

Estimation des coordonnées articulaires de la main à partir de signaux électromyographiques

S. Kirchhofer

T. Chateau

C. Bouzgarrou

Institut Pascal
UMR 6602 - UCA/CNRS/SIGMA
simon.kirchhofer@etu.uca.fr

Résumé

La classification de mouvements à partir de signaux électromyographiques est la solution la plus utilisée pour contrôler des prothèses de main robotiques. Elle reste néanmoins insatisfaisante car le nombre de gestes réalisables est limité. Dans cette publication, nous présentons une approche cherchant à décrire plus fidèlement les mouvements de la main. Pour commencer, une base de données comprenant des signaux électromyographiques et des coordonnées articulaires mesurées par vision par ordinateur a été réalisée. Ensuite, un réseau de neurones a été entraîné sur cette base pour reconstruire la position de la main par exploitation des séquences électromyographiques. Les premiers résultats sont encourageants et valident les limitations déduites de nos connaissances anatomiques.

Mots Clef

Electromyographie, capture de mouvement, contrôle de prothèse, main, coordonnées articulaires, apprentissage profond.

Abstract

Gestures classification using electromyographic signals (EMG) is a widespread solution for prosthetic hand control. Nevertheless, it remains unsatisfactory as the number of motions is limited. In this paper, we try to improve the precision of hand motions. A database was built with EMG and joint coordinates measured by computer vision. Then, a neural network was designed to estimate the hand position from EMG sequences. First results are hopeful and validate the limitations inherent to anatomy.

Keywords

Electromyography, motion capture, prosthetic control, hand gestures, joint coordinates, machine learning.

1 Introduction

Dans le cadre de la conception de prothèses de membre supérieur, la principale difficulté reste l'implémentation de l'interface homme-machine. Depuis des années, l'état de l'art s'est focalisé sur la recherche d'une solution visant à acquérir l'intention de l'utilisateur pour concevoir une

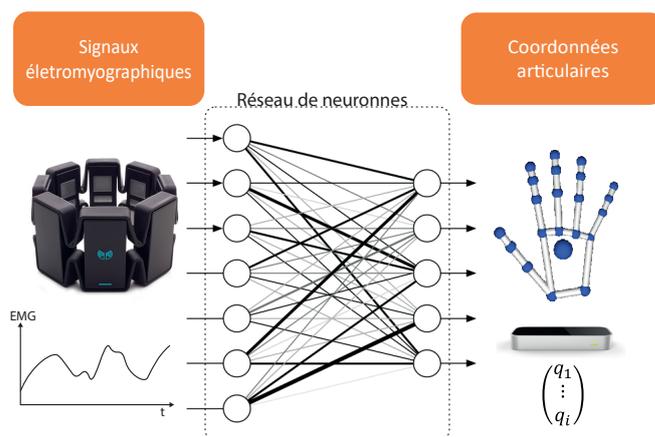


FIGURE 1 – Schéma de principe du lien électromyographie (EMG) / coordonnées articulaires (q_i)

commande de prothèse robotique la plus précise possible. À ce jour, la technique la plus prometteuse reste le traitement de signaux électromyographiques. Des électrodes électromyographiques de surface (sEMG) mesurant un ensemble de potentiels d'action actionnant les muscles sont largement utilisés en recherche. Elles ont l'avantage d'être non invasives, facile à mettre en place et elles ont permis de développer de nombreux algorithmes de classification de mouvement. Néanmoins, comme un nombre restreint de mouvements est classifié, la quantité d'information extraite reste limitante pour contrôler toutes les articulations d'une prothèse de main anthropomorphique. En conséquence, la commande est imprécise mais reste exploitable tant que la conception de la main robotique lisse ce défaut. C'est pourquoi les mains actuelles sont sous-actionnées : on réduit le degré d'actionnement pour diminuer la complexité de la commande. Il en résulte que la cinématique des gestes est la conséquence des choix de conception plutôt que de l'intention de l'utilisateur. Afin d'augmenter la complexité des mouvements possibles, nous proposons deux contributions : La première est une base de données contenant des mesures électromyographiques et cinématiques. La seconde est une modélisation pour l'apprentissage supervisé

du lien entre les mouvements de la main et les signaux électromyographiques. La première partie est consacrée à l'état de l'art pour présenter la visée de cette publication. La deuxième partie décrit les choix réalisés pour la conception de la base de données. Dans la troisième partie, un premier procédé pour estimer les coordonnées articulaires sera décrit et accompagné des premiers résultats.

2 État de l'art

A propos de commande de prothèses robotiques, la recherche s'est focalisée sur la classification de gestes à partir de signaux électromyographiques. Jusqu'à aujourd'hui, un des défis était d'extraire des caractéristiques pertinentes du signal pour augmenter la précision de la classification [1][2]. Mais avec l'émergence de l'apprentissage profond, cette première étape du traitement du signal tend à disparaître car elle est intégrée à l'apprentissage. Il a été montré qu'un réseau convolutionnel peut atteindre le même résultat avec le signal EMG en entrée plutôt qu'un ensemble de caractéristiques choisi empiriquement [3]. Dans les faits, les premières couches du réseau s'adaptent pour nourrir les couches suivantes avec les caractéristiques qui leurs paraissent pertinentes. Un réseau convolutionnel peut même arriver à une plus grande précision de la classification en utilisant des séquences EMG [4]. Comme les caractéristiques sont choisies de manière arbitraire et empirique, il paraît rationnel qu'elles ne soient pas optimisées pour le classifieur. Elles paraissent nécessaires pour réduire la dimension mais elles filtrent inmanquablement certaines informations. En parallèle, un réseau convolutif a la capacité d'apprendre à extraire les informations indispensables pour la classification.

La principale base de données pour la reconnaissance de mouvements par analyse des signaux EMG est la base NinaPro [5][6]. Cette base vise à être utilisée pour tester la performance des classifieurs de gestes et elle contient deux types de mesures : des mesures de cinématique et des mesures d'efforts.

- Pour les mesures cinématiques, des données EMG sont mesurées simultanément avec les acquisitions d'un gant électronique CyberGlove II. Il s'agit d'un gant à 22 capteurs repartis sur les articulations des doigts. La valeur renvoyée par chaque capteur dépend de l'angle de l'articulation. Lors de l'acquisition, le sujet est invité à recopier des mouvements projetés sur un écran. Le geste en exemple correspondant à une classe de mouvement, les données EMG sont liées à cette classe pour créer la base de données.
- Pour les mesures d'efforts, le gant électronique est remplacé par un capteur de force qui mesure la force exercée par chaque doigt. Ces données peuvent être utiles pour trouver le lien entre les signaux EMG et les efforts et ainsi développer un contrôleur de couple pour prothèses robotiques.

Même si de nombreux algorithmes ont été développés,

l'idée principale reste la classification d'un nombre fixe de mouvements. Ce nombre de mouvements semble limitant pour copier tous les gestes d'une main humaine sur une main robotique. Une commande plus continue a été développée en réalisant une combinaison de plusieurs mouvements classifiés [7], mais cette solution est toujours dépendante du nombre de mouvements présent dans la classification.

Nous proposons ici, dans une première contribution, d'évaluer s'il est possible d'aller plus loin dans l'exploitation de signaux EMG. Notre objectif est d'estimer les coordonnées articulaires de la main. Pour cela, les mesures cinématiques de la base de données NinaPro semblaient être la meilleure solution. Malheureusement, les données du CyberGlove ne sont pas calibrées et les coordonnées articulaires ne peuvent pas être extraites. C'est pourquoi nous proposons, dans une seconde contribution, une nouvelle base de données.

3 Création de la base de données

L'objectif de cet article est de développer un apprentissage supervisé pour l'estimation de coordonnées articulaires à partir d'un signal électromyographique. Voici une proposition afin de créer une base de données facile à mettre en place avec un coût réduit.

3.1 Matériel

Le signal EMG est enregistré avec un bracelet Myo (Thalmic Labs) à 8 canaux. En plus d'être plus rapide et plus facile à mettre en place que des électrodes séparées, cette solution est abordable et permet d'atteindre de bonnes performances pour les opérations de classification [8]. En contrepartie, les électrodes sont équitablement réparties autour de l'avant-bras et on ne peut donc pas choisir spécifiquement les muscles à mesurer. De plus, l'intervalle de fréquence recommandé pour le traitement électromyographique se trouve entre 5 et 500 Hz, donnant une fréquence d'échantillonnage minimum de 1KHz [9], alors que le bracelet Myo est limité à 200Hz. À notre connaissance, il s'agit du meilleur choix pour avoir un périphérique abordable et portable pour de la mesure EMG à des fins de commande de prothèses robotiques.

Pour la mesure cinématique, nous avons opté pour un Leap Motion. Cette caméra stéréoscopique de 1.3 mégapixels extrait les coordonnées euclidiennes de chaque articulation de la main, incluant le poignet et le coude. Avec un modèle cinématique donné, il est possible de calculer les coordonnées articulaires à partir des coordonnées euclidiennes. Avec une erreur inférieure à 2.5mm en dynamique, la précision de ce dispositif est acceptable pour notre application [10]. De plus, ce capteur est adapté à la création d'une base de données inter-individu car aucune calibration n'est nécessaire. Comme le bracelet Myo, c'est un système peu onéreux et facile à mettre en œuvre.

Cette base peut être facilement étendue étant donné que la partie matérielle est abordable et facile à mettre en place. La mesure de mouvements ne dépend pas du modèle cinématique et peut être utilisée pour d'autres travaux comme la recherche de synergies ou l'espace des coordonnées articulaires atteignables. A priori, nous sommes conscients que l'estimation des coordonnées articulaires va être complexe car la classification montre déjà des difficultés pour des gestes similaires. Mais si un modèle inter-individu s'avère inexploitable, il reste possible d'utiliser cette installation pour un apprentissage spécifique à chaque sujet.

3.2 Protocole d'acquisition

La base de données a été créée en enregistrant 12 sujets (7 hommes et 5 femmes) de 22 à 30 ans. Ils n'ont aucune particularité notable à part un sujet ayant subi une reconstruction chirurgicale du ligament collatéral ulnaire du pouce. La séquelle remarquable est une limitation de l'amplitude de la flexion de l'articulation metacarpophalangienne de ce même doigt (environ 15% de moins que le pouce intact de l'autre main). Seule la main droite des sujets a été mesurée. Le premier sujet a été de nouveau enregistré plusieurs mois après la première acquisition.

Pour chaque sujet, 5 enregistrements ont été réalisés :

- 1er enregistrement : Le sujet reste au repos. La main est environ 20 cm au-dessus du capteur et parallèle à celui-ci. Les doigts sont relâchés. Cet enregistrement peut être nécessaire pour une éventuelle calibration de l'apprentissage.
- 2ème enregistrement : Le sujet réalise des mouvements lents. Pour cette acquisition, l'ouverture et la fermeture de la main durent environ 2 secondes. Chaque sujet a réalisé les mouvements les plus variés possibles sans contrainte imposée. L'objectif est de permettre la mise en évidence de synergies et de focaliser l'apprentissage sur les mouvements naturels. On peut remarquer néanmoins que tous les sujets ont tendance à réaliser les mêmes types de mouvement : ouverture et fermeture de la main, opposition du pouce, compter sur les doigts et des mouvements de poignet.
- 3ème enregistrement : La consigne est la même que pour l'enregistrement 2 mais à plus grande vitesse. Les sujets ont réalisé des mouvements plus rapides avec des différences d'une personne à l'autre. Le but de cet enregistrement est de visualiser des effets dynamiques.
- 4ème enregistrement : Cet enregistrement est identique au 2ème mais sans mouvement de poignet. Il sera utile pour focaliser l'apprentissage sur la reconstruction des articulations inter-phalangiennes et metacarpophalangiennes. Ces articulations ont besoin de plus de données pour l'entraînement à cause d'un manque d'informations sur leur actionnement. En effet, les muscles lombricaux et interosseux dorsaux et palmaires tendent à découpler les

articulations de la main, et leur contraction n'est pas mesurée.

- 5ème enregistrement : Il consiste en la réalisation de six mouvements répétés plusieurs fois : Flexion / extension, déviation radiale / ulnaire du poignet et ouverture / fermeture de la main. Le sujet retrouve la position de repos entre chaque geste. Ces mouvements rappellent les gestes classifiés que l'on retrouve dans les bases de données de l'état de l'art.

Le premier enregistrement dure 30 secondes et les quatre autres une minute. Quelques dizaines de secondes sont accordées aux sujets entre chaque enregistrement pour éviter la fatigue musculaire. Comme il n'est pas habituel de tenir son bras mi fléchi au-dessus d'une table pendant plusieurs minutes sans poser le coude, les sujets avaient tendance à noter une gêne légère au niveau de l'épaule dû à une fatigue musculaire des deltoïdes. Il est important de noter que le bracelet Myo a été gardé à la même position sur chaque sujet pendant tous les enregistrements. Il était positionné à environ 20 cm du poignet avec le premier canal au niveau du muscle cubital postérieur. Suivant la morphologie du sujet, la distance entre le bracelet et le poignet a pu varier ± 5 cm pour assurer un contact suffisant entre les capteurs EMG et la peau tout en garantissant l'absence de gêne pour l'utilisateur.

3.3 Détails d'implémentation

Les informations délivrées par le bracelet Myo et la caméra Leap Motion sont enregistrées à l'aide de l'environnement ROS. Il s'agit d'une bibliothèque logicielle optimisée pour le traitement des flux de données. Des packages sont déjà disponibles pour notre matériel sur la plateforme GitHub^{1 2}. Dans les faits, le package du Leap Motion ne comprend pas les coordonnées du coude alors qu'elles sont calculées par le logiciel. C'est pourquoi nous avons développé un package quasi identique incluant les coordonnées du coude basé sur le kit de développement C++ du constructeur. Les données sont stockées dans des fichiers rosbag propre à la bibliothèque ROS. Ainsi, il est possible d'enregistrer et de rejouer des enregistrements en évitant la dé-sérialisation et la re-sérialisation des messages. Quand un rosbag est lu, il rejoue les flux enregistrés avec le codage temporel pour permettre une synchronisation.

Le bracelet Myo écrit des informations sur plusieurs topics :

- `myo_arm` détermine le bras qui porte le bracelet
- `myo_EmgArray` envoie un vecteur de taille 8 avec des valeurs de 0 à 2048 représentant les potentiels d'action des unités motrices.
- `myo_gest` est le résultat de la classification de mouvements réalisée par l'entreprise qui développe le Myo.
- `myo_gest_str` envoie aussi la classification mais sous forme de nom de mouvement et non de label.

1. https://github.com/ros-drivers/leap_motion

2. https://github.com/uts-magic-lab/ros_myo

- `myo_imu` contient un message standard provenant de la plateforme gyroscopique du Myo. Il s'agit d'un quaternion pour l'orientation ainsi que des valeurs de l'accéléromètre et du gyroscope.
- `myo_ori` est un message contenant le tangage, le lacet et le roulis du bracelet en radians.
- `myo_ori_deg` est identique à `myo_ori` mais en degrés

L'inconvénient majeur de la bibliothèque ROS du bracelet Myo est la limitation de la fréquence d'acquisition à 50Hz alors que sa fréquence théorique peut atteindre 200Hz. En accord avec les constatations précédentes, une fréquence d'acquisition basse est problématique pour assurer une bonne précision lors de la phase d'apprentissage.

De son côté, le Leap Motion n'écrit qu'un topic ROS avec les coordonnées euclidiennes de l'extrémité de chaque os de la main. L'origine est prise à la surface du capteur et les distances sont directement données en mm. Pour chaque doigt, on mesure la phalange proximale, médiane et distale ainsi que le métacarpe. A cela, il faut ajouter le centre du poignet, le coude et le centre de la paume de main. Les orientations de la paume de main et de l'avant-bras sont aussi disponibles. Au total, 27 points et 2 orientations sont envoyés à 120 Hz.

4 Modèle cinématique de la main

L'architecture cinématique de la main est complexe et quelques simplifications doivent être réalisées pour avoir un modèle cinématique transposable à un robot. Un tel modèle est pertinent pour une conception classique d'une main robotique composée de solides indéformables et de liaisons pivots. Il est évident que certains degrés de liberté (DDL) sont prépondérants pour des tâches communes comme la saisie d'objet. Notre modèle à 18 DDL (figure 2) est inspiré de [11] et de conceptions de mains robotiques [12] [13] [14] [15] [16]. L'abduction et adduction des articulations metacarpophalangiennes ne sont pas prises en compte. L'amplitude de celles-ci est réduite et dispensable pour des opérations de saisie, et l'actionnement par les muscles interosseux n'est pas mesuré. La liaison poignet/avant-bras et la liaison metacarpophalangienne du pouce sont modélisées par des cardans (2 DDL en rotation). Tous les os carpiens et métacarpiens (sauf pouce) sont assimilés à un unique solide indéformable. Les articulations inter-phalangiennes sont modélisées par des pivots. Ces simplifications n'entraînent pas de modifications majeures pour réaliser des mouvements usuels ou des opérations de saisie d'objet.

Le calcul des coordonnées articulaires se fait avec les coordonnées euclidiennes du centre des articulations. Chaque os est considéré comme un vecteur calculé à partir des coordonnées des liaisons à ses extrémités. Puis, pour les articulations metacarpophalangiennes et inter-phalangiennes, la valeur de la coordonnée articulaire est l'arc-cosinus du produit scalaire entre les vecteurs des deux os adjacents.

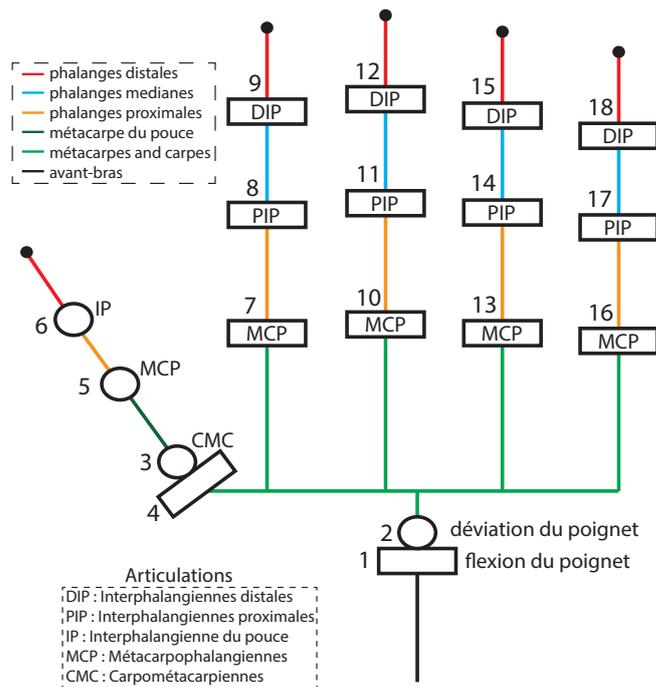


FIGURE 2 – Schéma cinématique de la main et du poignet

Comme le Leap Motion renvoie le vecteur normal au plan frontal de la paume de main, le plan sagittal est calculé avec le produit vectoriel entre le plan frontal et le métacarpe du majeur. La flexion du poignet est alors donné par l'angle entre la normale au plan frontal et le vecteur de l'avant-bras, et la déviation par l'angle entre la normale au plan sagittal et le vecteur de l'avant-bras. De la même manière, les 2 coordonnées articulaires de la liaison carpométacarpienne du pouce sont données avec l'arc-sinus du produit scalaire entre le vecteur du métacarpe du pouce et les normales au plan frontal et sagittal.

Un nœud ROS a été déployé pour souscrire au topic du Leap Motion et publier les coordonnées articulaires avec le même code temporel. Pour finir, un dernier nœud ROS reçoit les données articulaires et les informations EMG afin de les synchroniser selon leur code temporel avant d'écrire des fichiers CSV. La synchronisation a été réalisée avec un outils de la bibliothèque ROS³. En conclusion, on retrouve deux fichiers CSV pour chaque enregistrement de chaque sujet. Chaque ligne du fichier EMG correspond temporellement à la même ligne dans le fichier des coordonnées articulaires.

3. http://wiki.ros.org/message_filters/ApproximateTime

5 Architecture d'apprentissage profond pour l'estimation de coordonnées articulaires

5.1 Évaluation

Les performances des apprentissages sont évaluées en calculant la valeur efficace de l'erreur (RMS) entre les coordonnées articulaires estimées et celles de la base de données.

Pour quantifier la précision de l'estimation, on calculera pour chaque articulation la valeur moyenne de l'erreur et son écart type. Cette erreur est calculée pour l'ensemble de test (15% des données) et pour le sujet 12 qui n'apparaît pas pendant l'entraînement. Ces valeurs sont pertinentes pour déterminer la précision de l'estimation mais elles ne donnent pas la répartition des erreurs parmi les articulations. C'est pourquoi un diagramme en boîte est proposé pour voir cette distribution. L'écart d'estimation est comparé à l'amplitude maximale de l'articulation pour donner une erreur en pourcentage.

5.2 Détails d'implémentation

Les fichiers CSV sont chargés et découpés en séquence de 200 ms. Pour effectuer une commande de prothèse, le retard doit être sous les 300ms pour assurer de bonnes performances [17]. Comme le signal EMG est échantillonné à 50 Hz, chaque séquence contient 10 échantillons. La fenêtre glissante est décalée d'un seul incrément pour avoir un nombre maximum de séquences. Pour les 11 premiers sujets, environ 148.000 séquences EMG sont extraites. Chaque séquence est reliée aux coordonnées articulaires mesurées à la fin de la séquence EMG. En résumé, les coordonnées articulaires sont estimées avec les signaux EMG des 200 ms qui précèdent.

L'ensemble des couples coordonnées articulaires / séquences EMG des 11 sujets est divisé en 3 parties après un mélange aléatoire. 15% sont utilisés pour quantifier la précision de l'algorithme et n'interviennent pas dans l'apprentissage. Et parmi les 85% restant, 15% servent à la validation pendant l'entraînement.

Plusieurs structures de réseau ont été essayées. Nous avons commencé avec des architectures de réseaux convolutionnels utilisées dans la littérature pour de la classification de mouvements [4] [18]. Ces solutions ne requièrent pas d'extraction de caractéristiques car les premières couches sont dédiées à cette tâche. Elles sont donc particulièrement adaptées à notre cas car la fréquence d'acquisition relativement faible rend les techniques classiques d'extraction de caractéristiques inefficaces. Les réseaux récurrents ont été aussi testés pour leur capacité à traiter des signaux temporels. Dans tous les cas, le réseau contient une dernière couche dense sans fonction d'activation afin de calculer une régression des coordonnées articulaires. Un "dropout" a été ajouté pour éviter le phénomène de sur-apprentissage. Il a été construit de manière empirique et itérative : Des

couches et des neurones ont été ajoutés progressivement pour améliorer les performances tout en gardant la plus faible complexité possible. L'idée principale étant de garder un coût de calcul bas pour faciliter l'implémentation sur un système portable.

Le réseau a été développé avec la bibliothèque Keras en sur-couche de Tensorflow.

5.3 Résultats

La comparaison des performances des trois types de réseau est présentée dans le tableau 1. Le réseau convolutionnel est identique à celui proposé dans [4]. Le réseau récurrent est composé de deux couches de LSTM à 128 neurones et une couche dense à 128 neurones. Il s'agit du réseau récurrent le plus performant que nous ayons entraîné. Le réseau dense est composé de deux couches denses de 128 neurones. Il s'agit également du réseau dense qui fournit les meilleurs résultats.

Il apparaît que les architectures convolutionnelles classiques sont moins efficaces pour cette application. Les couches convolutionnelles dédiées à l'extraction de caractéristiques ne sont pas nécessaires et deviennent même contre-productives car elles entravent la convergence de l'entraînement. Ce résultat est intuitif car cette étape est indispensable pour réaliser une réduction de la dimension de l'espace d'entrée. Or ici les dimensions de l'entrée sont réduites (8 canaux par 10 échantillons) et il est utile de garder toutes les informations.

Le choix de deux couches denses de 128 neurones est intéressant pour voir apparaître des résultats. Il s'agit d'une structure assez simple qui donne des indices pour comprendre les possibilités de machine learning sur notre base de données.

Le tracé des estimations des coordonnées articulaires est proposé pour illustrer la performance du réseau. La figure 4 représente la mesure et l'estimation des coordonnées articulaires de deux articulations du premier sujet. Comme ce sujet est dans la base d'apprentissage, ces courbes permettent d'estimer la convergence de l'entraînement. Deux autres tracés (figure 5) montrent le même résultat mais avec un sujet en dehors de la base d'apprentissage pour vérifier la transposition inter-individu de l'estimateur.

5.4 Discussion

Pour commencer, nous pouvons noter que la précision varie suivant l'articulation. Sur la figure 3, on peut voir la répartition de l'erreur pour chaque articulation du sujet 1. À noter que l'on retrouve le même type de répartition sur les autres sujets, que ceux-ci proviennent de la base de test ou d'apprentissage. L'erreur d'estimation augmente avec la distance de l'articulation au poignet. Par exemple, l'estimation pour l'articulation inter-phalangienne distale est moins précise que celle de la flexion du poignet. Ce résultat est dû principalement aux muscles de la main (lombricaux, interosseux dorsaux et palmaires, muscles du pouce) qui sont impliqués dans les mouvements fins et précis de la main. Ces muscles découpent les synergies

		Réseaux convolutionnel [4]	Réseau récurrent	Réseau dense
Données de test	Erreur moyenne (en rad)	0.248	0.2015	0.199
	Écart type de l'erreur (en rad)	0.185	0.180	0.179
Données du sujet 12	Erreur moyenne (en rad)	0.406	0.313	0.306
	Écart type de l'erreur (en rad)	0.265	0.219	0.215

TABLE 1 – Quantification de l'erreur de reconstruction pour différents structures de réseaux.

initiées par les muscles de l'avant-bras et leur activité n'est mesurée par aucun capteur EMG. De plus, l'adducteur, l'abducteur, le fléchisseur et l'opposant du pouce sont majoritairement responsables des mouvements de la liaison carpométacarpienne. En conséquence, ces coordonnées articulaires ne peuvent être approchées que grâce aux synergies et sont faussement estimées lors de mouvements atypiques. Il faut aussi ajouter que certains muscles actionnent un seul doigt et ne sont pas mesurés car ils sont dans le compartiment profond de l'avant-bras. C'est le cas par exemple de l'extenseur de l'index et le court extenseur du pouce qui actionnent respectivement l'index et le pouce. Ils sont trop profonds pour être captés par le bracelet EMG.

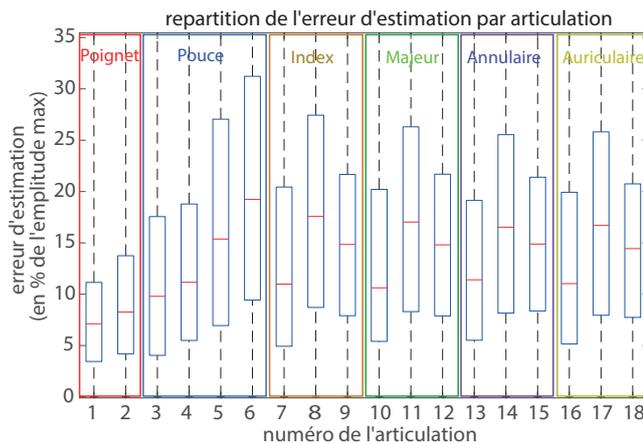


FIGURE 3 – Répartition de l'erreur entre les coordonnées articulaires estimées par le réseau et la mesure

Le deuxième résultat remarquable est la capacité du réseau à estimer les coordonnées articulaires dans des cas non statiques. On peut voir sur la figure 4 qu'une rapide variation d'une coordonnée articulaire (c'est-à-dire une vitesse élevée) est détectée et bien reconstruite, alors que le maintien d'une position a pour conséquence une estimation très bruitée. Cette constatation va dans le sens de la théorie. Le modèle dynamique de la main nous donne les accélérations articulaires en fonction de la force. Étant donné que le signal EMG est une mesure de l'activité musculaire, et donc d'une force, le réseau doit reproduire le modèle dynamique de la main avec deux intégrations temporelles de la sortie. Sachant qu'intégrer une erreur a tendance à l'amplifier, une mauvaise précision en statique

semble légitime. Ce résultat est aussi influencé par le protocole de la création de base de données. L'enregistrement numéro 3 contient des mouvements rapides qui influencent l'apprentissage. Après avoir réalisé deux apprentissages, avec et sans cet enregistrement, il est apparu que ces données à haute vitesse sont nécessaires pour détecter et recopier les pics des coordonnées articulaires.

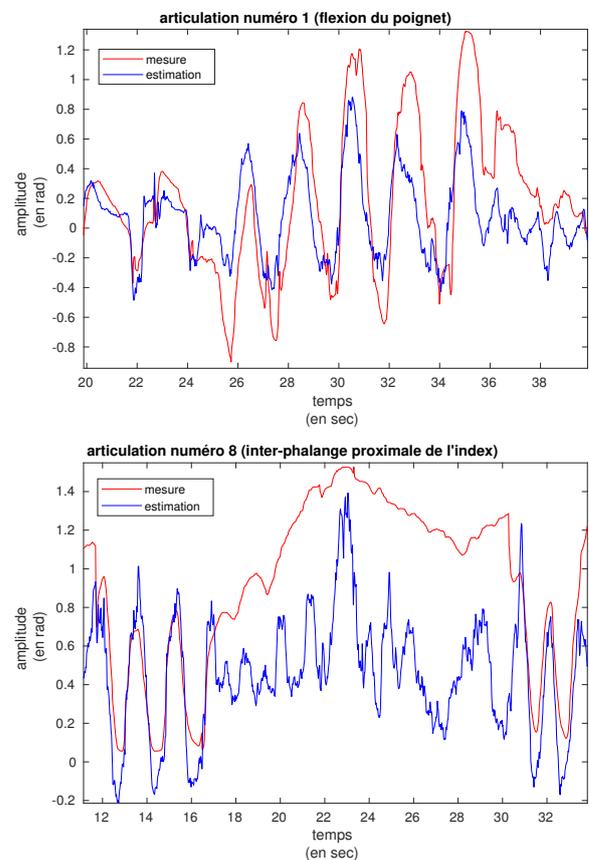


FIGURE 4 – Coordonnées articulaires mesurées par Leap Motion et estimées par le réseau à partir de signaux électromyographiques. Les données font parties de la base d'apprentissage

La figure 5 représente le résultat de l'estimation pour le 12ème sujet qui n'appartient pas aux données d'entraînements. L'erreur est plus grande que sur les données de test de la base d'apprentissage (tableau 1) mais avec le même type de répartition parmi les articulations. Un

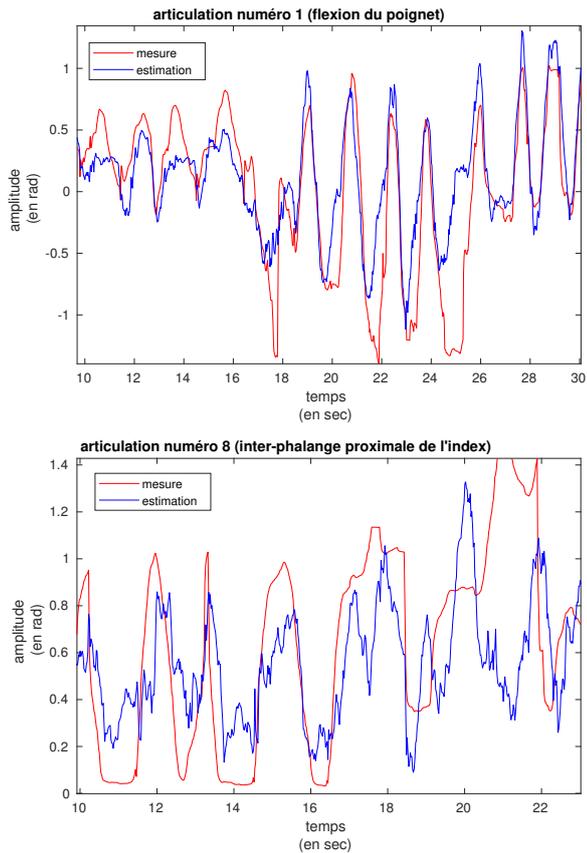


FIGURE 5 – Coordonnées articulaires mesurées par Leap Motion et estimées par le réseau à partir de signaux électromyographiques. Les données proviennent du sujet 12 et ne font pas parties de la base d’apprentissage

modèle inter-individu est donc envisageable mais nécessite un nombre de sujets plus élevé pour que l’entraînement ne se focalise pas sur les spécificités des sujets de la base d’apprentissage.

La disparité des synergies peut être une autre explication. Chaque sujet a sa propre façon de réaliser des mouvements. Une fois la main fermée, certains vont fermement serrer les doigts pendant que d’autres vont tenir la position sans forcer. Il en résulte un grand nombre de signaux EMG différents pour les mêmes coordonnées articulaires. Une base de données plus large peut aider à décoder ces situations.

6 Conclusion

Dans ce papier, une base de données avec des signaux électromyographiques et des coordonnées articulaires a été conçue et réalisée. Un contrôleur Leap Motion et un bracelet Myo ont été utilisés pour enregistrer simultanément les signaux EMG et les positions des articulations. Utilisant cette base, un réseau de neurones a été étudié pour construire un modèle entre EMG et coordonnées articu-

laires. Ce traitement a visé à évaluer la faisabilité d’un estimateur avec les données de ces deux capteurs à bas coût. Les premiers résultats sont encourageants avec une estimation du mouvement du poignet exploitable. D’un autre côté, en fonction de l’articulation ou du type de mouvement, certaines situations indiquent que l’estimateur fait face à des limitations. Les mouvements quasi-statiques et les articulations inter-phalangiennes posent problème. De plus, nos connaissances anatomiques précisent que l’on ne peut pas résoudre le modèle dynamique avec aussi peu de données si les synergies sont rompues.

La prochaine étape de notre travail consiste à répertorier des mouvements qui nous permettront de quantifier la contribution des muscles cachés. En nous appuyant sur le modèle biomécanique de la main, il est possible d’enrichir la base de données avec des gestes pertinents qui facilitent l’apprentissage.

Références

- [1] A. Phinyomark, P. Phukpattaranont, and C. Limsakul, “Feature Reduction and Selection for EMG Signal Classification,” *Expert Syst. Appl.*, vol. 39, no. 8, pp. 7420–7431, 2012. [Online]. Available : <http://dx.doi.org/10.1016/j.eswa.2012.01.102>
- [2] A. Altamirano, “EMG pattern prediction for upper limb movements based on wavelet and Hilbert-Huang transform,” Ph.D. dissertation, 2017.
- [3] U. Côté-Allard, C. L. Fall, A. Drouin, A. Campeau-Lecours, C. Gosselin, K. Glette, F. Laviolette, and B. Gosselin, “Deep Learning for Electromyographic Hand Gesture Signal Classification Using Transfer Learning,” pp. 1–18, 2018. [Online]. Available : <http://arxiv.org/abs/1801.07756>
- [4] Z. Ding, C. Yang, Z. Tian, C. Yi, Y. Fu, and F. Jiang, “sEMG-based gesture recognition with convolution neural networks,” *Sustainability (Switzerland)*, vol. 10, no. 6, pp. 1–12, 2018.
- [5] M. Atzori, A. Gijsberts, S. Heynen, A. G. M. Hager, O. Deriaz, P. Van Der Smagt, C. Castellini, B. Caputo, and H. Muller, “Building the Ninapro database : A resource for the biorobotics community,” *Proceedings of the IEEE RAS and EMBS International Conference on Biomedical Robotics and Biomechanics*, no. Section II, pp. 1258–1265, 2012.
- [6] M. Atzori and H. Muller, “The Ninapro database : A resource for sEMG naturally controlled robotic hand prosthetics,” *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, vol. 2015-Novem, pp. 7151–7154, 2015.
- [7] J. Yang, J. Pan, and J. Li, “sEMG-based continuous hand gesture recognition using GMM-HMM and threshold model,” in *2017 IEEE International Conference on Robotics and Biomimetics, ROBIO 2017*, 2018.

- [8] S. Pizzolato, L. Tagliapietra, M. Cognolato, M. Reggiani, H. Müller, and M. Atzori, "Comparison of six electromyography acquisition setups on hand movement classification tasks," *PLoS ONE*, vol. 12, no. 10, pp. 1–17, 2017.
- [9] A. R. Merletti and P. Torino, "Standards for reporting EMG data," *Journal of Electromyography and Kinesiology*, vol. 7, no. 2, pp. I–II, 1997. [Online]. Available : <http://linkinghub.elsevier.com/retrieve/pii/S1050641197900018>
- [10] F. Weichert, D. Bachmann, B. Rudak, and D. Fisseler, "Analysis of the accuracy and robustness of the Leap Motion Controller," *Sensors (Switzerland)*, vol. 13, no. 5, pp. 6380–6393, 2013.
- [11] J. Lenarcic, T. Bajd, and M. M. Stanišić, "Robot Mechanisms," vol. 60, 2013. [Online]. Available : <http://link.springer.com/10.1007/978-94-007-4522-3>
- [12] C. Gosselin, F. Pelletier, and T. Laliberté, "An anthropomorphic underactuated robotic hand with 15 dofs and a single actuator," *Proceedings - IEEE International Conference on Robotics and Automation*, pp. 749–754, 2008.
- [13] E. Matheson, Y. Aoustin, E. Le Carpentier, A. Leon, and J. Perrin, "Anthropomorphic underactuated hand with 15 joints," *4th Workshop on Medical and Service Robotics, MeSRob 2015*, vol. 39, pp. 277–295, 2016. [Online]. Available : <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84964866010{\&}partnerID=40{\&}md5=32f068c1af587a770e5a6130dd901af9>
- [14] L. Zollo, S. Roccella, E. Guglielmelli, M. C. Carrozza, and P. Dario, "Biomechatronic design and control of an anthropomorphic artificial hand for prosthetic and robotic applications," *IEEE/ASME Transactions on Mechatronics*, vol. 12, no. 4, pp. 418–429, 2007.
- [15] R. Deimel and O. Brock, "A novel type of compliant and underactuated robotic hand for dexterous grasping," *International Journal of Robotics Research*, vol. 35, no. 1-3, pp. 161–185, 2016.
- [16] C. Piazza, M. Catalano, G. S.B., R. M., G. Grioli, M. Bianchi, K. Zhao, and A. Bicchi, "The SoftHand Pro-H," *IEEE Robotics and Automation Magazine*, pp. 87–101, 2017.
- [17] T. R. Farrell and R. F. Weir, "The optimal controller delay for myoelectric prostheses," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 15, no. 1, pp. 111–118, 2007.
- [18] M. Atzori, M. Cognolato, and H. Müller, "Deep Learning with Convolutional Neural Networks Applied to Electromyography Data : A Resource for the Classification of Movements for Prosthetic Hands," *Frontiers in Neurorobotics*, vol. 10, p. 9, 2016. [Online]. Available : <http://journal.frontiersin.org/article/10.3389/fnbot.2016.00009>