

Titre: Développement d'une méthode de décomposition des mouvements du membre supérieur pour l'optimisation des séances de réadaptation
Title:

Auteur: Lauren Pelletier de Chambure Hémart du Neufpré
Author:

Date: 2022

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Pelletier de Chambure Hémart du Neufpré, L. (2022). Développement d'une méthode de décomposition des mouvements du membre supérieur pour l'optimisation des séances de réadaptation [Master's thesis, Polytechnique Montréal]. PolyPublie. <https://publications.polymtl.ca/10436/>
Citation:

 **Document en libre accès dans PolyPublie**
Open Access document in PolyPublie

URL de PolyPublie: <https://publications.polymtl.ca/10436/>
PolyPublie URL:

Directeurs de recherche: Maxime Raison
Advisors:

Programme: Génie biomédical
Program:

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

**Développement d'une méthode de décomposition des mouvements du membre
supérieur pour l'optimisation des séances de réadaptation**

LAUREN PELLETIER DE CHAMBURE HÉMART DU NEUFPRÉ

Institut de génie biomédical

Mémoire présenté en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

Génie biomédical

Aout 2022

© Lauren Pelletier de Chambure Hémart du Neufpré, 2022.

POLYTECHNIQUE MONTRÉAL

affiliée à l'Université de Montréal

Ce mémoire intitulé :

Développement d'une méthode de décomposition des mouvements du membre supérieur pour l'optimisation des séances de réadaptation

présenté par **Lauren PELLETIER DE CHAMBURE HÉMART DU NEUFPRÉ**

en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

a été dûment accepté par le jury d'examen constitué de :

Delphine PERIÉ-CURNIER, présidente

Maxime RAISON, membre et directeur de recherche

Abolfazl MOHEBBI, membre

REMERCIEMENTS

Je tiens à exprimer ma gratitude envers toutes les personnes m'ayant encadrée pendant ma maîtrise, tout particulièrement mon directeur de recherche Prof. Maxime Raison qui a cru en moi et m'a donné cette opportunité unique de découvrir le milieu de la réadaptation pédiatrique. Je tiens également à remercier Elizabeth Clark pour tous ses conseils, bonnes idées et sa vision de l'arrimage entre la clinique et la recherche qu'elle a réussi à me transmettre ; ainsi que l'ensemble des ergothérapeutes et physiothérapeutes du Centre de réadaptation Marie Enfant – CHU Sainte-Justine avec lesquels j'ai eu le plaisir de travailler. Votre passion est contagieuse et m'a guidée tout au long de ma maîtrise.

Merci à tous les patients du Centre de réadaptation Marie Enfant – CHU Sainte-Justine ayant participé à ce projet pour leur courage et leur patience.

Je tiens à remercier l'ensemble des étudiants de Polytechnique Montréal ayant accepté de participer activement à ce projet de recherche et notamment à la constitution de la base de données. Merci pour votre patience et disponibilité ayant permis de réaliser celle-ci en un temps record.

J'adresse également mes sincères remerciements à l'ensemble des autres stagiaires et étudiants du Technopôle et LiBRy pour leur soutien constant, sourire et bonne humeur, sans qui ce projet n'aurait pas abouti. Ces deux années n'auraient pas été les mêmes sans votre présence et votre contribution, de près ou de loin, à ce projet. Je tiens particulièrement à remercier Bastien Forcione, Erika Gagné, Baptiste Toussaint, Loyal Chaikho et Gaël Reynal qui m'ont aidée et guidée dans mes réflexions tout au long de ma maîtrise.

Finalement, merci à tous mes amis du Québec, de France et d'ailleurs qui m'ont encouragée par leur écoute, leur patience, leurs paroles de motivation et leur conseils pendant ces deux années de recherche. Vous m'avez aidée à tirer le meilleur de moi-même malgré les difficultés. Merci à mes colocataires, pour votre amitié, aide, écoute et disponibilité de tous les instants. Enfin, merci à ma famille, notamment mon frère Mathieu et ma sœur Sonia, pour votre soutien dans les moments les plus difficiles de ces deux années malgré la distance.

Merci à tous ceux et à toutes celles sans qui ce projet n'aurait pas vu le jour !

RÉSUMÉ

Les troubles neuromusculaires engendrent des déficits fonctionnels pour les patients, tout particulièrement dans la vie quotidienne où de simples gestes comme s'alimenter ou attraper des objets peuvent s'avérer compliqués. Les thérapies de réadaptation permettent de réduire ces déficits fonctionnels afin de faciliter la vie quotidienne des patients. Les nouvelles technologies de réalité virtuelle, combinées avec les thérapies conventionnelles, sont de plus en plus utilisées lors de ces thérapies. Si l'utilité de ces nouvelles modalités a déjà été démontrée, l'une des problématiques restantes est d'optimiser leur utilisation lors des sessions de thérapies, notamment en personnalisant les thérapies avec le bon défi, les bons jeux et le travail des bons mouvements pour chaque patient en fonction de ses possibilités et du plan prévu de thérapie. Cependant, les mouvements effectués naturellement lors de ces sessions sont complexes, c'est-à-dire que ces derniers mobilisent plusieurs articulations. Il est donc nécessaire de parvenir à décomposer les mouvements des patients en composantes de mouvements simples, c'est-à-dire n'impliquant qu'une seule articulation, afin d'analyser les mouvements et confirmer les objectifs thérapeutiques de chaque session.

L'objectif de cette étude est de développer une solution algorithmique permettant de décomposer les mouvements complexes multidimensionnels des membres supérieurs en composantes de mouvements simples à un seul degré de liberté. Cet objectif peut-être divisé en trois sous-objectifs qui sont la conception d'un algorithme de décomposition de mouvements complexes, l'évaluation de ses performances sur des gestes fonctionnels, puis son application sur des jeux de réalité virtuelle de réadaptation.

Des données cinématiques (IMU) et électromyographiques (EMG) lors de mouvements simples ont été mesurées chez 18 sujets adultes typiquement développés à l'aide de dix capteurs sans fil EMG-IMU afin de constituer une base de données. Des données EMG et IMU ont également été récoltées lors de l'exécution de gestes fonctionnels et de jeux de réalité virtuelle de réadaptation. Sept caractéristiques ont été extraites des signaux EMG des mouvements simples, et neuf caractéristiques pour les signaux IMU. Ces caractéristiques ont été utilisées pour entraîner des réseaux de neurones de longue mémoire à court terme. Les mouvements complexes ont été décomposés en 14 classes de mouvements sur quatre articulations (main, poignet, coude et épaule)

suivant une stratégie de classification en parallèle, à l'aide de huit réseaux de neurones classifiant chacun un degré de liberté.

Parmi les résultats, la précision moyenne des réseaux de neurones sur des données tests est de $98.2\% \pm 0.3\%$. L'application de cette solution algorithmique aux gestes fonctionnels donne des résultats cohérents avec les gestes effectués et les observations visuelles pendant les prises de mesure. Les résultats sur les jeux de réalité virtuelle permettent également d'analyser la conception de ces jeux de réadaptation et d'identifier les facteurs influençant les mouvements effectués pour permettre une meilleure précision des séances de réadaptation motrice.

Les résultats de cette maîtrise montrent le potentiel d'une méthode de décomposition des mouvements complexes pour améliorer la précision de la réadaptation motrice utilisant des dispositifs de réalité virtuelle de réadaptation et l'efficacité des séances de réadaptation. Il reste à développer une base de données de patients suivis en réadaptation afin de valider cette méthode sur ceux-ci. Comme perspective, cette méthode pourra également être appliquée en amont de la commercialisation des dispositifs de réalité virtuelle de réadaptation afin d'aider et d'évaluer la conception des jeux sérieux de réadaptation ciblant des mouvements spécifiques.

ABSTRACT

Neuromuscular disorders cause functional deficits for patients, especially in daily life where simple actions such as eating or reaching for objects can be complicated. Rehabilitation therapies help reduce these functional deficits in order to facilitate the daily life of patients. New virtual reality technologies, combined with conventional therapies, are increasingly used in these rehabilitation. If the usefulness of these new modalities has already been demonstrated, one of the remaining problems is to optimize their use during therapy sessions, notably by personalizing the therapies with the right challenge, the right games and the right movements for each patient according to his or her possibilities and the planned therapy plan. However, the movements naturally performed during these sessions are complex, i.e. they mobilize several joints. It is therefore necessary to subdivide the patients' movements into simple movement components, i.e. involving only one joint, in order to analyze the movements and confirm the therapeutic objectives of each session.

The objective of this study is to develop an algorithmic solution to decompose complex multidimensional movements of the upper limbs into components of simple movements with a single degree of freedom. This objective can be divided into three sub-objectives which are the design of an algorithm for decomposing complex movements, the evaluation of its performance on functional gestures, and its application on rehabilitation virtual reality games.

Kinematic (IMU) and electromyographic (EMG) data during simple movements were measured in 18 typically developed adult subjects using ten wireless EMG-IMU sensors to build a database. EMG and IMU data were also collected during the execution of functional gestures and rehabilitation virtual reality games. Seven features were extracted from the EMG signals of simple movements, and nine features from the IMU signals. These features were used to train long short-term memory neural networks. The complex movements were decomposed into 14 classes of movements on four joints (hand, wrist, elbow, and shoulder) following a parallel classification strategy, using eight neural networks each classifying one degree of freedom.

Among the results, the average accuracy of the neural networks on test data is $98.2\% \pm 0.3\%$. The application of this algorithmic solution to functional gestures gives results consistent with the gestures performed and the visual observations during measurements. The results on the virtual reality games also allow us to analyze the design of these rehabilitation games and to identify the

factors influencing the movements performed to allow a better precision of the motor rehabilitation sessions.

The results of this study show the potential of a complex movement decomposition method to improve the accuracy of motor rehabilitation using virtual reality rehabilitation devices and the effectiveness of rehabilitation sessions. It remains to develop a database of patients followed in rehabilitation in order to validate this method on them. As a perspective, this method could also be applied before the commercialization of virtual reality rehabilitation devices in order to help and evaluate the design of serious rehabilitation games targeting specific movements.

TABLE DES MATIERES

REMERCIEMENTS	III
RÉSUMÉ.....	IV
ABSTRACT	VI
TABLE DES MATIERES	VIII
LISTE DES TABLEAUX.....	XII
LISTE DES FIGURES.....	XIII
LISTE DES SIGLES ET ABBREVIATIONS	XVII
LISTE DES ANNEXES.....	XVIII
CHAPITRE 1 INTRODUCTION.....	1
CHAPITRE 2 REVUE DE LITTÉRATURE.....	3
2.1 Anatomie du membre supérieur	3
2.1.1 Système ostéoarticulaire.....	4
2.1.2 Système musculaire.....	8
2.2 Méthodes quantitatives d'évaluation du niveau fonctionnel du membre supérieur.....	11
2.2.1 Les échelles d'évaluation	11
2.2.2 Mesures et évaluation de la performance fonctionnelle à l'aide de données cinématiques et électromyographiques	12
2.3 Thérapie assistée par la robotique et l'intelligence artificielle.....	15
2.3.1 Les solutions technologiques en réadaptation.....	15
2.3.2 La thérapie Armeo®.....	18
2.3.3 Évaluation des thérapies grâce à l'intelligence artificielle.....	19
2.4 Reconnaissance de mouvements du membre supérieur	20
2.4.1 Reconnaissance de formes	20

2.4.2	Utilisation en réadaptation	22
2.4.3	Classification de séquences de mouvements.....	23
CHAPITRE 3 OBJECTIFS		26
3.1	Résumé de la problématique	26
3.2	Objectif principal.....	27
3.2.1	Sous-objectifs	27
3.2.2	Hypothèses	28
CHAPITRE 4 MÉTHODOLOGIE.....		29
4.1	Méthodologie	29
4.1.1	Acquisition des données.....	29
4.1.2	Traitement du signal.....	31
4.1.3	Entraînement des réseaux de neurones.....	32
4.2	Méthodologie complémentaire.....	32
4.2.1	Prise de données complémentaires.....	32
4.2.2	Tests et analyses complémentaires.....	32
CHAPITRE 5 ARTICLE 1 : TOWARDS MORE PRECISE UPPER EXTREMITY MOTOR REHABILITATION USING MACHINE LEARNING MOVEMENT DECOMPOSITION		34
5.1	Abstract	34
5.2	Keywords	35
5.3	Abbreviations and definitions:	35
5.4	Introduction	36
5.4.1	Rehabilitation using virtual reality gaming systems for upper extremities.....	36
5.4.2	Upper extremity rehabilitation using VR systems and the Armeo® Therapy Concept	37

5.4.3	Movement decomposition of upper extremity complex sequences in previous studies	37
5.4.4	Review limitations, objective and incentive of this study.....	39
5.5	Methodology	40
5.5.1	Participants	40
5.5.2	Data acquisition.....	40
5.5.3	Data Processing	43
5.5.4	Classification.....	45
5.5.5	Functional Gesture	48
5.5.6	Armeo®Senso Games and Hocoma Target Grid	48
5.6	Results	50
5.6.1	Classification accuracy.....	50
5.6.2	Functional Gesture Movement Components.....	52
5.6.3	Armeo®Senso Games Target Grid	54
5.7	Discussion	55
5.7.1	Classification Accuracy.....	55
5.7.2	Functional gestures.....	56
5.7.3	Armeo®Senso Games Design Optimization.....	57
5.7.4	Data processing optimization	58
5.7.5	Perspectives	59
5.8	Conclusion.....	59
5.9	Declaration of interest	60
5.10	Acknowledgments.....	60
5.11	References	60
5.12	Appendix	65

CHAPITRE 6	RÉSULTATS COMPLÉMENTAIRES	67
6.1	Impact des positions supplémentaires	67
6.2	Résultats complémentaires sur les gestes fonctionnels	68
CHAPITRE 7	DISCUSSION GÉNÉRALE	70
7.1	Synthèse de l'article	70
7.2	Analyse des résultats complémentaires	71
7.2.1	Impact du positionnement du membre supérieur lors du mouvement	71
7.2.2	Geste fonctionnel « Brosse »	72
7.3	Limites et perspectives	72
CHAPITRE 8	CONCLUSION	75
RÉFÉRENCES	77
ANNEXES	83

LISTE DES TABLEAUX

Tableau 2-1 Récapitulatif des muscles impliqués dans les mouvements du membre supérieur. ...	10
Tableau 2-2 Cinq échelles conventionnelles d'évaluation du niveau fonctionnel du membre supérieur	11
Tableau 3-1 Classes de mouvements et degrés de liberté (DDL) étudiés dans le mouvement du membre supérieur	27

LISTE DES FIGURES

Figure 2-1 Anatomie osseuse du membre supérieur, vue frontale (Image adaptée de [7]).....	3
Figure 2-2 Mouvements de l'épaule : A. Flexion/extension de l'épaule. B. Abduction/adduction horizontale de l'épaule (Image adaptée de [8]).	4
Figure 2-3 Mouvements de l'épaule : A. Rotation latérale/médiale de l'épaule (Image adaptée de [9]). B. Abduction/adduction de l'épaule (Image tirée de [10])......	5
Figure 2-4 Mouvement de flexion et d'extension du coude (Image tirée de [11]).	6
Figure 2-5 Mouvements possibles de l'avant-bras (pronation, supination) et du poignet (flexion, extension, abduction, adduction) (Image tirée de [12])	7
Figure 2-6 Mouvements de préhension de la main : A. Ouverture de la main. B. Fermeture de la main.....	7
Figure 2-7 Muscles principaux de l'épaule : A. Épaule antérieur. B. Muscles de la coiffe des rotateurs (Images adaptées de [13]).	8
Figure 2-8 Muscles principaux du bras : A. Triceps brachial (compartiment postérieur). B. Biceps brachial (compartiment antérieur). C. Brachialis (compartiment antérieur) (Images adaptées de [13])	9
Figure 2-9 Muscles de la couche superficielle de l'avant-bras : A. Compartiment antérieur (sauf brachioradial). B. Compartiment postérieur. (Image adaptée de [13])	9
Figure 2-10 Une unité motrice constituée d'un motoneurone innervant un groupe de fibres musculaires. Dans un modèle d'activation linéaire, le potentiel d'action de l'unité motrice (MUAP) est la réponse électrique à chaque stimulation ; et l'ensemble des MUAP génère un paquet de MUAP (MUAP train). (Image tirée de [20])	13
Figure 2-11 Robots de réadaptation du membre supérieur. A. Robot à effecteur terminal, le REAPlan (Image tirée de [41]). (1) Poignet du robot à effecteur terminal plan. (2) Interface visuelle pour le patient. (3) Interface pour le physiothérapeute. B. Robot orthèse ou exosquelette, ARMin III (Image tirée de [40]).	16

- Figure 2-12 Dispositifs de réalité virtuelle. A. Dispositif immersif : l'Oculus Quest 2 (Reality Labs, USA) composé d'un casque (1) et de deux manettes (2) (Image adaptée de [58]). B. Dispositif non immersif : Jeu de baseball dans Wii Sport (Nintendo, Japon). (Image tirée de [59]). 18
- Figure 2-13 Thérapie Armeo® : (1) Patient dans un Armeo®Spring. (2) Patient jouant à un jeu (Casses-Briques) avec l'Armeo®Senso. (Photo : Hocoma, Suisse). 19
- Figure 2-14 Étapes d'un système de reconnaissance de formes : A. Diagramme en blocs des étapes de conception d'un système de reconnaissance de formes. B. Représentation graphique en 3D de trois caractéristiques discriminant les 3 classes d'Iris (Iris setosa, Iris versicolor, Iris virginica). 22
- Figure 2-15 Application des techniques de reconnaissance de formes basées sur des EMG en réadaptation. (Image tirée de [75]) 23
- Figure 2-16 Deux types de stratégies de classification : la classification unique et la classification en parallèle. Dans cet exemple, nous considérons une classification de quatre classes de mouvements sur deux articulations : flexion/extension du coude et flexion/extension du poignet. 25
- Figure 4-1 Photos d'un sujet dans les quatre positions de départ : A. Position neutre. B. Supination de l'avant-bras. C. Pronation de l'avant-bras. D. Flexion de l'épaule. 30
- Figure 4-2 Photos de sujets effectuant les quatre gestes fonctionnels. A. Pyramide : Former une pyramide de quatre cylindres en bois. B. Main-bouche : Réaliser un geste main-bouche à l'aide d'une cuillère ou d'une fourchette. C. Bouteille : Attraper une bouteille et verser de l'eau dans un verre. D. Porte : Ouvrir une porte. 30
- Figure 4-3 Sujet jouant au jeu *Pirates* sur l'Armeo®Senso. L'objectif de ce jeu est de tirer sur des pirates en déplaçant le curseur de visée par des mouvements du membre supérieur, puis tirer grâce à une préhension du joystick tenu en main. 31
- Figure 4-4 Photo de deux sujets effectuant le cinquième geste fonctionnel étudié (Brosse) : Se brosser les cheveux avec une brosse. A. Sujet avec les cheveux longs. B. Sujet avec les cheveux courts 32
- Figure 5-1 Sensor placement on a subject – Muscles number : biceps brachii (1), triceps brachii (2), brachioradialis (3), pronator teres (4), anterior deltoid (5), posterior deltoid (6),

infraspinatus (7), pectoralis major (8), palmaris longus (9), and extensor carpi radialis (10).
41

Figure 5-2. Measurement session – A. The three objects used for functional gesture: bottle (1), four wood cylinders (2), spoon (3). The door used for the fourth functional gesture was not represented. B. Neutral position for discrete gesture recording. C. Material needed for Armeo®Senso recording: Trigno (Delsys) base station and EMG-IMU sensors (1), EmgWorks (Delsys) software (2), Armeo®Senso software (3), wearable Armeo®Senso IMU sensors (4). D. Subject playing with Armeo®Senso High Flyer (shoulder) game during session.43

Figure 5-3. Block Diagram of the classification system – Eight Long Short term Memory (LSTM) neural networks classify 14 movement classes : hand grip (HG), wrist flexion (WFlex), wrist extension (WExt), forearm supination (FSup), forearm pronation (FPro), elbow flexion (EFlex), elbow extension (EExt), shoulder flexion (SFlex), shoulder extension (SExt), shoulder abduction (SAbd), shoulder adduction (SAdd), shoulder horizontal abduction (SHAbd) and shoulder horizontal adduction (SHAdd), and a “no movement” (NM) class.47

Figure 5-4 Armeo®Senso Games : A. Subject playing Goalkeeper. B. Subject playing Hocokart.
49

Figure 5-5 Movement Target Grid for Armeo®Senso Games given by Armeo®Senso manufacturer (Hocoma, Switzerland) for games used in Armeo® Therapy. Dark blue cells are for the main movement targeted and light blue boxes are for the secondary movements targeted by the games. NaN values are for missing data.50

Figure 5-6. LSTM classification accuracy with test data with a data segmentation of 500 ms and 250 ms overlapping windows.....51

Figure 5-7. Movement Components for 3 subjects during functional gesture “Bottle”: A. Movements components for subject N°16. B. Movement components for subject n°10. C. Movement components for subject n°4.....52

Figure 5-8. Temporal distribution of movement components between subjects in the functional gesture “Bottle”.53

Figure 5-9. Average decomposition sequence into 14-movements class for three functional gestures: A. Bottle. B. Door. C. Hand-to-Mouth	53
Figure 5-10. Temporal Distribution of the 14 Movement Components for all subjects during the functional gesture “Blocks”.	54
Figure 5-11. Movement Target Grid for Arneo@Senso Games calculated by the MDPC algorithm. The value of each DoF corresponds to the percentage of time windows where this gesture was detected in the game on all the subjects who performed this game.	55
Figure 6-1 Précision de classification de LSTM entraînés avec des données en position neutre uniquement, ou avec des données en position neutre et supplémentaires (pronation de l’avant-bras, supination de l’avant-bras et flexion de l’épaule). La taille des fenêtres est de 500ms.	67
Figure 6-2 Geste fonctionnel moyen pour tous les sujets pour chacun des gestes fonctionnels, avec les données uniquement en position neutre. A. Bouteille. B. Porte. C. Main-bouche. D. Pyramide. C. Brosse	68
Figure 6-3 Geste moyen sur tous les sujets du geste fonctionnel « Brosse »	68
Figure 6-4 Exemples de décomposition de mouvements du geste fonctionnel « Brosse » chez 3 sujets. A. Décomposition chez le sujet n°1. B. Décomposition chez le sujet n°11. C. Décomposition chez le sujet n°13.	69

LISTE DES SIGLES ET ABREVIATIONS

ACC accéléromètre

ARAT « Action Research Arm Test », test d'action et recherche pour le bras

BBT « Box and Block Test », test de blocs et boîte

Pyramide geste fonctionnel de formation d'une pyramide de 4 blocs cylindriques

Bouteille geste fonctionnel de préhension d'une bouteille

DDL degré de liberté

Porte geste fonctionnel d'ouverture de porte

Brosse geste fonctionnel d'un brossage de cheveux

Main-bouche geste fonctionnel de main-bouche

EMG électromyographie

IMU « inertial measurement unit », unité de mesure inertielle

KNN « k-nearest neighbor », méthode des k plus proches voisins

LDA « linear discriminant analysis », analyse discriminante linéaire

LSTM « long short-term memory », réseau de neurones de longue mémoire à court terme

MACS « Manual Ability Classification System », système de classification de l'habileté manuelle

MAL « Motor Activity Log », logarithme de l'activité motrice

MAS « Modified Ashworth Scale », échelle d'Ashworth modifiée

MUAP « motor unit action potential », potentiel d'action d'une unité motrice

sEMG « surface electromyography », électromyographie de surface

SVM « support vector machine », machine à vecteur de support

TD typiquement développé

RV réalité virtuelle

LISTE DES ANNEXES

Annexe A Graphiques supplémentaires des gestes fonctionnels	83
Annexe B Exemples de signaux électromyographiques	84

CHAPITRE 1 INTRODUCTION

Les maladies neuromusculaires ont une prévalence de 13,4‰ chez les adultes et 5,4‰ chez les enfants au Canada [1]. S'il existe une grande variété de maladies neuromusculaires (paralysie cérébrale, dystrophie musculaire, troubles neuromusculaires post-accident vasculaire cérébral, etc.), la plupart de ces maladies se traduisent au quotidien par des troubles de la coordination du patient associés à une faiblesse musculaire [2]. Ces troubles gênent les patients dans la réalisation d'activités de la vie quotidienne comme manger, boire ou écrire dans le cas des membres supérieurs.

Les traitements de ces affections, qu'ils soient chirurgicaux, pharmaceutiques ou de réadaptation, varient en fonction de la sévérité et du diagnostic clinique du patient. Les technologies de réalité virtuelle (RV) associées à des jeux spécifiques à la réadaptation permettent de compléter les méthodes traditionnelles de réadaptation dans l'amélioration de la mobilité du patient et de sa qualité de vie [3]. Ces nouvelles modalités ont déjà montré leur potentiel en réadaptation en termes de récupération motrice des patients [4, 5], mais leur utilisation pourrait être améliorée, notamment en adaptant mieux les séances au besoin des patients. Cette personnalisation implique le choix d'un défi approprié à chaque patient, en termes de choix de jeux de RV et de niveau de difficulté, selon ses capacités physiques et mentales ainsi que selon les objectifs thérapeutiques de la séance. Dans le cadre des séances de réalité virtuelle, il est ainsi particulièrement important de s'assurer de l'adéquation entre les objectifs thérapeutiques de la séance (c'est-à-dire les mouvements et articulations à travailler) et les mouvements réellement effectués par le patient lors de l'utilisation des jeux. Les mouvements humains étant naturellement complexes, notamment en termes de segments et articulations actionnés simultanément, l'évaluation des mouvements des membres supérieurs engendre un besoin d'un outil de décomposition des séquences de mouvements en composantes de mouvements simples à un seul degré de liberté (DDL).

La décomposition de mouvements à l'aide d'algorithme d'intelligence artificielle utilisant la reconnaissance de formes a déjà été abordée dans plusieurs études concernant les systèmes de contrôle de prothèses myoélectriques. Cependant, aucune étude n'a pris en compte la totalité du membre supérieur, incluant l'épaule. De plus, il n'y a encore eu aucune application d'algorithmes de décomposition de mouvements à des gestes réels ou des séquences lors de mouvements de séances de réadaptation.

Dans ce contexte, l'objectif de ce mémoire est de développer une solution algorithmique permettant de décomposer les composantes de mouvement issues de séquences de mouvements complexes simultanés lors de gestes libres des patients en 3D. Un sous-objectif est d'appliquer cet algorithme de classification à des gestes fonctionnels de la vie quotidienne, ainsi qu'à des mouvements réalisés par les sujets lors de séances de réadaptation avec un dispositif de réalité virtuelle.

L'étude a été menée sur 18 sujets adultes sains équipés de capteurs électromyographiques et cinématiques, qui ont réalisé des gestes simples à 1 DDL de 14 classes de mouvements simples. Ils ont également effectué des gestes fonctionnels, et testé des jeux de réadaptation sur un dispositif de RV afin de pouvoir évaluer les performances de l'algorithme.

Le Chapitre 2 présente une revue des connaissances ainsi que le contexte théorique de l'étude, notamment l'anatomie du membre supérieur, les moyens d'évaluation du niveau fonctionnel, les technologies de réadaptation robotique et de RV, ainsi que les méthodes de reconnaissance de formes. Le Chapitre 3 présente l'objectif et les sous-objectifs du projet. Le Chapitre 4 présente un article constitutif de mon projet qui vient d'être soumis pour publication. La méthodologie détaillée ainsi que les résultats principaux de l'étude sur la précision de classification et l'application de notre algorithme y sont exposés. Le Chapitre 5 résume la méthodologie de l'étude et apporte des détails supplémentaires sur les analyses réalisées. Des résultats complémentaires non détaillés dans l'article sont exposés au Chapitre 6. L'article et les résultats complémentaires sont discutés au Chapitre 7, qui apporte aussi les limites et perspectives de l'article. Le Chapitre 8 conclut ce mémoire.

CHAPITRE 2 REVUE DES CONNAISSANCES

Dans un premier temps, l'anatomie fonctionnelle du membre supérieur sera présentée en Section 2.1 en s'appuyant sur les systèmes ostéoarticulaires et le système musculaire dont cette étude analysera respectivement le mouvement et l'activité. Dans un second temps, les méthodes d'évaluation du niveau fonctionnel des patients pour le membre supérieur, notamment électromyographiques et cinématiques utilisées dans cette étude, seront décrites en Section 2.2. Ensuite, les nouvelles technologies robotiques et de réalité virtuelle assistant les thérapies seront présentées en Section 2.3. Enfin, le domaine de la reconnaissance des formes sera expliqué en Section 2.4 pour mettre en évidence les défis actuels de la décomposition de mouvements complexes et la stratégie utilisée.

2.1 Anatomie du membre supérieur

Le membre supérieur est un membre mobile dont la principale fonction est le positionnement de la main d'un individu dans l'espace. Le membre supérieur est attaché au tronc par l'articulation de l'épaule et va jusqu'à la main [6]. Il peut être divisé en quatre segments qui le composent : l'épaule, le bras, l'avant-bras et la main (Figure 2-1).




Figure 2-1 Anatomie osseuse du membre supérieur, vue frontale (Image adaptée de [7]).

2.1.1 Système ostéoarticulaire

2.1.1.1 L'épaule

Seuls trois éléments osseux constituent le segment de l'épaule : la clavicule et la scapula (ou omoplate) qui forment ensemble la ceinture scapulaire, ainsi que la partie proximale de l'humérus (Figure 2-1). La clavicule est le seul os permettant de rattacher le tronc et l'épaule ; la fonction étant essentiellement assurée par des muscles. Cette particularité rend l'épaule mobile par rapport au reste du corps [6].

L'épaule est constituée de trois articulations : l'articulation sternoclaviculaire, l'articulation acromioclaviculaire et enfin l'articulation glénohumérale. Les deux premières articulations bougent conjointement pour permettre la mobilisation de la scapula contre la paroi thoracique, augmentant la mobilité globale du membre supérieur [6]. La structure de l'épaule est complexe et lui donne une grande mobilité permettant de nombreux mouvements et plusieurs DDL au niveau de cette région :

- La flexion et l'extension de l'épaule (Figure 2-2.A).
- L'abduction horizontale, aussi appelée extension horizontale de l'épaule, et l'adduction horizontale de l'épaule, aussi appelée flexion horizontale de l'épaule (Figure 2-2.B).
- La rotation médiale et la rotation latérale de l'épaule (Figure 2-3.A).
- L'abduction et l'adduction de l'épaule (Figure 2-3.B).




Figure 2-2 Mouvements de l'épaule : A. Flexion/extension de l'épaule. B. Abduction/adduction horizontale de l'épaule (Image adaptée de [8]).

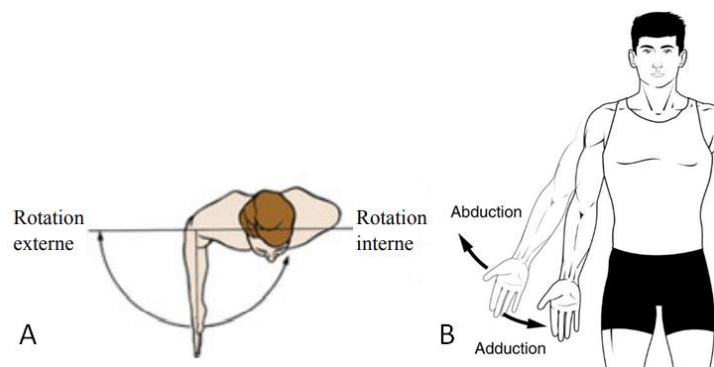


Figure 2-3 Mouvements de l'épaule : A. Rotation latérale/médiale de l'épaule (Image adaptée de [9]). B. Abduction/adduction de l'épaule (Image tirée de [10]).

2.1.1.2 Le bras et l'avant-bras

Le bras est le segment du membre supérieur situé entre l'épaule et le coude tandis que l'avant-bras se situe entre le coude et le poignet (Figure 2-1). L'avant-bras est constitué de deux structures osseuses : le radius en latéral et l'ulna en médial. La structure osseuse du bras est l'humérus qui s'insère sur la partie proximale du radius et de l'ulna au niveau de l'articulation du coude par une série complexe de ligaments [6].

La pronation et la supination de l'avant-bras sont assurées par une rotation du radius au niveau du coude. Cela entraîne également son passage en avant de l'ulna au niveau du poignet, à l'extrémité distale de l'avant-bras. Tout au long des mouvements, les os sont maintenus ensemble par la membrane interosseuse le long des diaphyses des deux os, ainsi qu'un ligament et un disque articulaire au niveau des articulations radio-ulnaires proximale et radiale [6].

La structure osseuse du bras et de l'avant-bras ne permet que deux DDL au niveau de ces régions :

- La flexion et l'extension du coude (Figure 2-4)
- La pronation et la supination de l'avant-bras (Figure 2-5)

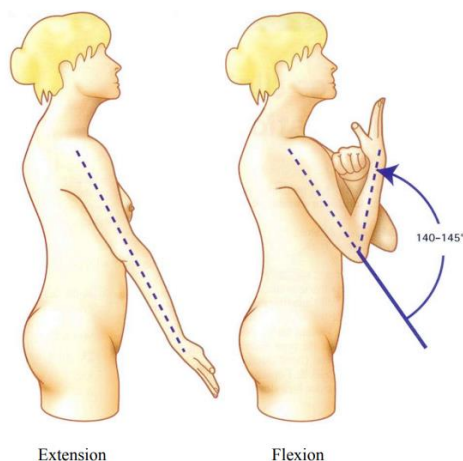


Figure 2-4 Mouvement de flexion et d'extension du coude (Image tirée de [11]).

2.1.1.3 La main

La main est le segment du membre supérieur le plus distal. Elle se subdivise en trois parties visibles sur la Figure 2-1 : le poignet, le métacarpe et les doigts au nombre de cinq. La structure osseuse est également divisée en trois groupes selon leur appartenance à une subdivision : les os du carpe formant le poignet, les métacarpiens pour le métacarpe ainsi que les phalanges pour les doigts. La main comporte au total quatre types d'articulations situées entre chaque groupe permettant d'expliquer sa dextérité : le poignet, l'articulation du carpe, les articulations carpométacarpiennes, ainsi que les articulations métacarpophalangiennes [6]. Les articulations interphalangiennes de la main permettent quant à elles les mouvements de flexion et d'extension des différentes phalanges des doigts.

Cette structure ostéoarticulaire permet de nombreux mouvements au niveau des différentes articulations de la main. Pour le poignet, il s'agit essentiellement de quatre mouvements (Figure 2-5) :

- La flexion et l'extension du poignet.
- L'abduction et l'adduction du poignet.

L'ensemble des flexions-extensions des doigts au niveau des différentes articulations permet les mouvements d'ouverture et de fermeture de la main visibles en Figure 2-6, et donc la préhension de la main.




Figure 2-5 Mouvements possibles de l'avant-bras (pronation, supination) et du poignet (flexion, extension, abduction, adduction) (Image tirée de [12])




Figure 2-6 Mouvements de préhension de la main : A. Ouverture de la main. B. Fermeture de la main

2.1.2 Système musculaire

2.1.2.1 Présentation des muscles principaux du membre supérieur

Les muscles du membre supérieur permettent le raccord de l'épaule au reste du tronc et sont les moteurs du membre supérieur. Ils sont séparés en différentes catégories selon leur localisation et leur profondeur par rapport à l'épiderme.

Les muscles principaux dans les mouvements de l'épaule sont le grand pectoral, le trapèze, le grand rond, le grand dorsal et le deltoïde (Figure 2-7.A), ainsi que tous les muscles de la coiffe des rotateurs (Figure 2-7.B). Ces derniers sont les muscles qui unissent la scapula à l'humérus et permettent la grande mobilité de l'épaule autour de l'articulation glénohumérale [6].

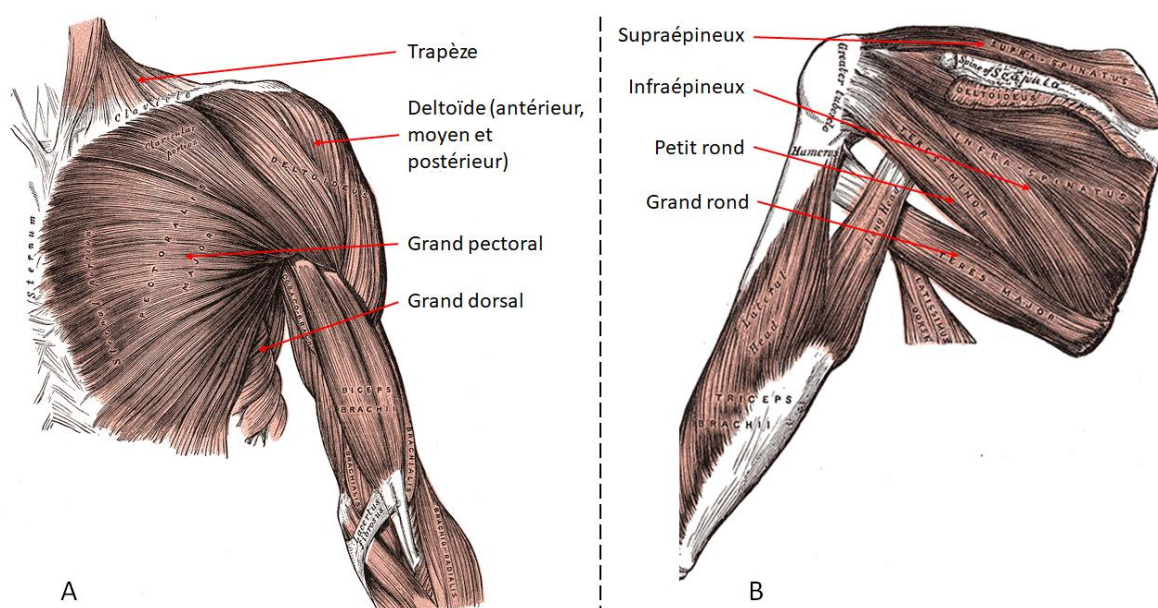


Figure 2-7 Muscles principaux de l'épaule : A. Épaule antérieure. B. Muscles de la coiffe des rotateurs (Images adaptées de [13]).

Les muscles des segments du bras et de l'avant-bras sont séparés par le squelette et les fascias en compartiments antérieurs (muscles fléchisseurs) et postérieurs (muscles extenseurs) [6]. Les muscles du bras agissent principalement sur l'articulation du coude ; le biceps brachial (deux chefs), le coracobrachial (couches superficielles) et le brachial (couche profonde) composent le

compartiment antérieur (Figure 2-8.B et Figure 2-8.C), tandis que le triceps brachial compose seul le compartiment postérieur (Figure 2-8.A). Les muscles de l'avant-bras s'activent essentiellement sur les mouvements du poignet et de la main. Pour la couche superficielle de l'avant-bras, le compartiment antérieur se compose du rond pronateur, le long palmaire et les fléchisseurs radial et ulnaire du carpe (Figure 2-9.A) [6]. Le compartiment postérieur se compose du brachioradial (bien que situé sur la face antérieure de l'avant-bras), des extenseurs des doigts, des extenseurs radial et ulnaire du carpe ainsi que de l'extenseur propre de l'auriculaire (Figure 2-9.B) [6].




Figure 2-8 Muscles principaux du bras : A. Triceps brachial (compartiment postérieur). B. Biceps brachial (compartiment antérieur). C. Brachialis (compartiment antérieur) (Images adaptées de [13])




Figure 2-9 Muscles de la couche superficielle de l'avant-bras : A. Compartiment antérieur (sauf brachioradial). B. Compartiment postérieur. (Image adaptée de [13])

2.1.2.2 Muscles impliqués lors des mouvements du membre supérieur

La mobilité de l'épaule, du bras, de l'avant-bras et de la main est assurée par de nombreux muscles. Le Tableau 2-1 présente les principaux muscles impliqués dans les mouvements du membre supérieur [14]. Les articulations « épaule » et « main » sont des raccourcis pour l'ensemble des articulations faisant partie de l'épaule et de la main (sauf poignet).

Tableau 2-1 Récapitulatif des muscles impliqués dans les mouvements du membre supérieur.

<i>Articulation</i>	Mouvements	Muscles impliqués
<i>Épaule</i>	Flexion	Deltoïde, Supra-épineux, Grand Pectoral, Coracobrachial, Biceps brachial
	Extension	Deltoïde, Grand dorsal, Grand rond, Petit rond, Triceps brachial
	Abduction	Deltoïde moyen, Supra-épineux, Infra-épineux, Sub-scapulaire, Biceps brachial
	Adduction	Grand pectoral, Grand Dorsal, Sub-scapulaire, Grand rond
	Abduction Horizontale	Infra-épineux, Deltoïde postérieur, Grand rond, Petit rond
	Adduction Horizontale	Grand Pectorel, Deltoïde antérieur
	Rotation latérale	Infra-épineux, Petit rond, Deltoïde postérieur
	Rotation médiale	Grand pectoral, Grand dorsal, Sub-scapulaire, Deltoïde antérieur, Grand rond
<i>Coude</i>	Flexion	Biceps brachial, Brachial, Brachioradialis, Rond pronateur, Fléchisseur radial du carpe
	Extension	Triceps brachial, Biceps brachial, Extenseur des doigts, Extenseurs ulnaire et radial du carpe
<i>Poignet</i>	Pronation	Rond pronateur, Carré pronateur, Brachioradial
	Supination	Long Supinateur, Biceps brachial
	Flexion	Fléchisseurs ulnaire et radial du carpe, Fléchisseur des doigts superficiel
	Extension	Extenseurs ulnaire et radial du carpe, Extenseur des doigts
	Abduction	Fléchisseur radial du carpe, extenseur radial du carpe, Abducteur du pouce
	Adduction	Extenseur ulnaire du carpe, Fléchisseur ulnaire du capre
<i>Main</i>	Ouverture	Extenseur des doigts
	Fermeture	Fléchisseur profond et superficiel des doigts

2.2 Méthodes quantitatives d'évaluation du niveau fonctionnel du membre supérieur

L'évaluation du niveau fonctionnel de chaque patient atteint de troubles neuromusculaires du membre supérieur est un des principes de base de la réadaptation. Cela permet de réaliser un programme de thérapies adapté aux besoins du patient. L'évaluation peut se faire de différentes manières détaillées dans cette section.

2.2.1 Les échelles d'évaluation

De nombreuses échelles d'évaluation ont été développées afin d'évaluer l'atteinte fonctionnelle du membre supérieur chez des patients souffrants de troubles neuromusculaires. Les échelles fonctionnelles utilisées dépendent généralement de la pathologie et de l'âge du patient (enfant ou adulte), ainsi que des paramètres évalués. Quelques échelles conventionnelles fréquemment utilisées en réadaptation sont présentées dans le Tableau 2-2 [14-17].

Tableau 2-2 Cinq échelles conventionnelles d'évaluation du niveau fonctionnel du membre supérieur

<i>Nom de l'échelle</i>	Paramètres évalués	Type de catégorisation
<i>Ashworth Modifié (MAS)</i>	Évaluation de la spasticité musculaire Mesure le tonus musculaire (à la fois mécanique et neurologique)	Division en 5 catégories: 0, 1, 1+, 2, 3, 4
<i>Motor Activity Log (MAL)</i>	Évaluation de la performance fonctionnelle du membre supérieur dans la vie réelle 4 versions selon le nombre d'objets	2 échelles de 1 à 5: Amount of Use et Quality of Movement
<i>Action Research Arm Test (ARAT)</i>	Évaluation de la performance des extrémités des membres supérieurs (fonction, coordination et dextérité) Déplacement de 19 objets avec difficulté croissante	Score de 0 à 3 pour chaque objet
<i>Manual Ability Classification System (MACS)</i>	Évaluation de l'habileté manuelle des enfants atteints de paralysie cérébrale dans les activités quotidiennes	Classification de I à V
<i>Box and Block Test (BBT)</i>	Évaluation de la dextérité manuelle du membre supérieur (unilatéral) Déplacement de blocs d'un compartiment à un autre séparé par une cloison d'une boîte	Nombre de blocs transférés en un temps limité

2.2.2 Mesures et évaluation de la performance fonctionnelle à l'aide de données cinématiques et électromyographiques

Les échelles d'évaluation cliniques présentées dans la Section 2.2.1 sont le standard dans l'évaluation et la quantification de la performance fonctionnelle des patients atteints de troubles neuromusculaires aux membres supérieurs. Cependant, ces outils de mesure nécessitent des ressources humaines et temporelles importantes, et sont limités par leur fiabilité inter et intra-clinicien [18]. Ces dernières années, de nombreuses études ont développé de nouvelles méthodes d'évaluation du niveau fonctionnel des patients, notamment grâce à l'utilisation de données cinématiques et électromyographiques associées à de l'intelligence artificielle.

2.2.2.1 Données électromyographiques

Le signal myoélectrique est le signal électrique produit lors des activités musculaires. Lors d'un mouvement, le cerveau envoie, grâce au système nerveux central, des signaux d'activations musculaires aux muscles recrutés. Ces muscles sont sous-divisés en unités motrices selon leur innervation. Une unité motrice est l'élément central du système musculaire, constituée d'un motoneurone innervant un groupe de fibres musculaires [19] (Figure 2-10). Plus la force à générer est importante, plus les motoneurones activés à l'aide de potentiels d'actions sont nombreux. Le signal myoélectrique est la superposition spatiale et temporelle des multiples potentiels d'action d'unités motrices (MUAP) [20]. L'électromyographie est utilisée pour enregistrer ces signaux myoélectriques. Dans le cas de signaux électromyographiques de surface (sEMG), des électrodes sèches ou gélifiées sont appliquées sur la peau du patient afin de capter les MUAP sous forme de différence de potentiel (Figure 2-10). Il existe également des électrodes intramusculaires sous forme d'aiguilles ou d'électrodes à fil, qui sont plus invasives et nécessitent des compétences médicales. En effet, si les électrodes de surface sont simples et rapides d'utilisation, leur positionnement sur la peau peut induire du bruit supplémentaire et est restreint aux muscles superficiels. Malgré ces inconvénients, les sEMG sont souvent privilégiés pour leur caractère non invasif facilitant les protocoles expérimentaux.




Figure 2-10 Une unité motrice constituée d'un motoneurone innervant un groupe de fibres musculaires. Dans un modèle d'activation linéaire, le potentiel d'action de l'unité motrice (MUAP) est la réponse électrique à chaque stimulation ; et l'ensemble des MUAP génère un paquet de MUAP (MUAP train). (Image tirée de [20])

Les signaux sEMG étant de faible amplitude et sensibles au bruit, ceux-ci doivent être amplifiés et filtrés avant toute application [21]. Il existe de nombreuses méthodes de filtrage des signaux sEMG. Les plus utilisées impliquent le passage des signaux à travers un filtre passe-bande pour filtrer les fréquences parasites, ainsi qu'une rectification half-wave (les valeurs négatives deviennent nulles) ou full-wave (valeur absolue). Un filtre passe-bas peut ensuite être appliqué pour lisser le signal [22].

Pour permettre une meilleure interprétation des signaux sEMG, il est nécessaire d'en extraire des caractéristiques. Ces dernières peuvent être dans le domaine temporel ou dans le domaine fréquentiel. Les caractéristiques temporelles, comme la variance ou la valeur efficace, sont mesurées en fonction du temps et ont généralement une implémentation simple [23]. Les caractéristiques fréquentielles, comme la fréquence moyenne ou médiane, sont généralement utilisées pour détecter les anomalies neuronales et la fatigue musculaire [23]. Des caractéristiques peuvent aussi se trouver dans les deux domaines simultanément [24]. Les caractéristiques les plus pertinentes sont celles permettant la meilleure discrimination interclasses et dépendent du choix du classificateur, des classes à discriminer et des signaux enregistrés.

Les sEMG sont aujourd'hui vus comme l'une des meilleures méthodes de qualification et de quantification de l'activité musculaire. De nombreuses méthodes d'analyse des sEMG allant des modèles de régression à l'utilisation de réseaux de neurones ou algorithmes de classification ont été développées pour extraire des indicateurs les plus précis possibles des signaux sEMG [25]. Plusieurs études [22, 26-31] ont utilisé les données électromyographiques, parfois couplées à des données cinématiques afin de calculer de nouveaux indices susceptibles d'évaluer la fonction du membre supérieur. Les outils développés ont parfois été comparés avec succès à des échelles d'évaluation conventionnelles comme MACS [28] ou BBT [31], montrant le potentiel du développement de tels outils quantitatifs d'évaluation du niveau fonctionnel des patients.

2.2.2.2 Données cinématiques

Le positionnement des différents segments du membre supérieur affecte les signaux EMG des muscles [32-34]. Par exemple, pour un même mouvement de flexion du poignet, les signaux sEMG mesurés seront différents selon que l'avant-bras est en pronation ou en supination. Afin de contrer cet « effet de la position du membre », des études ont enrichi les données électromyographiques avec des mesures cinématiques donnant une information sur le positionnement du membre et permettant de meilleures performances des algorithmes de classification et d'évaluation du niveau fonctionnel [27, 35].

Les mesures cinématiques reposent généralement sur des données d'accélération, obtenues à l'aide de centrales inertielles, ou des données de positions, obtenues par des capteurs rétro réfléchissants placés sur des points fixes de la structure osseuse du sujet [36]. Des caméras infrarouges captent la réflexion du rayonnement infrarouge des capteurs afin d'identifier leur position en 2D. L'assemblage des positions 2D de chaque capteur des différentes caméras permet de reconstruire le mouvement en 3D. Les mesures cinématiques obtenues peuvent ensuite être intégrées à un modèle cinématique inverse du membre supérieur pour calculer les coordonnées relatives articulaires.

L'acquisition de données cinématiques par caméras infrarouges requiert l'accès à un laboratoire d'analyse de mouvement et du matériel coûteux. De plus, ces séances de prises de mesures cinématiques sont longues et pénibles pour les sujets avec le positionnement des capteurs rétro réfléchissants. C'est pourquoi les centrales inertielles, faciles et rapides d'utilisation, sont parfois privilégiées malgré une moins bonne précision des mesures obtenues.

2.3 Thérapie assistée par la robotique et l'intelligence artificielle

Les séances de thérapie en réadaptation sont basées sur les principes de la neuroplasticité, notamment l'importance de l'intensité, la répétition, la spécificité de la thérapie et l'expérience du patient [37]. La robotique et les dispositifs d'assistance à la réadaptation permettent de faciliter la prise en compte de ces principes, augmentant l'efficacité de la thérapie.

2.3.1 Les solutions technologiques en réadaptation

2.3.1.1 Les robots de réadaptation du membre supérieur

Les robots de réadaptation pour le membre supérieur sont de plus en plus inclus dans la programmation de blocs de thérapies pour leur complémentarité et efficacité face aux méthodes plus traditionnelles de réadaptation [3].

Les robots de réadaptation peuvent être catégorisés selon différents critères [38]:

- Selon l'approche thérapeutique qui peut être passive, ou active si le robot attend un signal du patient pour l'assister dans son mouvement. L'approche de mouvement passif en continu ne requiert aucun effort volontaire du patient pour effectuer le mouvement. Cette approche est principalement utilisée dans les premières étapes de la thérapie, lorsque le patient n'a pas encore de réponse du membre affecté. Au contraire, l'approche active requiert un signal du patient (EMG ou début de mouvement) pour effectuer le mouvement avec lui. La thérapie active permet l'augmentation progressive des performances du patient grâce à une adaptation graduelle du niveau d'assistance ou d'opposition [39].
- Selon la structure du robot qui peut être un effecteur terminal ou un exosquelette. Un robot avec effecteurs terminaux n'a qu'une poignée distale mobile, comme le REAPlan (Axinosis, Belgique) (Figure 2-11.A). L'avant-bras du patient est installé dans une orthèse fixée à cette poignée et suit une trajectoire spécifique. Les robots avec effecteurs terminaux sont capables de s'adapter à différentes tailles ou types de trajectoires, mais sont en revanche incapables d'effectuer un mouvement de rotation comme une pronation ou une supination. Les robots orthèses ou exosquelettes, comme l'ARMin III [40], enveloppent la totalité du membre atteint (Figure 2-11.B). Ils calculent le couple nécessaire pour chaque

articulation de l'exosquelette afin de contrôler le mouvement du membre supérieur du patient.




Figure 2-11 Robots de réadaptation du membre supérieur. A. Robot à effecteur terminal, le REAPlan (Image tirée de [41]). (1) Poignet du robot à effecteur terminal plan. (2) Interface visuelle pour le patient. (3) Interface pour le physiothérapeute. B. Robot orthèse ou exosquelette, ARMin III (Image tirée de [40]).

2.3.1.2 Réadaptation utilisant la réalité virtuelle

Les systèmes d'environnement de jeux interactifs, associés à la réalité virtuelle (RV), sont reconnus et de plus en plus utilisés en réadaptation [42]. La capacité de mesurer les mouvements des patients de façon de plus en plus fiable depuis la Wii™ (Nintendo©, Kyoto, Japon) [43], notamment grâce à des centrales inertielle [44], a permis l'essor de ces systèmes en réadaptation liant thérapie et amusement [4, 45-47]. Il existe deux types de RV, immersive et non immersive [48]. La RV immersive permet à l'utilisateur de se sentir réellement au sein de l'environnement virtuel créé et d'interagir avec lui, notamment grâce à des casques de RV comme l'Oculus Rift recouvrant les yeux et de divers dispositifs sans fil haptiques (Figure 2-12.A). La RV non immersive ne contourne pas totalement les perceptions sensorielles et permet uniquement à l'utilisateur d'être observateur de l'univers virtuel. Les dispositifs de RV non immersive reposent sur des écrans ou des consoles de jeux vidéos, ainsi que des dispositifs permettant d'interagir avec l'environnement comme des souris, claviers ou manettes de contrôle (Figure 2-12.B).

Les systèmes de jeux par RV utilisent généralement des données cinématiques du patient pour reconstituer son mouvement et lui permettre de commander le jeu par ses mouvements. Ce contrôle, associé à une interface visuelle interactive (Figure 2-11.A (2)), permet l'immersion du patient dans cet environnement virtuel et facilite la répétition et l'accomplissement des exercices de réadaptation. Les patients, particulièrement les enfants, sont plus motivés et impliqués dans leur thérapie [49], ce qui est crucial pour le succès de la réadaptation. Ces environnements permettent aussi de développer l'autonomie des patients lors des séances qui sont guidées par l'environnement virtuel. De tels dispositifs permettent ainsi de réduire le coût des thérapies en s'affranchissant de la supervision permanente d'un thérapeute [50], tout en impliquant le patient dans sa rééducation grâce à un environnement ludique et interactif [51].

Les plateformes de jeux en environnement virtuel ont déjà montré leur potentiel d'augmentation de la récupération motrice et la satisfaction des patients lors de thérapies de longue durée [43, 52]. Couplées à la robotique, elles permettent d'augmenter les performances motrices des patients significativement plus que les thérapies conventionnelles [53-55]. Si les premiers essais de thérapies utilisant la RV étaient basés sur des consoles et jeux commerciaux [43, 45], la conception d'appareils et jeux « sérieux » spécifiques à la réadaptation a vite été nécessaire afin de s'adapter aux besoins spécifiques de la réadaptation et aux limitations mentales ou physiques des patients [56, 57]. La conception de ces jeux reste un challenge afin de remplir les différentes tâches attendues d'un jeu « sérieux » de réadaptation motrice [56]:

1. Adapter la difficulté et l'expérience de jeu aux capacités physiques et mentales du patient afin d'éviter un sentiment de frustration et d'échec ;
2. Détecter les mauvaises postures et mauvaises utilisations de l'appareil ou du jeu, ce qui le rendrait plus délétère pour le patient qu'utile dans sa thérapie ;
3. Donner une rétroaction en temps réel au patient et au thérapeute, permettant notamment d'entretenir la motivation et éventuellement adapter la difficulté de l'exercice ;
4. Avoir un objectif thérapeutique clair lors de la conception du jeu permettant de respecter le principe de spécificité de neuroplasticité [37].




Figure 2-12 Dispositifs de réalité virtuelle. A. Dispositif immersif : l'Oculus Quest 2 (Reality Labs, USA) composé d'un casque (1) et de deux manettes (2) (Image adaptée de [58]). B. Dispositif non immersif : Jeu de baseball dans Wii Sport (Nintendo, Japon). (Image tirée de [59]).

2.3.2 La thérapie Armeo®

La thérapie Armeo® (Hocoma, Suisse), combinant plusieurs équipements comme l'Armeo®Spring et l'Armeo®Senso, repose sur un environnement de jeux virtuels spécialement développé pour la réadaptation du membre supérieur et une rétroaction augmentée permettant de longues séances de thérapie intensive tout en gardant la motivation du patient. L'efficacité de cette thérapie a été montrée par plus de 10 tests cliniques randomisés [54]. Si plus de cinquante études ont porté sur l'Armeo®Spring, l'Armeo®Senso reste beaucoup moins étudié avec deux publications à notre connaissance [50, 60].

La thérapie Armeo® combine deux dispositifs majeurs, l'Armeo®Spring et l'Armeo®Senso, et plusieurs modules pouvant s'ajouter comme l'Armeo®Power ou le ManovoSpring :

- L'Armeo®Spring est un exosquelette de réadaptation, tout comme l'ARMin III, et permet des thérapies actives unilatérales (Figure 2-13 (1)). L'exosquelette a un double rôle d'assistance motrice du patient dans ses mouvements et de dispositif de contrôle dans les jeux.
- L'Armeo®Senso n'est pas un robot de réadaptation, mais un système de réadaptation à RV non immersive permettant une thérapie unilatérale. L'Armeo®Senso utilise des capteurs IMU sans fil afin de détecter le mouvement du patient et le faire évoluer dans un

environnement virtuel en 3D de jeux ciblant spécifiquement certains mouvements de réadaptation (Figure 2-13 (2)). Ce dispositif est facile d'utilisation et peut s'utiliser chez soi sans supervision immédiate [60], ce qui en fait sa grande force [61]. Il est également portable et sa prise en main est facile pour un nouvel utilisateur.




Figure 2-13 Thérapie Armeo® : (1) Patient dans un Armeo®Spring. (2) Patient jouant à un jeu (Casses-Briques) avec l'Armeo®Senso. (Photo : Hocoma, Suisse).

2.3.3 Évaluation des thérapies grâce à l'intelligence artificielle

Les nouvelles technologies robotiques sont aussi un moyen d'évaluation des thérapies et de l'amélioration des patients grâce à la multitude de données qu'elles récoltent (temps, répétitions, données cinématiques, données électromyographiques, score de performances, amplitude de mouvements, etc.) [55, 62-64]. Les données cinématiques ont montré leur fiabilité dans la reconstitution du mouvement [44] et sont des indicateurs précieux du niveau de performance des patients [18].

Ces données permettent de suivre l'évolution du patient lors du bloc de thérapies, mais aussi de mesurer des indicateurs de l'efficacité des thérapies pour permettre leur optimisation. Des études ont montré l'efficacité des thérapies assistées par la robotique ou les environnements de jeux virtuels [43, 51, 53, 54]. Mais il n'existe pas une seule thérapie optimale pour tous. Chaque patient requiert une thérapie et un niveau de difficulté adaptés à ses besoins et ses capacités [65]. Des études ont développé des solutions à la problématique de l'adaptation des thérapies à chaque patient [62, 65, 66]. Ces solutions algorithmiques sont basées sur des données électromyographiques [65] et cinématiques [66, 67] associées à de l'intelligence artificielle afin d'extraire les indicateurs nécessaires à l'évaluation de la performance du patient et l'adaptation de la thérapie.

Dans le cadre de la réalité virtuelle, ces évaluations peuvent aussi servir à adapter les choix de jeux à la pathologie du patient ainsi que vérifier le respect des quatre fonctions des jeux « sérieux » de réadaptation énoncées en Section 2.3.1.2. L'intelligence artificielle permet notamment de donner une rétroaction sur la conception du jeu, c'est-à-dire l'accord entre ses objectifs thérapeutiques et la performance des patients l'utilisant. Pour la réadaptation du membre supérieur, un des objectifs est généralement le choix de l'articulation ou du mouvement simple à 1 DDL entraîné selon la pathologie du patient (pronation/supination du coude par exemple). L'évaluation de cet objectif thérapeutique implique la détermination du mouvement précis du patient. Cependant, les mouvements humains sont par nature complexes (à plusieurs DDL) et évolutifs dans le temps, rendant la détermination d'un mouvement simple à 1 DDL au sein d'une séquence complexe de mouvements combinés plus difficile que la classification de mouvements simples.

2.4 Reconnaissance de mouvements du membre supérieur

2.4.1 Reconnaissance de formes

Le terme de reconnaissance de formes englobe un grand nombre de problèmes de traitement de l'information. C'est un sous-domaine de l'intelligence artificielle qui utilise les statistiques et l'apprentissage automatique [68]. L'objectif principal de la reconnaissance de formes consiste à catégoriser des objets, qu'ils soient physiques ou des concepts abstraits (images, textes, signaux, mesures, etc.). Les systèmes de reconnaissances de formes sont généralement des petites parties de plus gros systèmes dont l'objectif est de prendre une décision en fonction de la classification de

chaque objet. La catégorisation des objets se fait à l'aide de la définition et de l'extraction de caractéristiques qui leur sont propres, afin de les classer dans différentes classes prédéfinies [69]. Les caractéristiques doivent être choisies de façon à pouvoir séparer les différentes classes. Par exemple, la classification des iris en 3 classes (*Iris setosa*, *Iris versicolor*, *Iris virginica*) peut se faire à l'aide de 3 caractéristiques : la longueur des sépales, la longueur des pétales et la largeur des pétales (Figure 2-14.B). Après l'acquisition des données et la définition des caractéristiques, il convient de définir la méthode de classification et la structure du classificateur choisi (Figure 2-14.A).

Chaque classificateur possède ses avantages et inconvénients selon le problème à résoudre. Les classificateurs les plus utilisés sont l'analyse discriminante linéaire (LDA) [70, 71], les machines à vecteurs de support (SVM) [27], la méthode des k-plus proches voisins (KNN) [72], et les réseaux de neurones [35, 73, 74]. La structure du classificateur dépend de la dimension du vecteur des caractéristiques et de la nature des objets à classer. L'entraînement du classificateur peut se faire de façon supervisée, non supervisée ou par renforcement. L'entraînement supervisé est le plus simple, mais nécessite une base de données dont on connaît déjà la vraie valeur, c'est-à-dire la classe d'appartenance (labels). Ce genre d'apprentissage est par exemple utilisé pour classer des photos d'objets à l'aide de base de données de photos connues. L'entraînement par renforcement ne repose pas sur des labels, mais sur un signal de récompense, positif ou négatif, afin d'avancer sur l'exécution d'une tâche telle que gagner une partie d'échecs. Enfin l'entraînement non supervisé n'a ni label, ni signal de récompense. L'apprentissage se fait par des associations de similarité entre les données et peut être utilisé sur des problèmes à données inconnues comme la reconnaissance vocale.

Le terme « précision de classification », employé fréquemment en reconnaissance de formes et dans la suite de ce mémoire fait référence au pourcentage de bonnes prédictions du classificateur sur le nombre de prédiction totale.

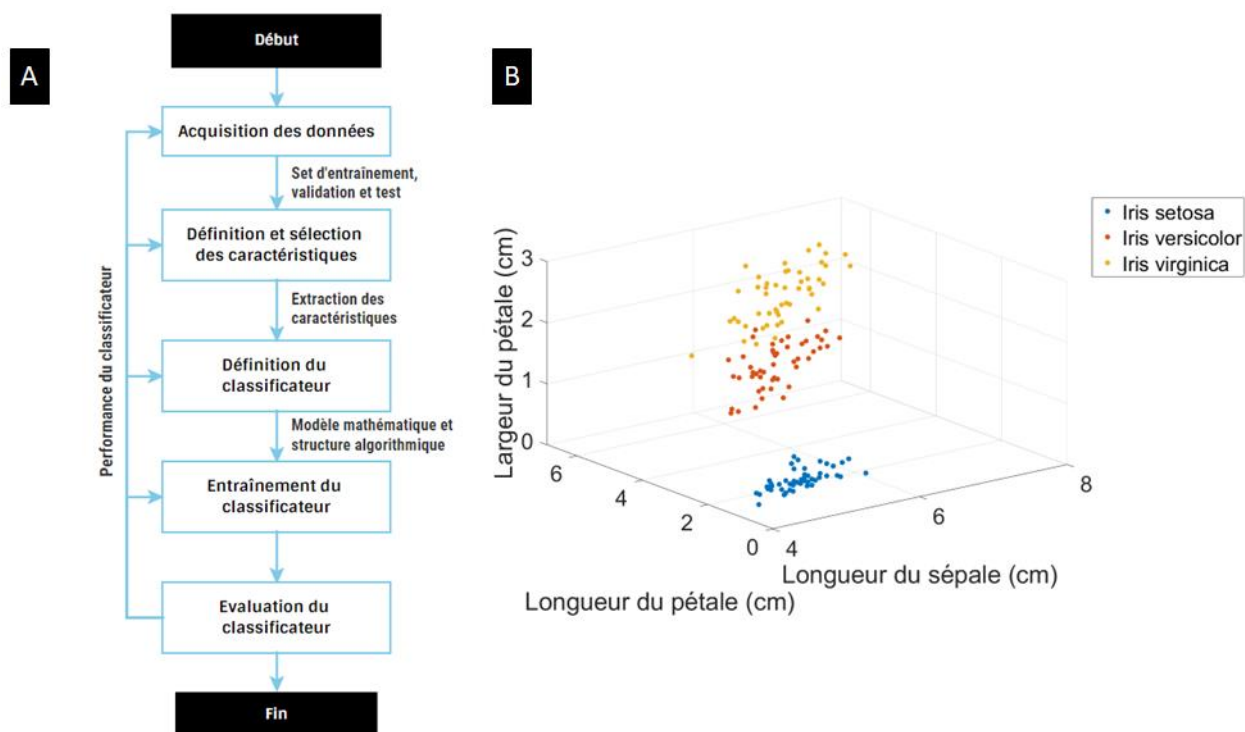


Figure 2-14 Étapes d'un système de reconnaissance de formes : A. Diagramme en blocs des étapes de conception d'un système de reconnaissance de formes. B. Représentation graphique en 3D de trois caractéristiques discriminant les 3 classes d'Iris (Iris setosa, Iris versicolor, Iris virginica).

2.4.2 Utilisation en réadaptation

L'apprentissage automatique et la reconnaissance de formes sont de plus en plus utilisées en réadaptation, notamment avec leur utilisation combinée avec les données électromyographiques et cinématiques des patients. Leurs applications sont multiples, allant de l'aide au diagnostic de maladies neuromusculaires aux stratégies de contrôle des robots et dispositifs d'assistance de réadaptation (Figure 2-15) [75]. L'apprentissage automatique est aussi utilisé pour l'évaluation de l'efficacité de la réadaptation et des nouvelles technologies (robotiques ou environnement virtuel) en thérapie comme expliqué dans la section 2.3.3 (Figure 2-15).

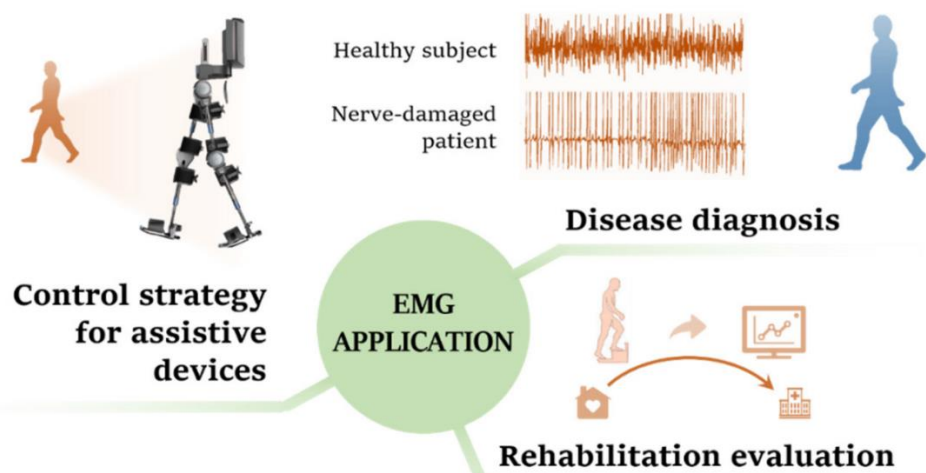


Figure 2-15 Application des techniques de reconnaissance de formes basées sur des EMG en réadaptation. (Image tirée de [75])

L'étude des stratégies de contrôle est l'un des domaines les plus actifs en réadaptation dans le développement de nouvelles méthodes de reconnaissances de formes basées sur des données EMG et IMU. Les récentes avancées dans les orthèses/prothèses myoélectriques ainsi que les robots de réadaptation ont nécessité de nouvelles méthodes de détermination et classification des mouvements humains [76-81]. Les systèmes de contrôle d'orthèses/prothèses nécessitent en effet une décomposition des intentions de mouvements du patient en composantes de mouvements simples à 1 DDL afin de pouvoir commander ces systèmes dynamiques. Cette problématique est similaire à la décomposition de séquences de mouvements complexes en mouvements simples unidimensionnels nécessaire à l'évaluation de l'efficacité et de la conception des jeux « sérieux » de réadaptation.

2.4.3 Classification de séquences de mouvements

2.4.3.1 Classification simultanée de mouvements complexes

La classification simultanée de différents mouvements est l'un des enjeux principaux actuels des systèmes de contrôle d'orthèses et prothèses myoélectriques. Comme expliqué précédemment, un classificateur permet de catégoriser des objets dans une classe prédéfinie. Ainsi, pour une entrée donnée, il ne peut y avoir qu'une seule sortie. Dans le cas de mouvements classifiés par EMG, un seul mouvement sera déterminé à partir des caractéristiques extraites des signaux EMG pour

chaque fenêtre temporelle. Or, les mouvements humains sont naturellement complexes et multidimensionnels. Pour pouvoir rendre compte de cette multidimensionnalité, il existe deux types d'approches : la classification séquentielle où chaque degré de liberté est déterminé successivement, et la classification simultanée où tous les degrés de liberté (DDL) sont déterminés simultanément pour chaque pas temporel. Si elle est plus simple d'implémentation, la classification séquentielle possède de nombreux inconvénients en vue d'une application en réadaptation. En effet, une classification séquentielle des mouvements entraîne une charge cognitive trop importante pour l'utilisateur qui doit prévoir tous ses mouvements et se voit incapable d'effectuer des mouvements complexes fluides et naturels [82]. Malgré une complexité d'implémentation, la classification simultanée avec des stratégies de reconnaissance de formes permet plus facilement un contrôle simultané multidimensionnel de systèmes myoélectriques [83].

2.4.3.2 Stratégie de classification en parallèle

Plusieurs stratégies de classification simultanée ont été proposées. Des solutions basées sur des canaux d'électromyographie intramusculaire indépendants [84-86] ont permis d'obtenir une classification simultanée de 3 à 6 DDL, mais ces méthodes invasives ne permettent pas une utilisation facile en réadaptation. D'autres technologies basées par exemple sur des signaux EMG à haute densité [77] sont prometteuses, mais encore peu matures.

L'une des stratégies les plus intuitives pour une classification simultanée est l'utilisation de classificateurs en parallèle, un pour chaque DDL. En effet, un classificateur unique pour tous les DDL ne permet d'obtenir qu'une seule sortie (une classe de mouvement) à chaque itération (Figure 2-16). Un unique classificateur ne peut donc faire qu'une classification séquentielle des mouvements complexes, un DDL à la fois. Au contraire, une classification en parallèle avec un classificateur par DDL comporte plusieurs sorties, avec une classe de mouvements par DDL (Figure 2-16). Cette stratégie de classification permet donc une classification simultanée de tous les DDL.

Dès 1973, trois DDL ont pu être discriminés par l'utilisation de signaux sEMG avec des séparateurs de classes hyperplans en parallèle calculés avec la méthode de Lawrence [87]. D'autres stratégies dérivées ont été proposées depuis avec une approche conditionnelle ou hiérarchique [70, 82], mais la stratégie de classification en parallèle a montré son efficacité pour la classification de 3 DDL en simultanée [71] et sa force face aux variations des signaux EMG [88]. Si cette technique n'a jamais

été utilisée à notre connaissance à plus de 3 DDL, sa simplicité d'implémentation peut permettre sa généralisation à de nombreux DDL comme le demande la décomposition de mouvements des membres supérieurs.

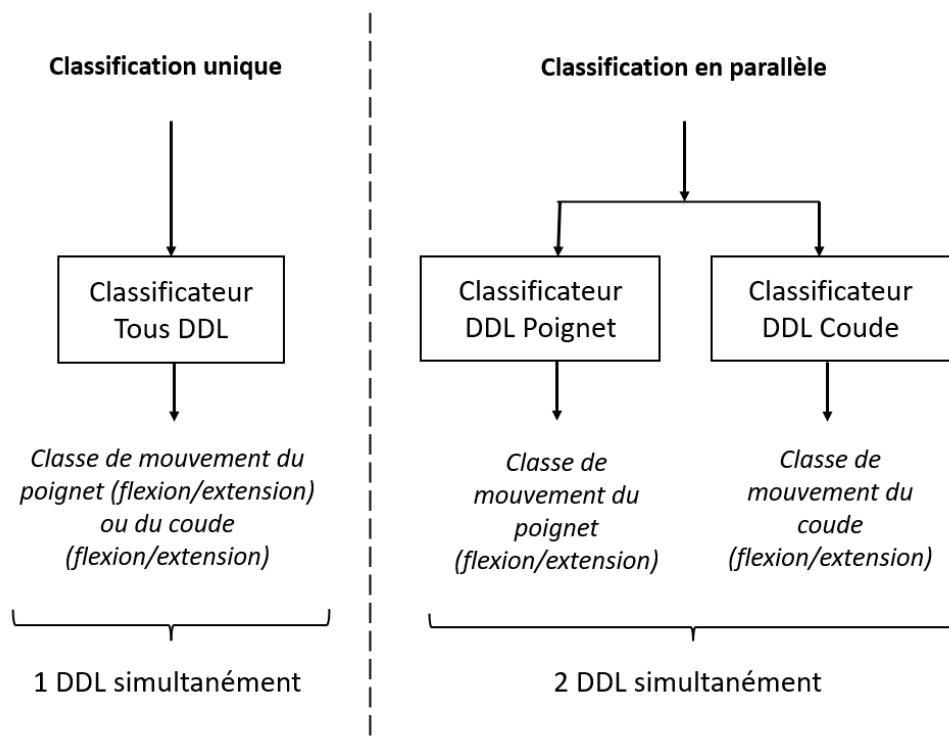


Figure 2-16 Deux types de stratégies de classification : la classification unique et la classification en parallèle. Dans cet exemple, nous considérons une classification de quatre classes de mouvements sur deux articulations : flexion/extension du coude et flexion/extension du poignet.

CHAPITRE 3 OBJECTIFS

3.1 Résumé de la problématique

L'évaluation du respect des quatre fonctions principales d'un jeu « sérieux » de réadaptation nécessite la détermination des mouvements travaillés lors de l'exécution du jeu par les patients. Cette détermination est ardue en raison de la complexité naturelle des mouvements humains, multidimensionnels. Elle nécessite la décomposition de ces séquences de mouvements complexes en composantes de mouvements simples à 1 DDL. Plusieurs méthodes de classification simultanée ont été développées dans le domaine des systèmes de contrôle de prothèses myoélectriques. Si le problème de la classification simultanée de mouvements et celle de la décomposition de séquences de mouvements complexes sont proches, plusieurs problématiques persistent pour une application directe des méthodes de contrôle à la décomposition de mouvements pour l'évaluation des thérapies de réadaptation :

- Les méthodes de classification simultanée non invasives ont rarement classifié plus de trois DDL simultanément, et aucune étude n'a intégré l'épaule dans les mouvements considérés. Or, les mouvements du membre supérieur au niveau des quatre principaux segments (main, avant-bras, bras et épaule) impliquent dans le cadre d'une modélisation simplifiée au moins sept DDL.
- La plupart des méthodes de classification simultanée présentées ici utilisent à la fois des mouvements simples (1 DDL) et combinés (2 DDL ou plus) pour la classification des mouvements. Si cette méthode permet d'obtenir un modèle plus représentatif de mouvements complexes, elle empêche la généralisation à de multiples DDL par la complexité et la longueur du protocole clinique qui en découlerait.
- À notre connaissance, aucune étude n'a appliqué les méthodes de classification simultanée à la décomposition de mouvements lors de séances de réadaptation

Il est donc nécessaire de développer une méthode de classification simultanée utilisant uniquement des mouvements simples et prenant en compte les mouvements de l'épaule. Tester cette méthode sur de véritables signaux enregistrés pendant les séances de réadaptation montrerait la fiabilité de l'algorithme et son potentiel pour une future utilisation clinique.

3.2 Objectif principal

L'objectif principal de ce mémoire est le développement d'une solution algorithmique permettant de décomposer les composantes de mouvements issues de séquences complexes simultanées lors de gestes libres en 3D, comprenant sept DDL sur quatre articulations (main, poignet, coude, épaule).

3.2.1 Sous-objectifs

L'objectif principal de ce mémoire peut être divisé en 3 sous-objectifs :

1. Concevoir un algorithme de classification de 13 mouvements du membre supérieur et une classe de non-mouvement (sept DDL) à partir de données électromyographiques et cinématiques (Tableau 3-1). (SO1)

Tableau 3-1 Classes de mouvements et degrés de liberté (DDL) étudiés dans le mouvement du membre supérieur

<i>Classe</i>	<i>Articulation</i>	<i>Nom du mouvement</i>	<i>DDL</i>
1	/	Non-Mouvement	/
2	Main	Préhension	Préhension
3	Poignet	Flexion du poignet	Flexion/Extension du poignet
4		Extension du poignet	
5		Pronation de l'avant-bras	Pronation/Supination de l'avant-bras
6		Supination de l'avant-bras	
7	Coude	Flexion du coude	Flexion/ Extension du coude
8		Extension du coude	
9	Épaule	Flexion de l'épaule	Flexion/Extension de l'épaule
10		Extension de l'épaule	
11		Abduction de l'épaule	Abduction/Adduction de l'épaule
12		Adduction de l'épaule	
13		Abduction Horizontale de l'épaule	
14	Adduction Horizontale de l'épaule	Abduction/Adduction horizontale de l'épaule	

2. Évaluer les performances de cet algorithme de classification pour la décomposition de gestes fonctionnels séquentiels et simultanés. (SO2)

3. Appliquer notre algorithme de décomposition de séquences de mouvements complexes à des séquences de jeux dans l'Armeo®Senso afin d'évaluer l'accomplissement des objectifs thérapeutiques de chaque jeu. (SO3)

3.2.2 Hypothèses

Les mouvements de rotations latérale et médiale de l'épaule n'ont pas été inclus dans l'étude en raison de leur importance présumée faible dans les gestes fonctionnels étudiés et dans les jeux de l'Armeo®Senso. (HR1) Ces mouvements devront être inclus dans une future étude avec l'Armeo®Spring ou d'autres technologies de réadaptation le nécessitant.

CHAPITRE 4 MÉTHODOLOGIE

Ce chapitre présente la méthode (Section 4.1) ayant mené à la publication de l'article (Chapitre 5) ainsi que la méthodologie complémentaire (Section 4.2) menant à des résultats complémentaires non mentionnés dans l'article.

4.1 Méthodologie

4.1.1 Acquisition des données

Dix-huit sujets adultes typiquement développés (TD) âgés entre 21 et 36 ans (moyenne : 25.0, déviation standard : 3.3) ont participé à notre étude. Le protocole de recherche a été validé par le comité d'éthique du CHU Sainte-Justine et des formulaires de consentement ont été signés par chaque participant.

Des données électromyographiques et cinématiques ont été prises à l'aide de dix capteurs sans-fil sEMG-IMU (Trigno, Delsys Inc., Natick MA, USA) placés sur 10 muscles du membre supérieur dominant du sujet. Le positionnement des capteurs est visible sur la Figure 5-1. 13 mouvements simples ont été inclus dans l'étude : préhension, flexion du poignet, extension du poignet, pronation de l'avant-bras, supination de l'avant-bras, flexion du coude, extension du coude, abduction de l'épaule, adduction de l'épaule, abduction horizontale de l'épaule, adduction horizontale de l'épaule, flexion de l'épaule, extension de l'épaule, plus une classe de non-mouvement pour un total de 14 classes de mouvements.

Les séances de prise de mesure s'effectuaient en trois étapes :

1. La réalisation des 13 mouvements étudiés à une fréquence de 1 Hz afin de constituer une base de données de gestes simples (1 DDL). Les sujets disposaient de 30s de repos entre chaque tâche. Chaque mouvement simple a été effectué dans différentes positions de départ : position neutre, avant-bras en pronation, avant-bras en supination, et épaule en flexion (Figure 4-1). Ces différentes positions donneront lieu à explications et analyses complémentaires en section 5.2.2 et des résultats complémentaires en section 6.1.




Figure 4-1 Photos d'un sujet dans les quatre positions de départ : A. Position neutre. B. Supination de l'avant-bras. C. Pronation de l'avant-bras. D. Flexion de l'épaule.

2. La réalisation des quatre gestes fonctionnels présentés à la Figure 4-2:

- Pyramide : Former une pyramide de quatre cylindres en bois (Figure 4-2.A).
- Main-bouche : Réaliser un geste main-bouche à l'aide d'une cuillère ou d'une fourchette (Figure 4-2.B).
- Bouteille : Attraper une bouteille et verser de l'eau dans un verre (Figure 4-2.C).
- Porte : Ouvrir une porte (Figure 4-2.D).




Figure 4-2 Photos de sujets effectuant les quatre gestes fonctionnels. A. Pyramide : Former une pyramide de quatre cylindres en bois. B. Main-bouche : Réaliser un geste main-bouche à l'aide d'une cuillère ou d'une fourchette. C. Bouteille : Attraper une bouteille et verser de l'eau dans un verre. D. Porte : Ouvrir une porte.

3. L'utilisation de l'Armeo®Sensio avec la sélection de 6 à 7 jeux (selon le temps écoulé) travaillant au total au moins 2 articulations (Figure 4-3)




Figure 4-3 Sujet jouant au jeu *Pirates* sur l'Armeo®Sensio. L'objectif de ce jeu est de tirer sur des pirates en déplaçant le curseur de visée par des mouvements du membre supérieur, puis tirer grâce à une préhension du joystick tenu en main.

4.1.2 Traitement du signal

Les signaux sEMG récoltés et normalisés ont ensuite été filtrés par un filtre passe-bande Butterworth 10-450 Hz, rectifiés par une valeur absolue et enfin lissés avec un passe-bas Butterworth à 50Hz [22]. Les signaux IMU ont été filtrés par un passe-bas Butterworth à 2 Hz [27]. L'opérateur d'énergie de Teager-Kaiser, ensuite utilisé sur les signaux sEMG afin d'obtenir une meilleure détection du début du signal [35], est défini par l'équation (1) :

$$\Phi[x(n)] = x^2(n) - x(n+1)x(n-1) \quad (1)$$

Où Φ est l'opérateur d'énergie de Teager-Kaiser, x la valeur du signal sEMG et n l'indice de la séquence temporelle du signal sEMG.

Le signal EMG de référence pour chaque muscle a été également soustrait des signaux sEMG traités. Les signaux traités ont enfin été normalisés par le maximum de chaque muscle sur tous les essais d'un patient [89].

Tous les signaux ont été segmentés avec des fenêtres temporelles de 250 ms et 500 ms desquelles ont été extraites sept caractéristiques pour les sEMG et neuf pour les données IMU (uniquement l'accélération) [31].

4.1.3 Entraînement des réseaux de neurones

La base de données obtenue a servi à l'entraînement, la validation et le test de huit réseaux de neurones de longue mémoire à court terme (« long short-term memory » en anglais (LSTM)). La plupart des mouvements étudiés comprenant des paires de mouvements antagonistes, les 14 classes de mouvements au sein de cette étude représentent un total de sept DDL en addition du non-mouvement (Tableau 2-1). Chaque LSTM a ainsi permis la classification d'un DDL, plus un pour le non-mouvement. L'ensemble de la stratégie de classification est illustré Figure 5-3.

4.2 Méthodologie complémentaire

4.2.1 Prise de données complémentaires

Un cinquième geste fonctionnel non détaillé dans l'article du Chapitre 5 a été réalisé par tous les sujets. Il s'agit d'un geste de brossage de cheveux illustré à la Figure 4-4.



Figure 4-4 Photo de deux sujets effectuant le cinquième geste fonctionnel étudié (Brosse) : Se brosser les cheveux avec une brosse. A. Sujet avec les cheveux longs. B. Sujet avec les cheveux courts

4.2.2 Tests et analyses complémentaires

L'enregistrement des mouvements simples dans différentes positions de départ est une originalité de cette étude. Des études ont utilisé des mouvements à plusieurs DDL dans l'entraînement de leur

base de données [71, 86] ; et d'autres ont fait réaliser à leurs sujets toutes les possibilités de mouvements à 1 et 2 DDL [70, 82]. L'utilisation de mouvements à 2 DDL ou plus améliore la qualité de la classification [86], notamment par une diversité de mouvements plus représentative des mouvements complexes naturels. Mais ces études ne portaient que sur 3 DDL, rendant possible la réalisation de tous les cas de figure par les sujets. Dans le cadre de notre étude, nous prenons en compte sept DDL sur quatre articulations et ne pouvons généraliser cette approche (169 possibilités d'associations pour des mouvements 1-DDL et 2-DDL). Afin de garder une base de données diversifiée tout en minimisant le nombre de gestes réalisés pour garder un protocole réalisable cliniquement, nous avons choisi de ne considérer que l'impact des mouvements de pronation/supination de l'avant-bras et de flexion de l'épaule. Ce choix s'appuie sur une observation expérimentale sur plusieurs sujets de l'impact du positionnement du membre sur les signaux sEMG.

Nous avons ensuite testé l'impact de ces positions en pronation de l'avant-bras (Figure 4-1.C), supination de l'avant-bras (Figure 4-1.B) et flexion de l'épaule (Figure 4-1.D) (appelées par la suite positions supplémentaires, en comparaison avec la position neutre de base) sur l'entraînement des réseaux de neurones et la décomposition de mouvements. Huit LSTM ont été entraînés sans ces positions supplémentaires (uniquement les données issues des positions neutres ont été utilisées) afin de comparer les résultats avec ceux entraînés avec les données en position neutre et en positions supplémentaires.

CHAPITRE 5 ARTICLE 1 : TOWARDS MORE PRECISE UPPER EXTREMITY MOTOR REHABILITATION USING MACHINE LEARNING MOVEMENT DECOMPOSITION

Cet article a été soumis le 30 juin 2022 dans la revue *Engineering Applications of Artificial Intelligence*.

Lauren Pelletier de Chambure Hémart du Neufpré, Maxime Raison, Elizabeth Clark

5.1 Abstract

Virtual reality systems, such as the Armeo®Senso for the upper extremities, are commonly adopted as modalities for rehabilitation. Today with these systems, one of the main issues is to optimize the benefit of therapy sessions, by selecting with more precision the best games for the right challenge, targeted movements and goals according to the treatment plan for each patient. However, each game involves continuously changing combinations, within a global complex movement that evolves over time. For therapy analysis and optimization, decomposing these complex movements into simple components would be necessary.

The objective is to develop an algorithm decomposing complex sequential movements into simple movement components. It was used for upper extremity gestures during functional tasks and during Armeo®Senso game sessions. The movements were measured on 18 healthy subjects, with 10 wearable sensors combining surface electromyography and inertial motor units. Decomposed by the algorithm, the movement components are classified into 14 classes of simple movements on four upper extremity joints (hand, wrist, elbow, and shoulder), including a no movement class. A parallel classification strategy was tested to train eight long short term memory classifiers, with one for each degree of freedom. This algorithmic method successfully decomposed the upper extremity movements with an average predictive rate of 98.2%. The proposed algorithm enabled us to evaluate the Armeo®Senso games design. These results support the consideration for this algorithm as a good mean for targeting best training activities. Better virtual environments could then be designed for more precise upper extremity motor rehabilitation.

5.2 Keywords

Virtual reality, surface electromyography (sEMG), exergames, parallel classification, Long short-term memory (LSTM)

5.3 Abbreviations and definitions:

- ACC : accelerometer
- Blocks : functional gesture where the subject plays with cylindrical blocks to form a pyramid
- Bottle : functional gesture where the subject lifts a bottle and pour liquid in a glass next to it
- DoF : degrees of freedom
- Door : functional gesture where the subject opens a door
- EExt : elbow extension
- EFlex : elbow flexion
- FPro : forearm pronation
- FSup : forearm supination
- Hand-to-Mouth : functional gesture where the subject grabs a spoon and brings it to his/her mouth to eat
- HG : hand grip
- IMU : inertial motor unit
- LDA : linear discriminant analysis
- LR : linear regression
- LSTM : long short term memory
- MDPC : movement decomposition using parallel classification
- NM : no movement
- SAbd : shoulder abduction
- SAdd : shoulder adduction
- sEMG : surface electromyography
- SExt : shoulder extension
- SFlex : shoulder flexion
- SHAbd : shoulder horizontal abduction
- SHAdd : shoulder horizontal adduction
- VR : virtual reality
- WExt : wrist extension
- WFlex : wrist flexion

5.4 Introduction

5.4.1 Rehabilitation using virtual reality gaming systems for upper extremities

Established for a while in rehabilitation, several intervention approaches are based on 10 principles of experience-dependent neural plasticity [1]. Three of these principles must be particularly considered in the treatment planning to increase effectiveness:

1. Dosage (repetition, intensity and frequency) of movement
2. Task-oriented training for therapy specificity [2].
3. Lived experience, i.e. tasks and activities that are significant and positive for the person, leading to adaptive behaviors [1, 3, 4].

Further, patient motivation is a factor of motor learning [4, 5] and an important factor of rehabilitation success [6]. Therefore, new intervention approaches and rehabilitation technologies that can enhance patient motivation and neuroplasticity are always being investigated. Activity based therapy is an approach regularly used in intensive rehabilitation programs [4, 7, 8]. Therapies are planned to provide task specific high dosage and cognitive participation for the patient [4].

Virtual reality (VR) gaming systems are modalities frequently proposed to patients in their treatment plan, and are increasingly used [9]. These ones can enhance the effectiveness of therapies, by facilitating compliance with these three neuroplasticity principles [10] and increasing the patient motivation.

1. High intensity and number of repetition are facilitated by the interactive environment of these gaming systems that can promote and increase patient interest [10] as well as hide repetitive tasks behind an entertaining experience [11].
2. The high flexibility of VR systems regarding environment and game design can provide task-oriented training [12-14].
3. The lived experience as well as the motivation is improved thanks to a playful and interactive environment [15] linking therapy and fun. Feedback through visual information or score systems allow the patient to visualize errors and can influence neuroplasticity [10]. This feedback helps the patient to focus on the game and therapy [11].

VR game platforms have already shown their potential for motor rehabilitation [12, 14, 16], despite the non-specificity of games design for therapeutic application in some studies [16, 17]. Studies have also indicated the importance of designing serious games for rehabilitation patients, with an emphasis on taking into account their limitations, whether physical or mental, notably through difficulty levels [11].

5.4.2 Upper extremity rehabilitation using VR systems and the Armeo® Therapy Concept

VR systems can be immersive or non-immersive depending on user experience and its immersion. Immersive VR enables people to feel a part of the virtual environment they experience [18]. In immersive VR systems such as the Oculus Rift DK2 [19] or XR Health, users usually wear a head-mounted display and multiple wireless tracking and haptic devices that allow them to interact with the virtual environment. Non-immersive VR systems such as rehabilitation systems using the Kinect™ (Microsoft Corporation, Redmond, WE, USA) [14] or EvolveRehab Hands (Evolv Rehabilitation Technologies S.L., Bizkaia, Spain), are based on a common computer, flat monitor or video game console, along with some input devices to improve user experience. While non-immersive VR systems cannot fully overwhelm users' sensory perceptions, they usually require less material and are easier to develop and use as well as providing good sense of presence [20].

Among VR systems, the *Armeo® Therapy Concept* is based on 1. a non-immersive virtual game environment specially developed for upper extremity rehabilitation and 2. augmented feedback allowing long intensive therapy while keeping the patient motivated [21]. This concept includes devices such as Armeo®Spring (Hocoma, Switzerland) and Armeo®Senso (Hocoma, Switzerland). The effectiveness of the *Armeo® Therapy* compared to conventional therapy has been observed in more than 10 randomized controlled trials [22]. Unlike the Armeo®Spring which relies on an exoskeleton to assist the patient, the Armeo®Senso system is easy to use and has the advantage of being used at home without immediate supervision [23]. This device uses wireless IMU sensors to detect the patient movement and bring them through a 3D virtual environment of games targeting specific rehabilitation movements [24]. A hand sensor augments the patient's realistic experience by allowing the patient to grip objects.

5.4.3 Movement decomposition of upper extremity complex sequences in previous studies

To tend toward more precise upper extremity motor training, one general challenge of these VR systems, including the Armeo®Senso, is to optimize the benefit of rehabilitation sessions to tailor

the patient's therapy according to his or her needs [25, 26]. This optimization includes selecting the best games and levels of difficulty for the right challenge in each session, in line with the therapeutic objective of each patient [27].

As for any functional gesture, each Armeo® game requires upper extremity multi-sequential movements, involving combinations and sequences of simple movements. To be able to recognize best targets for movement training, it would therefore be necessary to decompose this complex movement sequence into simple movement components, i.e. by degree of freedom and by articulation, e.g.: elbow flexion component, wrist supination, etc. The biomechanical term degree of freedom (DoF) refers in the following article to an independent movement for an articulation along one axis, i.e. wrist flexion/extension or forearm pronation/supination.

This challenge of subdividing such complex movement into simple movement components has already been partially addressed, especially in another field: the control of myoelectric systems. These systems require simultaneous control of different joints for better dexterity, speed, and more natural control for patients [28]. Sequential control brings undesirable effects, namely too much cognitive burden for the user who is unable to plan and perform smooth and natural complex movements [29]. Most studies have developed simultaneous control of several joints, at the level of the hand, wrist, and elbow [30, 31].

In the field of myoelectric prosthesis, control strategies are mainly based on pattern recognition control of surface electromyographic signals (sEMG). Even though intramuscular electrodes can be effective in movement classification for the control of myoelectric prostheses for amputees [31-33], these ones require heavy operations and are an obstacle to easy clinical use. Therefore, sEMGs are now widely used as a tool for qualification and quantification of muscle activity. Pattern recognition control strategies allow for simultaneous multi-dimensional control to be implemented more easily than the alternatives of myoelectric prosthesis control [34]. This simultaneous control requires algorithms capable of decomposing the movement intentions from sEMG into different DoFs for simultaneous control of the different joints of the prosthesis. Pattern recognition strategies are usually based on discrete and combined movement classification algorithms such as Linear Discriminant Analysis (LDA) [35] or Linear Regression (LR) [35, 36].

Several pattern recognition methods have been developed for movement classification solely using non-invasive and easy-to-use sEMG [29, 35, 36]. Herberts, et al. [37] proposed a method which

enable the control of a multifunctional prosthesis for elbow amputees with six sEMGs. Their pattern recognition method used hyperplanes to discriminate six wrist and hand movements with a parallel classification, controlling up to three simultaneous DoFs. Yatsenko, et al. [38] used a multi-channel sEMG network composed of 22 electrodes placed without consideration of the muscles, to control three DoFs of the hand and wrist thanks to orthonormalized contraction vectors derived from EMG energy. In Young, et al. [29], a hierarchical classification strategy using only LDA allowed control of 4 DoFs at the wrist and hand, including two DoFs simultaneously. This method using single (1 DoF) and all combined movements (2 DoFs) as training data provided significantly better control than with a single LDA classifier or a parallel classification strategy. The same team improved their results for 3 DoFs in [35] with the development of a conditional classification strategy following the same training methodology, achieving on average less than 15% misclassification on single and combined movements. Leone, et al. [36] refined the classification strategy in parallel using LDA and LR, with the addition of the elbow joint in addition to the hand and wrist studied previously. Six simple and 21 combined movements were recorded on 15 typically developed subjects to form three training sets and train three independent classifiers. This strategy resulted in an average F1 Score between 91.0% and 96.1% for the LR and 89.3% and 94.5% for the LDA algorithms. In the rest of the paper, these movement decomposition methods of complex movement sequences using a parallel classification strategy will be named Movement Decomposition using Parallel Classification (MDPC).

5.4.4 Review limitations, objective and incentive of this study

Although the studies presented in Section 1.3 pioneered the decomposition of complex movement sequences, these ones also highlighted current lacks, which refrains the use of such methods to guide rehabilitation sessions planning and optimization.

First, no study has yet classified movements on the entire upper extremity, including the shoulder. All studies mentioned above are limited to the hand, wrist, and elbow. Although the shoulder is not the most targeted joint for myoelectric prosthesis control, this joint receives much attention in rehabilitation, e.g in Daoud, et al. [39]. It is therefore essential to consider the shoulder in the movement decomposition.

Secondly, there has been no application of MDPC for movement decomposition of real complex movement sequences performed by subjects. A clinical application of such a machine learning movement analysis tool to a real device like the Armeo®Senso has never been tested before.

Thus, the objective of this study is to develop an algorithmic solution to decompose the components of complex simultaneous sequences of movements during free 3D gestures, including seven DoFs on four joints (hand, wrist, elbow, shoulder). To test the robustness of the proposed model and to illustrate it, an application to functional gestures and to the games of the virtual reality rehabilitation platform Armeo®Senso is performed in this study.

5.5 Methodology

5.5.1 Participants

The study included a parity group of 18 typically developed adults aged between 21.4 and 36.7 years (mean: 25.0, standard deviation: 3.3). The research protocol was validated by the Research Ethics Board of Sainte-Justine University Hospital Center, Montreal, Canada. Written consent for measurements, video and photos were signed by each participant.

5.5.2 Data acquisition

5.5.2.1 Instrumentation

Since the limb position affects the EMG signal [40, 41], electromyographic data were enriched with kinematic data. All data were acquired using wireless EMG-IMU sensors (Trigno, Delsys Inc., Natick MA, USA) at a sampling frequency of 1111.11 Hz. Each sensor included information of muscle activity through one sEMG channel and position through nine channels of triaxial accelerometers, gyroscopes and magnetometers. Ten EMG-IMU sensors were placed on the skin of the participants on ten muscles of the shoulder, arm, and forearm: *biceps brachii*, *triceps brachii*, *brachioradialis*, *pronator teres*, *anterior deltoid*, *posterior deltoid*, *infraspinatus*, *pectoralis major*, *palmaris longus*, and *extensor carpi radialis* (Figure 5-1). The sensors were placed in the dominant upper extremity of subjects according to SENIAM guidelines [42].

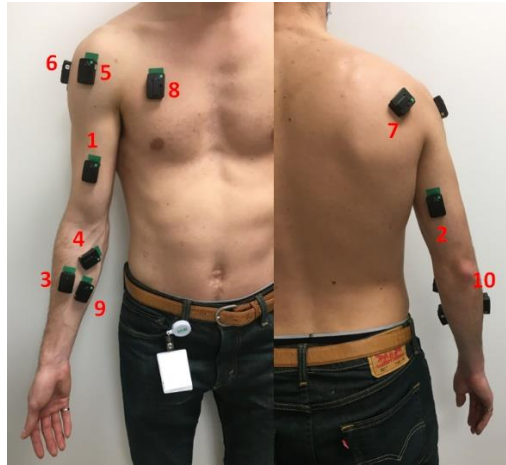


Figure 5-1 Sensor placement on a subject – Muscles number : biceps brachii (1), triceps brachii (2), brachioradialis (3), pronator teres (4), anterior deltoid (5), posterior deltoid (6), infraspinatus (7), pectoralis major (8), palmaris longus (9), and extensor carpi radialis (10).

5.5.2.2 Experimental set-up

Fourteen movement classes were included, namely: hand grip (HG), wrist flexion (WFlex), wrist extension (WExt), forearm supination (FSup), forearm pronation (FPro), elbow flexion (EFlex), elbow extension (EExt), shoulder flexion (SFlex), shoulder extension (SExt), shoulder abduction (SAbd), shoulder adduction (SAdd), shoulder horizontal abduction (SHAbd) and shoulder horizontal adduction (SHAdd), plus a “no movement” (NM) (Table 5-1).

Table 5-1 : Upper extremity Joints 14 Movement classes and Abbreviation

Class	Joint	Movement Name	Abbreviation
1	/	No Movement	NM
2	Hand	Hand Grip	HG
3	Wrist	Wrist Flexion	WFlex
4		Wrist Extension	WExt
5		Forearm Pronation	FPro
6		Forearm Supination	FSup
7	Elbow	Elbow Flexion	EFlex
8		Elbow Extension	EExt
9	Shoulder	Shoulder Flexion	SFlex
10		Shoulder Extension	SExt
11		Shoulder Abduction	SAbd
12		Shoulder Adduction	SAdd

13		Shoulder Horizontal Abduction	SHAbd
14		Shoulder Horizontal Adduction	SHAdd

The experimental protocol, inspired by Sarcher, et al. [43], was divided into three parts and was performed by each subject once:

1. The recording of muscle activity at rest for a baseline signal, then of the 14 simple gestures named above to form a training database. Each gesture was mimed before data collection and then performed five times by the subject at a frequency of 1 Hz (one movement every second) using an auditory metronome. The participants had 30 s between each task to rest, while remaining within a clinically acceptable protocol time. The order of the tasks was also randomized to mitigate the fatigue effect in the analysis. Each task was repeated twice to ensure data repeatability.

It is usual to perform each gesture in a neutral position, as described by Sarcher, et al. [43] and visualized in Figure 5-2B. However, better results have been obtained by also adding gestures performed in other positions (forearm pronation/supination [44], or shoulder flexion [41, 45]), while ensuring only one DoF of movement to keep the gesture simple. This allowed the creation of a database of discrete gestures performed in different positions to avoid limb position effect [41]. More diverse data facilitated the decomposition of complex sequences.

2. The performance of four functional gestures used in pediatric rehabilitation to test the decomposition algorithm: pouring liquid from a bottle to a glass of water (“Bottle”), opening a door (“Door”), playing with cylindrical blocks to form a pyramid (“Blocks”) and performing a hand-to-mouth gesture [43] while holding a spoon (“Hand-to-Mouth”). The objects used for these functional gestures can be seen in Figure 5-2A. Two of these gestures, namely Bottle and Door, are sequential complex gestures. And two other gestures, namely Blocks and Hand-to-Mouth, are simultaneous complex gesture.
3. The use of a portable virtual reality rehabilitation device (Armeo®Senso, Hocoma) pictured in Figure 5-2.C and Figure 5-2.D after prior calibration of the device. The subject performed six to seven therapeutic games within the session time. The games were randomly chosen among those proposed by the Armeo®Senso device and training at least two different joints. An adaptation time was given to the subjects at the beginning of each game. Recording time was of 55 s for each game.



Figure 5-2. Measurement session – A. The three objects used for functional gesture: bottle (1), four wood cylinders (2), spoon (3). The door used for the fourth functional gesture was not represented. B. Neutral position for discrete gesture recording. C. Material needed for Armeo@Senso recording: Trigno (Delsys) base station and EMG-IMU sensors (1), EmgWorks (Delsys) software (2), Armeo@Senso software (3), wearable Armeo@Senso IMU sensors (4). D. Subject playing with Armeo@Senso High Flyer (shoulder) game during session.

5.5.3 Data Processing

The signals were recorded by the EmgWorks (Delsys Inc., Natick, MA, USA) software. The sEMG and IMU-ACC were processed by a custom-written MATLAB® (MathWorks®, Natick, USA) scripts [46], along with the open-source library Biomechanical ToolKit [47] and other open-source MATLAB scripts, i.e. AlphaNumeric Sorting by Stephen Cobeldick (2021) and F1 Score Calculation by Eugenio Bertolini (2021).

5.5.3.1 Data Segmentation

First, the sEMG data were filtered following Sarcher, et al. [43], by using a 10-450 Hz band-pass Butterworth zero-lag 4th order filter, full-wave rectified and finally passed through a 50 Hz low-pass Butterworth zero-lag 4th order filter. The ACC signals were also processed following Raouafi, et al. [46].

The normalization to the maximum voluntary contraction is known to be important to allow inter-subject comparison [48]. However, children with neuromuscular deficits such as cerebral palsy are unable to produce such a movement [49]. As our MDPC decomposition algorithm is aimed at a population of children with such deficits, maximum voluntary contraction normalization was discarded in favor of a normalization by the maximum peak on all trials [49], which showed the lowest inter-subject variability for typically developed subjects [50].

The Teager-Kaiser energy operator was used to allow better sEMG onset detection [51]. For each signal, the activation threshold was calculated as formulated by Equation (1) [52] :

$$T = \mu + h\sigma, \quad (1)$$

where μ is the mean, σ is the standard deviation and $h = 6$ is an equation parameter set by the operator [51]. For each trial, the onset time was defined on the first point when the signal was over the activation threshold T for 25 consecutive samples [43, 51].

Processed sEMG and IMU-ACC signals for each trial was segmented using overlapping windows of 250ms with 50ms overlap [51]. To better predict slow movements of patients in rehabilitation therapy, data segmentation was also performed with 500 ms windows with a 250 ms overlap to form a second training set [53]. Overlap influence was not investigated in this study.

5.5.3.2 Features Extraction

Time and frequency domains features were calculated from segmented processed sEMG and ACC signals. The EMG features were chosen among the ones investigated by Raouafi, et al. [46]. These seven features were determined experimentally as the most suitable for the current data namely [46]: Spectral Moment 2, Integrated EMG, Average Amplitude Change, Zero Crossing, Multiple Window, Coefficients of Cepstral Analysis, Maximum Fractal Length.

Nine features were also extracted from ACC signals with the mean, minimum and maximum of the signal along each axis. The features were evaluated by using a covariance analysis and the RELIEFF algorithm [54] to chose the best ACC features from the ones proposed in Raouafi, et al. [46].

5.5.4 Classification

Long Short-Term Memory (LSTM) neural networks were used to classify the 13 upper extremity movements and the NM class. LSTM was chosen over more traditional method such as Support Vector Machine (SVM) [46] or LDA [35] because of its ability to learn temporal dependency contained by sEMG [55] and its effectiveness in similar studies [51, 55, 56].

The dataset was partitioned between a training set (60% of data), a validation set (20% of data), and a test set (20% of data). A parallel classification strategy was implemented, as described by Young, et al. [35] and Leone, et al. [36]. One LSTM neural network was trained for each DoF and the NM class [36] : HG, EFlex/EExt, WFlex /WExt, FPro/FSup, SFlex/SExt, SAbd/SAdd, SHAbd/SHAdd, NM (Figure 5-3). Two LSTM only discriminated one simple movement from all the other movements: LSTM HG (1 DoF) and NM. The other six LSTM discriminated a pair of opposing movements on the same joint (1 DoF) from all other movements: LSTM EFlex/EExt, WFlex /WExt, FPro/FSup, SFlex/SExt, SAbd/SAdd, SHAbd/SHAdd.

The structure of each neural network was determined experimentally, including two hidden layers of respectively 256 and 64 neurons, and a softmax layer. The number of neurons in the input layer was equal to the number of features multiplied by the number of muscles. The number of neurons in the output layer of each LSTM neural network depended on its number of movement classes: LSTM HG and LSTM NM had two output classes, respectively HG/no HG and NM/no NM. The other six LSTM had three output classes. For example, the three output classes of LSTM EFlex/EExt were: EFlex (class 1), EExt (class 2) and (no EFlex and no EExt) (class 0).

The processed data then passed through the eight independent LSTM neural network to obtain an 8-DoF decomposition matrix for each time window. Then the value of the LSTM output for each DoF allowed the extraction of a 14-movement decomposition matrix for each time window from the eight-DoFs decomposition matrix (Figure 5-3). This parallel classification strategy allowed for

the decomposition of the EMG-IMU signals of complex movement sequences over seven DoFs using independent neural networks.

For each LSTM neural network, classification accuracy was calculated from the test set. To better evaluate the classification performance especially with unbalanced dataset [57], the F1-score of each LSTM was also calculated. F1-score compares the correct positive predictions (true positive) to the errors made by the model (false negative and false positive) with the following Equation (2):

$$F1 - score = \frac{true\ positive}{true\ positive + \frac{1}{2}(false\ negative + false\ positive)} \quad (2)$$

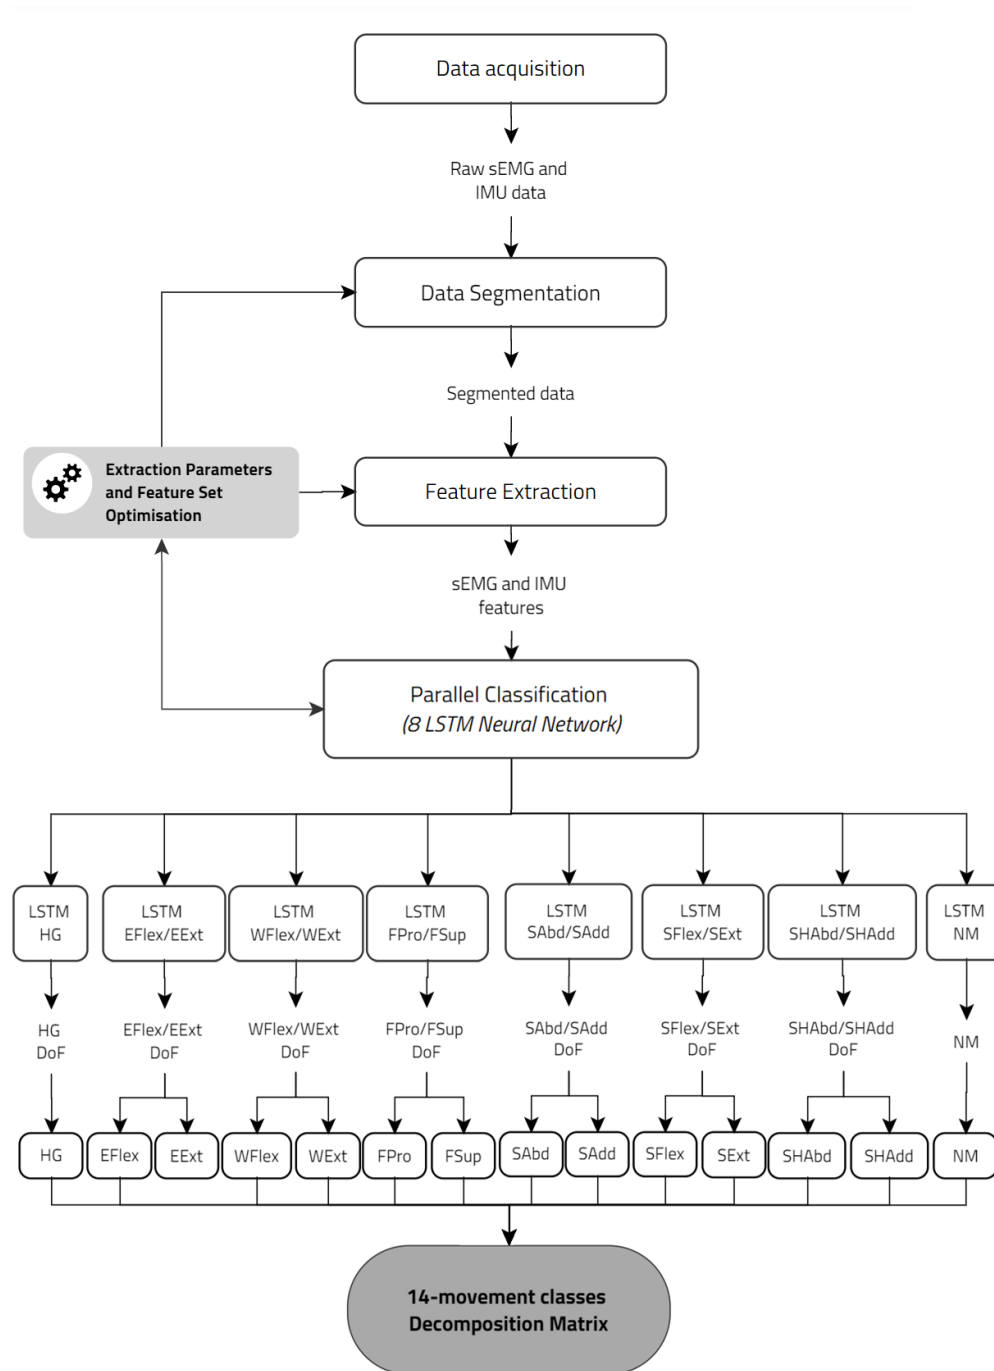


Figure 5-3. Block Diagram of the classification system – Eight Long Short term Memory (LSTM) neural networks classify 14 movement classes : hand grip (HG), wrist flexion (WFlex), wrist extension (WExt), forearm supination (FSup), forearm pronation (FPro), elbow flexion (EFlex), elbow extension (EExt), shoulder flexion (SFlex), shoulder extension (SExt), shoulder abduction (SAbd), shoulder adduction (SAdd), shoulder horizontal abduction (SHAbd) and shoulder horizontal adduction (SHAdd), and a “no movement” (NM) class.

5.5.5 Functional Gesture

The recorded signals of the functional gestures for each subject were processed as described above and segmented with 250 ms windows.

For functional gestures, the data were normalized post-classification over the duration of the movement to facilitate inter-subject comparison. The most representative discrete movements of the functional gesture were also determined by taking the majority discrete movement on all subjects for each temporal window.

5.5.6 Armeo®Senso Games and Hocoma Target Grid

Unlike functional gestures, sEMG and IMU signals during games were segmented with 500ms windows. This specific choice will lead to results in Section 3.1 and a discussion in Section 4.

A total of 28 games were available in the Armeo®Senso software used for this study. Each therapy game was designed by the manufacturer (Hocoma, Switzerland) to work on specific joints or movements, presented on the qualitative Movements Target Grid of Figure 5-5. Targeted movements required for the game performance are divided between a main movement (dark blue cells on the grid), which must be performed to achieve the game, and secondary movements (light blue cells) (Figure 5-5). It can be noted that some games are more specific than others into targeting movement training. Less specific games, i.e. with no main movement targeted according to Hocoma, often involve multi- movements (Figure 5-5). Specific games that only target one joint movement, such as *Air Hockey*, *Hocokart* or *Goalkeeper*, will be specifically analyzed to determine the predominance of said movement during game sessions. During those games with specific targets, other movements than the one targeted are not considered by the Armeo®Senso. For example, *Hocokart* is a 2D game where the player controls a kart trajectory by only movement of the wrist (WFlex and WExt) (Figure 5-4B). *Goalkeeper* is also a 2D game where the player controls a soccer goalkeeper with his or her forearm (FPro and FSup only) (Figure 5-4A).

Analysis of games with less specific targets movement such as *Frisbee*, *Plumber*, *Pirates* and *Farmer* will also be discussed. Comparison will be made with more specific target games. Three new games (*Paint*, *Connecting the dots*, *Follow the form*) were not included in the data given by Hocoma (Figure 5-5). Moreover, SAbd and SAdd movements were not included within the targeted

movements of Armeo®Senso games (Figure 5-5 Movement Target Grid for Armeo®Senso Games given by Armeo®Senso manufacturer (Hocoma, Switzerland) for games used in Armeo® Therapy. Dark blue cells are for the main movement targeted and light blue boxes are for the secondary movements targeted by the games. NaN values are for missing data..

To compare the results with Hocoma Movements Target Grid (Figure 5-5) and observe the use of the Armeo®Senso games during therapy sessions, a grid detailing the average percentage of training time for each simple movement component for each game was calculated by our MDPC algorithm.



Figure 5-4 Armeo®Senso Games : A. Subject playing Goalkeeper. B. Subject playing Hocokart.




Figure 5-5 Movement Target Grid for Armeo®Senso Games given by Armeo®Senso manufacturer (Hocoma, Switzerland) for games used in Armeo® Therapy. Dark blue cells are for the main movement targeted and light blue boxes are for the secondary movements targeted by the games. NaN values are for missing data.

5.6 Results

5.6.1 Classification accuracy

The classifiers accuracy data are illustrated in Figure 5-6, for 500 ms and 250 ms windows segmented. In Fig. 6, the average classification accuracy was $98.2 \pm 0.3\%$ with the 500 ms windows, and $97.5 \pm 0.3\%$ with the 250 ms windows. The 500 ms windows are more accurate than 250 ms windows. The classification loss remains under 5% for all classifiers. The F1-score for both windows length is presented in Table 5-2.

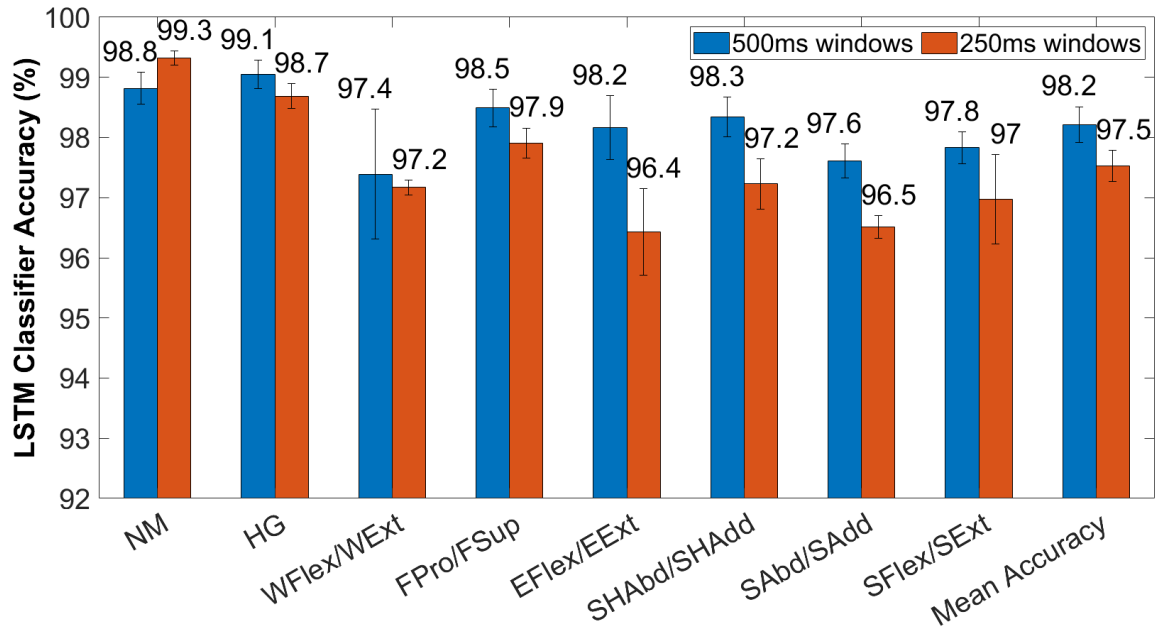


Figure 5-6. LSTM classification accuracy with test data with a data segmentation of 500 ms and 250 ms overlapping windows

Table 5-2 : F1 Score Values for LSTM classifiers with a data segmentation of 500 ms and 250 ms overlapping windows

Class	LSTM Classifier F1 Score	
	500 ms windows data	250 ms windows data
NM	97.0 ± 0.1	97.9 ± 0.1
EFlex	89.6 ± 0.3	82.2 ± 0.1
EExt	88.4 ± 0.4	81.9 ± 0.8
SFlex	89.7 ± 0.1	82.6 ± 0.6
SExt	90.2 ± 0.2	83.4 ± 0.4
WFlex	92.0 ± 0.2	86.1 ± 0.2
WExt	90.1 ± 0.8	85.2 ± 0.7
FPro	91.8 ± 0.1	81.4 ± 0.6
FSup	91.6 ± 1.5	83.2 ± 0.1
SAbd	86.9 ± 0.7	81.6 ± 0.2
SAdd	86.5 ± 0.9	81.2 ± 0.7
SHAdd	85.0 ± 1.2	83.9 ± 0.1
SHAbd	86.2 ± 0.8	80.5 ± 0.1
HG	90.3 ± 0.2	86.8 ± 0.2
Mean	89.7 ± 0.3	84.1 ± 0.2

5.6.2 Functional Gesture Movement Components

5.6.2.1 Bottle Functional Gesture

As an example of the algorithm output, the decomposition of the complex sequence of the gesture Bottle is given for 3 subjects in Figure 5-7. In Figure 5-7, the subjects were chosen for their general pattern and differences in movement components. All gestures are represented in time via a percentage of execution of the gesture sequence to normalize their duration. For example, 75% of the execution time of a 5s gesture corresponds to 3.75s. An instant without any movement is an instant where no movement class was detected by the algorithm because of signals complexity (Figure 5-7).

The visualization of the simple movement components of the functional gesture according to the set of subjects can be done through Figure 5-8. This figure represents the percentage of subjects performing each movement component for each time window.

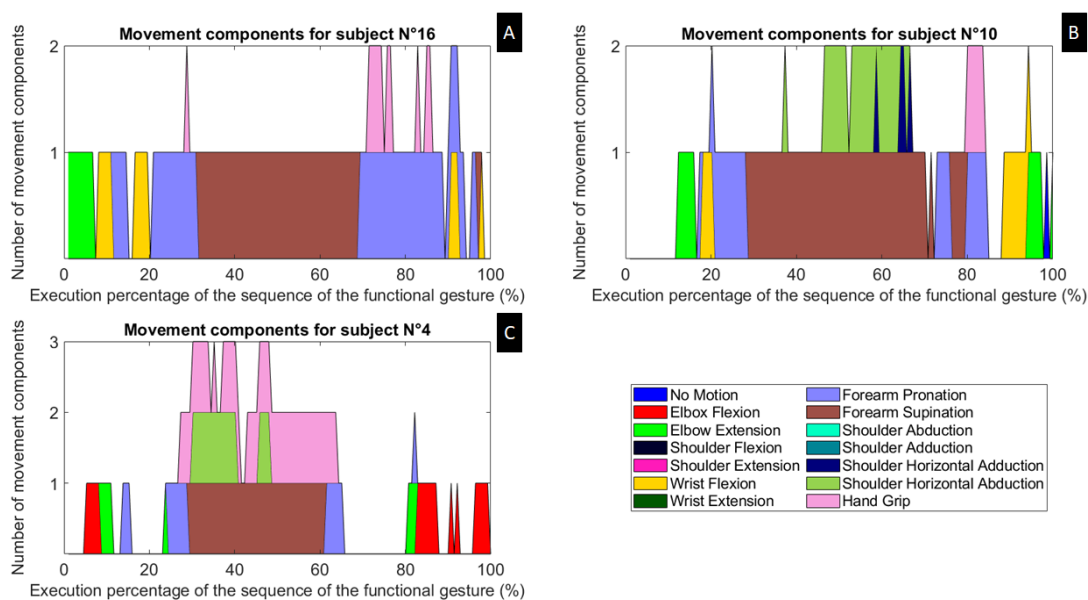


Figure 5-7. Movement Components for 3 subjects during functional gesture “Bottle”: A. Movements components for subject N°16. B. Movement components for subject n°10. C. Movement components for subject n°4.

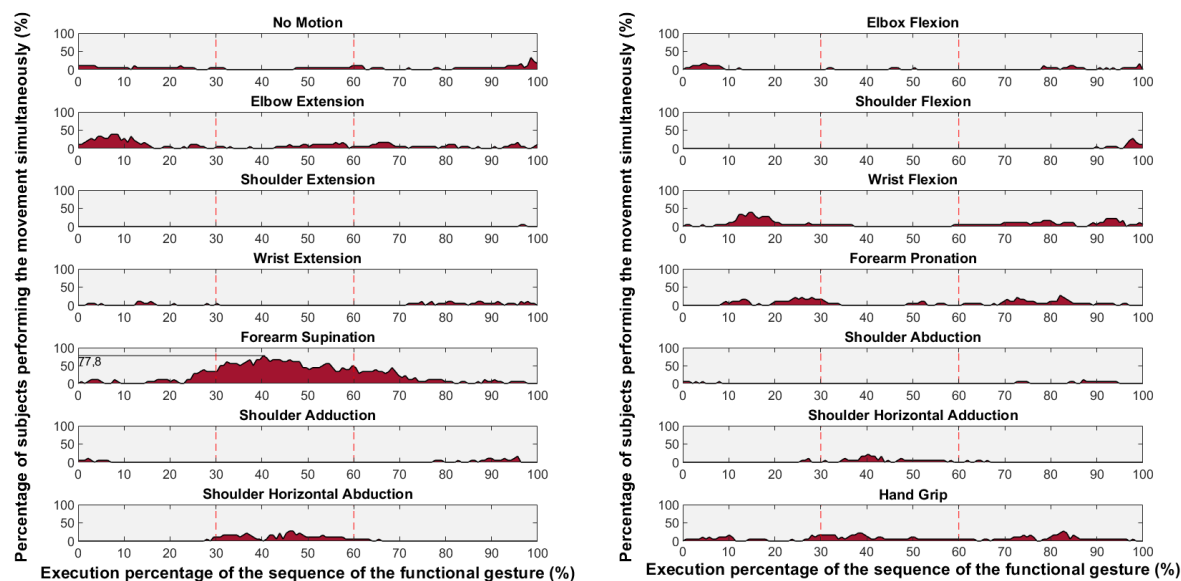


Figure 5-8. Temporal distribution of movement components between subjects in the functional gesture “Bottle”.

5.6.2.2 Main gesture

For each gesture, the most representative decomposition sequence of the functional gesture was also determined by taking the majority simple movement component on all subjects at each time window (Figure 5-9.).

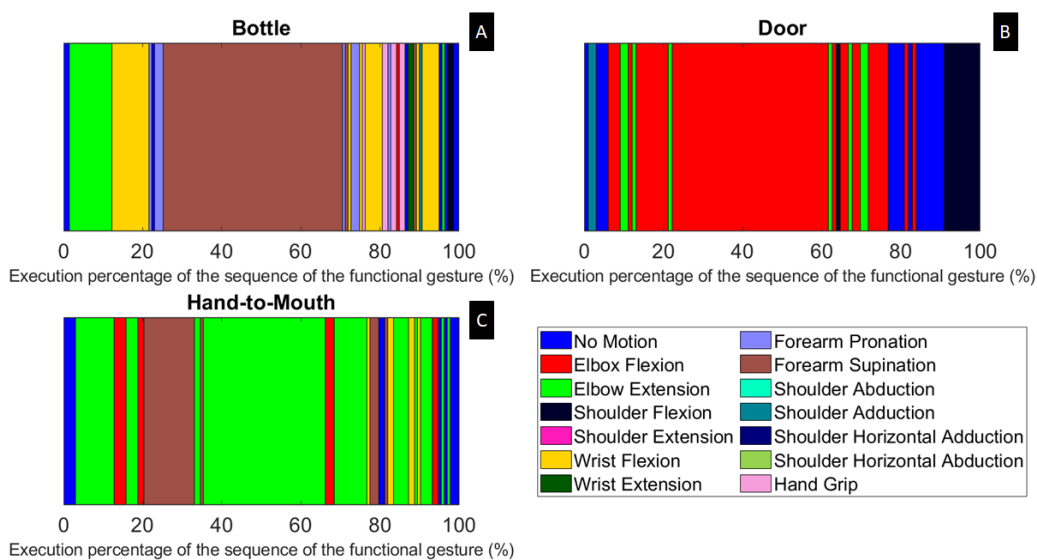


Figure 5-9. Average decomposition sequence into 14-movements class for three functional gestures: A. Bottle. B. Door. C. Hand-to-Mouth

5.6.2.3 Blocks Functional Gesture

The result of the decomposition is presented in

Figure 5-10 with the proportion of each simple movement component during the functional gesture “Blocks”. Let us note that, since the execution time of this gesture highly depended on the subject (between 10s and 20s), the average decomposition sequence for this gesture was not relevant for movement decomposition.

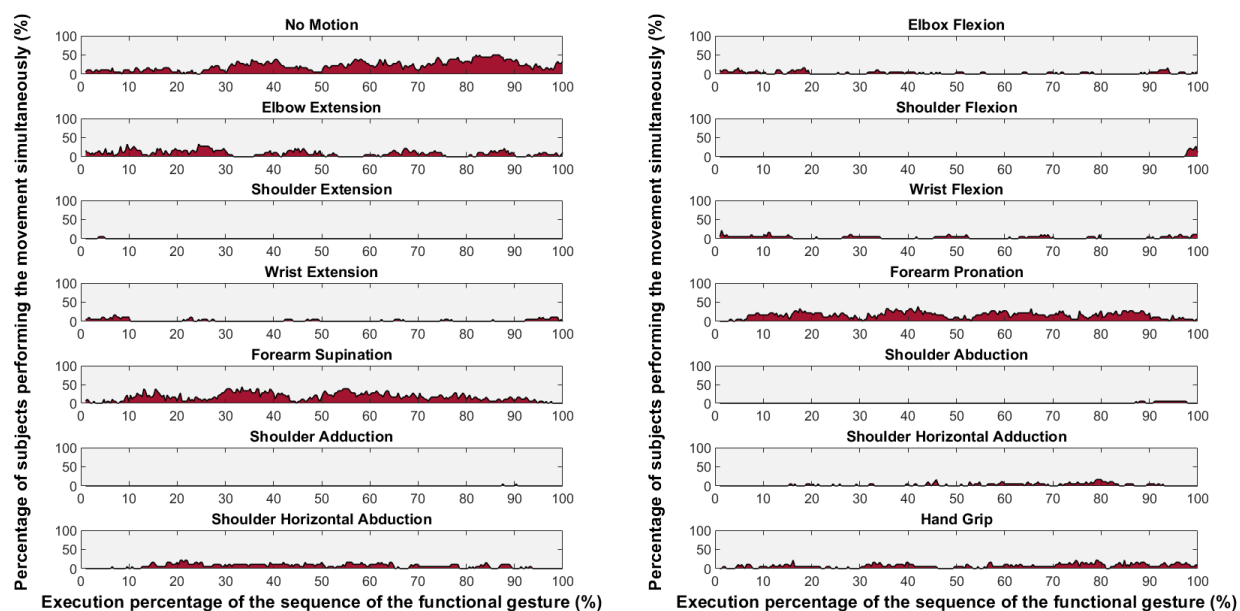


Figure 5-10. Temporal Distribution of the 14 Movement Components for all subjects during the functional gesture “Blocks”.

5.6.3 Armeo®Sensio Games Target Grid

Figure 5-11 illustrates the performance of subjects during Armeo®Sensio games sessions. The value for each DoF corresponds to the percentage of the time window where this movement was determined by the MDPC algorithm during the game for all the subjects who performed the game. Therefore, this corresponds to the average percentage of working time of this movement during a therapy session.




Figure 5-11. Movement Target Grid for Armeo@Senso Games calculated by the MDPC algorithm. The value of each DoF corresponds to the percentage of time windows where this gesture was detected in the game on all the subjects who performed this game.

5.7 Discussion

This study developed an algorithm that decompose for analysis purpose a subject's upper extremity motion into 14-simple movement components: HG, EFlex, EExt, WFlex, WExt, FPro, FSup, SFlex, SExt, SAbd, SAdd, SHAbd, SHAdd and NM. The proposed algorithmic solution successfully decomposed four functional gestures and Armeo@Senso games movement sequences for healthy subjects (Figure 5-6 and Table 5-2).

5.7.1 Classification Accuracy

Our main result of a mean classification accuracy of $98.2 \pm 0.3\%$ for LSTM classifiers supports the use of MDPC proposed by Leone, et al. [36] to decompose a complex sequence of movements (Figure 5-6). For 500 ms windows, LSTM classifiers accuracy are between $97.4 \pm 0.95\%$ and $99.1 \pm 0.2\%$ (Figure 5-6.). For 250 ms windows, LSTM classifiers accuracy are between $96.4 \pm 0.6\%$ and $99.3 \pm 0.1\%$ (Figure 5-6.). This prediction is within the range or better than the ones obtained by previous studies using LSTM for upper extremity movements classification : Li, et al. [58] with

test accuracy of 97.75% and Samadani [59] who obtained 89.5% accuracy with a multi-class LSTM. The classification error is under 5% for all LSTM classifiers, less than the classification error of Young, et al. [35] and Leone, et al. [36] who also implemented parallel classification.

F1 scores values are between 85.0 ± 1.2 and 97.0 ± 0.1 for the 14-movement class with 500ms data with an average of 89.7 ± 0.3 (Table 5-2). This score is slightly below the F1 Score values found by Leone, et al. [36]. Their mean F1 value was $96.1 \% \pm 2.9$ for the hand, $91.7 \% \pm 4.1$ for the elbow and $91.0 \% \pm 4.8$ for the wrist, obtained for 3 DoFs classified with LR. However given the 14-movement class and seven DoFs, this LSTM classification accuracy and F1 Score, shows the large potential of LSTM and parallel classification strategy for EMG-based gesture classification.

Wrist (WFlex, WExt) with a mean accuracy of 97.3% and shoulder (SFlex, SExt, SAbd, SAdd, SHAbd, SHAdd) movements were the most difficult to discriminate from other movements (Figure 5-6). The large number of DoFs of the shoulder joint, i.e. three DoFs, associated with a reduced number of EMG-IMU sensors (four sensors) dedicated to this joint probably explained the lower prediction. Given the size of forearm muscles, smaller wearable EMG sensors [55, 56] should be better suited to detect hand and wrist movements.

5.7.2 Functional gestures

The use of sequential and simultaneous functional gestures allowed us to confirm the functionality and reliability of the proposed MDPC algorithm, i.e. its capacity to satisfy the need stated and maintain its level of performance under different conditions. For all functional gestures, up to three movements were detected in a given time window. For most subjects, at least one simple movement among the 14 classes was detected at each moment for more than 60% of the gesture execution time despite the signal complexity.

The decomposition given by the proposed MDPC algorithm is corresponding to the actual gesture performed by the subjects and visually observed. For example, for the “Bottle” gesture, the three subjects in Fig. 5 follow the same pattern with an EExt to grab the bottle and a supination to pour the liquid. FSup and SHAbd composes the main part of the gesture, between 30% and 60% of execution, when the bottle is hold above the glass. At 40% of execution time, 77.8% of subjects perform a FSup simultaneously (Figure 5-8). A FSup and brief FPro closes the functional gesture

to put the bottle down on the table. The average decomposition sequence also demonstrates this pattern (Figure 5-9A). It is interesting to note that the detected gestures are not always the ones imagined beforehand. For the “Bottle” gesture, one could have predicted an extended FPro during the pouring of the static liquid above the glass. However, it is an extended FSup sometimes associated with a SHAbd that is detected. This can be explained by an isometric muscle contraction when holding the bottle which opposes natural movement due to gravity (FPro and SHAdd).

The three other functional gestures were also consistent with the subject 3D movements:

1. The “door” gesture mainly consisted of a combination of SFlex and EExt, followed by a EFlex to hold the door (Figure 5-9B).
2. The “hand-to-mouth” gesture is characterized by a FPro associated with an EFlex to bring the spoon to the mouth (Figure 5-9C), then an EExt and WFlex to bring the spoon down on the table.
3. The “blocks” gesture consisted of an alternation of EFlex and EExt to grab the cylinders, as well as FPro and FSup to place them on the pyramid (
4. Figure 5-10). The signals can be divided into four repeating cycles, corresponding to the placement of the four cylinders on the pyramid. The delay between FSup and EExt is visible in
5. Figure 5-10. On the contrary, NM (static) and FSup are synchronized during the placement of each cylinder. FPro and FSup are simultaneous but slightly shifted considering the placement sequence of the cylinders. The cycles seem to lengthen in duration towards the end of the signal (3rd and 4th repetition), especially on the NM, FSup and FPro signals. This can be explained by the progressive desynchronization of the subjects as the long gesture progress.

5.7.3 Armeo®Senso Games Design Optimization

The application of the proposed MDPC method to the Armeo®Senso games also gave results consistent with the movements performed and the physical therapeutic objectives of the games. Movement target grids (Figure 5-5 and Figure 5-11) allow a comparison between the results obtained with MDPC algorithm (Figure 5-11) and the targeted movement for each game (Figure 5-5).

The games designed to target a specific joint showed few discrepancies between the targeted movements (Figure 5-5) and the results of the subjects (Figure 5-11). For the wrist, the games *Air Hockey* (wrist) and *Hocokart* (wrist) were respectively at an average of 42.6% and 48.5% of training time for wrist joint during each game (Figure 5-11). For the SHAbd/SHAdd movements, the *Air Hockey* (shoulder) and *Rain Mug* (shoulder) games were also at more than 32% of game

training time for the targeted movement (Figure 5-11). At the elbow joint, the *Plumber* game reaches 39.3% of training time within the game (Figure 5-11). The *Brick Breaker* and *High Fly* games have lower scores due to high latency times ($> 5s$) within the game (Figure 5-11). However, these games remain quite specific with twice as much training time for the main movement than the second most targeted movement for most games (Figure 5-11). The design of these less intense games favors the work of a joint and its maintenance for several seconds. This allows clinicians to work on the precision and stability of the patients' movements while giving them sufficient rest time.

On the other hand, for less specific games such as *Farmer*, *Supermarket* or *Balloons*, the MDPC algorithm results (Figure 5-11) do not support strong correlation with the Hocoma Target Grid content (Figure 5-5) for the Armeo®Senso. *Farmer* game which is supposed to work all movement types (Figure 5-5), have results below 6.3% for all movements except WFlex/WExt at 14.6%. Similarly, the *Frisbee* game shows surprising results with a predominance of elbow use (Figure 5-11), although it is supposed to work mainly the wrist joint (Figure 5-5). Identifying some influential factors from the design of the game can provide some understanding for our results. For example in *Farmer*, depth plays an important role within the game for target distance that the player can control, usually with EFlex and EExt. The user may have to contract elbow more often for stability and to find the target, rather than of the wrist to throw the frisbee. Our algorithm results can help design serious games by identifying parameters that may alter targeted movements. Higher cognitive charge and motor planning and coordination skills requirements from the game (visual spatial analysis requirements, anticipation requirements, ideation response for more demanding figure ground skills, etc.) could be factors explaining discrepancies from the algorithm results and should be considered in game designs

5.7.4 Data processing optimization

The proposed study improved data processing for EMG-based gesture classification. The RELIEFF algorithm and experimental results confirmed the contribution of kinematic data in addition to electromyographic data in the features extracted from the signals, which can be explained by the limb position effect of myoelectric data [41, 44, 45]. Furthermore, studies tend to favor small window sizes (≥ 250 ms) for EMG signal classification [51, 55, 60]. This allows for more data and

a more responsive model, especially for real-time applications. The results on functional gestures showed that a data segmentation of 250 ms windows obtained a sufficient accuracy for applications on gestures of rather short duration (between 5 and 10s in average). However, for offline applications on long and complex sequences like the Armeo®Senso games, a segmentation with 500 ms windows is preferable for its better performances. It is consistent with Banos, et al. [53] results that large data window are better suited for complex activities detection and recognition. The movements of Armeo®Senso games are indeed slow and long enough compared to 500 ms to be classified by neural networks trained with data of this duration. Let us note that the proposed method leads to a weak detection of short duration movements such as hand grasping. This effect could be eliminated by training the neural networks on windows of different sizes between 100 and 500 ms and applying a simple majority rule to determine the classified movement at each time.

5.7.5 Perspectives

Future works could consist in applying the proposed protocol and classification strategy to children subjects, as well as patients with neuromuscular disorders, to determine to which extent this study can be applied to patients. Indeed, in this study, the games were played by healthy subjects. Upper extremity movements and muscle synergy differ for typically developed subjects from patients [61, 62]. Moreover, they also differ between patients depending on their level of motor dysfunction and diagnostic. The way a game is played is influenced by the patient's abilities. Using the MDPC algorithm would allow the design and use of each game to be adapted to the therapeutic needs of the patient, the first step towards more precise motor rehabilitation therapy sessions.

5.8 Conclusion

This study successfully developed an algorithmic solution to decompose the components of complex simultaneous sequences of movements, including seven DoFs on four joints: the hand, wrist, elbow, and shoulder. The mean accuracy for the LSTM classifiers was $98.2 \pm 0.3\%$, making it suitable for online and offline application in the recognition of complex activities. The accuracy, functionality and reliability of the classification algorithm was tested with functional gestures, and

the output was consistent with subject performance and visual observation. This study also proposed a visualisation tool of movement components decomposition. The MDPC algorithm application to Armeo®Senso allowed us to give more precision on activity analysis of games that are targeting specific movement training. The MDPC algorithm applied to new game design and during session patient evaluation could improve therapy personalization and efficiency.

5.9 Declaration of interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

5.10 Acknowledgments

The authors would like to thank the subjects who participated in this study. The authors would also like to thank the Strategic Cluster in Interactive technologies of engineering in rehabilitation (INTER), from the Fonds de recherche du Québec – Nature et technologies (FRQNT), for their funding. The authors would like to thank Fonds Melio of CHU Sainte-Justine Foundation and the biomedical team from Sainte-Justine UHC for their generous support concerning the equipment studied.

5.11 References

- [1] J. A. Kleim and T. A. Jones, "Principles of experience-dependent neural plasticity: implications for rehabilitation after brain damage," 2008.
- [2] L. Carey *et al.*, "Finding the intersection of neuroplasticity, stroke recovery, and learning: scope and contributions to stroke rehabilitation," *Neural Plasticity*, vol. 2019, 2019.
- [3] E. J. Lenze *et al.*, "Significance of poor patient participation in physical and occupational therapy for functional outcome and length of stay," *Archives of physical medicine and rehabilitation*, vol. 85, no. 10, pp. 1599-1601, 2004.
- [4] A. L. Behrman *et al.*, "Activity-based therapy targeting neuromuscular capacity after pediatric-onset spinal cord injury," *Topics in spinal cord injury rehabilitation*, vol. 25, no. 2, pp. 132-149, 2019.
- [5] M. Lotze, C. Braun, N. Birbaumer, S. Anders, and L. G. Cohen, "Motor learning elicited by voluntary drive," *Brain*, vol. 126, no. 4, pp. 866-872, 2003.

- [6] M. Covarrubias, A. Mansutti, M. Bordegoni, and U. Cugini, "Interacting game and haptic system based on point-based approach for assisting patients after stroke," in *International Conference on Computers for Handicapped Persons*, 2014: Springer, pp. 289-296.
- [7] A. L. Behrman *et al.*, "Restorative rehabilitation entails a paradigm shift in pediatric incomplete spinal cord injury in adolescence: An illustrative case series," *Journal of Pediatric Rehabilitation Medicine*, vol. 5, no. 4, pp. 245-259, 2012.
- [8] K. Hagen, C. Porter, R. Martin, J. Dean, C. Salorio, and C. Sadowsky, "Improvements in function following inpatient activity-based therapy for children with acute flaccid myelitis," *Topics in Spinal Cord Injury Rehabilitation*, vol. 26, no. 4, pp. 275-282, 2020.
- [9] Q. Wang, P. Markopoulos, B. Yu, W. Chen, and A. Timmermans, "Interactive wearable systems for upper body rehabilitation: a systematic review," *Journal of neuroengineering and rehabilitation*, vol. 14, no. 1, pp. 1-21, 2017.
- [10] K. L. Cheung, E. Tunik, S. V. Adamovich, and L. A. Boyd, "Neuroplasticity and virtual reality," in *Virtual reality for physical and motor rehabilitation*: Springer, 2014, pp. 5-24.
- [11] N. A. Borghese, M. Pirovano, P. L. Lanzi, S. Wüest, and E. D. de Bruin, "Computational intelligence and game design for effective at-home stroke rehabilitation," *Games for Health: Research, Development, and Clinical Applications*, vol. 2, no. 2, pp. 81-88, 2013.
- [12] K. N. Fong, Y. M. Tang, K. Sie, A. K. Yu, C. C. Lo, and Y. W. Ma, "Task-specific virtual reality training on hemiparetic upper extremity in patients with stroke," *Virtual Reality*, vol. 26, no. 2, pp. 453-464, 2022.
- [13] P. Dias *et al.*, "Using virtual reality to increase motivation in poststroke rehabilitation," *IEEE computer graphics and applications*, vol. 39, no. 1, pp. 64-70, 2019.
- [14] I. Cikajlo *et al.*, "Telerehabilitation of upper extremities with target based games for persons with Parkinson's disease," in *2017 International Conference on Virtual Rehabilitation (ICVR)*, 2017: IEEE, pp. 1-2.
- [15] N. Saywell, N. Taylor, E. Rodgers, L. Skinner, and M. Boocock, "Play-based interventions improve physical function for people with adult-acquired brain injury: a systematic review and meta-analysis of randomised controlled trials," *Clinical rehabilitation*, vol. 31, no. 2, pp. 145-157, 2017.
- [16] G. Saposnik *et al.*, "Effectiveness of virtual reality using Wii gaming technology in stroke rehabilitation: a pilot randomized clinical trial and proof of principle," *Stroke*, vol. 41, no. 7, pp. 1477-1484, 2010.
- [17] Y.-J. Chang, W.-Y. Han, and Y.-C. Tsai, "A Kinect-based upper limb rehabilitation system to assist people with cerebral palsy," *Research in developmental disabilities*, vol. 34, no. 11, pp. 3654-3659, 2013.
- [18] W.-S. Kim *et al.*, "Clinical application of virtual reality for upper limb motor rehabilitation in stroke: review of technologies and clinical evidence," *Journal of clinical medicine*, vol. 9, no. 10, p. 3369, 2020.
- [19] X. Huang, F. Naghdy, G. Naghdy, and H. Du, "Clinical effectiveness of combined virtual reality and robot assisted fine hand motion rehabilitation in subacute stroke patients," in

- 2017 *International Conference on Rehabilitation Robotics (ICORR)*, 2017: IEEE, pp. 511-515.
- [20] I. Dubovi, S. T. Levy, and E. Dagan, "Now I know how! The learning process of medication administration among nursing students with non-immersive desktop virtual reality simulation," *Computers & Education*, vol. 113, pp. 16-27, 2017.
- [21] L. Schwickert, J. Klenk, A. Stähler, C. Becker, and U. Lindemann, "Robotic-assisted rehabilitation of proximal humerus fractures in virtual environments," *Zeitschrift für Gerontologie und Geriatrie*, vol. 44, no. 6, pp. 387-392, 2011.
- [22] J. Mehrholz, M. Pohl, T. Platz, J. Kugler, and B. Elsner, "Electromechanical and robot-assisted arm training for improving activities of daily living, arm function, and arm muscle strength after stroke," *Cochrane Database of Systematic Reviews*, no. 9, 2018.
- [23] F. Wittmann *et al.*, "Self-directed arm therapy at home after stroke with a sensor-based virtual reality training system," *Journal of neuroengineering and rehabilitation*, vol. 13, no. 1, pp. 1-10, 2016.
- [24] F. Wittmann *et al.*, "Assessment-driven arm therapy at home using an IMU-based virtual reality system," in *2015 IEEE international conference on rehabilitation robotics (ICORR)*, 2015: IEEE, pp. 707-712.
- [25] H. I. Krebs *et al.*, "Rehabilitation robotics: Performance-based progressive robot-assisted therapy," *Autonomous robots*, vol. 15, no. 1, pp. 7-20, 2003.
- [26] C. Behar, M. Lustick, M. H. Foreman, J. Webb, and J. R. Engsborg, "Personalized virtual reality for upper extremity rehabilitation: Moving from the clinic to a home exercise program," *Journal of Intellectual Disability-Diagnosis and Treatment*, vol. 4, no. 3, pp. 160-169, 2016.
- [27] M. Nahum, H. Lee, and M. M. Merzenich, "Principles of neuroplasticity-based rehabilitation," *Progress in brain research*, vol. 207, pp. 141-171, 2013.
- [28] A. J. Young, L. H. Smith, E. J. Rouse, and L. J. Hargrove, "A comparison of the real-time controllability of pattern recognition to conventional myoelectric control for discrete and simultaneous movements," *Journal of neuroengineering and rehabilitation*, vol. 11, no. 1, pp. 1-10, 2014.
- [29] A. J. Young, L. H. Smith, E. J. Rouse, and L. J. Hargrove, "A new hierarchical approach for simultaneous control of multi-joint powered prostheses," in *2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob)*, 2012: IEEE, pp. 514-520.
- [30] A. L. Ciancio, F. Cordella, K.-P. Hoffmann, A. Schneider, E. Guglielmelli, and L. Zollo, "Current Achievements and Future Directions of Hand Prostheses Controlled via Peripheral Nervous System," in *The Hand*, 2017.
- [31] J. A. George, T. S. Davis, M. R. Brinton, and G. A. Clark, "Intuitive neuromyoelectric control of a dexterous bionic arm using a modified Kalman filter," *Journal of Neuroscience Methods*, vol. 330, p. 108462, 2020.
- [32] L. H. Smith and L. J. Hargrove, "Comparison of surface and intramuscular EMG pattern recognition for simultaneous wrist/hand motion classification," in *2013 35th annual*

- international conference of the IEEE engineering in medicine and biology society (EMBC)*, 2013: IEEE, pp. 4223-4226.
- [33] J. J. Baker, E. Scheme, K. Englehart, D. T. Hutchinson, and B. Greger, "Continuous detection and decoding of dexterous finger flexions with implantable myoelectric sensors," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 18, no. 4, pp. 424-432, 2010.
- [34] M. Zecca, S. Micera, M. C. Carrozza, and P. Dario, "Control of multifunctional prosthetic hands by processing the electromyographic signal," *Critical Reviews™ in Biomedical Engineering*, vol. 30, no. 4-6, 2002.
- [35] A. J. Young, L. H. Smith, E. J. Rouse, and L. J. Hargrove, "Classification of simultaneous movements using surface EMG pattern recognition," *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 5, pp. 1250-1258, 2012.
- [36] F. Leone, C. Gentile, F. Cordella, E. Gruppioni, E. Guglielmelli, and L. Zollo, "A parallel classification strategy to simultaneous control elbow, wrist, and hand movements," *Journal of NeuroEngineering and Rehabilitation*, vol. 19, no. 1, pp. 1-17, 2022.
- [37] P. Herberts, C. Almström, R. Kadefors, and P. D. Lawrence, "Hand prosthesis control via myoelectric patterns," *Acta Orthopaedica Scandinavica*, vol. 44, no. 4-5, pp. 389-409, 1973.
- [38] D. Yatsenko, D. McDonnall, and K. S. Guillory, "Simultaneous, proportional, multi-axis prosthesis control using multichannel surface EMG," in *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2007: IEEE, pp. 6133-6136.
- [39] M. I. Daoud, A. Alhuseini, M. Z. Ali, and R. Alazrai, "A game-based rehabilitation system for upper-limb cerebral palsy: A feasibility study," *Sensors-Basel*, vol. 20, no. 8, p. 2416, 2020.
- [40] D. Maclsaac, P. Parker, R. Scott, K. Englehart, and C. Duffley, "Influences of dynamic factors on myoelectric parameters," *IEEE engineering in medicine and biology magazine*, vol. 20, no. 6, pp. 82-89, 2001.
- [41] A. Fougner, E. Scheme, A. D. Chan, K. Englehart, and Ø. Stavadahl, "Resolving the limb position effect in myoelectric pattern recognition," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 19, no. 6, pp. 644-651, 2011.
- [42] H. Hermens, B. Freriks, C. Disselhorst-Klug, and G. Rau, "The SENIAM project: Surface electromyography for non-invasive assessment of muscle," in *ISEK Congress*, 2002, pp. 22-25.
- [43] A. Sarcher *et al.*, "Impact of muscle activation on ranges of motion during active elbow movement in children with spastic hemiplegic cerebral palsy," *Clinical Biomechanics*, vol. 30, no. 1, pp. 86-94, 2015.
- [44] J. C. Jamison and G. E. Caldwell, "Muscle synergies and isometric torque production: influence of supination and pronation level on elbow flexion," *Journal of neurophysiology*, vol. 70, no. 3, pp. 947-960, 1993.

- [45] M. R. Masters, R. J. Smith, A. B. Soares, and N. V. Thakor, "Towards better understanding and reducing the effect of limb position on myoelectric upper-limb prostheses," in *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2014: IEEE, pp. 2577-2580.
- [46] S. Raouafi, M. Raison, and A. Sofiane, "Modeling the assessment of the upper limb motor function impairment in children with cerebral palsy using sEMG and IMU sensors," *bioRxiv*, p. 748202, 2019.
- [47] A. Barre and S. Armand, "Biomechanical ToolKit: Open-source framework to visualize and process biomechanical data," *Computer methods and programs in biomedicine*, vol. 114, no. 1, pp. 80-87, 2014.
- [48] B. Cahyadi *et al.*, "Upper limb muscle strength analysis for movement sequence based on maximum voluntary contraction using EMG signal," in *2018 International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*, 2018: IEEE, pp. 1-5.
- [49] R. Gross *et al.*, "The influence of gait speed on co-activation in unilateral spastic cerebral palsy children," (in English), *Clinical Biomechanics*, vol. 28, no. 3, pp. 312-317, Mar 2013, doi: 10.1016/j.clinbiomech.2013.01.002.
- [50] A. Sarcher *et al.*, "Patterns of upper limb muscle activation in children with unilateral spastic cerebral palsy: Variability and detection of deviations," *Clinical Biomechanics*, vol. 59, pp. 85-93, 2018.
- [51] G. Gaudet, M. Raison, and S. Achiche, "Classification of Upper limb phantom movements in transhumeral amputees using electromyographic and kinematic features," (in English), *Eng Appl Artif Intel*, vol. 68, pp. 153-164, Feb 2018, doi: 10.1016/j.engappai.2017.10.017.
- [52] K. Tedroff, L. M. Knutson, and G. L. Soderberg, "Synergistic muscle activation during maximum voluntary contractions in children with and without spastic cerebral palsy," *Developmental medicine and child neurology*, vol. 48, no. 10, pp. 789-796, 2006.
- [53] O. Banos, J.-M. Galvez, M. Damas, H. Pomares, and I. Rojas, "Window size impact in human activity recognition," *Sensors-Basel*, vol. 14, no. 4, pp. 6474-6499, 2014.
- [54] I. Kononenko, E. Šimec, and M. Robnik-Šikonja, "Overcoming the myopia of inductive learning algorithms with RELIEFF," *Applied Intelligence*, vol. 7, no. 1, pp. 39-55, 1997.
- [55] M. Jabbari, R. N. Khushaba, and K. Nazarpour, "Emg-based hand gesture classification with long short-term memory deep recurrent neural networks," in *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, 2020: IEEE, pp. 3302-3305.
- [56] M. Simão, P. Neto, and O. Gibaru, "EMG-based online classification of gestures with recurrent neural networks," *Pattern Recognition Letters*, vol. 128, pp. 45-51, 2019.
- [57] D. Chicco and G. Jurman, "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC genomics*, vol. 21, no. 1, pp. 1-13, 2020.

- [58] Z. Li, J. Zuo, Z. Han, X. Han, C. Sun, and Z. Wang, "Intelligent classification of multi-gesture emg signals based on lstm," in *2020 International Conference on Artificial Intelligence and Electromechanical Automation (AIEA)*, 2020: IEEE, pp. 62-65.
- [59] A. Samadani, "Gated recurrent neural networks for EMG-based hand gesture classification. A comparative study," in *2018 40th annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2018: IEEE, pp. 1-4.
- [60] J. L. Betthausen *et al.*, "Stable responsive EMG sequence prediction and adaptive reinforcement with temporal convolutional networks," *IEEE Transactions on Biomedical Engineering*, vol. 67, no. 6, pp. 1707-1717, 2019.
- [61] A. Summa, G. Vannozzi, E. Bergamini, M. Iosa, D. Morelli, and A. Cappozzo, "Multilevel upper body movement control during gait in children with cerebral palsy," *PloS one*, vol. 11, no. 3, p. e0151792, 2016.
- [62] L. Tang, X. Chen, S. Cao, D. Wu, G. Zhao, and X. Zhang, "Assessment of upper limb motor dysfunction for children with cerebral palsy based on muscle synergy analysis," *Frontiers in Human Neuroscience*, vol. 11, p. 130, 2017.

5.12 Appendix

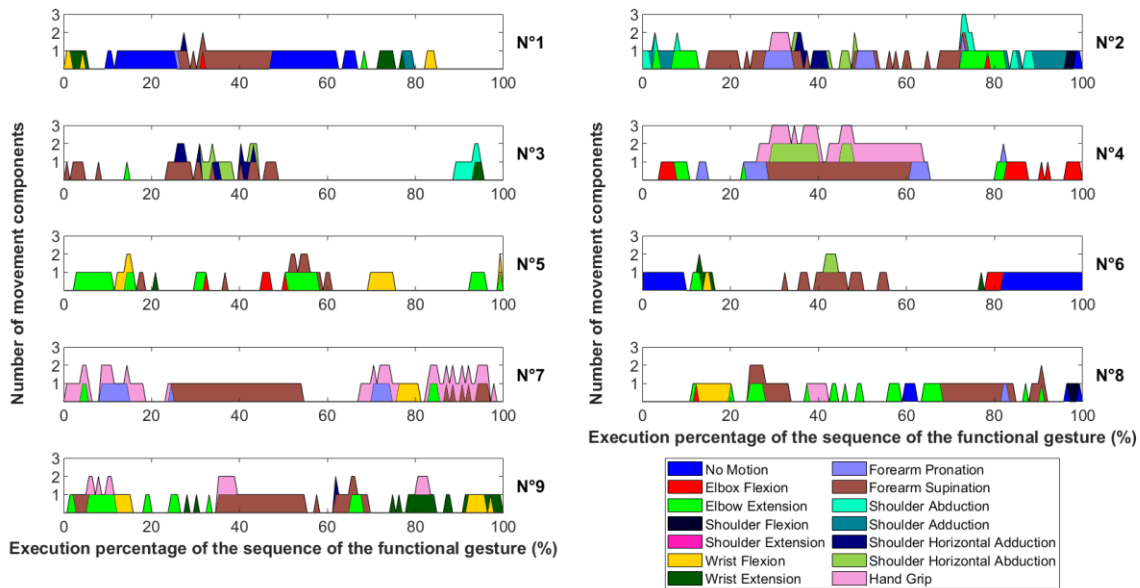


Fig. A Movements components for subjects 1 to 9 during the functional gesture "Bottle".

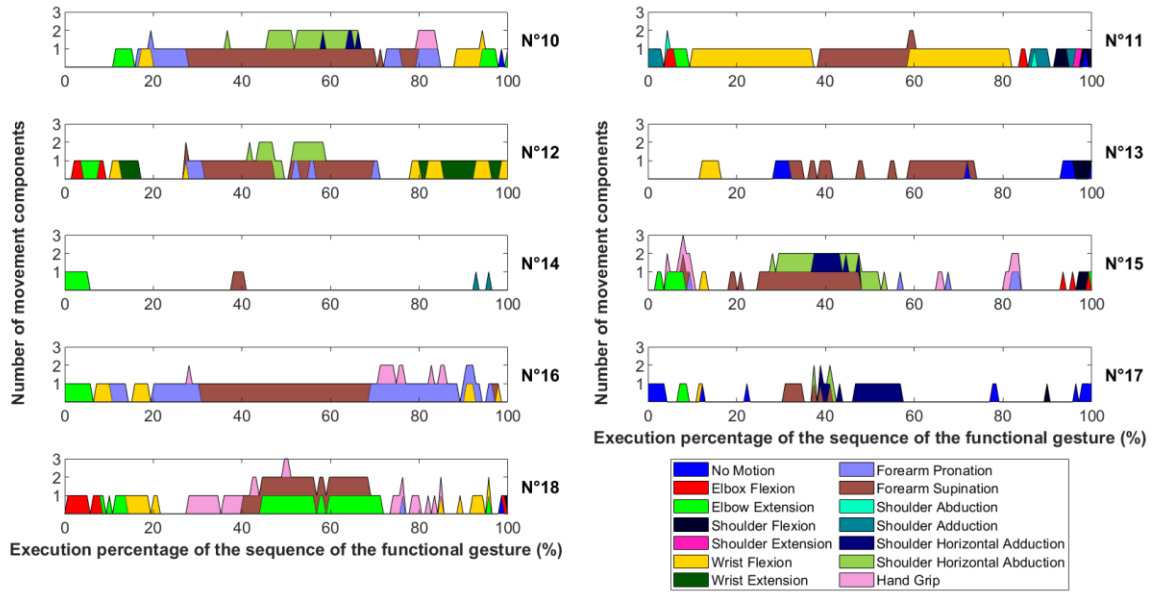


Fig. B Movements components for subjects 10 to 18 during the functional gesture “Bottle”.

CHAPITRE 6 RÉSULTATS COMPLÉMENTAIRES

6.1 Impact des positions supplémentaires

La figure Figure 6-1 montre la précision de classification des LSTM entraînés soit avec les données de toutes les positions enregistrées (neutre + supplémentaires), soit uniquement avec la position neutre. Les LSTM entraînés uniquement avec les données en position neutre ont en moyenne de précision de classification avec $98.6\% \pm 0.3\%$ contre $98.2\% \pm 0.3\%$ pour les LSTM entraînés avec toutes les données.

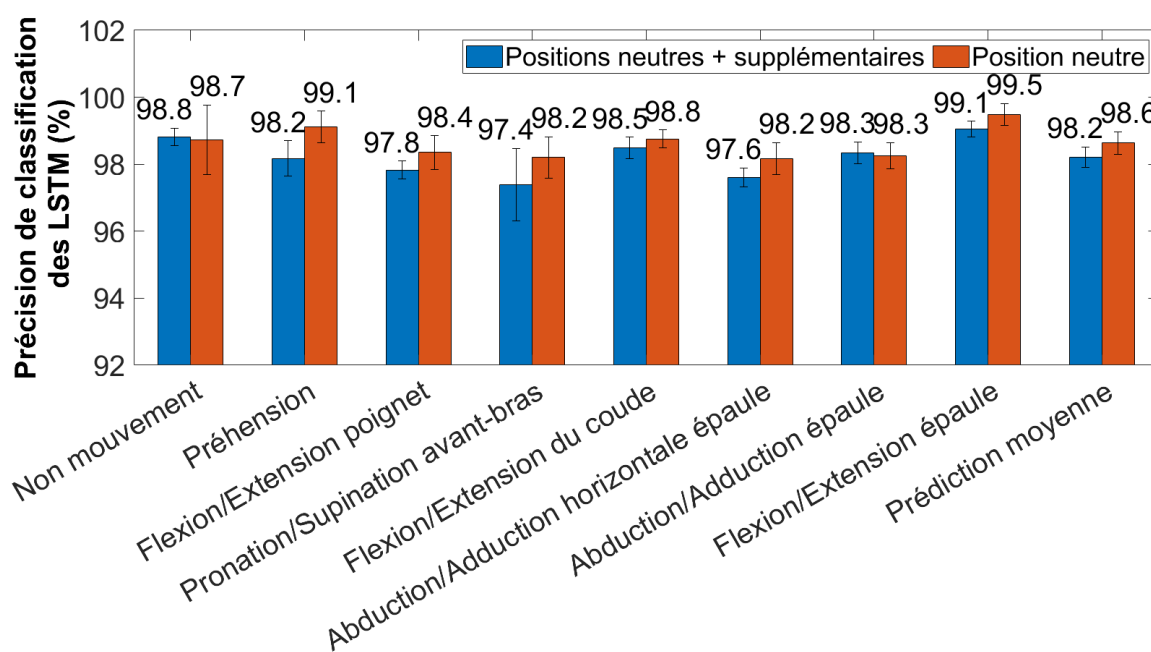


Figure 6-1 Précision de classification de LSTM entraînés avec des données en position neutre uniquement, ou avec des données en position neutre et supplémentaires (pronation de l'avant-bras, supination de l'avant-bras et flexion de l'épaule). La taille des fenêtres est de 500ms.

La Figure 6-2 présente les résultats de décomposition des cinq gestes fonctionnels sous la forme du geste moyen pour tous les sujets. Les résultats sont obtenus avec des LSTM entraînés uniquement avec les données en position neutre.

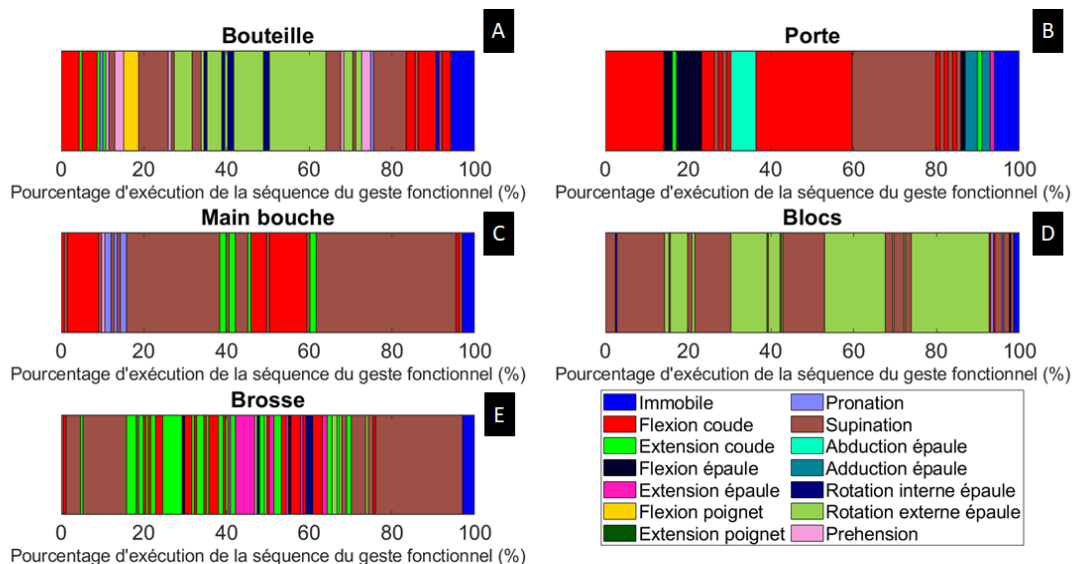


Figure 6-2 Geste fonctionnel moyen pour tous les sujets pour chacun des gestes fonctionnels, avec les données uniquement en position neutre. A. Bouteille. B. Porte. C. Main-bouche. D. Pyramide. E. Brosse

6.2 Résultats complémentaires sur les gestes fonctionnels

Les résultats de la décomposition de mouvements lors du geste « Brosse » sont présentés à la Figure 6-3 en moyennant les résultats sur tous les sujets. Des exemples de décomposition chez trois sujets sont donnés à la Figure 6-4. Pour ces deux figures, toutes les données (position neutre et positions supplémentaires) ont été utilisées, tout comme dans l'article présenté dans ce mémoire.

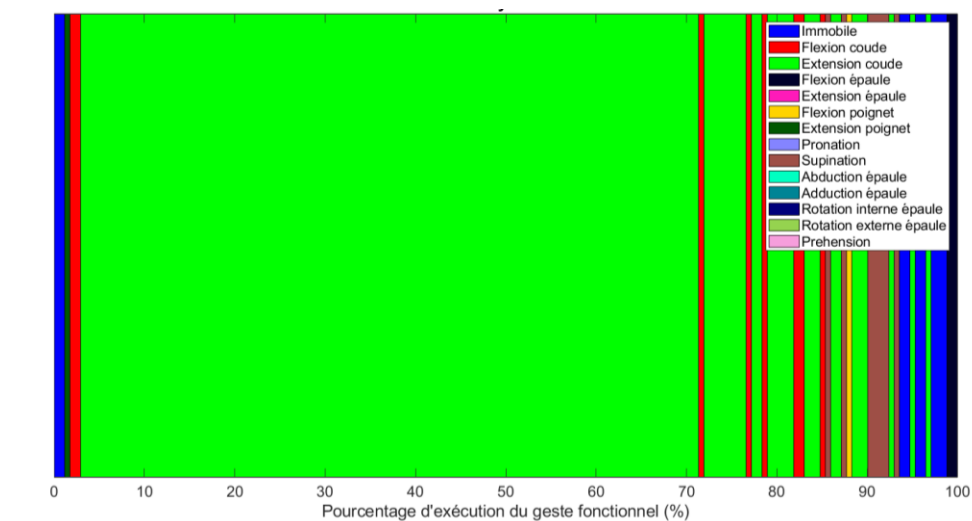


Figure 6-3 Geste moyen sur tous les sujets du geste fonctionnel « Brosse »

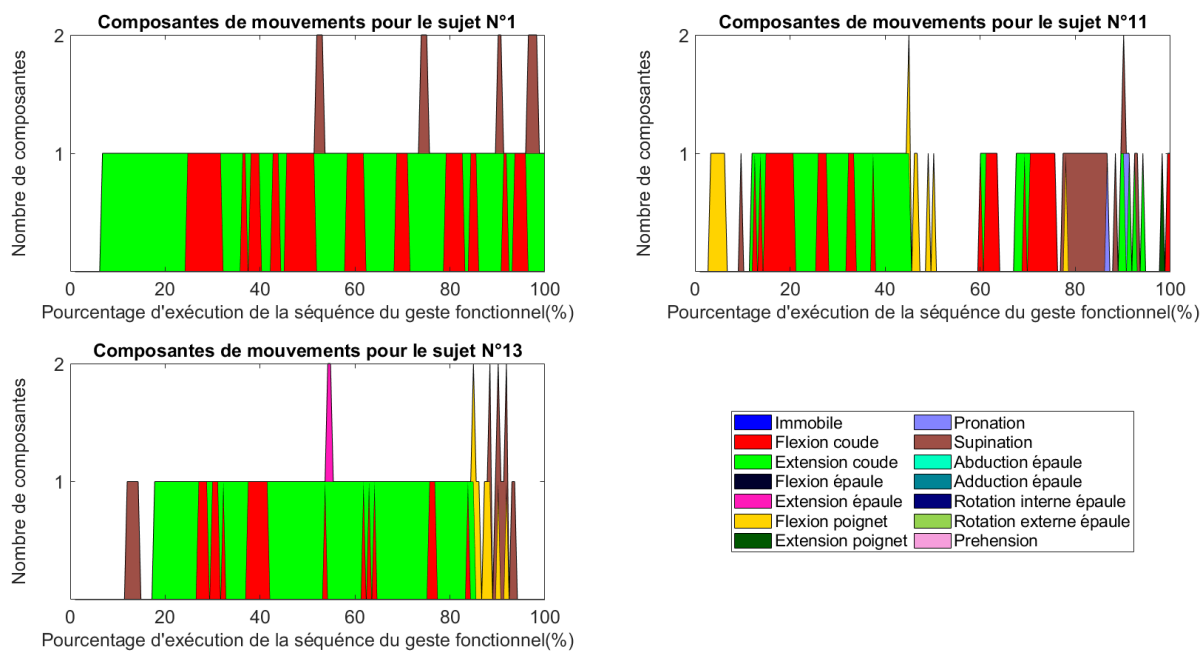


Figure 6-4 Exemples de décomposition de mouvements du geste fonctionnel « Brosse » chez 3 sujets. A. Décomposition chez le sujet n°1. B. Décomposition chez le sujet n°11. C. Décomposition chez le sujet n°13.

CHAPITRE 7 DISCUSSION GÉNÉRALE

L'objectif général de l'étude, soit le développement d'une solution algorithmique de décomposition de mouvements du membre supérieur incluant sept DDL sur quatre articulations (main, poignet, coude, épaule), a été rempli. Cette section présente une synthèse de la discussion de l'article du Chapitre 5, ainsi qu'une discussion complémentaire sur les résultats complémentaires. Les limites et perspectives de l'étude présentée dans ce mémoire sont aussi abordées.

7.1 Synthèse de l'article

Les résultats de classification des LSTM donnent une excellente prédiction moyenne de $98.2\% \pm 0.3\%$ pour ceux entraînés avec des données segmentées à 500ms (Figure 5-6) (SO1). Ces résultats sont du même ordre de grandeur que ceux utilisant des stratégies de classification similaires, mais à 3 DDL [70, 71, 73, 82]. L'algorithme de décomposition, testé sur quatre gestes fonctionnels séquentiels ou simultanés, a obtenu des résultats cohérents avec les gestes en question et les observations visuelles des expérimentateurs (Figure 5-7, Figure 5-8, Figure 5-9, Figure 5-10) (SO2).

Concernant l'application de l'algorithme aux signaux enregistrés pendant les jeux avec l'Armeo®Senso, les résultats (Figure 5-11) ont pu être comparés avec la grille d'objectifs thérapeutiques des jeux fournie par le fabricant Hocoma (Figure 5-4) (SO3). Cette comparaison a mis en évidence une adéquation globale entre nos résultats et la grille d'Hocoma, et permis d'identifier certains problèmes de conception des jeux déjà ressentis lors de leur utilisation par les sujets. Les jeux peu spécifiques, c'est-à-dire avec un objectif d'entraînement de plus de deux ou trois mouvements, ont montré plus de problématiques en termes de conception que les autres jeux plus spécifiques. L'étude avec les gestes fonctionnels et les jeux de l'Armeo®Senso ont montré la bonne performance de notre algorithme de décomposition de mouvement et son potentiel pour de futures applications cliniques.

7.2 Analyse des résultats complémentaires

7.2.1 Impact du positionnement du membre supérieur lors du mouvement

Les résultats de prédiction des classificateurs LSTM sont en moyenne meilleurs pour ceux entraînés avec les données en position neutre uniquement que ceux entraînés avec toutes les positions. Cependant, la différence est non significative vu les intervalles de confiance avec une moyenne de classification de $98.6\% \pm 0.3\%$ contre $98.2\% \pm 0.3\%$ pour les LSTM entraînés avec toutes les données (Figure 6-1). Cette différence, même si non significative, peut s'expliquer par le fait que les positions supplémentaires « brouillent » les signaux EMGs. En effet, une position non neutre implique la contraction isométrique de certains muscles, comme le rond pronateur pour la position en pronation, ou le deltoïde pour la position en flexion de l'épaule. Cette contraction se reflète sur les signaux sEMG. Il devient donc plus difficile pour un algorithme de classification, quel qu'il soit, de distinguer une flexion du coude en position de pronation, d'un mouvement de pronation. Les résultats de la Figure 6-1 suggèrent cependant que les réseaux de neurones sont capables de distinguer les différentes classes de mouvements même dans des positions non neutres, permettant d'apporter de la diversité au sein des données tout en gardant une excellente précision de classification.

Les positions supplémentaires permettent en effet une meilleure décomposition face à des signaux réels, que ce soient des gestes fonctionnels ou de l'Armeo®Senso. Les résultats de décomposition des gestes fonctionnels sans positions supplémentaires de la Figure 6-2 montrent une prédominance des mouvements de l'avant-bras (notamment supination de l'avant-bras) et de l'épaule (notamment abduction/adduction horizontale de l'épaule) par rapport aux résultats de décomposition avec toutes les positions des Figure 6-3 et Figure 5-9. Cette prédominance n'est pas justifiée d'après l'observation visuelle des gestes fonctionnels des sujets. Cela peut s'expliquer par la co-contraction des muscles de l'avant-bras et de l'épaule sur les signaux sEMG, notamment lors des mouvements s'effectuant les bras en l'air en luttant contre la gravité. Les muscles contractés (particulièrement le rond pronateur et le deltoïde) sont en effet caractéristiques des mouvements de pronation/supination de l'avant-bras et des mouvements de l'épaule.

Ces résultats montrent l'importance de la position de réalisation des gestes et de la nécessité de diversifier la base de données avec des signaux aussi réalistes que possible.

7.2.2 Geste fonctionnel « Brosse »

Le geste fonctionnel « Brosse » n'a pas été inclus dans l'article en raison de la longueur de l'article et de la non-standardisation du geste. En effet, la durée du geste n'était pas standardisée avec certains sujets se brossant les cheveux pendant 5s et d'autres 10s. Par ailleurs, la nature du geste en lui-même n'était pas standardisée. Chaque personne se brosse différemment, notamment en fonction de la longueur de cheveux. La Figure 4-4 montre les deux approches les plus souvent effectuées : les sujets à cheveux longs se brossent souvent les cheveux latéralement (Figure 4-4A) et les personnes à cheveux courts se brossent plutôt sur le dessus du crâne (Figure 4-4B).

Les résultats de la décomposition de ce geste fonctionnel sont cependant cohérents avec l'observation du geste, notamment par l'alternance de flexion et d'extension du coude visible sur les trois graphiques de la Figure 6-4. Cette alternance est moins visible sur le geste moyen de la Figure 6-3, en raison de la durée variée des enregistrements de ce geste.

7.3 Limites et perspectives

Bien que l'objectif et les sous-objectifs de cette étude aient été atteints comme cela a été montré dans la Section 7.1, cette maîtrise reste une étude de développement dont les résultats, bien que prometteurs ne sauraient être appliqués directement en clinique. Les limites de la présente étude ouvrent la voie à de futurs travaux et des perspectives pour les patients et cliniciens en réadaptation.

Simplification du protocole clinique et du nombre de DDL

Le protocole de prise de mesure a été pensé pour pouvoir s'insérer dans le cadre des séances de thérapie de patients d'une durée de 45 min. La totalité des prises de mesure des gestes simples standardisés devait donc tenir en 30 min, placement des sEMG compris. Un choix a donc été fait sur les mouvements étudiés et le nombre de capteurs sEMG-IMU afin de respecter cette contrainte temporelle et obtenir l'adhésion des patients et des cliniciens. Le choix de se limiter à sept DDL, nombre déjà élevé dans le domaine de la classification de mouvements, était délibéré afin de garantir la simplicité du protocole, mais aussi du modèle qui, en restant réaliste, néglige tout de même certains mouvements (HR1). Tout en gardant le même nombre de DDL, le protocole pourrait être amélioré en augmentant le nombre de capteurs sEMG-IMU sur de nouveaux muscles afin de

mieux discriminer les mouvements de l'épaule et du poignet qui étaient les plus durs à classer (Figure 5-6). Par exemple, les muscles grand dorsal, grand rond, ainsi que l'utilisation combinée des fléchisseurs/extenseurs radiaux et ulnaires pourraient être une piste envisagée respectivement pour la classification des mouvements de l'épaule et du poignet.

Il faut noter que les mouvements étudiés dans cette étude ont également été choisis en fonction des gestes fonctionnels et des jeux de l'Armeo®Sensio, comme cela a été expliqué par l'hypothèse de recherche HR1. Dans le cadre de l'étude d'un autre appareil pour son optimisation, d'autres mouvements devront être envisagés. Par exemple, dans le cadre de l'Armeo®Spring, il semble indispensable d'inclure la rotation latérale et médiale de l'épaule. Ces gestes pourront remplacer l'abduction et l'adduction de l'épaule qui sont des mouvements impossibles à réaliser par les patients à cause de l'exosquelette. Au vu des résultats obtenus sur les jeux de l'Armeo®Sensio (Figure 5-11), l'abduction et l'adduction de l'épaule pourraient aussi être négligés dans une future étude sur l'Armeo®Sensio afin d'étudier l'importance de la rotation latérale et médiale de l'épaule non pris en compte dans cette étude.

Les gestes plus subtils de la main, travaillés en réadaptation pour les activités de la vie quotidienne, sont aujourd'hui indétectables avec notre méthode étant donné le nombre limité de capteurs sEMG à notre disposition et la petite taille des muscles en jeu. D'autres méthodes d'acquisition des signaux sEMG, comme les sEMG haute-densité ou les réseaux d'électrodes, pourraient davantage être utilisées pour une telle application.

Amélioration de l'algorithme de décomposition de mouvements par classification parallèle

La bonne performance de la stratégie de classification a été montrée sur des gestes de courte durée et des mouvements plus lents pendant les jeux de l'Armeo®Sensio. Il reste cependant possible d'améliorer le traitement des signaux ainsi que la décomposition des mouvements. 16 caractéristiques ont été extraites des signaux, sept pour les sEMG et neuf pour l'ACC en raison des trois axes. Un nombre de caractéristiques trop important peut nuire à une bonne prédiction. Il pourrait être intéressant d'essayer de réduire ce nombre de caractéristiques, surtout sur les signaux ACC où il serait possible d'en trouver de nouvelles combinant les informations des trois axes.

Par ailleurs, la base de données utilisée pour l'entraînement des LSTM ne contenait que les données sEMG et IMU de 18 sujets TD. La qualité des signaux enregistrés variait aussi selon les sujets. Par

conséquent, l'algorithme de décomposition de mouvements donnait de meilleurs résultats pour certains sujets que pour d'autres. L'inclusion de nouveaux sujets dans la base de données permettrait l'obtention de données plus diverses et la diminution du nombre de décompositions de mouvements de mauvaise qualité.

Transfert clinique

La solution algorithmique présentée dans cette maîtrise n'est pas prête pour être déployée en l'état en clinique. Elle repose en effet sur une base de données de sujets adultes TD. Elle reste cependant un outil intéressant pour la validation des objectifs thérapeutiques des jeux en amont des séances de réadaptation. Par exemple, nous avons montré dans l'article présenté au Chapitre 5 l'influence de la profondeur du jeu en 3D *Frisbee* de l'Armeo®Senso sur l'utilisation de la flexion/extension du coude aux dépens de la flexion/extension du poignet.

Un prolongement de cette étude pourrait être la création d'une base de données de signaux sEMG-IMU issus de patients enfants et adultes suivis en réadaptation. Une telle base de données permettrait la comparaison des résultats avec les sujets TD et observer les différences de comportements et mouvements lors de l'exécution des jeux de l'Armeo®Senso. Il serait également intéressant d'obtenir suffisamment de données pour comparer les résultats de décomposition de mouvements selon les pathologies des patients.

CHAPITRE 8 CONCLUSION

La présente étude avait pour objectif de développer une solution algorithmique de décomposition des mouvements complexes du membre supérieur en 13 mouvements simples à 1 DDL et une classe de non mouvement, à l'aide de données électromyographiques et cinématiques de sujets adultes TD. Afin de considérer l'influence du positionnement initial du membre sur les signaux sEMG (notamment l'avant-bras en pronation/ supination et le bras en flexion), les mouvements simples constituant la base de données ont été enregistrés dans quatre positions différentes. Ces différents positionnements ont montré leur importance sur l'efficacité de la décomposition des mouvements.

La prédiction moyenne des LSTM atteint $98.2\% \pm 0.3\%$ pour les données segmentées à 500 ms (SO1). Notre algorithme de décomposition de mouvements, testé sur des gestes fonctionnels de la vie quotidienne et sur des jeux utilisés en réadaptation, a montré sa fonctionnalité et sa bonne performance à l'aide de nouveaux outils de visualisation développés en parallèle de l'algorithme. Les résultats de la décomposition pour les gestes fonctionnels sont en adéquation avec les observations visuelles des mouvements complexes réalisés (SO2). Les résultats de la décomposition sur les jeux de l'Armeo®Senso mettent en évidence les mouvements simples les plus travaillés dans chaque jeu, généralement en adéquation avec les informations sur les objectifs thérapeutiques fournis par le fabricant Hocoma. Ces résultats permettent également d'évaluer la conception de chaque jeu pour des sujets adultes TD, et d'identifier des facteurs dans la conception du jeu influençant les mouvements exécutés et pouvant nuire à l'efficacité thérapeutique du jeu (SO3). Les résultats de l'algorithme de décomposition des mouvements pour les jeux plus spécifiques s'écartent moins des objectifs de réadaptation motrice que les jeux non spécifiques. Ces résultats montrent le potentiel de notre algorithme de décomposition de mouvements dans l'aide à la conception et l'évaluation des dispositifs de réalité virtuelle utilisés en réadaptation.

Les limites d'applications cliniques de notre algorithme résident aujourd'hui dans son utilisation de données provenant de sujets adultes TD, et son nombre limité de mouvements étudiés malgré sept DDL, notamment au niveau de l'épaule, mais aussi de la main. Une simplification du

traitement des données et une réduction du nombre de caractéristiques extraites permettraient également une implémentation plus rapide et efficace.

Une des perspectives serait la création d'une base de données électromyographiques et cinématiques de patients adultes et enfants suivis en réadaptation, ce qui n'était malheureusement pas possible dans le cadre de cette étude. Celle-ci permettrait l'évaluation des mouvements du patient en temps réel et ouvrirait la voie à la personnalisation des thérapies en fonction de la pathologie, des capacités et objectifs thérapeutiques de chaque patient.

RÉFÉRENCES

- [1] L. Rose *et al.*, "Trends in incidence, prevalence, and mortality of neuromuscular disease in Ontario, Canada: A population-based retrospective cohort study (2003-2014)," vol. 14, n° 3, p. e0210574, 2019.
- [2] M. Gunn *et al.*, "User evaluation of a dynamic arm orthosis for people with neuromuscular disorders," vol. 24, n° 12, p. 1277-1283, 2015.
- [3] G. Kwakkel, B. J. Kollen et H. I. Krebs, "Effects of robot-assisted therapy on upper limb recovery after stroke: a systematic review," vol. 22, n° 2, p. 111-121, 2008.
- [4] I. Cikajlo *et al.*, "Telerehabilitation of upper extremities with target based games for persons with Parkinson's disease," communication présentée à 2017 International Conference on Virtual Rehabilitation (ICVR), 2017, p. 1-2.
- [5] K. N. Fong *et al.*, "Task-specific virtual reality training on hemiparetic upper extremity in patients with stroke," vol. 26, n° 2, p. 453-464, 2022.
- [6] R. L. Drake, A. W. Vogl et A. W. Mitchell, "GRAY'S Anatomie - Le manuel pour les étudiants, 4e édition," éd: Elsevier Masson, 2020.
- [7] M. R. Villarreal. (2022) Wikipedia commons, public domain. [En ligne]. Disponible: https://en.wikipedia.org/wiki/File:Human_arm_bones_diagram.svg
- [8] S. Namdari *et al.*, "Defining functional shoulder range of motion for activities of daily living," vol. 21, n° 9, p. 1177-1183, 2012.
- [9] B. Delaney. (2022) Muscles That Move the Arm. [En ligne]. Disponible: <https://www.acefitness.org/fitness-certifications/ace-answers/exam-preparation-blog/3535/muscles-that-move-the-arm/>
- [10] T. Ogele. (2022) Wikipedia commons, public domain. [En ligne]. Disponible: https://commons.wikimedia.org/wiki/File:Body_Movements_I.jpg
- [11] A. I. Kapandji, *Anatomie fonctionnelle: Volume 1-Membre supérieur*: Maloine, 2021.
- [12] N. Omarkulov *et al.*, "Preliminary mechanical design of NU-Wrist: A 3-DOF self-aligning Wrist rehabilitation robot," communication présentée à 2016 6th IEEE international conference on biomedical robotics and biomechatronics (BioRob), 2016, p. 962-967.
- [13] H. Gray, "Anatomy of the Human Body, Lea & Febiger, Philadelphia, US," 1918.
- [14] S. Raouafi, "Développement d'un outil automatique d'aide au diagnostic pour les enfants atteints de paralysie cérébrale en réadaptation robotique," Polytechnique Montréal, 2019.
- [15] L. Turner-Stokes, "Evaluation of functional outcome measures for the hemiparetic upper limb: a systematic review," vol. 40, p. 787-795, 2008.
- [16] A. Harb et S. Kishner, "Modified ashworth scale," dans *StatPearls [Internet]*: StatPearls Publishing, 2021.

- [17] A.-C. Eliasson *et al.*, "The Manual Ability Classification System (MACS) for children with cerebral palsy: scale development and evidence of validity and reliability," vol. 48, n^o. 7, p. 549-554, 2006.
- [18] C. Bosecker *et al.*, "Kinematic robot-based evaluation scales and clinical counterparts to measure upper limb motor performance in patients with chronic stroke," vol. 24, n^o. 1, p. 62-69, 2010.
- [19] C. J. de Luca, P. J. Foley et Z. Erim, "Motor unit control properties in constant-force isometric contractions," vol. 76, n^o. 3, p. 1503-1516, 1996.
- [20] K. Englehart, "Signal representation for classification of the transient myoelectric signal," 1998.
- [21] J. Wang, L. Tang et J. E. Bronlund, "Surface EMG signal amplification and filtering," vol. 82, n^o. 1, 2013.
- [22] A. Sarcher *et al.*, "Impact of muscle activation on ranges of motion during active elbow movement in children with spastic hemiplegic cerebral palsy," vol. 30, n^o. 1, p. 86-94, 2015.
- [23] A. Phinyomark *et al.*, "Evaluation of EMG feature extraction for hand movement recognition based on Euclidean distance and standard deviation," communication présentée à ECTI-CON2010: The 2010 ECTI International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, 2010, p. 856-860.
- [24] M. S. H. Majid *et al.*, "EMG feature extractions for upper-limb functional movement during rehabilitation," communication présentée à 2018 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS), 2018, p. 314-320.
- [25] R. H. Chowdhury *et al.*, "Surface electromyography signal processing and classification techniques," vol. 13, n^o. 9, p. 12431-12466, 2013.
- [26] M. Raison *et al.*, "Assessment of antagonistic muscle forces during forearm flexion/extension," dans *Multibody Dynamics*: Springer, 2011, p. 215-238.
- [27] S. Raouafi, M. Raison et A. Sofiane, "Modeling the assessment of the upper limb motor function impairment in children with cerebral palsy using sEMG and IMU sensors," p. 748202, 2019.
- [28] S. Raouafi *et al.*, "Classification of upper limb disability levels of children with spastic unilateral cerebral palsy using K-means algorithm," vol. 56, n^o. 1, p. 49-59, 2018.
- [29] T. Qing *et al.*, "Upper limb muscle strength prediction based on motion capture and sEMG data," communication présentée à 2019 25th International Conference on Automation and Computing (ICAC), 2019, p. 1-5.
- [30] J. Kim, H. Kim et J. Kim, "Quantitative assessment test for upper-limb motor function by using EMG and kinematic analysis in the practice of occupational therapy," communication présentée à 2017 39th annual international conference of the IEEE engineering in medicine and biology society (EMBC), 2017, p. 1158-1161.
- [31] S. Raouafi, M. Raison et S. Achiche, "Robot-Assisted Therapy Influence on Kinematic and EMG Activity in the Upper Limb for Children with Cerebral Palsy," 2020.

- [32] A. Fougner *et al.*, "Resolving the limb position effect in myoelectric pattern recognition," vol. 19, n^o. 6, p. 644-651, 2011.
- [33] M. R. Masters *et al.*, "Towards better understanding and reducing the effect of limb position on myoelectric upper-limb prostheses," communication présentée à 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2014, p. 2577-2580.
- [34] D. Maclsaac *et al.*, "Influences of dynamic factors on myoelectric parameters," vol. 20, n^o. 6, p. 82-89, 2001.
- [35] G. Gaudet, M. Raison et S. Achiche, "Classification of Upper limb phantom movements in transhumeral amputees using electromyographic and kinematic features," *Engineering Applications of Artificial Intelligence*, vol. 68, p. 153-164, Feb 2018. [En ligne]. Disponible: <Go to ISI>://WOS:000423894400014
- [36] H. Tsushima, M. E. Morris et J. McGinley, "Test-retest reliability and inter-tester reliability of kinematic data from a three-dimensional gait analysis system," vol. 6, n^o. 1, p. 9-17, 2003.
- [37] J. A. Kleim et T. A. Jones, "Principles of experience-dependent neural plasticity: implications for rehabilitation after brain damage," 2008.
- [38] H. M. Qassim et W. Wan Hasan, "A review on upper limb rehabilitation robots," vol. 10, n^o. 19, p. 6976, 2020.
- [39] T. Proietti *et al.*, "Upper-limb robotic exoskeletons for neurorehabilitation: a review on control strategies," vol. 9, p. 4-14, 2016.
- [40] T. Nef, M. Guidali et R. Riener, "ARMin III—arm therapy exoskeleton with an ergonomic shoulder actuation," vol. 6, n^o. 2, p. 127-142, 2009.
- [41] M. Gilliaux, "A robotic device to asse upper limb movements children and str," Université catholique de Louvain, 2015.
- [42] Q. Wang *et al.*, "Interactive wearable systems for upper body rehabilitation: a systematic review," vol. 14, n^o. 1, p. 1-21, 2017.
- [43] G. Saposnik *et al.*, "Effectiveness of virtual reality using Wii gaming technology in stroke rehabilitation: a pilot randomized clinical trial and proof of principle," vol. 41, n^o. 7, p. 1477-1484, 2010.
- [44] C. Bauer *et al.*, "Concurrent validity and reliability of a novel wireless inertial measurement system to assess trunk movement," vol. 25, n^o. 5, p. 782-790, 2015.
- [45] Y.-J. Chang, W.-Y. Han et Y.-C. Tsai, "A Kinect-based upper limb rehabilitation system to assist people with cerebral palsy," vol. 34, n^o. 11, p. 3654-3659, 2013.
- [46] I. Dimbwadyo-Terrer *et al.*, "Upper limb rehabilitation after spinal cord injury: a treatment based on a data glove and an immersive virtual reality environment," vol. 11, n^o. 6, p. 462-467, 2016.
- [47] S. Leniston-Kahsai, "Mirror VR: The design of a fully immersive virtual reality game for upper limb rehabilitation post-stroke using mirror therapy," 2020.

- [48] W.-S. Kim *et al.*, "Clinical application of virtual reality for upper limb motor rehabilitation in stroke: review of technologies and clinical evidence," vol. 9, n^o. 10, p. 3369, 2020.
- [49] K. L. Cheung *et al.*, "Neuroplasticity and virtual reality," dans *Virtual reality for physical and motor rehabilitation*: Springer, 2014, p. 5-24.
- [50] F. Wittmann *et al.*, "Assessment-driven arm therapy at home using an IMU-based virtual reality system," communication présentée à 2015 IEEE international conference on rehabilitation robotics (ICORR), 2015, p. 707-712.
- [51] N. Saywell *et al.*, "Play-based interventions improve physical function for people with adult-acquired brain injury: a systematic review and meta-analysis of randomised controlled trials," vol. 31, n^o. 2, p. 145-157, 2017.
- [52] I. Afyouni *et al.*, "A therapy-driven gamification framework for hand rehabilitation," vol. 27, n^o. 2, p. 215-265, 2017.
- [53] G. Taveggia *et al.*, "Efficacy of robot-assisted rehabilitation for the functional recovery of the upper limb in post-stroke patients: a randomized controlled study," vol. 52, n^o. 6, p. 767-773, 2016.
- [54] J. Mehrholz *et al.*, "Electromechanical and robot-assisted arm training for improving activities of daily living, arm function, and arm muscle strength after stroke," n^o. 9, 2018.
- [55] S. E. Fasoli *et al.*, "New horizons for robot-assisted therapy in pediatrics," vol. 91, n^o. 11, p. S280-S289, 2012.
- [56] N. A. Borghese *et al.*, "Computational intelligence and game design for effective at-home stroke rehabilitation," vol. 2, n^o. 2, p. 81-88, 2013.
- [57] I. Bortone *et al.*, "Integration of serious games and wearable haptic interfaces for Neuro Rehabilitation of children with movement disorders: a feasibility study," communication présentée à 2017 International Conference on Rehabilitation Robotics (ICORR), 2017, p. 1094-1099.
- [58] KKPCW. (2020) Wikipedia commons, public domain. [En ligne]. Disponible: https://commons.wikimedia.org/wiki/File:Oculus_Quest_2_-_2.jpg
- [59] M. Tallon, "Benevolent Game Matrix: Establishing Rules for Accommodating Positive Change in the Player through Game Design."
- [60] F. Wittmann *et al.*, "Self-directed arm therapy at home after stroke with a sensor-based virtual reality training system," vol. 13, n^o. 1, p. 1-10, 2016.
- [61] P. Maciejasz *et al.*, "A survey on robotic devices for upper limb rehabilitation," vol. 11, n^o. 1, p. 1-29, 2014.
- [62] L. Dipietro *et al.*, "Customized interactive robotic treatment for stroke: EMG-triggered therapy," vol. 13, n^o. 3, p. 325-334, 2005.
- [63] J. Fong *et al.*, "An investigation into the reliability of upper-limb robotic exoskeleton measurements for clinical evaluation in neurorehabilitation," communication présentée à 2015 7th International IEEE/EMBS Conference on Neural Engineering (NER), 2015, p. 795-798.

- [64] U. Keller *et al.*, "Robot-assisted arm assessments in spinal cord injured patients: A consideration of concept study," vol. 10, n^o. 5, p. e0126948, 2015.
- [65] H. I. Krebs *et al.*, "Rehabilitation robotics: Performance-based progressive robot-assisted therapy," vol. 15, n^o. 1, p. 7-20, 2003.
- [66] R. Colombo *et al.*, "Taking a lesson from patients' recovery strategies to optimize training during robot-aided rehabilitation," vol. 20, n^o. 3, p. 276-285, 2012.
- [67] Y. Morita *et al.*, "Development of rehabilitation training support system of upper limb motor function for personalized rehabilitation," communication présentée à 2008 IEEE International Conference on Robotics and Biomimetics, 2009, p. 300-305.
- [68] C. M. Bishop et N. M. Nasrabadi, *Pattern recognition and machine learning* vol. 4: Springer, 2006.
- [69] J. Beyerer, M. Richter et M. Nagel, *Pattern recognition: introduction, features, classifiers and principles*: Walter de Gruyter GmbH & Co KG, 2017.
- [70] A. J. Young *et al.*, "Classification of simultaneous movements using surface EMG pattern recognition," vol. 60, n^o. 5, p. 1250-1258, 2012.
- [71] F. Leone *et al.*, "A parallel classification strategy to simultaneous control elbow, wrist, and hand movements," vol. 19, n^o. 1, p. 1-17, 2022.
- [72] R. M. Tello *et al.*, "Towards sEMG classification based on Bayesian and k-NN to control a prosthetic hand," communication présentée à 2013 ISSNIP Biosignals and Biorobotics Conference: Biosignals and Robotics for Better and Safer Living (BRC), 2013, p. 1-6.
- [73] Z. Li *et al.*, "Intelligent classification of multi-gesture emg signals based on lstm," communication présentée à 2020 International Conference on Artificial Intelligence and Electromechanical Automation (AIEA), 2020, p. 62-65.
- [74] M. Simão, P. Neto et O. Gibaru, "EMG-based online classification of gestures with recurrent neural networks," vol. 128, p. 45-51, 2019.
- [75] C. Fang *et al.*, "EMG-centered multisensory based technologies for pattern recognition in rehabilitation: state of the art and challenges," vol. 10, n^o. 8, p. 85, 2020.
- [76] M. Gandolla *et al.*, "EMG-controlled robotic hand rehabilitation device for domestic training," communication présentée à XIV Mediterranean Conference on Medical and Biological Engineering and Computing 2016, 2016, p. 644-648.
- [77] D. Xiong *et al.*, "Hand Gesture Recognition Using Instant High-density EMG Graph via Deep Learning Method," communication présentée à 2020 Chinese Automation Congress (CAC), 2020, p. 5143-5148.
- [78] M. Jabbari, R. N. Khushaba et K. Nazarpour, "Emg-based hand gesture classification with long short-term memory deep recurrent neural networks," communication présentée à 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), 2020, p. 3302-3305.
- [79] J. L. Betthausen *et al.*, "Stable responsive EMG sequence prediction and adaptive reinforcement with temporal convolutional networks," vol. 67, n^o. 6, p. 1707-1717, 2019.

- [80] G. Gaudet, "Classification de mouvements fantômes du membre supérieur chez des amputés huméraux à l'aide de mesures électromyographiques et cinématiques," École Polytechnique de Montréal, 2016.
- [81] A. Samadani, "Gated recurrent neural networks for EMG-based hand gesture classification. A comparative study," communication présentée à 2018 40th annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2018, p. 1-4.
- [82] A. J. Young *et al.*, "A new hierarchical approach for simultaneous control of multi-joint powered prostheses," communication présentée à 2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob), 2012, p. 514-520.
- [83] M. Zecca *et al.*, "Control of multifunctional prosthetic hands by processing the electromyographic signal," vol. 30, n°. 4-6, 2002.
- [84] J. J. Baker *et al.*, "Continuous detection and decoding of dexterous finger flexions with implantable myoelectric sensors," vol. 18, n°. 4, p. 424-432, 2010.
- [85] J. A. George *et al.*, "Intuitive neuromyoelectric control of a dexterous bionic arm using a modified Kalman filter," vol. 330, p. 108462, 2020.
- [86] L. H. Smith et L. J. Hargrove, "Comparison of surface and intramuscular EMG pattern recognition for simultaneous wrist/hand motion classification," communication présentée à 2013 35th annual international conference of the IEEE engineering in medicine and biology society (EMBC), 2013, p. 4223-4226.
- [87] P. Herberts *et al.*, "Hand prosthesis control via myoelectric patterns," vol. 44, n°. 4-5, p. 389-409, 1973.
- [88] X. Li *et al.*, "A new approach to mitigate the effect of force variation on pattern recognition for myoelectric control," communication présentée à 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2016, p. 1684-1687.
- [89] R. Gross *et al.*, "The influence of gait speed on co-activation in unilateral spastic cerebral palsy children," *Clin Biomech*, vol. 28, n°. 3, p. 312-317, Mar 2013. [En ligne]. Disponible: <Go to ISI>://WOS:000320217400012

ANNEXE A GRAPHIQUES SUPPLEMENTAIRES DES GESTES FONCTIONNELS

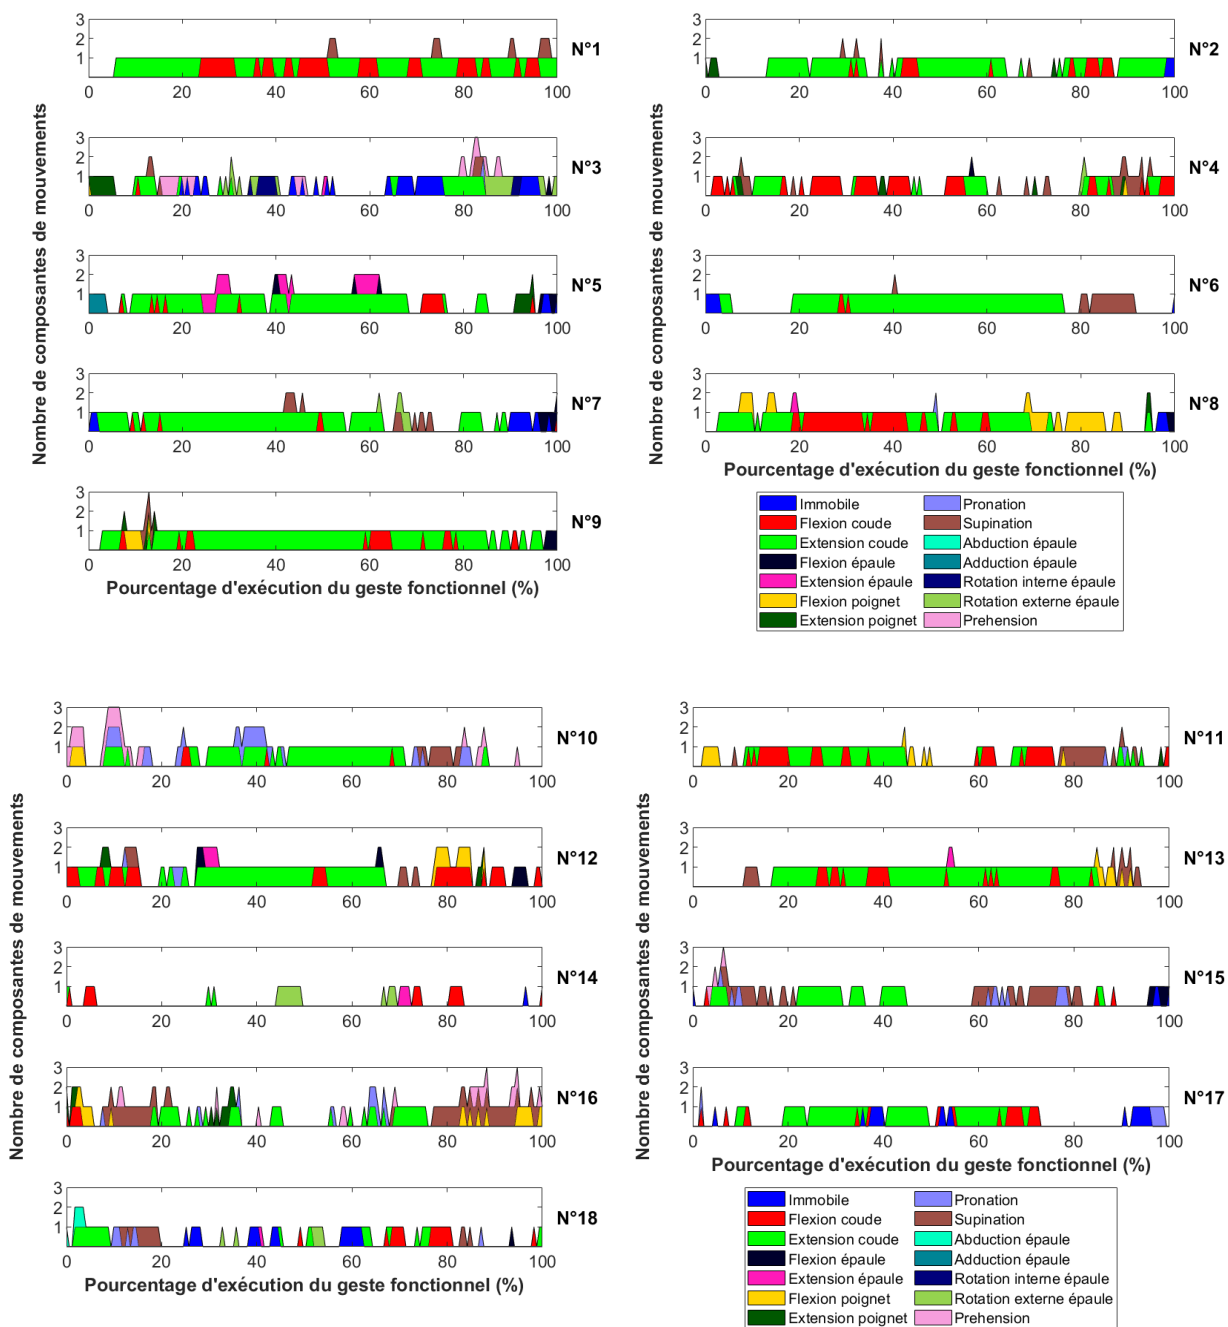


Figure A-1 Décomposition de mouvements par l'algorithme MDPC du geste fonctionnel « Brosse » pour les 18 sujets

ANNEXE B EXEMPLES DE SIGNAUX ELECTROMYOGRAPHIQUES

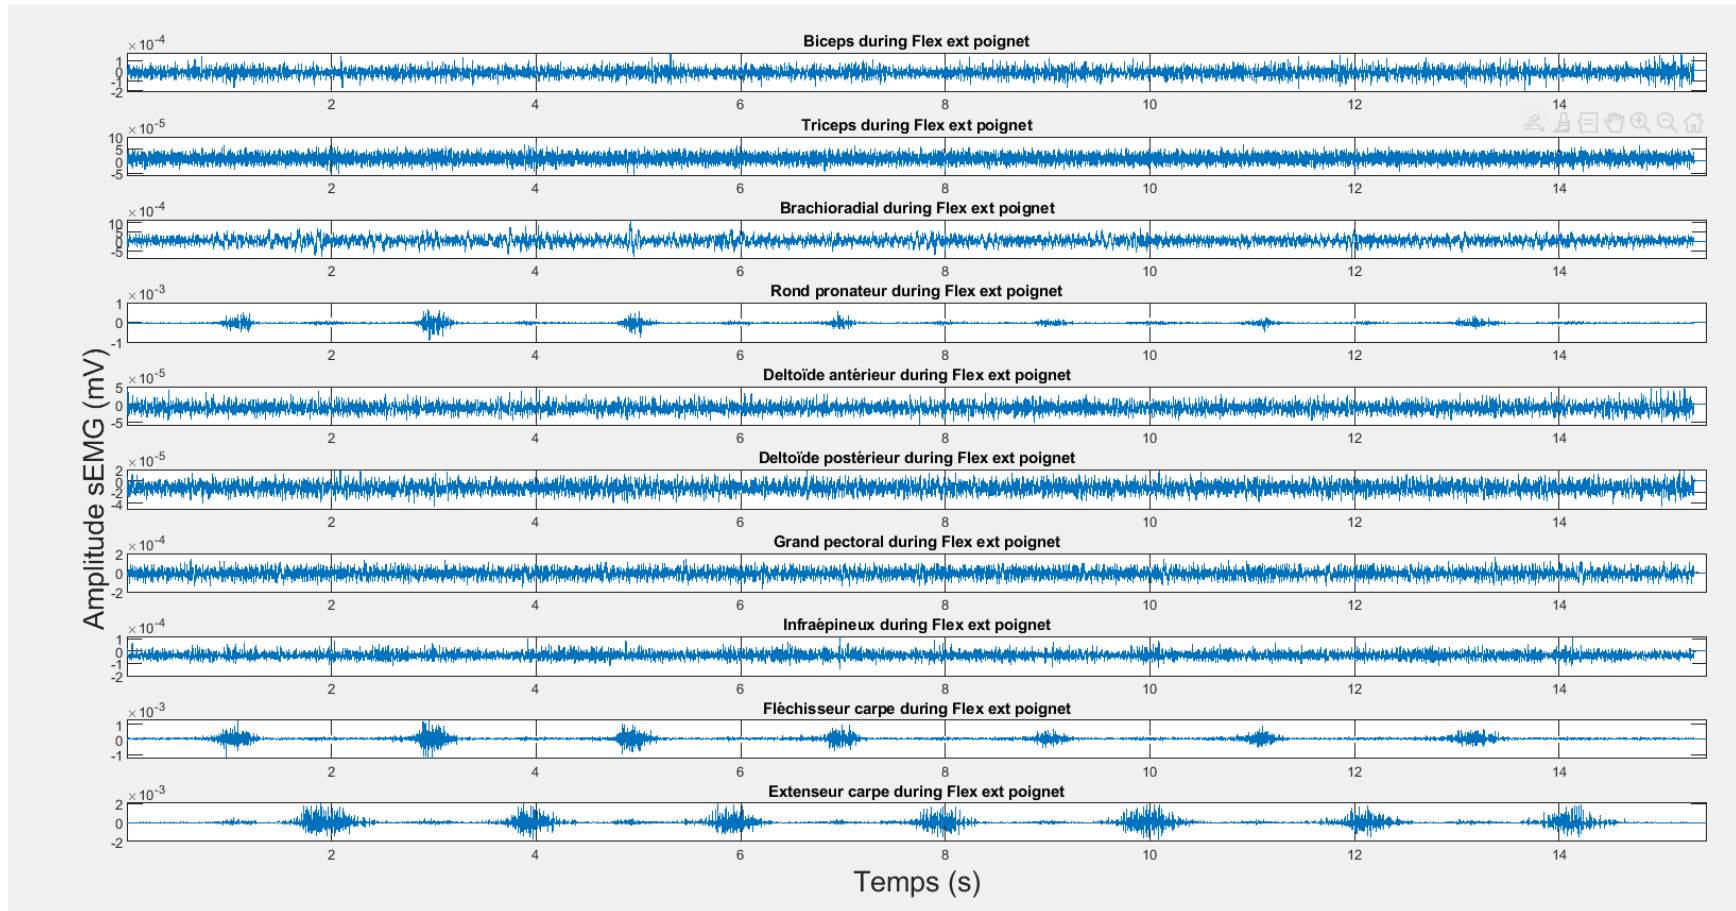


Figure B-1 Signaux électromyographiques bruts d'un sujet lors de mouvements de flexion/extension du poignet

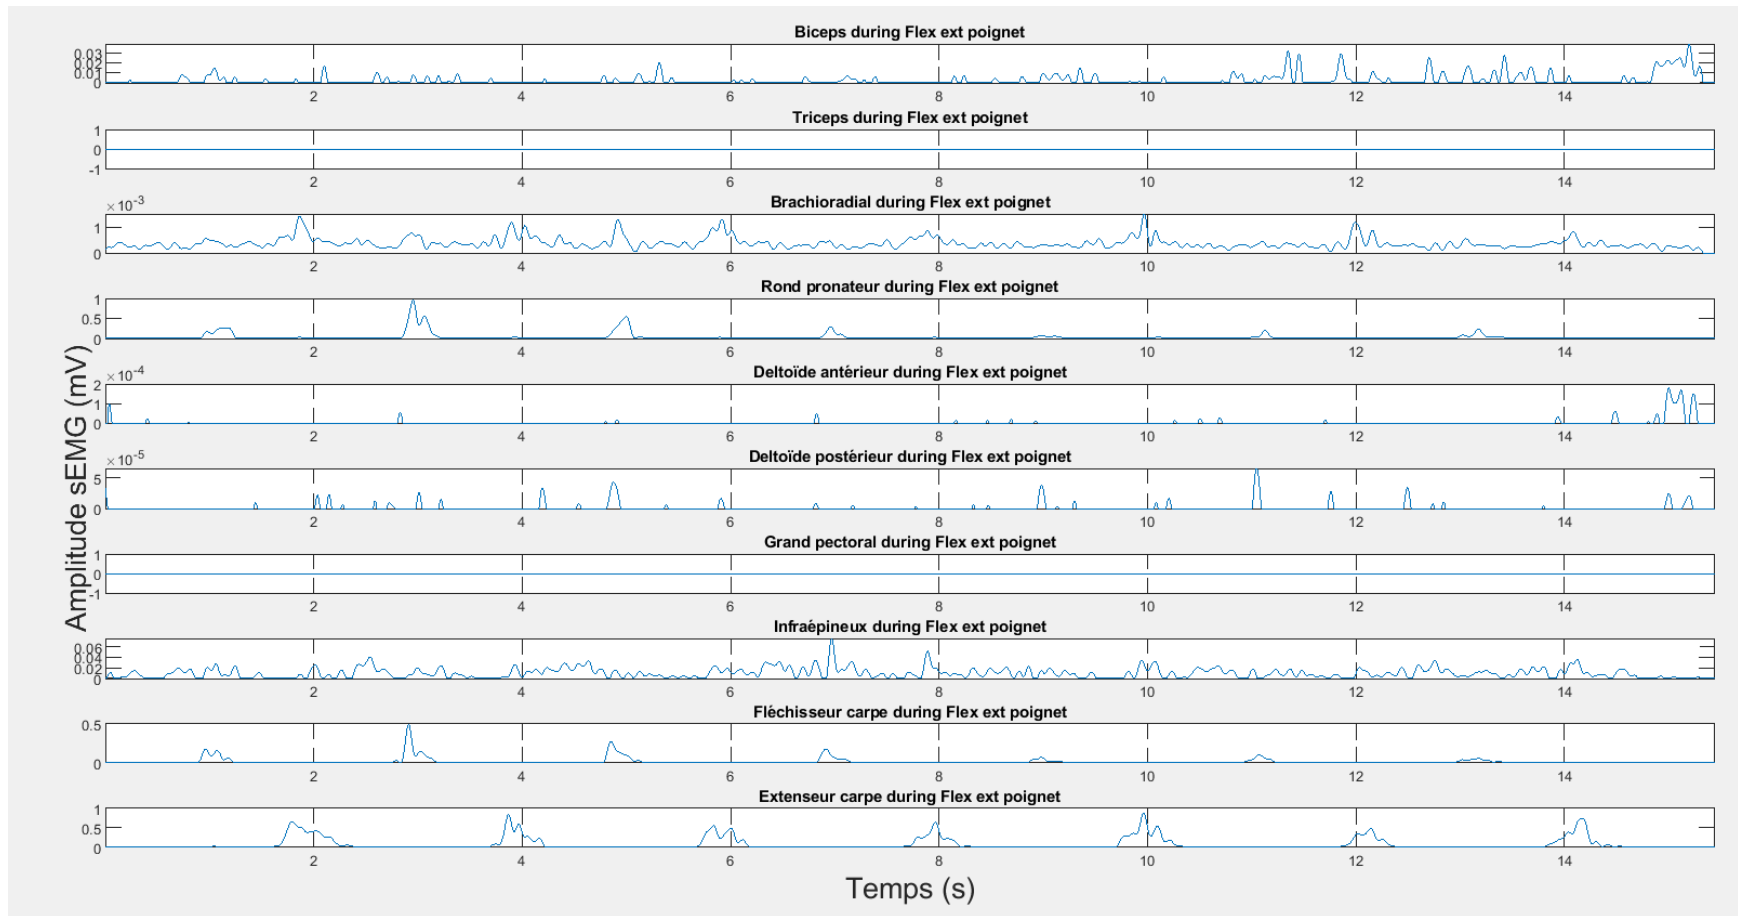


Figure B-2 Signaux électromyographiques post-traitement d'un sujet lors de mouvements de flexion/extension du poignet