiliser le nombre de muscles profonds contractés au même moment. Il serait intéressant pour la suite d'acquies plus de données, ainsi que de faire effectuer aux sujets d'autres exercices. De plus l'acquisition de données provenant de sujets pathologiques peut également être intéressante car le fonctionnement des muscles et les schémas de co-contractions musculaires diffèrent chez ces patients. Afin d'éviter toute confusion dans la classification expert, nous comptons rajouter une deuxième échographie lors d'une prochaine acquisition. L'essai de différents algorithmes d'apprentissage est également envisagé. Finalement, ce type d'algorithme pourrait améliorer la prise en charge thérapeutique dans le cadre de rééducation pour certaines pathologies, en permettant de travailler les muscles de manière isolée.

Références

- [1] V.K. Mishra, V. Bajaj, A. Kumar, D. Sharma, G.K. Singh, "An efficient method for analysis of EMG signals using improved empirical mode decomposition", *International Journal of Electronics and Communications*, vol. 72, pp. 200-209, 2016.
- [2] P. Waongenngarm, B.S. Rajaratnam, P. Janwantanakul, "Internal Oblique and Transversus Abdominis Muscle Fatigue Induced by Slumped Sitting Posture after 1 Hour of Sitting in Office Workers", *Safety and Health at Work*, vol. 7, pp. 49-54, 2015.
- [3] J.M. Fajardo, O. Gomez, F. Prieto, "EMG hand gesture classification using handcrafted and deep features", *Biomedical Signal Processing and Control*, vol. 63, art.102210, 2020.
- [4] L. Ai, J. Wang, R. Yao, "Classification of parkinsonian and essential tremor using empirical mode decomposition and support vector machine", *Digital Signal Processing*, vol. 21, pp. 543-550, 2011.
- [5] N. Gozzia, L. Malandri, F. Mercurio, A. Pedrocchi, "XAI for myo-controlled prosthesis : Explaining EMG data for hand gesture classification", *Knowledge-Based Systems*, vol. 240, art.108053, 2022.
- [6] C. Tepe, M.C. Demir, "The effects of the number of channels and gyroscopic data on the classification performance in EMG data acquired by Myo armband", *Journal of Computational Science*, vol. 51, art.101348, 2021.