

Extraction de caractéristique améliorée pour les signaux sEMG par transformées temps-fréquence et réduction de dimension

Somar KARHEILY, Ali MOUKADEM, Jean-Baptiste COURBOT, Djaffar OULD ABDESLAM

IRIMAS UR 7499 - Université de Haute Alsace
Mulhouse, France
somar.karheily@uha.fr

Résumé – Dans cet article, nous nous intéressons à l'extraction de caractéristiques pour la classification des signaux électromyographiques de surface (sEMG). Pour cela, nous utilisons une version généralisée de la transformée en S discrète orthogonale (DOST), notée GDOST. Le vecteur ainsi produit subit une réduction de dimension selon la méthode MDS (multi-dimentional scaling) pour laquelle nous remplaçons la distance euclidienne par une distance invariante à la translation. Les résultats obtenus sont prometteurs, par comparaison avec l'utilisation de la DOST ou de MDS dans leurs versions classique. Ainsi, pour classer 17 mouvements, nous obtenons 97,56% de classifications correctes.

Abstract – This paper proposes a method based on a generalized version of the Discrete Orthonormal Stockwell Transform (GDOST) with Gaussian window to extract features from surface electromyography (sEMG) signals in order to identify hand's movements. The features space derived from the GDOST is then reduced by applying a modified Multi-Dimensional Scaling (MDS) method. The proposed modification on MDS consists in using a translation in kernel building instead of the direct distance calculation. The results are compared with another study applied on the same dataset where usual DOST and MDS are applied. We achieved significant improvements in classification accuracy, attaining 97.56% for 17 hand movements.

1 Introduction

La perte d'un membre, en affectant la capacité à effectuer des tâches journalières, a un fort impact sur la vie d'une personne. On estime qu'il y a actuellement environ 57 millions de personnes amputées dans le monde [7]. De nombreux travaux de recherche ont été menés afin de développer des prothèses qui remplacent certaines fonctions anatomiques, mais cela s'accompagne de nombreux défis, tels que la précision et l'augmentations des degrés de libertés.

Actuellement, la plupart des prothèses utilisent les signaux électro-myographiques de surface (sEMG) afin d'identifier le mouvement souhaité par le patient [10] Une des raisons sous-jacentes à cette large adoption des sEMG est qu'il s'agit de signaux non invasifs, et plutôt facile à mesurer. Typiquement, un signal SEMG a une amplitude variant de 50 μV à 10mV, avec une fréquence variant de 20 Hz à 500 Hz [8].

1.1 Travaux antérieurs

Comme les signaux sEMG sont non-stationnaires, utiliser une transformée temps-fréquences (TF) permet d'en préserver la variance dans le temps, ce qui peut s'avérer être un motif distinctif utile pour la classification.

Cela se confirme par l'avantage que prennent les TF sur l'utilisations de caractéristiques temporelles seules. Ainsi dans [13] plusieurs jeux de caractéristiques temporelles ont été combinées pour obtenir 85% de classes correctes avec un KNN sur une

base de données sur 17 mouvements. Nous avons pu montrer, dans une étude précédente et avec le même jeu de données [6], qu'utiliser la transformée de Fourier à court terme (STFT) ou la transformée en S (ST) permettait d'obtenir plus de 90% de bonnes classifications.

La STFT [14] détermine le spectre local d'un signal en appliquant la transformée de Fourier sur une fenêtre glissante. Elle a été utilisée, Avec une fenêtre gaussienne, la STFT a permis d'obtenir un taux de 92% de bonnes classifications, sur une base de 17 mouvements et en utilisant un classifieur par KNN ou par SVM [17]. D'autre part, la transformée en S (ST) améliore la STFT en permettant une largeur de fenêtre variable selon les fréquences. Pour la classification des signaux sEMG, la ST a permis d'obtenir 98,12% de bonnes classifications sur 6 mouvements différents [15].

La complexité calculatoire de l'obtention des TF rend leur utilisation difficilement envisageable sur des prothèse, pour lesquels le temps de réponse doit être suffisamment court. La DOST permet de répondre à ce problème : nous avons montré dans une précédente étude [6] qu'elle permet d'effectuer une classification 10 fois plus rapidement que la STFT ou la ST, au prix de performances légèrement amoindries (88,08% pour la DOST, au lieu de 90,05% et 90,96% pour la STFT et la ST respectivement).

Dans tous les cas, bien que les TF fournissent une représentation fine des signaux, elles vivent dans un espace de très grande dimension : pour permettre la classification, il faut recourir à des outils de réduction de dimension. Outre l'ACP que

l'on peut retrouver dans [3] (96% de bonnes classifications, 9 mouvements), la littérature récente montre que les méthodes non-linéaires de réduction de dimension sont plus efficaces. En atteste par exemple [11], dans lequel les *diffusion maps* (DM) améliorent les résultats de l'ACP lorsque relativement peu de données d'entraînement sont disponibles.

1.2 Cet article

Dans cet article, nous nous concentrons sur l'amélioration de la DOST d'une part, et de la réduction de dimension d'autre part, avec la méthode dite *multi-dimensional scaling* (MDS). L'objectif est de tirer profit de :

- la rapidité de la DOST
- le moindre besoin en données d'entraînement dans le cas d'une réduction de dimension non linéaire.

Nous avons pour cela :

- utilisé une version généralisée de la DOST (notée GDOST) pour laquelle nous utilisons une fenêtre gaussienne
- modifié le noyau de calcul de distances de la méthode MDS afin de le rendre invariant au décalage temporel.

Dans la suite de cet article, la section 2 détaille ces améliorations, et les résultats numériques sont présentés en section 3.

2 Méthodologie

Les signaux sEMG que nous considérons sont acquis sur m canaux. Après normalisation (les données sont centrées, réduites), chaque signal est ensuite séparé en plusieurs segments temporels de même taille. Ainsi une observation, sur une fenêtre temporelle, prend la forme $X = \{x_1, x_2, \dots, x_m\}$, avec $X \in \mathbb{R}^{m \times a}$ où a est le nombre d'échantillons par fenêtre.

2.1 Caractéristiques basées sur la DOST et la GDOST

La DOST est la version orthonormale de la ST, qui ne calcule que les coefficients non redondants avec une moindre complexité algorithmique [16]. Notons $f(t) \in L^2([0, 1])$ un signal à transformer. La DOST est construite avec une fonction de base $D_{p,\tau}$, donnée par [12]

$$D_{p,\tau}(t) = \frac{1}{\sqrt{\beta(p)}} \sum_{f=\nu(p)-\beta(p)/2}^{\nu(p)+\beta(p)/2-1} e^{2\pi i f t} e^{-2\pi i f \tau / \beta(p)}, \quad t \in \mathbb{R}, \quad (1)$$

dans laquelle p est l'indice de la bande fréquentielle utilisée, ν et β repèrent respectivement le centre et la largeur d'une bande fréquentielle, et τ est la localisation temporelle.

Les coefficients de la DOST en (p, τ) peuvent être ensuite calculés par

$$f_{p,\tau} = \langle f, D_{p,\tau} \rangle \quad (2)$$

Utiliser $D_{p,\tau}$ revient à utiliser la ST avec une fonction porte [16]. Pour généraliser la DOST à une fenêtre généralisable, il est pro-

posé dans [2] d'utiliser la base suivante pour la GDOST :

$$E_{p,\tau}^\varphi(t) = \frac{1}{\sqrt{\beta(p)}} \sum_{j=0}^{\beta(p)-1} [c_{p,j}^\varphi(\nu(p))]^{-1} e^{2\pi i (\beta(p)+j)(t - \frac{\tau}{\beta(p)})} \quad (3)$$

où les coefficients de la GDOST sont :

$$c_p^\varphi = \langle f, E_{p,\tau}^\varphi \rangle. \quad (4)$$

Dans cet article, nous utilisons une fenêtre gaussienne (comme utilisée dans la ST) avec σ fixé, soit $\varphi = g(t) = \frac{1}{\sigma\sqrt{2\pi}} \exp(-\frac{t^2}{2\sigma^2})$.

Dans la suite, on considère la GDOST d'une observation sous la forme $GDOST(X) = \{F_{x_1}, F_{x_2}, \dots, F_{x_m}\}$, avec $F_{x_i} \in \mathbb{R}^a$ la GDOST de x_i . L'observation d'un mouvement comportera donc $K = m \times a$ valeurs, ce qui permet de produire une matrice $F \in \mathbb{R}^{N \times K}$ des caractéristiques, avec N le nombre d'éléments dans la base de données.

2.2 Réduction de dimension : MDS et amélioration

La méthode MDS [4] remplace les caractéristiques liées aux données par un ensemble de mesure de similarité entre chaque observation. Ses principales étapes sont [4] :

- Calcul de la matrice de distance D . Soient deux mouvements x et y représentés par $\{F_{x_1}, F_{x_2}, \dots, F_{x_m}\}$ et $\{F_{y_1}, F_{y_2}, \dots, F_{y_m}\}$, alors la distance inter-observations est :

$$d_{xy} = \sum_{i=1}^m \|F_{x_i} - F_{y_i}\|_2 \quad (5)$$

- Calcul d'une matrice de similarité A de sorte à avoir, $\forall i, j \in \{1, \dots, N\} : a_{ij} = -\frac{1}{2} d_{ij}^2$
- Centrage des valeurs pour produire $B = HAH$ avec $H = I_N - \frac{1}{N} J_N$ la matrice de centrage et J_N la matrice de valeurs 1.
- Décomposition de $B = \mathcal{V}\Lambda\mathcal{V}^T$, où \mathcal{V} contient les vecteurs propres, et Λ les valeurs propres.
- Les caractéristiques en dimension réduite sont alors $Z = \mathcal{V}_q \Lambda_q^{\frac{1}{2}}$, où $q \ll K$ indique le nombre de composantes conservées.

Utiliser la distance euclidienne dans MDS rend cette méthode sensible au décalage temporel entre deux observations, produisant une distance élevée entre deux versions translatées d'un même signal. Comme la synchronisation de chaque observation n'est pas possible, il faut rendre le calcul de distance invariant aux décalages temporels.

Notons $\mathcal{T}^j F$ le décalage circulaire de distance $j \in \mathbb{Z}$ d'une séquence F . Alors la distance entre deux signaux x et y peut être calculée avec :

$$d_{xy} = \min_{j \in \{0, \dots, a-1\}} \sum_{i=1}^m \|(\mathcal{T}^j F_{x_i}) - F_{y_i}\|_2 \quad (6)$$

Nous proposons d'utiliser ce calcul de distance à la place de (5) pour produire la matrice de distances D , afin d'améliorer les performances de MDS.




FIGURE 1 – Étapes principales de l’algorithme de classification de mouvements.

2.3 Algorithme de classification

L’extraction de caractéristique que nous utilisons effectue successivement la séparation des signaux en fenêtre de taille fixe, les transformées temps-fréquence puis la réduction de dimension. Nous verrons dans la suite que cela rend les signaux suffisamment différents entre chaque classe pour utiliser une méthode simple, comme les kNN, pour la classification. La figure 1 illustre graphiquement les étapes de traitement.

3 Résultats numériques

3.1 Données et paramètres

Données. Nous utilisons la base publique du projet Nina-pro [1] qui fournit plusieurs types d’acquisitions, sur plusieurs sujets. Nous travaillons avec le premier exercice du deuxième jeu de données, qui contient les signaux sEMG bruts pour 17 mouvements de base (cf. Fig. 2). Les signaux sont enregistrés sur $m = 12$ électrodes à 2 kHz. Pour la séparation des signaux, nous prenons une fenêtre de 250 ms et un recouvrement de 125 ms.

Représentations temps-fréquence. Avec un échantillonnage à 2 kHz sur 250 ms, nous avons $a = 500$ échantillons sur chacun des $m = 12$ canaux, soit une observation à $K = 6000$ composantes. Comme la DOST d’un signal contient le même nombre d’échantillons, c’est bien un vecteur de 6000 valeurs qui doit subir une réduction de dimension.

Réduction de dimension. Nous utilisons le calcul de distance synchronisé (6) au sein de MDS. La Fig. 3 représente les transformées DOST pour une composante du signal, et le processus de synchronisation. Le nombre q de dimensions en espace réduit est fixé à $q = 191$ après une recherche du meilleur taux de classification correcte, en cherchant q dans $[10, 400]$.

Classification. Nous utilisons un algorithme des k plus proches voisins avec $k = 3$, et les résultats sont fournis par validation croisée en 5 passes.




FIGURE 2 – Illustration des 17 mouvements traités dans ce travail, d’après la base NinaPro [1].

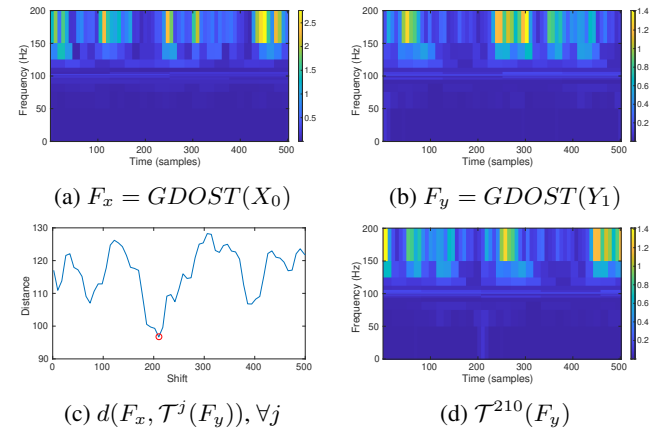


FIGURE 3 – Illustration du procédé de synchronisation entre deux signaux x et y . Dans (a) et (b) nous voyons leur transformée GDOST, arrangée dans le plan temps-fréquence. Dans (c), nous voyons toutes les distances possibles entre F_x et les versions translattées de F_y . (d) illustre le meilleur décalage trouvé, qui permet une comparaison pertinente F_x et $\mathcal{T}^{210}(F_y)$ dans l’algorithme MDS.

3.2 Résultats

Nous avons appliqué la méthode proposée (Fig. 1) sur 5 sujets différents, et atteint une performance moyenne de 97.56%. Nous avons choisi les mêmes sujets que dans une précédente étude, avec la même méthode de classification, afin de faire une comparaison pertinente. Dans ces mêmes conditions, nous avons trouvé comme meilleur résultat un taux de 90.96%, en combinant la ST avec une ACP. Quant à la combinaison DOST/MDS, bien que plus rapide, elle permettait d’atteindre un taux moyen de 87.13%. Nous avons donc une amélioration nette des résultats, apportée par l’utilisation conjointe de la GDOST et de MDS synchronisé. Cette différence provient essentiellement de la synchronisation dans MDS, car une combinaison DOST/MDS amélioré donne déjà 96.73% de bons résultats. Le tableau 1 résume les résultats, ainsi que ceux obtenus dans la littérature sur le même jeu de données.

4 Conclusion

Dans le cadre de la classification des signaux sEMG, nous avons montré qu’il était possible d’améliorer la DOST pour l’extraction de caractéristiques temps-fréquence, ainsi que de la méthode MDS pour la réduction de dimension. Ce résultat est important, car il permet d’envisager des calculs temps-fréquence rapides dans ce contexte, et car les méthodes de réduction de dimension non-linéaires semblent plus efficaces sur de petits ensembles d’entraînement et pour des applications inter-sujets [11]. Ces deux points sont donc une avancée vers l’utilisation pratique de ces méthodes.

Dans de futurs travaux, nous envisageons d’optimiser les paramètres de la GDOST en se basant sur un critère équivalent à la concentration en énergie dans le plan temps fréquence [9],

Méthode	Performance	Références
Caractéristiques temporelles, kNN	85%	Robinson <i>et al.</i> , 2017 [13]
Caractéristiques temporelles et fréquentielles, PANN ¹	76% ± 9.1%	Favieiro, 2016 [5]
STFT, SVM ² , kNN	92%	Too <i>et al.</i> , 2019 [17]
ST, ACP	90.96%	Karheily <i>et al.</i> , 2022 [6]
DOST, MDS	87.13%	
DOST, MDS amélioré	96.73%	Cet article
GDOST, MDS amélioré	97.56%	

¹PANN : Para-consistent artificial neural network et ² SVM : support vector machines

TABLEAU 1 – Résumé des performances obtenues, sous la forme de taux moyens de classifications correctes, sur la base de données Ninapro [1], *i.e.* avec 17 mouvements différents à classer.

ce qui pourrait encore améliorer les résultats.

Références

- [1] M. Atzori et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific data*, 1(1) :1–13, 2014.
- [2] U. Battisti and L. Riba. Window-dependent bases for efficient representations of the stockwell transform. *Applied and Computational Harmonic Analysis*, 40(2) :292–320, 2016.
- [3] J.-U. Chu, I. Moon, and M.-S. Mun. A real-time emg pattern recognition system based on linear-nonlinear feature projection for a multifunction myoelectric hand. *IEEE Transactions on biomedical engineering*, 53(11) :2232–2239, 2006.
- [4] M.A.A. Cox and T.F. Cox. Multidimensional scaling. In *Handbook of data visualization*, pages 315–347. Springer, 2008.
- [5] G.W. Favieiro, K. Moura, and A. Balbinot. Novel method to characterize upper-limb movements based on paraconsistent logic and myoelectric signals. In *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 395–398. IEEE, 2016.
- [6] S. Karheily, A. Moukadem, J.-B. Courbot, and D.O. Abdeslam. semg time-frequency features for hand movements classification. 2022. preprint HAL : hal.archives-ouvertes.fr/hal-03223176.
- [7] C. L. McDonald, S. Westcott-McCoy, Marcia R. Weaver, J. Haagsma, and D. Kartin. Global prevalence of traumatic non-fatal limb amputation. *Prosthetics and orthotics international*, page 0309364620972258, 2021.
- [8] N. Meselmani, M. Khrayzat, K. Chahine, M. Ghantous, and M. Hajj-Hassan. Pattern recognition of emg signals : Towards adaptive control of robotic arms. In *2016 IEEE International Multidisciplinary Conference on Engineering Technology (IMCET)*, pages 52–57. IEEE, 2016.
- [9] A. Moukadem, Z. Bouguila, D.O. Abdeslam, and A. Dieterlen. A new optimized stockwell transform applied on synthetic and real non-stationary signals. *Digital Signal Processing*, 46 :226–238, 2015.
- [10] N. Parajuli, N. Sreenivasan, P. Bifulco, M. Cesarelli, S. Savino, V. Niola, D. Esposito, T. J. Hamilton, G. R. Naik, U. Gunawardana, et al. Real-time emg based pattern recognition control for hand prostheses : A review on existing methods, challenges and future implementation. *Sensors*, 19(20) :4596, 2019.
- [11] N. Rabin, M. Kahlon, S. Malayev, and A. Ratnovsky. Classification of human hand movements based on emg signals using nonlinear dimensionality reduction and data fusion techniques. *Expert Systems with Applications*, 149 :113281, 2020.
- [12] M. J. B. Reddy, R.K. Raghupathy, K.P. Venkatesh, and D.K. Mohanta. Power quality analysis using discrete orthogonal s-transform (dost). *Digital Signal Processing*, 23(2) :616–626, 2013.
- [13] C.P. Robinson, B. Li, Q. Meng, and M. Pain. Pattern classification of hand movements using time domain features of electromyography. In *Proceedings of the 4th International Conference on Movement Computing*, pages 1–6, 2017.
- [14] E. Sejdíć, I. Djurović, and J. Jiang. Time–frequency feature representation using energy concentration : An overview of recent advances. *Digital signal processing*, 19(1) :153–183, 2009.
- [15] H. She, J. Zhu, Y. Tian, Y. Wang, H. Yokoi, and Q. Huang. Semg feature extraction based on stockwell transform improves hand movement recognition accuracy. *Sensors*, 19(20) :4457, 2019.
- [16] R.G. Stockwell. A basis for efficient representation of the s-transform. *Digital Signal Processing*, 17(1) :371–393, 2007.
- [17] J. Too, A.R. Abdullah, N.M. Saad, N. M. Ali, and T.N.S. Zawawi. Application of gabor transform in the classification of myoelectric signal. *Telkomnika*, 17(2) :873–881, 2019.