



**HAL**  
open science

# Étude et conception d'un système de pilotage intuitif d'exosquelette pour l'assistance au port de charges

Benjamin Treussart

► **To cite this version:**

Benjamin Treussart. Étude et conception d'un système de pilotage intuitif d'exosquelette pour l'assistance au port de charges. Robotique [cs.RO]. Université Paris-Saclay, 2021. Français. NNT : 2021UPASG019 . tel-03188484

**HAL Id: tel-03188484**

**<https://theses.hal.science/tel-03188484>**

Submitted on 2 Apr 2021

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# Étude et conception d'un système de pilotage intuitif d'exosquelette pour l'assistance au port de charges

**Thèse de doctorat de l'université Paris-Saclay**

École doctorale n° 580, sciences et technologies de  
l'information et de la communication  
Spécialité de doctorat : Robotique  
Unité de recherche : Université Paris-Saclay, CEA, Institut LIST, 91191,  
Gif-sur-Yvette, France  
Réfèrent : Faculté des sciences d'Orsay

**Thèse présentée et soutenue à Palaiseau, le 24/03/2021, par**

**Benjamin Treussart**

## Composition du jury :

<b>Véronique Perdereau</b> Professeure des université, Sorbonne Université	Présidente
<b>Alexandre Pitti</b> Maitre de conférence - HDR, Université de Cergy-Pontoise	Rapporteur et Examineur
<b>Charles Pontonnier</b> Maitre de conférence - HDR, ENS Rennes	Rapporteur et Examineur
<b>Isabelle Siegler</b> Professeure des université, Université Paris-Saclay	Examinatrice
<b>Frédéric Marin</b> Professeur des université, Université de technologie de Compiègne	Directeur de thèse
<b>Franck Geffard</b> Ingénieur de recherche, CEA-LIST	Co-directeur de thèse
<b>Nicolas Vignais</b> Maitre de conférence, Université Paris-Saclay	Co-encadrant de thèse

# Remerciements

---

Ces années de thèse ont été une expérience riche, avec ses épreuves et ses moments forts. Ce qui a permis à ces années d'être aussi belles, ce sont les personnes que j'ai rencontrées ou qui m'ont accompagnées. Ces personnes ont rendu possible ces travaux de thèse, et ce dans des conditions aussi favorables que possible et je souhaite leur exprimer ma gratitude.

En premier lieu, je tiens à remercier mes trois encadrants. Ils ont su me guider pour que ce projet de thèse puisse se concrétiser. Frédéric Marin, qui a dirigé cette thèse, m'a aidé à canaliser mes idées afin de construire un projet cohérent et articulé. Nicolas Vignais a été d'une grande aide tout au long de ces travaux, en particulier lors des expérimentations, pour leur mise en place et leur exploitation. Nicolas était toujours disponible lorsque j'avais besoin de conseils. Franck Geffard était mon encadrant au CEA, il m'a accompagné avec bienveillance et son aide a été inestimable aux cours de ces années. Travailler avec Franck a été très enrichissant.

Je voudrais ensuite remercier les membres du jury, qui ont accepté de s'intéresser à mes travaux et avec qui nous avons eu une discussion réfléchie et intéressante au cours de la soutenance. Merci à Veronique Perdereau, qui a présidé le jury. Merci à Alexandre Pitti, Charles Pontonnier qui ont été les rapporteurs de ces travaux et à l'examinatrice Isabelle Siegler.

Je souhaiterais remercier aussi mes collègues. Je ne pourrais pas tous les nommer mais leur aide a été précieuse. J'ai pu compter sur eux et ils m'ont épargné bien des tracas, notamment en cas de problèmes avec le robot, que ce soit un problème software ou hardware. Sans eux, l'avancement des travaux aurait été plus laborieux.

Je remercie mes parents, qui m'ont soutenu et encouragé au cours de mon parcours. Bernadette, Bernard, Lulu, merci pour tout.

Enfin, les mots ne suffisent pas pour exprimer ma gratitude envers ma femme, Ekaterina, pour son soutien indéfectible et bien plus.

# Glossaire

---

- AVC** Accident Vasculaire Cérébral
- BCI** *Brain Computer Interface* - interface cerveau/ordinateur
- BHV2** Bras Hercule Version 2
- BLE** *Bluetooth Low Energy* - bluetooth basse consommation
- BLEEX** *Berkeley Lower Extremity Exoskeleton* - exosquelette de membre inférieur de Berkeley
- BTP** Bâtiments Travaux Publique
- CEA** Commissariat aux Énergies Atomiques et alternatives
- CG** Compensation de Gravité
- CNAMTS** Caisse Nationale d'Assurance Maladie des Travailleurs Salariés
- CNN** *Convolutional Neural Network* - réseau de neurones à convolutions
- Cobot** *COLlaborative roBOT* - robot collaboratif
- DDL** Degré De Liberté
- DHM** Denavit-Hartenberg modifiés (paramètres de)
- DI** Détection d'Intentions
- Drop out** Couche d'un réseau de neurones annulant aléatoirement une proportion des entrées
- DZ-I** *Dead Zone Integrator* - intégrateur avec zone morte
- EEG** Électro-EncéphaloGramme
- EMD** *Electro-Mechanical Delay* - délai électro-mécanique
- EMG** ÉlectroMyoGraphie
- Fine Tuning** Affinage
- IMU** *Inertial Measurement Unit* - centrale inertielle
- INRS** Institut National de Recherche et de Sécurité pour la prévention des accidents du travail et des maladies professionnelles
- KNN** *K Nearest Neighbours* - k plus proches voisins
- LSTM** *Long Short-Term Memory* - longue mémoire à court terme, type de couche récurrente de réseau de neurones

**MI** *Motor Imagery* - imagerie moteur

**MLP** *Multi-Layer Perceptron* - perceptron multi-couches

**MNIST** *Mixed National Institute of Standards and Technology* - nom d'une base de données de chiffres écrits manuellement

**MMG** MéchanoMyoGraphie

**Myo** référence au bracelet MyoArmband, Thalmic Labs, Ontario

**NMF** *Non-negative Matrix Factorization* - factorisation par matrices non négatives

**PME** Petite ou Moyenne Entreprise

**ReLU** *Rectified Liner Unit*

**RMC** *Relative Maximale Contraction* - contraction maximale relative

**RMS** *Root Mean Square* - moyenne quadratique

**RNN** *Recurrent Neural Network* - réseau de neurones récurrent

**SCP** *Slow Cortical Potentials* - potentiels corticaux lents

**SNC** Système Nerveux Centraux

**SSVEP** *Steady State Visually Evoked Potential* - potentiel évoqué visuellement en régime permanent

**SVM** *Support Vector Machine* - machine à vecteur de support

**TMS** Troubles MusculoSquelettiques

**VAF** *Variance Accounted For* - variance expliquée

**VGG net** *Visual Geometry Group Network* - réseau de neurones présenté dans [Simonyan and Zisserman, 2014]

# Sommaire

---

<b>Remerciements</b>	<b>iii</b>
<b>Glossaire</b>	<b>iv</b>
<b>Sommaire</b>	<b>ix</b>
<b>Table des figures</b>	<b>xiii</b>
<b>Liste des tableaux</b>	<b>xv</b>
<b>1 Introduction</b>	<b>1</b>
1.1 Plan du mémoire . . . . .	3
1.2 Contexte . . . . .	4
1.2.1 Manutention d’objets lourds . . . . .	4
1.2.2 Les muscles impliqués dans le port de charges . . . . .	5
1.2.2.1 Le coude . . . . .	5
1.2.2.2 L’épaule . . . . .	6
1.2.3 Les troubles musculo-squelettiques . . . . .	6
1.2.3.1 La santé des travailleurs . . . . .	7
1.2.3.2 Le coût des troubles musculo-squelettiques . . . . .	8
1.3 La co-manipulation . . . . .	9
1.3.1 Intérêts . . . . .	9
1.3.2 Les outils d’assistance existants . . . . .	11
1.3.2.1 Les grues, ponts roulants, potences, palans . . . . .	11
1.3.2.2 Les manipulateurs pneumatiques . . . . .	11
1.3.2.3 Les bras manipulateurs industriels . . . . .	12
1.3.2.4 Les cobots . . . . .	15
1.3.2.5 Les exosquelettes . . . . .	16
1.3.3 Différentes approches de conception . . . . .	21
1.3.3.1 Les applications basées sur la tâche . . . . .	21
1.3.3.2 Les applications basées sur l’intention de l’opérateur . . . . .	22
1.3.3.3 Synthèse . . . . .	22

1.3.4	Acquisition d'information pour la détection d'intention . . . . .	23
1.3.4.1	Signaux du cerveau . . . . .	23
1.3.4.2	Suivi de mouvement . . . . .	25
1.3.4.3	Signaux musculaires . . . . .	27
1.4	Synthèse . . . . .	29
<b>2</b>	<b>Etude 1 : Détection d'intention</b> . . . . .	<b>31</b>
2.1	Matériels . . . . .	33
2.1.1	Bras Hercule V2 (BHV2) . . . . .	33
2.1.2	Myo Armband . . . . .	34
2.2	Revue de littérature . . . . .	36
2.2.1	Apprentissage profond . . . . .	36
2.2.1.1	Perceptron . . . . .	37
2.2.1.2	Réseaux convolutifs . . . . .	39
2.2.1.3	Réseaux récurrents . . . . .	40
2.2.2	Signal EMG . . . . .	40
2.2.2.1	Origine du signal EMG . . . . .	40
2.2.2.2	Exploitation du signal EMG . . . . .	42
2.3	Conception . . . . .	45
2.3.1	Principe, choix et contexte . . . . .	45
2.3.2	Estimation de l'intensité (cf. Fig. 2.11) . . . . .	47
2.3.2.1	Pré-traitements . . . . .	47
2.3.2.2	Modélisation . . . . .	48
2.3.2.3	Calibration . . . . .	49
2.3.3	Estimation de la direction (cf. Fig. 2.11) . . . . .	52
2.3.3.1	Conception . . . . .	52
2.3.3.2	Comparaisons des variations . . . . .	56
2.3.3.3	Entraînement . . . . .	58
2.3.4	Fusion . . . . .	59
2.4	Évaluation . . . . .	60
2.4.1	Protocole . . . . .	60
2.4.2	Résultats . . . . .	60
2.5	Conclusion . . . . .	64

<b>3 Étude 2 : Assistance au port de charges</b>	<b>65</b>
3.1 Commande des exosquelettes . . . . .	67
3.1.1 Méthodes basées modèle . . . . .	67
3.1.2 Méthodes basées bio-sigaux . . . . .	68
3.1.3 Méthodes basées signaux physiques . . . . .	69
3.1.4 Méthodes hybrides . . . . .	69
3.1.5 Synthèse . . . . .	70
3.2 Commande par intégration . . . . .	70
3.2.1 Principe et analyse . . . . .	70
3.2.2 Application aux bras de type BHV2 . . . . .	73
3.3 Évaluation . . . . .	74
3.3.1 Protocole . . . . .	75
3.3.2 Résultats et discussion . . . . .	76
3.3.2.1 Performance de la commande . . . . .	77
3.3.2.2 Activité musculaire . . . . .	77
3.3.2.3 Évaluation subjective . . . . .	81
3.3.2.4 Étude de l'impact sur les synergies musculaires . . . . .	82
3.4 Conclusion . . . . .	86
<b>4 Étude 3 : Amélioration de la calibration et personnalisation de la commande</b>	<b>89</b>
4.1 Réduction du temps de calibration . . . . .	90
4.1.1 Entraînement groupé . . . . .	90
4.1.2 Affinage de l'apprentissage . . . . .	93
4.2 Personnalisation du gain . . . . .	95
4.2.1 Simulation de la boucle d'interaction . . . . .	96
4.2.1.1 Boucle globale . . . . .	96
4.2.1.2 Groupe musculaire . . . . .	98
4.2.1.3 Modèle cinématique et dynamique . . . . .	99
4.2.1.4 Modélisation de la consigne musculaire (bloc SNC sur la Fig 4.5) . . . . .	101
4.2.1.5 Résultats . . . . .	101
4.2.2 Évaluation du temps avant activation . . . . .	103



4.2.2.1	Protocole . . . . .	103
4.2.2.2	Résultats et discussion . . . . .	104
4.3	Évaluation de la personnalisation du gain . . . . .	108
4.3.1	Protocole . . . . .	108
4.3.2	Résultats et discussion . . . . .	111
4.3.2.1	Activité musculaire . . . . .	111
4.3.2.2	Précision . . . . .	112
4.3.2.3	Questionnaire . . . . .	112
4.3.2.4	Synthèse . . . . .	115
4.4	Conclusion . . . . .	116
<b>5</b>	<b>Conclusions</b>	<b>119</b>
5.1	Contributions . . . . .	119
5.2	Perspectives . . . . .	122
	<b>Bibliographie</b>	<b>125</b>
<b>A</b>	<b>Comparaisons des performances des filtres moyennés, RMS et Butterworth</b>	<b>I</b>
<b>B</b>	<b>Calculs des caractéristiques choisies pour le SVM</b>	<b>III</b>
<b>C</b>	<b>Exploration : Régression avec un CNN</b>	<b>IV</b>
<b>D</b>	<b>Tables</b>	<b>XI</b>
<b>E</b>	<b>Figures</b>	<b>XVIII</b>

# Table des figures

---

1.1	Exemple de tâches variées impliquant de la manutention d'objets lourds (sources : [ViaPrévention, 2016] et [du patronat du Québec, 2020]) . . . . .	4
1.2	Représentation des muscles du coude . . . . .	5
1.3	Représentation des muscles de l'articulation gléno-humérale . . . . .	5
1.4	Répartitions des cas de TMS en France (source : [L'Assurance Maladie, 2017]) . . . . .	7
1.5	Évolution du nombre de cas de TMS du tableau 57 [INRS, 2015] . . . . .	8
1.6	Coûts par unité en fonction du nombre d'unités produites pour différents types de poste de travail [Makarov, 2013], [Hägele et al., 2002] . . . . .	10
1.7	Les différents types de co-manipulation . . . . .	10
1.8	Exemples de grues et ponts roulants (sources : [Dumora, 2014] et indeva- group.fr) . . . . .	12
1.9	Manipulateurs pneumatiques . . . . .	13
1.10	Exemple de solution équipée d'une poignée avec capteurs (6-axis Articula- ted Robot, Star Automation Europe) . . . . .	13
1.11	Exemples de téléopération . . . . .	14
1.12	Cobomanip de la société Sarrazin Technologies . . . . .	15
1.13	Exemples d'exosquelettes conçus pour la rééducation (Atalante, Wander- craft et ABLE7D, CEA et [Fleischer et al., 2006] et [Zimmermann et al., 2019]) . . . . .	18
1.14	Exosquelettes actifs complets (membres supérieurs et inférieurs) . . . . .	19
1.15	Exosquelettes passifs . . . . .	20
1.16	Système d'acquisition Enobio®EEG (Neuroeletrics ®) . . . . .	24
1.17	Principe des systèmes de capture du mouvement optique (source : Opti- Track.com ) . . . . .	26
1.18	Système de suivi du regard portable (TobiiPro) . . . . .	26
1.19	Datagloves . . . . .	27
1.20	MyoArmband (Thalmic Labs) . . . . .	28
2.1	Exosquelette BHV2 . . . . .	33
2.2	MyoArmband . . . . .	35

2.3	Placement du bracelet . . . . .	35
2.4	Représentation du perceptron . . . . .	38
2.5	Exemple de problème non linéairement séparable . . . . .	38
2.6	Représentation d'un réseau perceptron multi-couches (1 couche cachée) . . . . .	39
2.7	Exemple de CNN : LeNet5 [LeCun et al., 1998] . . . . .	39
2.8	RNN : représentations enroulée et déroulée. $x$ représente les entrées; $o$ les sorties, $h$ les états et $W$ , $V$ et $U$ les poids du réseau. . . . .	40
2.9	Représentation d'une unité motrice [Konrad, 2005] . . . . .	41
2.10	Représentation des phénomènes de recrutement et de fréquence de déclenchement et de leur contribution sur la signal EMG brut mesuré en surface [Konrad, 2005] . . . . .	42
2.11	Approche générale (Intensité <sub>B</sub> and Intensité <sub>T</sub> correspondent respectivement à l'intensité de l'activation du biceps et de l'activation du triceps. Ces grandeurs seront présentées en détail dans la section 2.3.2) . . . . .	46
2.12	Mise en évidence du crosstalk et de son exploitation . . . . .	47
2.13	Résultats de la régression pour un participant, pour l'activation du triceps . . . . .	50
2.14	Couple modélisé avec l'équation 2.11, en fonction des valeurs EMG 2.10, pour les paramètres de chaque participant . . . . .	51
2.17	Architecture du réseau de neurones pour l'estimation de la direction souhaitée à partir d'EMG (méthode mixte) . . . . .	55
2.18	Evolution du score de confiance pendant les transitions . . . . .	61
2.19	Comparaison de la classe dominante avec différentes méthodes de stabilisation : MAX, SEUIL et FILTRAGE (les ordonnées représentent la classe choisie : 0 = repos, 1 = Triceps, 2 = Biceps, 3 = Co-contraction) . . . . .	62
3.1	Exemple de poignée (a) avec préhenseur spécialisé (b) [Yu et al., 2018] . . . . .	69
3.2	Boucle de commande de la méthode proposée. *bloc contenant Fig. 2.11 . . . . .	71
3.3	Environnement de l'expérience . . . . .	76
3.4	Exemple des données pour une répétition de la tâche . . . . .	78
3.5	Précision de l'assistance proposée comparée à CG . . . . .	79
3.6	Comparaisons des activations musculaire entre les trois situations (* : $p < 0.05$ , *** : $p < 0.001$ ) . . . . .	80
3.10	Impressions de performances comparées . . . . .	83

4.1	Représentation des étapes de la calibration du chapitre 2 . . . . .	90
4.2	Représentation de la calibration visée . . . . .	91
4.3	Illustrations des temps de réponse, réflexe et avant activation [Scott, 2004]. Le stimulus (en vert) est l'instant de départ et les évènements écrits en rouge sont les instants de fin de l'intervalle considéré. (a) Représentation du temps de réponse, (b) représentation du temps de réflexe et (c) repré- sentation du temps avant activation . . . . .	96
4.4	Représentation du système simulé . . . . .	97
4.5	Boucle d'interaction . . . . .	97
4.6	Modèle du groupe musculaire . . . . .	99
4.7	Modèle cinématique et dynamique du système . . . . .	100
4.8	Modélisation du SNC . . . . .	102
4.9	Résultats de la simulation . . . . .	103
4.10	Relation entre gain limite avant instabilité et temps avant activation . . . . .	104
4.11	Schéma d'une impulsion pour estimer le temps avant activation . . . . .	105
4.12	Indicateurs de temps avant activation extraits du signal $EMG_f$ . . . . .	106
4.13	Indicateur de temps avant activation extrait du signal $EMG_{chan_i}$ d'un cap- teur seul . . . . .	106
4.14	Affichage des indicateurs . . . . .	109
4.15	Comparaison de la nouvelle (à droite) et de l'ancienne (à gauche) attache . . . . .	109
4.16	Résultats obtenus avec les signaux EMG : (a) Activité musculaire moyenne avec le gain générique en bleu et avec le gain personnalisé en rouge, (b) Activité moyenne du deltoïde pour les 10 participants au cours de chaque série, (c) Activité moyenne du deltoïde pour la première série de 10 (pour le gain générique en bleu et en rouge pour le gain personnalisé) et (d) Activité moyenne du deltoïde antérieur pour la première situation de chaque participants (5 avec le mode personnalisé et 5 avec le mode générique) . . . . .	110
4.17	Résultats obtenus avec les positions articulaires . . . . .	113
4.18	Réponses aux questions générales du tableau D.12. En bleu pour le gain générique et en rouge pour le gain personnalisé, les lignes pointillées verti- cales séparent les différentes catégories de question ainsi que les questions positives (+) et les questions négatives (-) . . . . .	114

4.19 Réponses aux questions de comparaison du tableau 4.7 . . . . .	115
A.1 Spectrogrammes . . . . .	I
A.2 Visuel des filtrage . . . . .	II
A.3 Temps de réponse à un échelon . . . . .	II
C.1 Architecture du réseau de neurones pour l'estimation du couple appliqué à partir d'EMG . . . . .	V
C.2 Résultats de l'apprentissage du modèle avec LSTM en fonction de la longueur de la fenêtre glissante. De bas en haut 15, 30, 50, 100, 200 échantillons et le résultats obtenus avec la méthode MIXTE 2.11 . . . . .	VI
C.3 Répartitions des fréquences des estimations représentées Fig. C.2(De gauche à droite 15, 30, 50, 100, 200 échantillons, en bas à droite le signal original et en bas à gauche le filtrage avec le modèle) . . . . .	VII
C.4 Comparaison des estimations avec les méthodes MIXTE et Dense200 . . . . .	X
E.1 Evolution du nombre de cas de TMS INRS [2015] . . . . .	XVIII
E.2 Représentations graphiques de trois fonctions d'activation . . . . .	XVIII
E.3 Questionnaire de Ressenti de l'étude 2 . . . . .	XXI
E.4 Consentement éclairé de l'étude 2 . . . . .	XXIII
E.5 Indicateurs de temps de réponse sur le signal non filtré. En bleu le signal rectifié non filtré, en vert le déclenchement de l'à-coup, en cyan - $\Delta$ Max $EMG_r$ et en rouge - Max $EMG_r$ . . . . .	XXIV
E.6 Indicateurs de temps de réponse sur le signal de chaque électrode . . . . .	XXIV
E.7 Réponse à un gain trop important . . . . .	XXV
E.8 Réponse stable (gain suffisamment faible) . . . . .	XXV
E.9 Activité moyenne du trapèze pour les 10 participants au cours de chaque série . . . . .	XXVI
E.10 Activité moyenne du deltoïde pour la cinquième série . . . . .	XXVI

# Liste des tableaux

---

1.1	Nombre de cas de TMS recensés (extrait du tableau E.1)	8
1.2	Différence de représentation des MMG and EMG dans la littérature	28
4.1	Précision du réseau entraîné et testé avec les données d'une même personne	91
4.2	Précision du réseau entraîné avec les données de 20 personnes et testé avec les données de la personne restante	92
4.3	Matrice confusion des données de test personne 6	93
4.4	Précision du réseau entraîné avec les données de 17 personnes et testé avec les données de la personne restante	93
4.5	Précision du réseau affiné	95
4.6	Tableau des p-valeurs obtenues suite à des tests de Student entre les séries de répétitions	112
4.7	Les questions sur la comparaison des deux situations	115
C.1	Erreurs RMS pour les différents modèles et longueur de fenêtre glissante ( $10^{-3}N.m$ ). Pour comparaison : méthode MIXTE, $24.9 * 10^{-3}N.m$	VIII
C.2	Intégrale des spectrogrammes au-delà de la fréquence limite $F_{lim}$ . Pour comparaison : Couple mesuré, 0.32 et méthode MIXTE, 0.34	IX
C.3	Erreurs RMS en fonction de la quantité de données( $10^{-3}N.m$ ).	IX
C.4	Intégrale du spectrogramme	X
D.3	Matrice confusion des données d'entraînement personne 6	XI
D.4	Matrice confusion personne 8	XI
D.5	Matrice confusion personne 18	XII
D.6	Précision du réseau entraîné et testé sur la même personne	XII
D.7	Précision du réseau entraîné avec les données de 17 personnes et testés sur la dernière	XII
D.8	Précision du réseau ajusté	XIII
D.9	Résultats des t-tests	XIV
D.10	Résultats de l'expérience préliminaire partie 1	XV
D.11	Résultats de l'expérience préliminaire partie 2	XVI

D.12 Les questions sur l'assistance (posées une fois pour chaque assistance) . . . XVII

# Introduction

---

## Sommaire

<b>1.1 Plan du mémoire</b> . . . . .	<b>3</b>
<b>1.2 Contexte</b> . . . . .	<b>4</b>
1.2.1 Manutention d'objets lourds . . . . .	4
1.2.2 Les muscles impliqués dans le port de charges . . . . .	5
1.2.3 Les troubles musculo-squelettiques . . . . .	6
<b>1.3 La co-manipulation</b> . . . . .	<b>9</b>
1.3.1 Intérêts . . . . .	9
1.3.2 Les outils d'assistance existants . . . . .	11
1.3.3 Différentes approches de conception . . . . .	21
1.3.4 Acquisition d'information pour la détection d'intention . . . . .	23
<b>1.4 Synthèse</b> . . . . .	<b>29</b>

La co-manipulation est une sous-catégorie de la collaboration Homme-Robot. Il s'agit du cas particulier où robot et humain manipulent ensemble et en même temps un objet. L'objectif de la co-manipulation est de tirer parti à la fois du savoir-faire humain et de la force des robots, il s'agit d'exploiter les points forts des deux partis identifiés par la liste Fitts (aussi connue sous le nom de HABA-MABA, *humans are better at/ machines are better at*). Cet objectif émerge d'un double constat. D'un côté, à ce jour, les capacités de prise de décisions des robots sont loin d'égaliser celles des humains. D'autre part, les capacités physiques humaines sont limitées et les troubles musculo-squelettiques sont les affections les plus représentées parmi les maladies professionnelles . Un des enjeux de la co-manipulation est alors de fournir des solutions d'assistance sur des postes de travail pour lesquels les volumes de production ne sont pas suffisamment importants pour justifier une automatisation complète.



Aujourd'hui, des solutions d'assistance sont déjà déployées dans l'industrie mais celles-ci sont spécialisées et difficilement adaptables. Pour permettre plus de flexibilité d'usage, nous nous intéressons aux méthodes qui prennent en compte les intentions de l'utilisateur. Pour permettre une meilleure acceptabilité le système proposé doit être facile à prendre en main, intuitif, et rapide à mettre en place.

Dans ce mémoire nous présentons nos travaux sur **l'étude et la conception d'un système de pilotage intuitif d'exosquelettes pour l'assistance au port de charges**. L'objectif est de mettre au point une stratégie de contrôle permettant une assistance physique des travailleurs afin de réduire l'effort fourni, diminuant ainsi le risque de développer un TMS.

Afin de proposer une solution pertinente nous commençons par passer en revue les outils existants et leurs utilisations, que ce soit pour l'assistance physique ou la captation d'intention. Ensuite, nous détaillons l'implémentation de la partie portant sur la détection d'intention et son évaluation par des opérateurs. Puis nous faisons de même pour la stratégie de contrôle basée sur cette détection d'intention. Enfin, nous explorons des axes d'amélioration de la méthode proposée.

Dans ce premier chapitre nous présentons le contexte autour du thème de nos travaux, l'assistance à la manipulation dans un milieu industriel. Nous commençons par détailler les causes et l'impact des troubles musculo-squelettiques. Ensuite, nous présentons les différents moyens d'assistance physique qui sont déployés aujourd'hui dans l'industrie. Enfin nous passons en revue les outils de captation des intentions de l'utilisateur. Nous analysons leurs domaines d'utilisation ainsi que les forces et faiblesses des capteurs afin de choisir la solution la plus pertinente par rapport à nos objectifs pour la suite des travaux.

## 1.1 Plan du mémoire

Dans le **chapitre 1** nous présentons le contexte autour du thème de nos travaux, l'assistance à la manipulation dans un milieu industriel. Nous détaillons les causes et l'impact des troubles musculo-squelettiques. Ensuite, nous présentons les différents moyens d'assistance physique qui sont déployés aujourd'hui dans l'industrie. Enfin, nous passons en revue les outils de captation des intentions. Nous analysons leurs domaines d'utilisation ainsi que les forces et faiblesses des capteurs afin de choisir la solution la plus pertinente par rapport à nos objectifs pour la suite des travaux.

Le **chapitre 2** traite d'un module de détection de l'intention que nous avons conçu. Nous y décrivons l'exosquelette et les capteurs que nous utilisons au cours de nos travaux. Nous passons en revue les différentes approches d'exploitation du signal électromyographique (EMG) que nous pouvons trouver dans la littérature. Nous introduisons aussi des notions d'apprentissage profond et de réseaux de neurones artificiels, une approche que nous utilisons pour traiter le signal EMG. Ensuite, nous décrivons les différents composants de notre module de détection d'intention : l'estimation de l'intensité et de la direction du mouvement. Le module de détection d'intention doit être calibré pour chaque nouvel utilisateur. Enfin, nous évaluons la précision du module au travers d'une expérience à laquelle 7 sujets ont participé.

Dans le **chapitre 3** nous présentons notre stratégie d'assistance au port de charges, qui utilise comme entrée le résultat du module de détection d'intention calibré. Nous commençons par discuter les stratégies de commande mises en place avec succès dans le cadre du pilotage d'exosquelette. Nous analysons les avantages et limitations de différentes approches afin de proposer une approche qui pourrait pallier à certaines de leurs limitations. Nous évaluons ensuite notre approche de commande par intégration en utilisant deux situations de contrôle : sans assistance, et une assistance par compensation de gravité classique.

Dans le **chapitre 4** nous proposons des axes d'améliorations du système complet. Le premier consiste à réduire le temps de calibration nécessaire. Cela permet au système d'être plus pratique et plus facile à déployer. Pour cela nous nous appuyons sur les données récoltées au cours des expériences précédentes et la capacité de généralisation des réseaux de neurones. D'autre part, nous étudions la possibilité de personnaliser le gain d'intégration du système pour mieux s'adapter à chaque utilisateur. Nous explorons l'effet

du temps de réponse d'un individu sur la stabilité du système, pour en déduire un gain adapté.

## 1.2 Contexte

### 1.2.1 Manutention d'objets lourds

La manutention d'objets lourds est un besoin qui concerne de nombreux secteurs d'activités. C'est le cas notamment dans le secteur de la logistique pour la mise en magasin ou la préparation de commande, ou encore dans le secteur du BTP (Bâtiment et Travaux Publics) pour le transport manuel des matières premières sur site ou bien le port d'outillage à main [L'Assurance Maladie, 2020].



FIGURE 1.1 – Exemple de tâches variées impliquant de la manutention d'objets lourds (sources : [ViaPrévention, 2016] et [du patronat du Québec, 2020])

Ce type de tâche est très courant dans l'industrie et peut conduire à l'apparition

de troubles musculo-squelettiques (TMS) qui est un enjeu majeur du milieu industriel aujourd'hui.

## 1.2.2 Les muscles impliqués dans le port de charges

Notre méthode de détection de l'intention étant basé sur le signal EMG, nous allons lister les muscles impliqués dans l'élévation d'une charge, nous considérons une situation où la charge est posée sur une table au départ, à hauteur de taille, puis est levée à hauteur d'épaule. Les articulations sollicitées sont principalement le coude et l'épaule, en flexion. Comme il s'agit d'une charge lourde, le rachis est aussi impliqué dans l'élévation de la charge. Nous allons voir plus en détails quels sont les muscles intervenant dans la mobilité de ces deux articulations et leur rôle.




FIGURE 1.2 – Représentation des muscles du coude




FIGURE 1.3 – Représentation des muscles de l'articulation gléno-humérale

### 1.2.2.1 Le coude

Le coude peut être considéré comme un pivot mécanique (1 degré de liberté en rotation, DDL). En effet, il est souvent estimé comme suffisant de représenter la position du coude sous la forme d'un angle [Zhang et al., 2017], [Artemiadis and Kyriakopoulos, 2010]. Deux mouvements sont possibles au niveau du coude : la flexion et l'extension.

Les muscles fléchisseurs du coude sont le biceps brachial (2), le brachial (3) et le brachio-radial (4). Les muscles extenseurs sont le triceps brachial (1) et l'anconé (5) (voir Fig. 1.2).

### 1.2.2.2 L'épaule

Au niveau de l'épaule, l'articulation la plus sollicitée dans le port de charge est l'articulation gléno-humérale. Elle peut être modélisée comme une rotule mécanique (3 DDL en rotation). En général, une représentation à 3 angles est utilisée [Zhang et al., 2017], [Artemiadis and Kyriakopoulos, 2010], 1 angle par degré de liberté (et deux actions par degré de liberté). Les actions possibles sont la flexion, l'extension, l'adduction, l'abduction, et les rotations médiale et latérale.

Les muscles fléchisseurs principaux sont le deltoïde antérieur (4) et le grand pectoral (6). Le muscle coraco-brachial (5) et le biceps brachial sont deux muscles qui participent de manière accessoire à la flexion. Les muscles extenseurs de l'épaule sont principalement le deltoïde postérieur (1) et le grand dorsal (3) et accessoirement le grand rond (2) et le triceps brachial (voir Fig. 1.3).

De plus nous pouvons mentionner aussi les muscles rotateurs de la coiffe (supra-épineux, infra-épineux, petit-rond, sub-scapulaire) dont le rôle principal est la stabilisation de la tête humérale.

### 1.2.3 Les troubles musculo-squelettiques

Le terme générique de "trouble musculosquelettique" regroupe de nombreuses pathologies des tissus mous (muscles, tendons, nerfs) et osseux. Les TMS sont des affections péri-articulaires. Ils proviennent d'un déséquilibre entre les capacités du corps et les contraintes auxquelles il est exposé. Lorsque les sollicitations sont supérieures aux capacités fonctionnelles du corps, les structures musculo-tendineuses et osseuses sont sursollicitées, et donc le risque de TMS apparaît. Ce risque est plus important si les temps de récupération sont insuffisants. Les facteurs de risque sont les suivants [Ministère du Travail, 2010] :

- des gestes répétitifs,
- des efforts excessifs,
- un travail statique de faible intensité maintenu dans le temps,
- des positions articulaires extrêmes.

L'activité professionnelle peut jouer un rôle dans leur fréquence d'apparition, leur durée ou leur aggravation et elle en est la première cause. De nombreuses entreprises sont concernées et cela représente un enjeu économique important pour elles (cf. section 1.2.3.2).

### 1.2.3.1 La santé des travailleurs




FIGURE 1.4 – Répartitions des cas de TMS en France (source : [L'Assurance Maladie, 2017])

Les TMS impactent les salariés de multiples manières. Ils touchent principalement les articulations des membres supérieurs (épaules, coudes, poignets, mains et doigts) et le bas du dos comme la Fig. 1.4 nous permet de le voir (d'après [L'Assurance Maladie, 2017]). A long terme, ils peuvent dégrader la qualité de vie des salariés : douleurs, restrictions d'aptitude, handicap . . . Cela peut même parfois mener à une désinsertion professionnelle. A titre d'exemple, la lombalgie est la première cause d'inaptitude avant 45 ans. De plus, 45% des TMS entraînent des séquelles lourdes (incapacités permanentes). Dans le cadre du port de charges lourdes, nous pouvons citer comme affections fréquentes les tendinites au niveau du coude et de l'épaule.

L'influence des TMS peut même s'étendre au collectif de travail par une modification de la répartition des charges, une désorganisation ou encore des remplacements répétés. Cette dégradation du climat de travail peut elle même favoriser l'apparition de nouveaux

cas de TMS [L'Assurance Maladie, 2019].

### 1.2.3.2 Le coût des troubles musculo-squelettiques




FIGURE 1.5 – Évolution du nombre de cas de TMS du tableau 57 [INRS, 2015]

Année	Nombre de cas	Nombre de cas 57 <sup>a</sup>
2013	40 234	36 252
2014	40 852	36 779
2015	40 281	36 236
2016	38 787	35 083
2017	38 568	34 869

TABLE 1.1 – Nombre de cas de TMS recensés (extrait du tableau E.1)

<sup>a</sup>. Cas 57 : Affections périarticulaires provoqués par certains gestes et postures de travail

Les TMS représentent de loin la première cause de maladies professionnelles indemniées avec 87 % (TMS membres et lombalgies) des maladies reconnues par le régime général de la sécurité sociale en 2017 ([L'Assurance Maladie, 2017]). De plus, les TMS déclarées ont fortement augmentées entre 1992 et 2012 (cf Fig. 1.5) et semblent se stabiliser au delà de 2012 (cf tableau 1.1). Le coût des TMS pour les entreprises peut prendre différentes formes comme la perte de journées de travail (10 millions en 2012 [INRS, 2015]), ou encore des coûts directs à travers les cotisations accidents du travail et maladies professionnelles (près de 2 milliards d'euros en 2017). Certaines conséquences sont moins directes comme la baisse de productivité et de qualité, des difficultés de recrutement, de reclassement des victimes ou encore une dégradation de la réputation de l'entreprise.

Ce phénomène, qui est largement sous-estimé par les statistiques de maladies professionnelles [Rivière et al., 2018], n'est pas propre à la France. Les TMS occupent la première place des maladies professionnelles reconnues dans plusieurs pays d'Europe [Parent-Thirion et al., 2016]. Le taux de sous-déclaration des TMS a été estimé en France en 2011 à 53% pour les TMS du rachis lombaire, à 60 % pour les syndromes du canal carpien, à 62 % pour les TMS de l'épaule et à 73 % pour les TMS du coude [Rivière et al., 2018].

Pour prévenir les TMS une solution est de fournir une assistance physique au travailleur pour éviter qu'il dépasse les limites fonctionnelles de son corps (afin de réduire les facteurs de risques évoqués précédemment [1.2.3](#)) . Il ne s'agit pas seulement de proposer une solution fonctionnelle. En effet, pour qu'une solution soit plus facilement acceptable dans le milieu industriel nous pensons qu'il est intéressant d'ajouter les critères suivants :

- Il est préférable que son déploiement soit rapide et ne nécessite pas d'expertise particulière.
- Elle doit aussi être intuitive, c'est à dire que la prise en main ne nécessite pas ou peu de formation.
- La capacité d'être transposable à plusieurs tâches serait aussi un avantage qui faciliterait l'intégration.

Ces considérations s'inscrivent dans le domaine de la co-manipulation que nous allons présenter dans la section à venir.

## 1.3 La co-manipulation

### 1.3.1 Intérêts

La co-manipulation est une sous-catégorie de la robotique qui ne cherche pas à remplacer l'homme mais à l'assister. En effet, les robots comme les bras manipulateurs industriels sont conçus pour réaliser rapidement et avec précision des tâches répétitives mais dans un environnement structuré. Mais les systèmes automatiques n'ont pas, à ce jour, la capacité d'adaptation des opérateurs humains. La co-manipulation quant à elle, permet d'exploiter à la fois les capacités physiques (force, stabilité, ...) des robots et les capacités d'adaptation et de la planification des humains pour dépasser les limites de chacun [[Dumora, 2014](#)].

La co-manipulation trouve particulièrement bien sa place dans les petites et moyennes entreprises (PME). En effet, pour qu'un poste de travail robotisé ou une machine outils spécialisée soit rentable il faut un volume de production important. Il faut aussi des tâches qui ont une faible variabilité intrinsèque. La [Fig. 1.6](#) illustre les différents domaines de rentabilité.

Nous pouvons distinguer 3 classes d'interaction de co-manipulation [[Lamy, 2011](#)] :

- la co-manipulation parallèle, les efforts du robots et de l'opérateur s'ajoutent pour



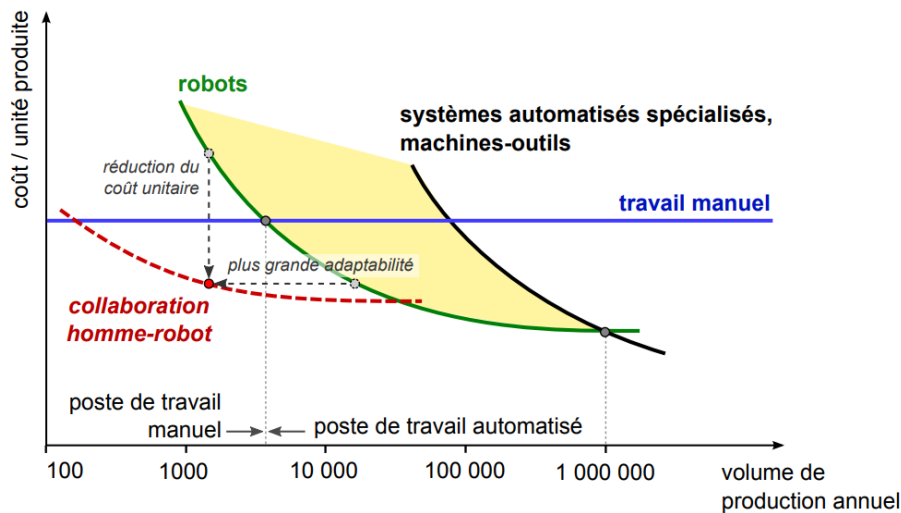


FIGURE 1.6 – Coûts par unité en fonction du nombre d’unités produites pour différents types de poste de travail [Makarov, 2013], [Hägele et al., 2002]



(a) co-manipulation Parallèle (b) co-manipulation Orthétique (c) co-manipulation Sérielle

FIGURE 1.7 – Les différents types de co-manipulation

former l’effort final appliqué sur l’environnement ou sur une charge. L’ensemble des efforts entre le robot et l’opérateur sont transmis au niveau de la main et de l’effecteur (voir Fig. 1.7a).

- la co-manipulation orthétique, les efforts du robot sont répartis en plusieurs points de l’opérateur. Les exosquelettes correspondent à ce type d’interaction (voir Fig. 1.7b). Là aussi les efforts extérieurs sont répartis entre le cobot et l’opérateur.
- la co-manipulation sérielle, l’opérateur, le robot et la charge forme une chaîne en série. Ce type d’assistance se présente sous forme d’appareil portatif et les prothèses en sont un exemple (voir Fig. 1.7c).

## 1.3.2 Les outils d'assistance existants

Dans le cadre de l'assistance à la manipulation de charges lourdes nous nous intéressons seulement aux cas de co-manipulation parallèle et orthétique. Nous allons voir les solutions déjà présentes dans l'industrie qui s'y apparentent.

### 1.3.2.1 Les grues, ponts roulants, potences, palans

Les grues, ponts roulants, potences et palans sont utilisés pour manipuler des charges lourdes et/ou encombrantes. Ces systèmes assurent la montée ou la descente de la charge ainsi que les déplacements latéraux. L'orientation de la pièce en rotation est possible, partiellement si cela joue sur la souplesse du câble ou bien complètement si un dérouleur est présent. Cependant, ce type d'architecture ne permet ni de compenser les moments de la pièce manipulée ni de maintenir son orientation. Si besoin, c'est à l'opérateur d'assurer ces fonctions qui peuvent entraîner des efforts importants (voir Fig. 1.8).

Les moyens de pilotage de ces systèmes ne sont pas adaptés à la manipulation. Le grutier se trouve dans une cabine, loin de l'objet à manipuler, de ses partenaires et de la scène (Fig. 1.8c). Dans le cas des ponts roulants, potences et palans, l'opérateur doit tenir une télécommande dans une main afin de piloter le système, et orienter l'objet tout en compensant les moments du poids avec l'autre main (Figs. 1.8a et 1.8b).

Des variantes de ces systèmes qui incorporent des technologies issues de la robotique existent. L'ajout de capteurs permet de rendre leur utilisation beaucoup plus intuitive. Un capteur permettant de mesurer l'angle du câble avec la verticale permet de connaître la direction de déplacement désirée sans utiliser de télécommande. Une poignée équipée de capteur placée au niveau du préhenseur permet de piloter les mouvements verticaux (Fig. 1.8d).

### 1.3.2.2 Les manipulateurs pneumatiques

Parmi les systèmes permettant de manipuler des pièces lourdes et/ou encombrantes il existe aussi les manipulateurs pneumatiques. A la différence des grues et ponts roulants vus au paragraphe précédent, le poids de la charge est compensé par un système d'équilibrage, qui est à régler dès que l'on change la masse à transporter. Ces mécanismes n'étant pas motorisés, l'opérateur doit fournir un certain effort pour déplacer la pièce puisque l'inertie et les frottements ne sont pas compensés. La réaction du système aux impulsions de



(a) Pont roulant



(b) Pont roulant



(c) Grue (les travailleurs au sol doivent aider au positionnement précis)



(d) Electric manipulator Liftronic®Easy-6, Scaglia Indeva

FIGURE 1.8 – Exemples de grues et ponts roulants (sources : [Dumora, 2014] et indeva-group.fr)

l'opérateur n'étant pas immédiate, ces systèmes souffrent d'un manque de fluidité dans les mouvements. De plus, dans la plupart des cas, l'opérateur doit gérer la prise et la dépose par l'intermédiaire de l'organe de pilotage assez encombrant fixé à l'extrémité du bras. Ce mode de commande offre une mauvaise visibilité de la scène. Afin de profiter d'un meilleur point de vue, l'opérateur est amené à adopter des postures peu ergonomiques, comme l'illustrent les Figs. 1.9.

### 1.3.2.3 Les bras manipulateurs industriels

Les bras manipulateurs industriels sont motorisés et permettent de contrôler les six degrés de liberté d'une charge.

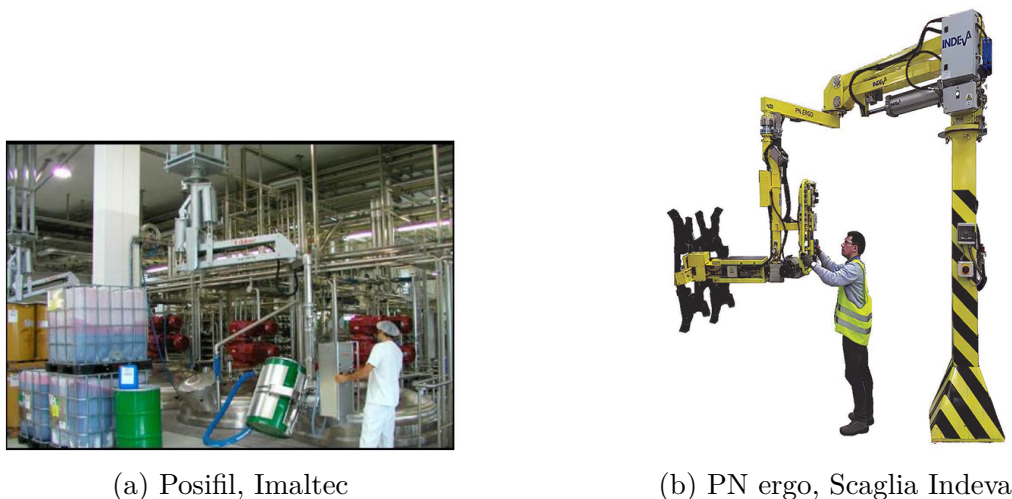


FIGURE 1.9 – Manipulateurs pneumatiques



FIGURE 1.10 – Exemple de solution équipée d'une poignée avec capteurs (6-axis Articulated Robot, Star Automation Europe)

Le système de pilotage classique est un boîtier de commande manuel comme sur la Fig. 1.10. Dans ce cadre d'utilisation l'interaction entre l'opérateur et le système charge/robot est indirecte. Le boîtier ne permet pas de retour d'effort vers l'opérateur donc celui-ci ne peut pas ressentir les interactions entre le robot, la charge et l'environnement. De plus, le boîtier ne permet de contrôler la charge que dans des repères liés au robot (base ou organe terminal, par exemple).

Un système de télémanipulation à retour d'effort [Geffard et al., 2012] permet de rendre la commande plus intuitive et introduire le retour d'effort.

Le système comprend un bras maître motorisé aussi transparent que possible (voir Fig. 1.11a) commandé via un contrôleur de télémanipulation.

L'organe terminal du bras manipulateur reproduit les mouvements de celui du bras maître. Ce lien maître/esclave fonctionne aussi dans le sens inverse, un effort appliqué au robot ou à la charge par l'environnement sera retransmis à l'opérateur grâce aux actionneurs du bras maître. Des études ont montré que ce retour d'effort aidait la réalisation de la tâche et aussi qu'il y a aussi une diminution des efforts appliqués sur l'environnement (réduisant les risques d'endommagement) [Wagner et al., 2007].



(a) Bras maître Virtuose<sup>TM</sup> 6D – Haption SA (b) Téléopération pour la médecine (source : (avant-plan) et bras esclave (arrière-plan) [Borden Jr and Kozlowski, 2006])

FIGURE 1.11 – Exemples de téléopération

De manière similaire aux manipulateurs pneumatiques vus précédemment, ce type de système de pilotage à distance présente l'inconvénient de pas permettre de disposer d'une bonne vision de la tâche. Cela peut être corrigé à l'aide de caméras. Cependant cette solution ajoute des contraintes supplémentaires quant au nombre de capteurs et au positionnement des caméras pour éviter les occultations. Enfin, cela réduit les possibilités de déplacements du système.

Des applications récentes introduisent des solutions d'assistance en plus de transmettre les efforts. Cela peut être des frontières virtuelles pour limiter l'espace de travail ou encore filtrer les tremblements de l'opérateur pour maintenir l'effecteur du robot stable [David et al., 2014]. Ces approches sont particulièrement intéressantes pour les applications de chirurgie télé-opérées [Chauhan et al., 2019]. D'autres travaux ont aussi permis de transformer un manipulateur industriel en cobot en ajoutant un capteur d'effort à l'effecteur [Lamy, 2011].



FIGURE 1.12 – Cobomanip de la société Sarrazin Technologies

#### 1.3.2.4 Les cobots

Les cobots (fusion de **CO**llaborative **roBOTS**) sont des robots qui ont été conçus pour être en interaction avec l'humain, par opposition aux automates industriels classiques qui sont confinés dans des cages de protection. Cette approche de la robotique ne cherche plus à remplacer l'humain mais à l'assister.

Un cobot a pour fonction d'assister l'opérateur de manière hybride, en accompagnant les mouvements dans les directions autorisées et en contraignant les directions non autorisées.

Un exemple d'application dans une chaîne d'assemblage automobile est présenté dans [Colgate et al., 2003]. Contrairement aux versions de ponts roulants présentés précédemment, le cobot a une structure rigide qui lui permet de contraindre le mouvement. Il est utilisé pour positionner le tableau de bord dans une voiture tout en évitant les collisions avec la carrosserie et l'habitacle. La chaîne d'assemblage est en mouvement, et un suivi de ligne maintient la fenêtre virtuelle alignée avec la voiture.

Ce cobot va au-delà des capacités des manipulateurs pneumatiques grâce à son actionnement mais il présente le même défaut d'obstruction du champ de vision conduisant à des positions peu ergonomiques. Cela vient du fait que le système ne permet pas une bonne vision de la tâche, ni la manipulation directe de la charge.

Une application plus récente consiste à utiliser un capteur d'effort au niveau de l'ef-

fecteur, et en partant du principe que la charge à manipuler est connue (notamment sa masse), pour permettre une manipulation directe de la charge. Cette approche est pertinente dans le cadre d'une chaîne de montage pour laquelle la charge est toujours la même (Fig. 1.12 [FactoryLab, 2018]). Une approche alternative pour libérer en partie le point d'interaction de l'utilisateur consiste à équiper le robot d'une peau tactile. L'utilisateur peut alors interagir avec le robot grâce à cette nouvelle interface. Des travaux ont mis en valeur cette approche avec une commande en admittance [Pugach et al., 2016].

Par ailleurs, une autre limite commune à ces applications est que l'assistance est adaptée "sur mesure" à la tâche. L'adaptation à une nouvelle application nécessitera de redéfinir des nouvelles limites virtuelles. Cela peut être anticipé, et des tâches variées peuvent être pré-programmées, mais cela augmente le coût et le temps de développement et de mise en œuvre.

### 1.3.2.5 Les exosquelettes

**1.3.2.5.1 Définition** Les exosquelettes sont des cobots avec une interaction homme-machine de type orthétiques (cf. section 1.3.1). Comme son nom l'indique l'exosquelette présente une géométrie et une cinématique bio-inspirée, pour suivre au mieux les mouvements de l'utilisateur. Les exosquelettes peuvent être classés selon leur utilisateur cible. Il peut s'agir d'individus sans ou avec déficit neuro-musculo-squelettique. Le second cas concerne essentiellement le monde médical, on parle alors d'exosquelettes dits de compensation.

**1.3.2.5.2 Exosquelettes de compensation** Ces exosquelettes sont généralement pilotés en position et génèrent des trajectoires pré-établies. L'utilisateur est alors suiveur. Les applications sont, en général, la rééducation ou la compensation de mouvements qui ne sont plus possibles pour l'utilisateur. Pour la rééducation, les exosquelettes développés peuvent être très variés, pour cibler différentes parties du corps (bras, mains [Fleischer et al., 2006], jambes [Rupal et al., 2017], Fig. 1.13). Les applications les plus courantes concernent la reprise de mobilité après un Accident Vasculaire Cérébral (AVC) ou une pathologie dégénérative ou traumatique de la moelle épinière [Louie and Eng, 2016] [Gunasekara et al., 2012]. Cette utilisation est sensée permettre plus d'autonomie au cours de la rééducation et ainsi soulager la charge du personnel médical tout en assurant des

mouvements contrôlés et sûrs.

Pour la compensation de mouvement, il s'agit de pallier à une incapacité de réaliser certains mouvements sur le long terme. Par exemple, il existe de nombreux travaux dont le but est de refaire marcher des personnes qui n'en sont plus capables par elles-mêmes [Rupal et al., 2017]. Une part importante des solutions existantes aujourd'hui est destinée aux personnes atteintes de paraplégie. Ces solutions nécessitent d'avoir l'usage de ses membres supérieurs : pour équilibrer le système avec des béquilles, Phoenix (suitX), ou déclencher le signal de la marche, Atalante (Wandercraft), par exemple. Cependant, des travaux récents destinés aux personnes atteintes de tétraplégie s'appuient sur l'utilisation d'interfaces Cerveau-Machines (*Brain-Computer Interfaces*, BCI) pour déclencher la marche et même réaliser des tâches de pointage en trois dimensions avec le bras [Benabid et al., 2019] (Fig. 1.14a).

Les exosquelettes de compensation ont notamment pour objectifs de surpasser les limites des systèmes existants, à savoir les chaises roulantes :

- Une posture assise prolongée, qui entraîne des risques sanitaires (ostéoporose, escarres, problèmes de tension, ...)
- Une limitation de mobilité, l'utilisateur ne peut pas monter les marches et il a une portée de manipulation réduite par rapport à une posture debout

**1.3.2.5.3 Exosquelettes d'assistance** Pour les utilisateurs ayant une mobilité complète on parle d'exosquelettes d'assistance. Ce type d'exosquelette permet d'apporter une aide à l'utilisateur lors de tâches nécessitant des efforts sollicitants (efforts importants, postures non ergonomiques, voire les deux). Ces derniers exosquelettes sont généralement plutôt commandés en effort. C'est l'utilisateur qui génère la trajectoire et l'exosquelette doit le suivre en le gênant le moins possible, tout en apportant une assistance lorsque cela est nécessaire. Cette catégorie peut aussi se décomposer en deux grandes classes. La première correspond aux exosquelettes passifs, c'est-à-dire ne comportant pas d'actionneurs. Et la seconde comprend les exosquelettes actifs.

**Exosquelettes passifs** Il y a deux grands moyens de faire de l'équilibrage passif, soit en utilisant des ressorts, soit en utilisant des contrepoids. L'inconvénient du contrepoids réside principalement dans le fait de devoir transporter ce contrepoids, ce qui ajoute une contrainte au niveau des points d'appui du système. A notre connaissance il n'existe




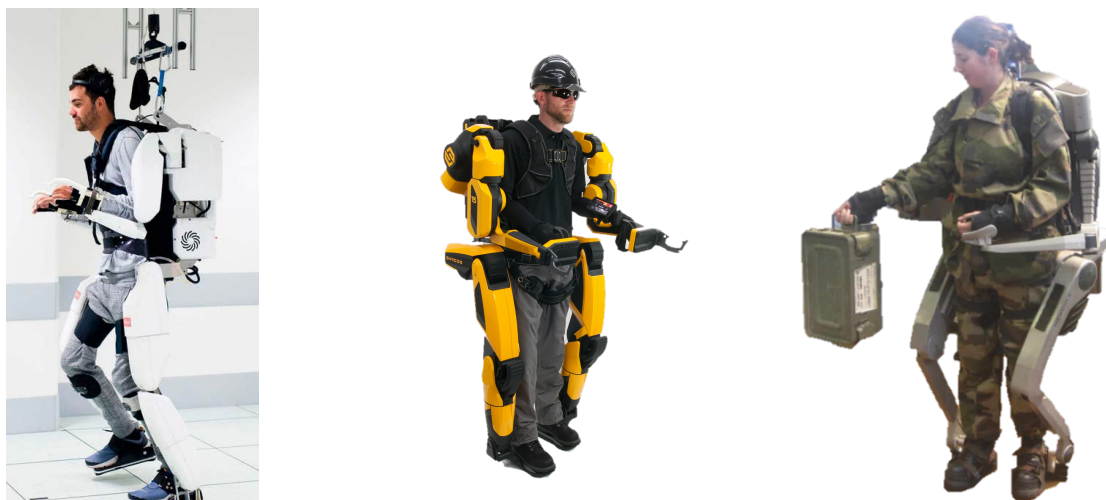


FIGURE 1.13 – Exemples d'exosquelettes conçus pour la rééducation (Atalante, Wander-craft et ABLE7D, CEA et [Fleischer et al., 2006] et [Zimmermann et al., 2019])



(a) Exosquelette complet à destination des personnes atteintes de tétraplégie [Benabid et al., 2019] (b) "XO Guardian" de la société Sarcos (c) "HV2" des sociétés CEA et RB3D

FIGURE 1.14 – Exosquelettes actifs complets (membres supérieurs et inférieurs)

pas d'exosquelette utilisant cette approche, nous pouvons trouver de l'équilibrage par contrepoids plutôt dans la conception de bras-maître de téléopération.

Nous pouvons distinguer deux cas d'utilisation des ressorts dans la conception d'exosquelettes passifs. Les exosquelettes posturaux fournissent une assistance en fonction de leur position actuelle. Par exemple, pour des tâches avec les bras levés l'effort n'est présent que lorsque les bras sont à l'horizontale et l'effort est absent lorsqu'ils sont baissés (cf Fig. 1.15b) [Maurice et al., 2019]. Les exosquelettes d'équilibrage fournissent un effort constant à l'effecteur, quelque soit la position. Par exemple, si les ressorts sont tendus pour équilibrer une charge de 10kg (i.e. 98.1N) alors, lorsque l'opérateur dépose la charge, les 98.1N restent appliqués par l'exosquelette. Cela oblige l'opérateur soit à forcer de 98.1N dans le sens opposé afin de conserver sa position et/ou pouvoir bouger, soit à laisser ses bras monter jusqu'à la butée (cf Fig. 1.15a). Un autre inconvénient réside dans le fait que l'opérateur ne doit pas s'incliner au risque de ne plus avoir une compensation verticale. C'est pourquoi, l'intérêt de ces exosquelettes passifs se limite à l'assistance posturale ou au port d'outil sans inclinaison.

**Exosquelettes actifs** La deuxième classe concerne donc les exosquelettes actifs, c'est-à-dire avec des actionneurs. Ces derniers solutionnent tous les problèmes des exosquelettes passifs cités plus haut (c'est-à-dire qu'ils peuvent appliquer une multitude d'efforts



(a) Exhauss



(b) EksoVest

FIGURE 1.15 – Exosquelettes passifs

indépendamment de l'inclinaison et sont donc à priori la seule solution pour l'augmentation d'effort). Néanmoins, cette solution présente aussi des limitations, qui sont le poids, le coût, le besoin d'une source d'énergie et l'usage. En ce qui concerne le problème de poids la solution est de faire en sorte que cela ne soit pas à l'utilisateur de supporter le poids du système. Il existe différentes solutions, comme utiliser un bras manipulateur comme potence pour tenir l'exosquelette et suivre l'utilisateur sur un espace de travail défini [Yu et al., 2018]. Une autre solution répandue consiste à utiliser un exosquelette complet pour que la partie inférieure porte la partie supérieure et soulage l'opérateur (comme le modèle Fig. 1.14b). Cette approche permet d'avoir un système mobile, cependant elle apporte son lot de problématiques, surtout en ce qui concerne la commande, notamment pour la transparence et l'équilibre du système. En ce qui concerne la partie supérieure la commande est aussi une problématique majeure. L'avantage des exosquelettes actifs par rapport à ceux passifs est leur adaptabilité, il faut cependant être à même de les contrôler correctement. Une des solutions consiste à interagir avec l'exosquelette au moyen de capteurs d'efforts (XO Guardian, Sarcos, Fig. 1.14b [Bogue, 2018]). L'interaction de l'humain avec la charge devient alors indirecte et l'exosquelette doit être capable de faire la préhension. L'interprétation des intentions de l'utilisateur afin de commander un exosquelette est un des enjeux majeurs des travaux de recherches actuels les concernant [Gull et al., 2020], [Chen et al., 2016].

La commande est donc une problématique importante dans le développement des exosquelette, tout comme l'évaluation de leur utilisation. Cette évaluation est critique puisqu'elle permet de déterminer si l'exosquelette apporte bien une aide à l'utilisateur,

et si l'utilisateur n'est pas exposé à de nouveaux risques. Différents travaux se sont déjà intéressés à l'impact des exosquelettes sur l'activité physique du travailleur [Rashedi et al., 2014] [Theurel et al., 2018]. Bien qu'ils constatent une réduction de l'activité musculaire au niveau de l'épaule, les auteurs mettent en garde contre les possibles répercussions négatives. Ces travaux concernent des exosquelettes passifs et l'utilisation d'exosquelettes actifs pourrait minimiser certaines de ces répercussions, notamment concernant l'impact sur les muscles antagonistes.

### 1.3.3 Différentes approches de conception

Nous pouvons distinguer deux manières fondamentales de concevoir des systèmes d'assistance. La première consiste à considérer des tâches planifiées. Une des problématiques dans ce cas est l'adaptation du système à de nouvelles tâches. La seconde approche consiste à définir l'assistance en fonction de l'opérateur et de ses intentions, pour réaliser des tâches non planifiées.

#### 1.3.3.1 Les applications basées sur la tâche

Les guides ou butées virtuels sont de bons exemples de solutions conçues pour une tâche spécifique. Ils consistent à partager la responsabilité selon les différents degrés de libertés. Le robot contraint l'opérateur à suivre une trajectoire dans le cas d'un guide virtuel [Joly, 1997] ou bien empêche l'opérateur de s'approcher de certaines zones dans le cas de butées virtuelles [David et al., 2014]. C'est à l'opérateur de décider la vitesse de parcours de cette trajectoire. Par exemple, dans le cas d'une tâche de perçage ou de ponçage, le robot peut contraindre l'outil à être perpendiculaire à la surface à modifier [Raiola et al., 2018]. C'est ensuite à l'utilisateur de choisir les points de perçage et la pression qu'il faut appliquer sur la perceuse. Ce type d'approche est très lié à la tâche et peut poser des problèmes d'adaptation à d'autres trajectoires. Une solution a été proposée, inspirée par la programmation par démonstration. Elle consiste à montrer la trajectoire au robot pour définir le guide virtuel. La programmation par démonstration avait été proposée pour une tâche de soudure [Ang et al., 1999]. Dans ce cas le robot rejouait la trajectoire sans l'opérateur. Cela permettait de simplifier le travail d'adaptation du robot à une autre tâche et réduire le niveau de qualification nécessaire pour le réaliser (plus besoin d'avoir des notions de programmation par exemple). La démonstration est rendue

possible par un capteur d'effort placé sur l'effecteur et un contrôle en admittance inspiré de [Newman and Zhang, 1994].

Cette approche d'apprentissage de trajectoire par démonstration a été adaptée et améliorée pour l'utilisation de guides virtuels. Il ne s'agit plus de montrer l'intégralité de la trajectoire mais seulement des points de passage. D'autres fonctionnalités comme l'ajout ou la modification de points en ligne rendent cette approche plus flexible [Restrepo et al., 2017]. Ce type d'approche convient très bien pour des tâches assez répétitives avec peu de variabilité.

### 1.3.3.2 Les applications basées sur l'intention de l'opérateur

Pour les approches où on fait abstraction de la tâche afin de permettre plus de flexibilité d'utilisation, la problématique principale consiste à estimer l'intention de l'utilisateur. Une application immédiate est la compensation du poids de la charge. A l'origine, il s'agissait d'utiliser un enrouleur pneumatique à régler manuellement pour appliquer un effort constant qui compense le poids de la charge. Avec les améliorations mentionnées précédemment (Section 1.3.2.1) le réglage manuel n'est plus nécessaire. Cette approche a pu être adaptée à des robots manipulateurs grâce à l'ajout d'un capteur d'effort au niveau de l'effecteur, saisi par l'opérateur. Ce capteur d'effort permet de percevoir les intentions en effort de l'utilisateur. Mais dans ces conditions la manipulation directe de l'objet n'est plus possible. En effet, cette estimation est assez directe mais elle contraint le point de saisie de l'opérateur puisqu'il doit saisir le capteur d'effort et non la charge. Néanmoins, si le poids de la charge est connu, il est alors possible de la manipuler directement [Sylla et al., 2014]. On retrouve cette problématique avec le contrôle des exosquelettes.

### 1.3.3.3 Synthèse

Dans nos travaux nous nous intéresserons au cas d'assistance basé sur l'intention de l'opérateur, c'est-à-dire sans connaissance à priori de la tâche, et/ou de la masse de la charge à transporter. Un système d'assistance fonctionnel qui n'aurait pas besoin de spécification sur la tâche serait très facilement transposable à une plus grande variété d'applications.

Nous allons éviter l'utilisation de capteurs d'effort afin de ne pas contraindre la saisie et de permettre une manipulation directe. Nous nous sommes donc intéressés aux alternatives

permettant de détecter l'intention de l'opérateur.

### 1.3.4 Acquisition d'information pour la détection d'intention

Un des enjeux pour mettre au point des systèmes d'assistance flexibles et facilement transposables d'une tâche à l'autre est de détecter les intentions de l'utilisateur. Nous allons passer en revue les différentes modalités envisageables pour estimer l'intention de l'utilisateur et piloter des outils robotiques. Dans leur état de l'art, Ajoudani et al. (2018) distinguent deux types d'interfaces homme-robot : les interfaces améliorant la perception de l'humain et celles améliorant la perception du robot [Ajoudani et al., 2018]. Nous allons nous intéresser à ce deuxième type d'interfaces. En effet, nous voulons que le robot s'adapte à ce qu'il perçoit de l'utilisateur et non pas que l'utilisateur ait une modalité de plus à prendre en compte pour comprendre la stratégie du robot.

#### 1.3.4.1 Signaux du cerveau

Étant donné que nous nous concentrons sur des applications industrielles nous allons laisser de côté les techniques de mesures invasives (comme les électrodes intra-crâniennes) ou non portables. A l'origine les applications envisagées concernent des personnes présentant des handicaps afin de leur permettre de retrouver un peu d'autonomie [Horki et al., 2011]. La méthode d'acquisition par électroencéphalogramme (EEG) est la plus répandue dans la littérature (cf. Fig. 1.16), car elle présente une meilleure résolution temporelle, une plus grande facilité de mesure et un ratio signal/bruit supérieur aux autres méthodes [Rebsamen et al., 2010] (par exemple : Functional Near-Infrared Imaging ou Magnetoencephalographie). Les applications publiées sur les interfaces cerveau-ordinateur (*Brain Computer Interface*, BCI) pour le contrôle de robots peuvent être séparées en deux. D'une part, les techniques basées sur des signaux spontanés et d'autre part les techniques basées sur des signaux de réponse à un stimuli ou les potentiels évoqués (*Event Related Potentials*, ERPs).

Pour les méthodes utilisant les ERPs il s'agit de détecter la réaction du cerveau à un signal externe (c'est pourquoi on parle de méthodes exogènes). Les deux principales méthodes qui les représentent sont Steady State Visual Evoked Potentiel (SSVEP) [Zhu et al., 2010] et P300 [Donchin et al., 2000]. Les SSVEP sont provoqués par un stimulus visuel supérieur à 6Hz. Par exemple, si le stimulus est un clignotement les SSVEP



FIGURE 1.16 – Système d’acquisition Enobio®EEG (Neuroelectric®)

montrons une forme semblable à une sinusoïde de fréquence fondamentale similaire à celle du stimulus. Grâce à cela on peut attribuer différentes actions à différents stimuli et l’utilisateur choisit en fixant son regard sur les sources des stimuli [Prueckl and Guger, 2009]. Pour le P300, le principe est similaire mais avec un signal inattendu. Dans un cas d’utilisation classique les symboles, ou choix, que l’on désire détecter sont placés dans une matrice dont les colonnes et lignes clignotent de manière aléatoire [Martínez-Cagigal et al., 2017].

L’avantage principal de ces approches est qu’il ne nécessite pas, ou peu, d’entraînement côté utilisateur. Cependant, il y a un risque qu’il s’habitue aux stimuli, réduisant les performances du système [Ravden and Polich, 1999].

Pour les méthodes endogènes il s’agit de détecter un signal généré spontanément par l’utilisateur. Les signaux concernés sont appelées Slow Cortical Potentials (SCP) [Birbaumer et al., 1990] et les rythmes sensorimoteurs (*Sensorimotor Rhythm*, SMR) [Yuan and He, 2014]. L’utilisation des rythmes sensorimoteurs, liée au phénomène d’imagerie motrice (MI) est la plus répandue des deux. Les oscillations concernées sont dans les bandes de fréquences mu(7-13 Hz) et beta (13-30 Hz) [Yuan and He, 2014]. Elles sont liées aux tâches motrices (même si le mouvement réel n’est pas nécessaire pour les altérer). Les approches classiques consistent à faire un mapping entre les mouvements souhaités et des instructions distinctes imaginées (ex : Serrer le poing droit/gauche/les deux). [Baali et al., 2015]

Les méthodes endogènes permettent une utilisation plus souple que les méthodes exogènes et sembleraient permettre une détection plus rapide (peu d'articles mentionnent les temps de détection). Néanmoins elles nécessitent un apprentissage long côté utilisateur.

Dans la littérature les applications ont souvent pour objectif de redonner de l'indépendance aux personnes tétraplégiques comme le contrôle de chaise roulante [Li et al., 2013] [Swee and You, 2016], ou de bras robotiques [Jeong et al., 2018].

#### 1.3.4.2 Suivi de mouvement

Les techniques de capture de mouvements peuvent aussi permettre d'obtenir des informations sur l'utilisateur. Ces méthodes peuvent avoir différentes portées et résolutions de détection : du corps complet, des mains, des yeux.

**1.3.4.2.1 Suivi de corps complet** Les systèmes de capture des mouvements du corps complet ont montré leur utilité pour l'évaluation de l'ergonomie de postes de travail, notamment en estimant les contraintes subies lors de tâche de port de charges [Muller et al., 2020]. Ces informations pourraient être utilisées dans la conception de systèmes d'assistance afin de diminuer ces contraintes. D'autre part, l'utilisation des systèmes de capture du corps complet pourrait être pertinente dans le cas de la co-manipulation parallèle mais moins dans le cas de la co-manipulation orthétique (puisque les capteurs articulaires de l'orthèse peuvent déjà fournir ces informations). De plus, les systèmes les plus répandus sont des systèmes optoélectroniques qui nécessitent un espace de mesure pré-calibré ce qui sédentarise et limite spatialement le système (comme les ensembles de caméras proposées par Vicon ®).

**1.3.4.2.2 Suivi du point de mire** Le suivi de mouvement peut aussi être concentré sur une seule partie du corps, comme les yeux ou les mains. Pour le suivi des yeux on parle d'oculométrie (*eye tracking*), le système d'acquisition peut être monté sur une paire de lunettes (voir Fig. 1.18). En terme de contrôle, on peut envisager les mêmes applications qu'avec les BCI exogènes 1.3.4.1, avec l'avantage d'être plus faciles à mettre en œuvre (calibration et nécessité de balise scintillante). [Ishizuka et al., 2018] présente une solution de contrôle de chaise roulante grâce aux points de mire de l'utilisateur avec un contrôle amélioré grâce à une détection de l'environnement faite par un capteur de profondeur.






FIGURE 1.17 – Principe des systèmes de capture du mouvement optique (source : OptiTrack.com )



FIGURE 1.18 – Système de suivi du regard portable (TobiiPro)

**1.3.4.2.3 Suivi des mains** Dans le cas de la manipulation, le suivi le plus pertinent semble être celui des mains. En général on parle de gant de mesure ou de Dataglove pour faire référence au système d'acquisition. Leur développement a commencé il y a environ 40 ans [Dipietro et al., 2008] et plusieurs types de signaux ont été exploités. La stratégie la plus répandue consiste à utiliser des capteurs de flexions pour estimer les positions articulaires des doigts (VMG30, CyberGlove, ManusVR, ..). Ces capteurs permettent d'obtenir la position relative des doigts par rapport au dos de la main. Pour obtenir une orientation absolue certaines approches on fait le choix d'équiper le dos de la main d'un capteur d'orientation (centrale inertielle pour le ManusVR). L'entreprise Polhemus a fait le choix d'obtenir directement des positions absolues de plusieurs points de la main au moyen de capteurs magnétiques. Cependant, dans un milieu industriel avec des grandes pièces métalliques ils pourraient subir des perturbations importantes. Le gant Noitom Hi5VR se base lui sur une combinaison de centrales inertielles et la connaissance de la dynamique du corps humain. Les solutions à base de capteurs optiques n'ont pas été évoquées, elles ont l'inconvénient d'être sensibles aux problèmes d'occultation et ont tendance à sédentariser le système (nécessité d'une cage de caméra par exemple, cf. Fig.

1.17).



FIGURE 1.19 – Datagloves

Jusqu'à présent le développement des gants de mesure était principalement orienté pour des applications en réalité virtuelle. Les efforts ont donc été concentrés sur la mesure de la position mais peu de produits en vente aujourd'hui proposent des capteurs pour les informations de contact.

Les applications à la manipulation relèvent plus de la téléopération pour l'instant. Un buste humanoïde a été contrôlé avec une paire de gants de mesure et un casque de réalité virtuelle [Park et al., 2017], par exemple. Les gants fournissant des informations de contact sont plus pertinents dans le cadre de la co-manipulation. [Paredes-Madrid and De Santos, 2013]

### 1.3.4.3 Signaux musculaires

Deux méthodes sont mentionnées dans la littérature pour caractériser l'activité musculaire : la méchanomyographie (MMG) et l'électromyographie (EMG) [Geng et al., 2012].

Le signal MMG est beaucoup moins exploité dans la littérature (cf. tableau 1.2) et il n'y a peu de systèmes de mesures disponibles commercialement à notre connaissance (cf. Moten Tech), nous allons donc nous concentrer sur les signaux EMG.

Les signaux EMG, obtenus via des électrodes placées sur les muscles cibles (surface EMG, sEMG), sont très utilisés dans la recherche pour le contrôle de prothèses ou de bras d'assistance [Ison et al., 2015] [Tavakoli et al., 2017]. Ils présentent plusieurs avantages. Tout d'abord, certains ensembles de capteurs ont été développés pour être sans-fils et faciles à placer (par exemple sous forme de bracelet comme sur la Fig. 1.20). L'acquisition peut donc être pratique et efficace.

Mot-clef 1	Mot-clef 2	Scopus	IEEE Xplore
Human Robot Interface	EMG	169	246
	MMG	0	2
Robot Control	EMG	579	585
	MMG	3	7
Prosthesis	EMG	1456	583
	MMG	55	18
	EMG	43900	5021
	MMG	1510	292

TABLE 1.2 – Différence de représentation des MMG and EMG dans la littérature



FIGURE 1.20 – MyoArmband (Thalmic Labs)

Des études ont montré l'existence du délai électromécanique (*electromechanical delay*, EMD)[[Begovic et al., 2014](#)] de 50-100ms, qui consiste en l'intervalle entre l'apparition du signal EMG et le début du mouvement. Ce point permet d'envisager des stratégies qui s'appuieraient sur la prédiction, l'anticipation du mouvement. Enfin, le signal EMG est une information très riche car elle ne porte pas seulement l'information de mouvement, mais contient aussi des informations sur la raideur des membres ou encore l'état de fatigue musculaire [[Artemiadis, 2012](#)].

Cependant l'utilisation du signal EMG présente aussi des inconvénients, le premier étant d'être dépendant de l'individu. En effet, d'une personne à l'autre le signal varie et il est nécessaire de calibrer les algorithmes pour chaque utilisateur. Le signal EMG est aussi très dépendant des conditions autour du capteur (sueur, fatigue, position)[[Artemiadis and Kyriakopoulos, 2010a](#)]. Enfin, il y a le phénomène de croisement de signaux (ou *crosstalk*) [[Solomonow et al., 1994](#)]. En effet, le but initial est d'obtenir le signal EMG pour un muscle en particulier dont on connaît l'influence, cependant les muscles sont proches les uns des autres et parfois même se superposent et les informations EMG obtenues ne sont alors jamais issues d'un seul muscle.

L'utilisation du signal EMG est divisé en deux catégories : les méthodes discrètes et les méthodes continues. Les méthodes discrètes sont très représentées dans la recherche aujourd'hui. L'objectif des méthodes discrètes est en général de discriminer plusieurs états ou actions (par exemple poing fermé ou main ouverte, ... [Mendez et al., 2017]). Les méthodes continues cherchent quant à elles à extraire une information continue, telles que la position ou l'effort [Ryu et al., 2008]. Ces deux approches seront plus détaillées dans la section 2.2.2.

## 1.4 Synthèse

Comme nous avons pu le voir dans les section précédentes, les outils d'assistance physique type exosquelette existent et arrivent sur le marché. Une problématique importante pour mettre au point des systèmes plus adaptables et plus intuitifs à utiliser est le choix de la stratégie de contrôle. Aujourd'hui certaines solutions évitent le problème en étant dédiées à des tâches spécifiques et en facilitant les moyens de transfert d'une tâche à l'autre (ex : apprentissage par démonstration des guides virtuels). Une approche prometteuse dans la conception des systèmes d'assistance indépendants de la tâche consiste à estimer les intentions de l'utilisateur et à construire la stratégie d'assistance en fonction de celles-ci. Dans la section 1.3.4, nous avons passé en revue les différentes possibilités de mesure sur l'être humain. Les systèmes les plus adaptés à la co-manipulation avec charge portée par l'opérateur sont les gants de mesures avec informations tactiles et les signaux EMG. Une limitation qu'il est important de noter pour les gants est qu'ils sont plus difficilement exploitables dans le cas de la co-manipulation orthétique du fait de la charge portée par l'opérateur. Cela engendrerait une activité permanente au niveau des capteurs qu'il faudrait dissocier de l'intention de mouvement. De plus, la plupart des modèles de gants disponibles avec capteurs de pression utilisent des capteurs unidirectionnels. La mesure des efforts de cisaillement avec des capteurs intégrables dans du textile demeure à ce jour un problème à part entière, surtout de manière omnidirectionnelle.

Les BCI ne conviennent par car les résultats de l'état de l'art sont trop lents pour une application industrielle et avec une utilisation trop limitée (plusieurs secondes pour une tâche de classification). Pour les approches qui ne requièrent pas d'entraînement, le système présente les mêmes capacités que du suivi de point de mire alors que celui-ci est

plus facile à déployer (lunettes instrumentées au lieu d'électrodes sur le crâne).

Notre objectif sera donc d'étudier un système d'assistance au port de charges basé sur le signal EMG. Il devra être intuitif, facile à prendre en main, et rapide à déployer, c'est-à-dire que la calibration doit être courte et la mise en place des capteurs, rapide (et pratique).

# Etude 1 : Détection d'intention

---

## Sommaire

<b>2.1 Matériels</b>	<b>33</b>
2.1.1 Bras Hercule V2 (BHV2)	33
2.1.2 Myo Armband	34
<b>2.2 Revue de littérature</b>	<b>36</b>
2.2.1 Apprentissage profond	36
2.2.2 Signal EMG	40
<b>2.3 Conception</b>	<b>45</b>
2.3.1 Principe, choix et contexte	45
2.3.2 Estimation de l'intensité (cf. Fig. 2.11)	47
2.3.3 Estimation de la direction (cf. Fig. 2.11)	52
2.3.4 Fusion	59
<b>2.4 Évaluation</b>	<b>60</b>
2.4.1 Protocole	60
2.4.2 Résultats	60
<b>2.5 Conclusion</b>	<b>64</b>

Dans ce chapitre notre objectif est de développer et d'évaluer un système de détection de l'intention de l'utilisateur à partir des signaux EMG. Ce système sera ensuite utilisé pour commander un exosquelette afin d'assister au port de charges.

Nous commençons par décrire l'exosquelette et les capteurs que nous utilisons au cours de nos travaux. Nous passons en revue les différentes approches d'exploitation du signal EMG issues de la littérature. Nous introduisons aussi des notions d'apprentissage profond et de réseaux de neurones artificiels, une approche que nous utilisons pour traiter le signal EMG. Ensuite, nous présentons la stratégie mise en place pour détecter l'intention de l'utilisateur et ses différents composants : l'estimation de l'intensité et de la direction du

mouvement. Enfin, nous évaluons le système au cours d'une expérience impliquant sept participants. Pour cette étude et les suivantes, le problème mécanique est assimilé à un problème à un degré de liberté sur l'axe vertical. Dans le cadre de l'assistance au port de charges cela reste pertinent dans le sens où nous cherchons à contrer la gravité.

Une partie des travaux présentés dans ce chapitre ont fait l'objet de la publication [[Treussart et al., 2019](#)]

## 2.1 Matériels

### 2.1.1 Bras Hercule V2 (BHV2)

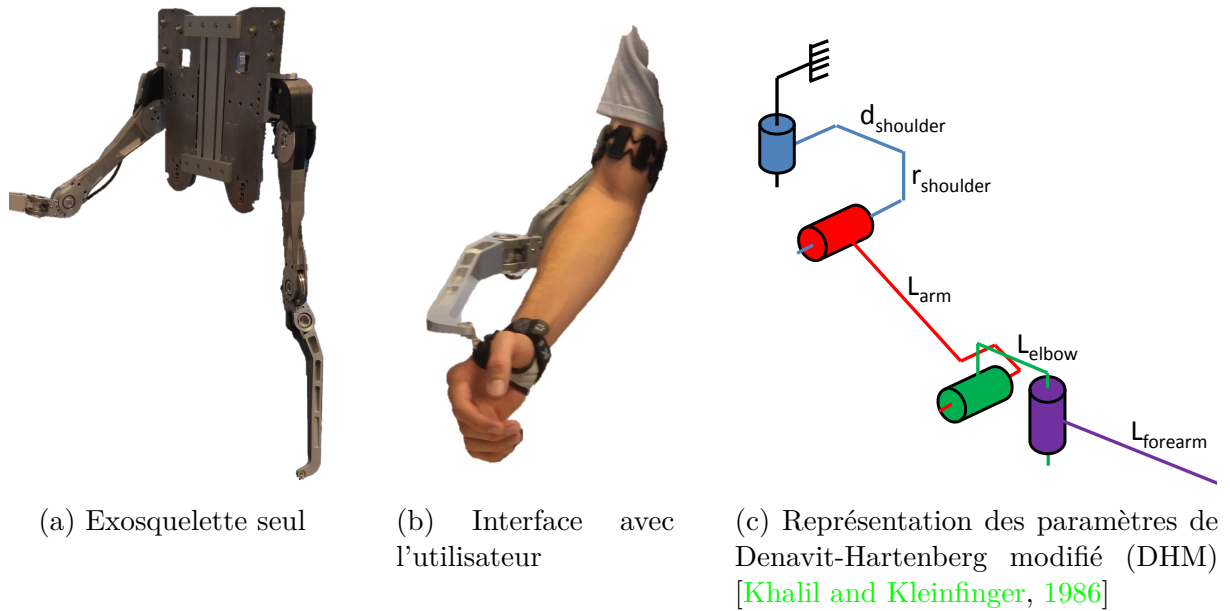


FIGURE 2.1 – Exosquelette BHV2

L'exosquelette qui est utilisé dans nos recherches est un exosquelette de membre supérieur, sous actionné et réversible (cf. Fig 2.1). Chaque bras est constitué de deux segments (bras et avant-bras) et 4 articulations. Deux articulations sont passives ( $\theta_1$  et  $\theta_4$ ) et les deux autres sont couplées de manière proportionnelle ( $\theta_3 = 1.5 * \theta_2$  [Garrec et al., 2012]) et actionnées par le même moteur (cf. Fig. 2.1c and Tab. 2.1). Pour les deux premières études l'opérateur interagit avec l'exosquelette uniquement au niveau de l'effecteur au moyen d'une dragonne. Ce système permet uniquement de fournir une assistance de traction verticale.

TABLE 2.1 – Tableau des paramètres DHM du bras BHV2 [Khalil and Kleinfinger, 1986]

	$\alpha_i$	$d_i$	$r_i$	$\theta_i$
Frame 1	0	0	$r_{shoulder}$	$\theta_1$
Frame 2	$+\frac{\pi}{2}$	$d_{shoulder}$	0	$\theta_2$
Frame 3	0	$L_{arm}$	0	$\theta_3 = 1.5 * \theta_2$
Frame 4	$-\frac{\pi}{2}$	$L_{elbow}$	0	$\theta_4$
Frame 5	0	$L_{forearm}$	0	0



La réversibilité d'un exosquelette ou d'un robot est sa capacité à transmettre des efforts de l'effecteur vers les actionneurs. La qualité de la réversibilité est caractérisée par les pertes d'énergie dues aux frottements, à l'inertie et dans certains cas à la gravité lors de la transmission de l'effort depuis l'effecteur vers l'actionneur. Plus les pertes sont faibles, meilleure est la réversibilité. Une bonne réversibilité permet dans certains cas de se passer de capteurs de forces pour réaliser une commande en effort. On peut aussi parler de transparence du robot du point de vue de l'effecteur.

Pendant le fonctionnement, les dynamiques de l'humain et du robot sont couplées et peuvent être modélisées de la façon suivante [Bastide et al., 2018] :

$$\begin{cases} M_r \ddot{\Theta}_r + b_r \dot{\Theta}_r + \tau_{F_{NL}} + Q_r(\Theta_r) = \tau_r - \tau_i \\ M_h \ddot{\Theta}_h + b_h \dot{\Theta}_h + Q_h(\Theta_h) = \tau_h + \tau_i + J_h^t F_e \end{cases} \quad (2.1)$$

Où  $\tau_i$  est un vecteur à 2 lignes représentant le couple d'interaction entre l'humain et le robot,  $\tau_r$  - le couple du robot,  $\tau_h$  - le couple sur les articulations de l'humain et  $M$  - la matrice d'inertie,  $b$  - la viscosité,  $\tau_{F_{NL}}$  - les frottements non linéaires et  $Q$  le couple exercé par la gravité.  $F_e$  sont les forces extérieures appliquées à l'humain et  $J_h^t$  - est la matrice jacobienne transposée de l'humain. Les indices  $r$  et  $h$  dénotent des grandeurs similaires relatives à l'humain et au robot respectivement. Nous considérons des interactions quasi-statiques et nous compensons l'effet de la gravité sur les différents segments du robot, et une partie des frottements non-linéaires ( $F_{NL}$ ) (la réversibilité du robot nous assure que  $F_{NL}$  est faible [Garrec, 2010]) :

$$\tau_r = \tau_{rc} + Q_r(\Theta_r) + \tau_{F_{NL}} + b_r \dot{\Theta}_r \quad (2.2)$$

d'où le couple sur les articulations de l'opérateur :

$$\tau_h = -\tau_{rc} - J_h^t F_e + Q_h(\Theta_h) \quad (2.3)$$

Où le couple  $\tau_{rc}$  est notre variable de commande.

### 2.1.2 Myo Armband

Dans l'objectif d'un usage industriel le système d'acquisition des signaux EMG doit être robuste, facile à mettre en place et permettre une utilisation temps réel.



FIGURE 2.2 – MyoArmband

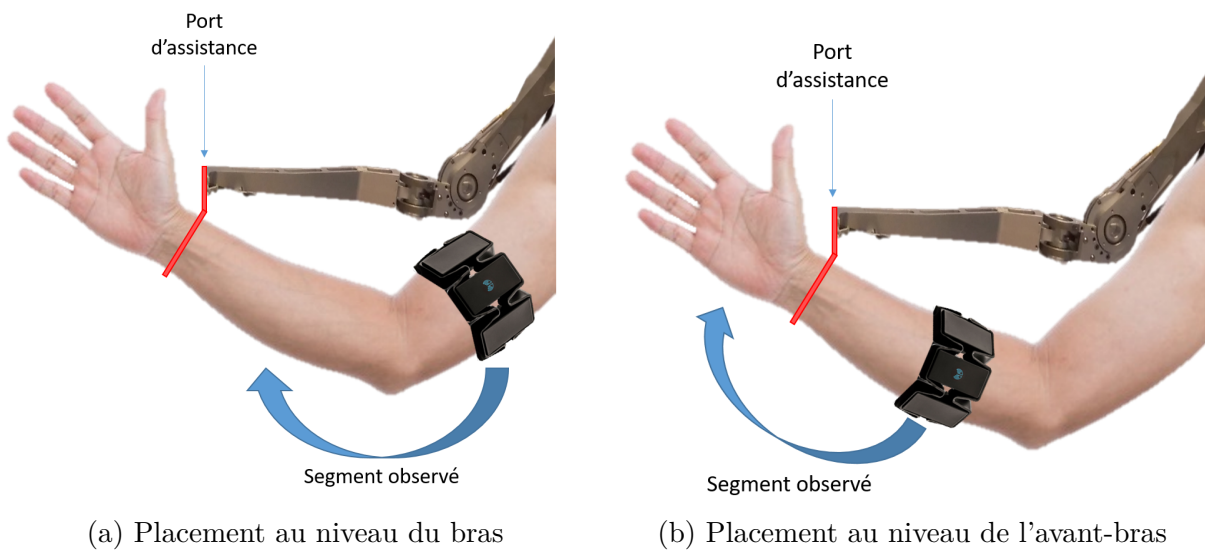


FIGURE 2.3 – Placement du bracelet

Le Myo-Armband (Thalmic Labs, Ontario), visible sur la Fig. 2.2, remplit tous ces critères. Le bracelet est constitué de huit paires d'électrodes sèches et d'une centrale inertielle. La communication se fait par Bluetooth Low Energy (BLE) à une fréquence de 100Hz, , mais l'acquisition n'est possible qu'à 200Hz. Les mesures des 8 électrodes sont envoyées par paires avec en plus les informations de la centrale inertielle qui elle a une fréquence d'acquisition de 50Hz. Le signal brut envoyé par les capteurs EMG prend la forme d'un signal centré sur zéro codé sur 8 bits, il n'a pas d'unité et est compris entre -126 et +127.

Il est à noter que la position des points d'attache entre l'humain et l'exosquelette va influencer de manière importante l'utilité des capteurs en fonction de leur position. Pour le pilotage d'un exosquelette, il est plus intéressant de mesurer l'activité musculaire des segments avant le port d'interaction. Cette activité est alors directement influencée par l'exosquelette, ce qui en fait un signal pertinent pour la commande (voir Fig. 2.3).

Or, dans notre cas, le bracelet Myo a été conçu pour être placé sur l'avant-bras. Cependant, l'exosquelette BHV2 ne permet pas de fournir une assistance qui soulage les articulations du poignet et de la main. Par contre, nous pouvons soulager les efforts musculaires au niveau du bras bras (ce qui influence l'activité du biceps et du triceps) en supportant l'utilisateur au niveau du poignet. De plus, comme nous l'avons vu dans la section 1.2.2, le biceps intervient dans la flexion du coude et d'épaule, et le triceps intervient lui pour l'extension de ces deux articulations. Il y a donc deux raisons pour utiliser le bracelet Myo au niveau du bras : (i) l'aspect pratique, et (ii) l'importance de ces muscles pour des tâches de port de charges.

## 2.2 Revue de littérature

Le signal EMG issu du bracelet Myo va donc être utilisé pour détecter l'intention de l'utilisateur. Voyons à présent quelles méthodes de traitement du signal EMG peuvent être employées pour détecter les différents mouvements pendant le port de charges.

### 2.2.1 Apprentissage profond

L'apprentissage profond, ou *Deep Learning*, peut être vu comme une sous-catégorie de l'apprentissage statistique. Plusieurs ouvrages permettent d'avoir un point de vue approfondi du sujet, comme [Goodfellow et al., 2016]. Nous nous intéressons à l'apprentissage supervisé, qui est une sous-partie de l'apprentissage statistique. Nous allons présenter les notions nécessaires à la compréhension des techniques employées au cours de nos travaux, en adoptant un formalisme similaire à [Vielzeuf, 2019].

On considère  $\mathcal{X}$  l'ensemble des entrées possibles et  $\mathcal{Y}$ , l'ensemble des sorties possibles. Il existe une distribution de probabilités inconnue  $p(x, y)$  sur l'ensemble  $\mathcal{X} \times \mathcal{Y}$ . L'apprentissage consiste à chercher une fonction  $f : \mathcal{X} \rightarrow \mathcal{Y}$  telle que  $f(x) = \hat{y}$ , où  $\hat{y}$  est une estimation de la valeur réelle  $y$  associé à  $x$ . On appelle fonction de coût une fonction  $L(\hat{y}, y)$  qui permet d'évaluer l'écart entre l'estimation  $\hat{y} = f(x)$  et la valeur réelle  $y$ . La distribution  $p(x, y)$  étant inconnue, nous utiliserons une base de données d'entraînement qui est un sous-ensemble de  $N$  éléments de  $\mathcal{X} \times \mathcal{Y}$  issus de  $p(x, y)$ . Cela nous donne des paires  $(x_i, y_i)$  qui serviront d'exemples. L'objectif devient alors de trouver une fonction  $f^*$  telle que  $\mathcal{E}(f^*)$  soit minimal :

$$\mathcal{E}(f) = \frac{1}{N} \sum_{i=0}^N L(\hat{y}_i, y_i) \quad (2.4)$$

Par la suite nous considérons que la fonction  $f$  peut être représentée par des paramètres  $\theta$  qui seront nos variables d'apprentissage. Le modèle  $M$ , fonction des paramètres  $\theta$ , permet de réaliser l'inférence :

$$\hat{y} = M(\theta, x) \quad (2.5)$$

Et le problème de minimisation revient à trouver  $\theta^*$  tel que :

$$\theta^* = \operatorname{argmin}_{\theta} \left( \frac{1}{N} \sum_{i=0}^N L(\hat{y}_i, y_i) \right) \quad (2.6)$$

On parle d'apprentissage supervisé car on considère que nous avons des données d'entraînement, des couples de l'ensemble  $\mathcal{X} \times \mathcal{Y}$ . Il s'agit en général d'annotations (ou *vérité terrain*) fournies par un humain. On peut distinguer deux objectifs principaux à atteindre : (i) il y a la discrimination entre différentes catégories, on parle de classification et (ii) l'estimation de valeurs continues, on parle alors de régression. Dans le cadre d'une régression, un exemple de fonction de coût classique est l'erreur quadratique.

Nous allons maintenant nous intéresser aux réseaux neuronaux, qui forment une classe particulière de modèles, et leurs différentes architectures.

### 2.2.1.1 Perceptron

L'idée qui a motivé le développement des réseaux neuronaux est l'imitation du fonctionnement de cerveau : une structure simple (neurone) répétée un grand nombre de fois. La première architecture proposée est celle du perceptron [Rosenblatt, 1958], représentée sur la Fig. 2.4, conçue à l'origine pour faire de la classification binaire. L'entrée est un vecteur  $\mathbf{x}$  de dimension  $n$ . Les paramètres du modèle sont représentés par un vecteur  $\boldsymbol{\omega}$  de même dimension  $n$ . On effectue le produit scalaire entre l'entrée et les paramètres. On applique ensuite une fonction d'activation  $\sigma$  au résultat de ce produit scalaire.




FIGURE 2.4 – Representation du perceptron




FIGURE 2.5 – Exemple de problème non linéairement séparable

$$\hat{y} = \sigma((\omega_1, \omega_2, \dots, \omega_n) \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{pmatrix}) \quad (2.7)$$

La formulation peut être étendue à plusieurs sorties :

$$\hat{\mathbf{y}} = \sigma(\Omega, \mathbf{x}) \quad (2.8)$$

Avec  $\hat{\mathbf{y}}$ , un vecteur de dimension  $m$  et  $\Omega$  une matrice de dimension  $m \times n$ .

Le perceptron ainsi défini permet de résoudre des problèmes linéaires. Il n'est en revanche pas capable de résoudre des problèmes non-linéaires. Sur la Fig. 2.5, nous pouvons voir un exemple de problème de classification qu'il ne peut pas résoudre. Une solution existante est l'astuce du noyau (ou *kernel trick*), elle consiste à transformer les données dans un espace de plus grande dimension où elles seront alors linéairement séparables [Aizerman, 1964].

Une architecture alternative proposée pour pallier à ce manque est le Perceptron Multi-couches (MLP) [Rumelhart et al., 1986]. Il s'agit d'empiler plusieurs perceptrons séparés par des fonctions d'activation non-linéaires. Un exemple de MLP avec une couche cachée est présenté sur le Fig. 2.6 C'est la non-linéarité introduite par les fonctions d'activation qui permet la résolution de problèmes non-linéaires, sans cela, empiler les couches ne servirait à rien puisque la sortie resterait une combinaison linéaire des entrées. Des fonctions d'activation classiques sont la tangente hyperbolique, la sigmoïde ou encore la Rectified Linear Unit (ReLU) (voir Fig. E.2).




FIGURE 2.6 – Représentation d'un réseau perceptron multi-couches (1 couche cachée)

### 2.2.1.2 Réseaux convolutifs

Les réseaux convolutifs (CNN, Convolutional Neural Network) ont été proposés pour traiter des problèmes avec des dimensions d'entrée plus importantes, en re-introduisant des notions de filtrage sans pour autant imposer le type de filtrage. Une application a révélé le potentiel des CNN, il s'agit de la classification d'images de chiffres écrits à la main [LeCun et al., 1998] (voir Fig. 2.7) . Sur la base données MNIST les MLP atteignent un precision autour de 90 % alors les CNN atteignent 99 %.




FIGURE 2.7 – Exemple de CNN : LeNet5 [LeCun et al., 1998]

L'architecture classique d'un CNN est composée de trois types de couches différentes :

- Les couches de convolutions : il s'agit de filtres dont les poids du noyau sont les paramètres d'apprentissage. La taille du noyau est un hyper-paramètre à choisir au moment de concevoir le modèle.
- Les couches d'agrégation : il s'agit de sous échantillonner la sortie des couches de convolutions. En général cela consiste à extraire la moyenne ou le maximum parmi un ensemble de valeurs (d'une matrice carrée par exemple pour les images)
- Les couches complètement connectées : ces couches interviennent uniquement au niveau des dernières couches. Il s'agit de perceptrons avec une activation non-

linéaire.

Parmi les caractéristiques intéressantes des couches de convolution nous pouvons mentionner la connectivité locale, la taille limitée du noyau permet d'obtenir une sortie liée spatialement à des éléments qui sont proches, et l'invariance à la translation. L'apparition de multiples bases de données, avec un très grand nombre d'exemples a permis la conception d'architectures variées [Khan et al., 2019]. La forme d'architecture de CNN sur laquelle nous allons nous concentrer est une architecture permettant de traiter des données temporelles [Dieleman and Schrauwen, 2014], notamment des signaux EMG [Zhai et al., 2017].

### 2.2.1.3 Réseaux récurrents




FIGURE 2.8 – RNN : représentations enroulée et déroulée.  $x$  représente les entrées ;  $o$  les sorties,  $h$  les états et  $W$ ,  $V$  et  $U$  les poids du réseau.

Les réseaux récurrents (RNN) connaissent du succès pour le traitement de séquence de données, comme des textes. Leur particularité est qu'ils rebouclent sur eux-mêmes. C'est à dire que l'état interne du réseau pour l'entrée  $t$  est transmis comme entrée à  $t+1$  en plus de l'entrée  $t+1$ . Cela est représenté sur la Fig. 2.8. Des variantes de cette architecture comme les Réseaux de Neurones Récurrents à Mémoire Court et Long Terme ou Long Short Term Memory (LSTM) [Hochreiter and Schmidhuber, 1997] facilitent le transport d'informations dans la durée pour faciliter le traitement de longues séquences.

## 2.2.2 Signal EMG

### 2.2.2.1 Origine du signal EMG

La plus petite unité fonctionnelle impliquée dans le contrôle moteur est l'unité motrice (*Motor Unit*, MU). Elle est constituée d'un motoneurone, situé dans la moelle épinière,




FIGURE 2.9 – Représentation d'une unité motrice [Konrad, 2005]

et d'un axone, partant du motoneurone et allant se connecter à une ou plusieurs fibres musculaires. La connexion entre axone et fibre musculaire se fait au travers des plaques motrices (voir Fig.2.9).

Lorsqu'une contraction est commandée, le motoneurone génère un potentiel d'action. Si ce potentiel dépasse un certain seuil en arrivant aux plaques motrices alors il se transforme en potentiel d'action musculaire, caractérisé par un influx d'ion sodium  $\text{Na}^+$ . Une dépolarisation de la membrane musculaire a alors lieu et se propage le long de la fibre musculaire. Il est possible avec un paire d'électrodes placées le long de la fibre de détecter cette différence de potentiel qui se propage. Les fibres musculaire n'étant pas isolées, c'est la somme de toutes ces différences de potentiel qui est mesurée. On parle alors de signal EMG brut (*raw EMG* [Konrad, 2005]).

Il est à noter que la contraction musculaire n'intervient pas immédiatement après la dépolarisation de la membrane. Elle est déclenchée par la libération d'ions calcium. Le délai entre la dépolarisation et la contraction est appelé délai électromécanique (*Electromechanical Delay*, EMD). Ce délai varie entre 30 et 100 ms [Cavanagh and Komi, 1979]. Il à été estimé à  $26 \pm 11\text{ms}$  pour le triceps et  $41 \pm 13\text{ms}$  pour le biceps [Norman and Komi, 1979].

Deux mécanismes permettent de moduler la force développée par un muscle : le recrutement des unités motrices et leur fréquence de déclenchement (voir Fig. 2.10). L'augmentation de la force générée est assurée par une augmentation du nombre de MU re-



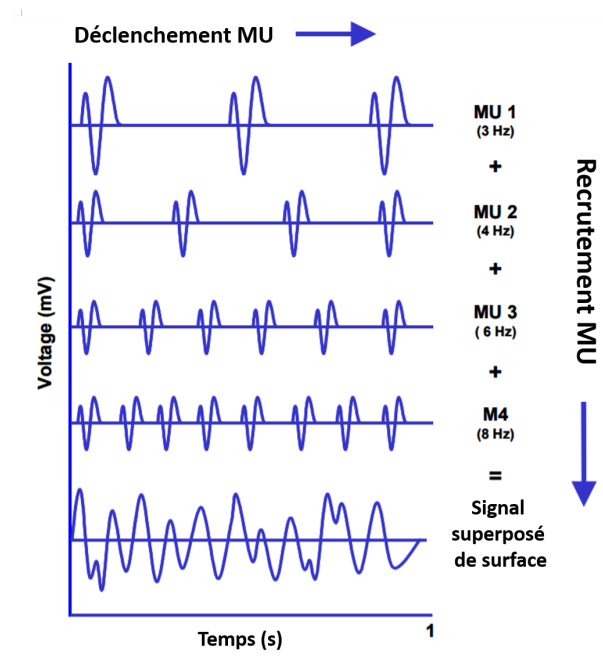


FIGURE 2.10 – Représentation des phénomènes de recrutement et de fréquence de déclenchement et de leur contribution sur la signal EMG brut mesuré en surface [Konrad, 2005]

crutées et/ou une augmentation de leur fréquence de déclenchement. L'organisation et la connexion entre ces deux phénomènes est approfondie dans des travaux comme [Henneman, 1957] et [Hu et al., 2014].

### 2.2.2.2 Exploitation du signal EMG

Il existe deux types de capteurs pour mesurer les signaux EMG : les électrodes de surfaces, posées sur la peau (sEMG) et les électrodes intra-musculaires. Ce deuxième type étant invasif nous n'allons pas nous y intéresser dans un cadre d'application industrielle. Concrètement les EMG mesurent le potentiel électrique généré au moment du recrutement des fibres musculaires pour la contraction. Les électrodes peuvent être ciblées, c'est-à-dire positionnées individuellement et précisément sur les muscles que l'on souhaite observer, ou non ciblées comme des rangées d'électrodes disposées autour d'un bracelet à enfiler autour du bras. Par ailleurs, on distingue aussi les électrodes dites "mouillées", pour lesquelles on utilise du gel pour réduire l'impédance de la peau, et les électrodes "sèches", pour lesquelles aucune préparation de la peau est nécessaire. Les électrodes sèches sont plus adaptées à une utilisation régulière car elles sont complètement réutilisables contrairement aux électrodes mouillées pour lesquelles il faut remettre du gel à chaque fois ou bien changer des embouts

spécifiques. Le Bracelet Myo décrit dans la section 2.1.2 est équipé d'électrodes sèches non ciblées, ce qui rend sa mise en place particulièrement pratique et rapide.

Les signaux EMG ont déjà été utilisés pour contrôler des systèmes robotique [Ajudani et al., 2018, Simão et al., 2019]. Quel que soit le type d'électrodes, un inconvénient majeur pour une utilisation en commande est leur faible ratio signal/bruit. Nous allons passer en revue des exploitations possibles du signal EMG, spécifiques au contrôle de robots.

L'exploitation du signal EMG se divise en deux catégories : les méthodes discrètes et les méthodes continues.

**2.2.2.2.1 Méthodes discrètes** Les méthodes discrètes consistent en général à faire de la reconnaissance de séquences. Une approche classique consiste à choisir des caractéristique du signal à extraire qui servent ensuite à entraîner un classificateur (SVM, MLP, KNN, ...) [Phukpattaranont et al., 2018]. Les caractéristiques pouvant être extraites du signal sont très nombreuses, et il y a un choix varié dans classificateurs utilisables. Certains travaux se sont concentrés sur le choix de ces caractéristiques, ainsi que l'évaluation de différents classificateurs [Abbaspour et al., 2020]. Une approche alternative utilise un réseau de neurones artificiels pour traiter les données de bout en bout et faire la classification [Gandolla et al., 2017].

Le principal inconvénient des approches discrètes pour la détection d'intention est le manque de flexibilité. En effet, il y a un compromis à trouver entre le panel d'actions possibles (lié au nombre de classes) d'une part et, la fiabilité du classificateur et la charge d'apprentissage d'autre part. En effet, si on augmente le nombre de classes, il devient plus difficile pour l'utilisateur d'apprendre les actions correspondantes. De même, en augmentant le nombre de classes, on augmente la possibilité d'avoir des classes qui se ressemblent et donc plus difficiles à discriminer. Ce deuxième aspect est mis en évidence dans les travaux de [Tkach et al., 2014]. Dans cette étude les auteurs étudient les performances d'une grille d'électrodes comparée à un placement ciblé. On remarque que lorsque le nombre de classes augmente la précision de la classification diminue.

Exemple d'utilisation d'une méthode discrète :

Dans le cas du contrôle d'un robot mobile, une classe peut correspondre à une direction avec une vitesse fixe [DaSalla et al., 2005].

**2.2.2.2.2 Méthodes continues** Les méthodes continues ont pour objectif d'extraire des grandeurs continues du signal EMG [Ryu et al., 2008]. Si elles peuvent sembler plus pertinentes dans le cadre du contrôle de systèmes robotiques, elles présentent leurs propres désavantages. Tout d'abord, elles sont plus complexes. En effet, généralement les relations entre les caractéristiques du signal EMG et les grandeurs observées sont non linéaires [Zajac, 1989]. Par ailleurs, ces méthodes nécessitent, le plus souvent, un placement ciblé des électrodes qui complexifie l'installation

Les grandeurs continues observables avec des EMG sont en particulier, la position et l'effort. La position est plus adaptée à une co-manipulation sérielle (comme le contrôle de prothèses) ou à de la téléopération qu'à des situations de co-manipulation parallèle, au cours desquelles les couples de l'utilisateur et du robot s'influencent l'un l'autre. Pour la co-manipulation parallèle il sera préférable d'utiliser une observation de l'effort.

Exemple d'utilisation d'une méthode continue :

Dans l'étude [Artemiadis and Kyriakopoulos, 2010b], une estimation 3D de la position de la main a été réalisée à l'aide de 9 électrodes ciblées.

**2.2.2.2.3 Calibration** Enfin, les caractéristiques des signaux EMG sont propres à chaque individu et varient d'une personne à l'autre. C'est pourquoi les méthodes de traitement du signal EMG doivent être calibrées pour chaque utilisateur. Différentes méthodes de calibration ont été proposées dans la littérature. Elles peuvent être basées sur des contractions volontaires pour collecter des données d'entraînement pour des classificateurs. En général, des données de toutes les classes sont nécessaires [Jung et al., 2007] mais dans certains cas, il est possible de reconnaître une situation spécifique comparée à plusieurs autres (comme un classificateur à 1 classe [Amsuess et al., 2015]).

Dans le cadre de la calibration en effort, une stratégie consiste à utiliser des efforts externes connus (comme des capteurs d'effort ou un set de poids). Cette approche est adaptée pour certaines évaluations continues mais l'utilisation de capteurs d'effort augmente le coût et la complexité de la procédure de calibration. De plus, le positionnement des capteurs est souvent critique [Al Harrach et al., 2017]. Dans le cas de la calibration en position (cas courant dans la littérature), des systèmes de capture de mouvement sont utilisés pour calibrer des méthodes continues [Imrani et al., 2018].

Nous proposons une approche alternative qui consiste à se servir de l'exosquelette qui sera utilisé par la suite pour apporter une assistance en effort. Cela permettra de ne pas

complexifier la procédure avec du matériel additionnel, mais aussi de contrôler précisément l'enregistrement des données de calibration. Dans le chapitre 4, nous nous intéressons à la généralisation potentielle du système à partir de données de multiples utilisateurs afin de réduire le temps de calibration.

## 2.3 Conception

### 2.3.1 Principe, choix et contexte

Tout d'abors rappelons que nos travaux ont pour objectif de contribuer à l'utilisation industrielle, voire grand public, des exosquelettes. C'est pourquoi nous avons fait le choix d'utiliser l'exosquelette que nous serons amenés à contrôler comme moyen de calibration. Le choix du MyoArmband s'inscrit aussi dans cette logique puisqu'il s'agit d'un capteur à bas coût et facile à mettre en place.

Pour notre système de détection d'intention, nous utilisons une approche mixte qui mêle une composante continue et une composante discrète. L'objectif étant de compenser le manque de souplesse d'une approche discrète et la complexité d'une approche continue pour concevoir un système fiable et fonctionnel. La sortie de ce système est utilisé comme entrée pour une loi de commande en couple dans le chapitre 3.4b. Nous supposons que le fait de rendre la sortie indépendante des caractéristiques du signal EMG de l'utilisateur permettra d'unifier le réglage de la future loi de commande. C'est pourquoi nous avons choisi de représenter les intentions de l'utilisateur sous la forme d'un couple plutôt qu'une activation EMG normalisée comme c'est le cas en général.

Notre approche a pour but de tirer parti de la facilité de mise en place des méthodes discrètes et de la finesse de contrôle que permettent les méthodes continues. La composante discrète va nous permettre de choisir entre différentes sous composantes continues, une stratégie similaire à celle présentée par [Amsuess et al., 2015]. Les sous-composantes continues peuvent donc être simplifiées et rendues plus simples à calibrer qu'une méthode intégralement continue. Dans notre cas, la composante continue fournit l'information sur l'intensité de l'intention de l'utilisateur et la composante discrète détermine la direction du mouvement voulu. De plus, pour rendre ce système directement exploitable par une future loi de commande, nous avons choisi d'estimer l'intensité de l'intention sous la forme d'un couple, plutôt qu'un pourcentage de contraction maximal. Notre hypothèse est que

si nous utilisons une valeur objective de l'intensité le comportement de la loi de contrôle sera le même d'un utilisateur à l'autre. Cela permettrait un réglage de la loi de contrôle indépendant de l'utilisateur.

La procédure de détection d'intention peut être séparée en deux traitements parallèles (cf. Fig. 2.11) : Le premier est un classificateur qui détermine la direction du mouvement (décrit dans la section 2.3.3). Le second est conçu pour estimer l'intensité du mouvement voulu sous la forme d'un couple (décrit dans la section 2.3.2).

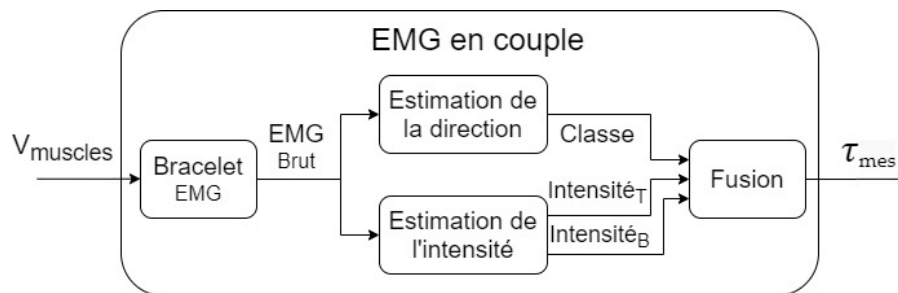


FIGURE 2.11 – Approche générale ( $\text{Intensité}_B$  and  $\text{Intensité}_T$  correspondent respectivement à l'intensité de l'activation du biceps et de l'activation du triceps. Ces grandeurs seront présentées en détail dans la section 2.3.2)

Alternativement, une approche où un traitement de bout en bout avec un réseau de neurones est aussi testée en annexe C (FULLNN). Différentes architectures sont testées, qui prennent le signal brut en entrée et estiment directement la valeur signée du couple appliqué. Les tests en annexes montrent que ce type d'approche peut atteindre des performances équivalentes à celles de la méthode décrite ci-après (MIXTE). Cependant, plusieurs points incitent à choisir la méthode MIXTE. Tout d'abord, le nombre de paramètres dans le réseau FULLNN le plus performant est d'environ 150 000, alors que dans la méthode MIXTE, une version avec environ 3 000 paramètres atteint des performances satisfaisantes. Cette augmentation du nombre de paramètres a deux effets notables : (i) une augmentation du temps nécessaire pour réaliser l'apprentissage du réseau et (ii) une augmentation du nombre de calculs à réaliser pour obtenir une estimation en temps-réel. De plus, le contrôle qu'offre les paramètres de réglage (comme la taille de la fenêtre d'entrée) est déterminé de manière empirique et est moins maîtrisé que les paramètres de la méthode mixte (comme la fréquence de coupure du filtre de Butterworth et les paramètres de modèle EMG-couple). C'est pourquoi nous avons continué nos travaux avec la méthode MIXTE présentée dans ce chapitre plutôt qu'avec la méthode FULLNN utilisant un réseau de neurones de bout en bout.

## 2.3.2 Estimation de l'intensité (cf. Fig. 2.11)

### 2.3.2.1 Pré-traitements

La première étape consiste à sommer les signaux rectifiés de chaque capteur (cf. eq.(2.9) et (2.10)). En faisant cela nous perdons les informations spatiales liées aux signaux (i.e. quel capteur est actif), mais nous comptons sur la composante discrète de notre approche pour exploiter cet aspect. En contrepartie, cela permet d'exploiter le phénomène de "cross-talk"<sup>1</sup> et d'augmenter notre capacité de mesure au delà de la saturation des électrodes. En effet, lorsque l'électrode placée juste au-dessus du muscle actif est saturée, les électrodes placées à côté ne sont pas saturées et sont capables de mesurer une augmentation dans l'intensité grâce au crosstalk.

Ce phénomène est mis en avant sur la Fig. 2.12. Nous pouvons voir le signal EMG brut des huit capteurs lors d'une contraction par paliers de plus en plus intense du biceps. Le capteur 1 est celui placé directement sur le biceps et les limites d'affichage correspondent aux valeurs de saturation (+127 et -126). Nous pouvons donc voir que, lorsque le capteur 1 est saturé (autour de 4000 ms), les capteurs adjacents ne sont pas saturés et peuvent encore permettre de mesurer une augmentation de l'intensité.




FIGURE 2.12 – Mise en évidence du crosstalk et de son exploitation

$$EMG_{rectif} = abs(EMG_i) \quad (2.9)$$

$$EMG_{rectif,sum} = \sum_{i=1}^8 EMG_{rectif,i} \quad (2.10)$$

1. Le "crosstalk" dénomme le fait que l'activité musculaire de muscles adjacents à celui où est placé le capteur peut être mesurée par le capteur

Ensuite le résultat  $EMG_{rectif,sum}$  est filtré avec un filtre passe-bas [Hogan, 1976].

Les filtres moyenneurs et RMS (Root mean square, moyenne quadratique) sont souvent utilisés avec pour lisser le signal EMG [Merletti and Di Torino, 1999]. Comme pour tout filtre il y a un compromis à faire entre effet de lissage et déphasage.

Dans le cas des filtres moyenneurs et RMS, augmenter la fenêtre de filtrage accroît l'effet de lissage mais également le déphasage. C'est pourquoi ce type de filtre est essentiellement utilisé pour des traitements hors-lignes, car il est possible de supprimer le déphasage en centrant le filtre sur la valeur du signal à filtrer, ou en faisant un filtrage aller-retour. Ceci n'étant pas possible en temps réel, des filtres avec une réponse en fréquence plus satisfaisante, sont en général préférés. Un autre filtre souvent utilisé pour le lissage de signaux EMG est le filtre de Butterworth [Butterworth, 1930, Buchanan et al., 2004]. C'est le filtre que nous avons également retenu, un filtre Butterworth d'ordre 2 et de fréquence de coupure 2 Hz. Une comparaison des performances de ces différents filtres est présentée en Annexe A.

### 2.3.2.2 Modélisation

Le résultat obtenu après le filtrage reste dépendant de l'utilisateur. Notre hypothèse est que, si on parvient à obtenir une valeur objective, une loi de commande peut alors être réglée indépendamment de l'utilisateur. L'objectif de cette section est d'obtenir une valeur objective à partir du résultat du filtrage de la section précédente 2.3.2.1. Pour cela nous nous intéressons aux modélisations du couple appliqué estimé à partir du signal EMG. Cette approche est facilitée par la simplicité du coude en tant qu'articulation (voir section 1.2.2)

Pour faire le lien entre l'activité EMG mesurée au niveau du bras et le couple développé au niveau du coude plusieurs approches ont été employées [Cao, 2010]. Ces approches peuvent être basées sur des modèles biomécaniques, le modèle de Hill étant parmi les plus utilisés et avec de multiples variations [Winters, 1990, Haeufle et al., 2014], dont les paramètres correspondent à des grandeurs physiologiques (comme la longueur d'un muscle). D'autres approches utilisent des techniques d'apprentissage comme [Ullauri et al., 2015], ou les travaux présentés dans l'annexe C. Enfin, certaines méthodes sont basées sur des modèles mathématiques [Ullah and Kim, 2009, Hosoda and Venture, 2014].

Pour obtenir une valeur objective à partir du résultat du filtrage, nous utilisons le

modèle présenté par [Ullah and Kim, 2009], qui lie l'activité EMG à un couple.

$$\tau = u^a * e^{(c-b*u)} \quad (2.11)$$

$\tau$  étant le couple modélisé,  $u$  le signal EMG filtré  $a, b$  et  $c$  les paramètres à déterminer séparément pour le biceps et le triceps lors de la calibration.

Dans l'article de [Ullah and Kim, 2009], ce modèle était calibré dans un environnement contrôlé, il y avait une seule électrode placée précisément sur le biceps, avec une fréquence d'acquisition de 1000Hz, et les données de calibration étaient enregistrées en restreignant les mouvements des participants de manière à ce que le capteur d'effort mesure précisément le couple au niveau du coude. Dans notre cas, nous avons étendu l'utilisation du modèle à deux muscles (biceps et triceps) et avec un placement approximatif de multiples capteurs EMG ayant une fréquence d'acquisition plus faible (200Hz).

### 2.3.2.3 Calibration

A la différence de [Ullah and Kim, 2009], nous nous sommes interdits d'utiliser une instrumentation trop complexe (capteurs d'efforts, masses calibrées), de façon à pouvoir envisager une application industrielle la plus simple possible. Deux sets de paramètres sont à estimer pour caractériser les liens entre le couple généré et l'activation EMG correspondante : un pour caractériser la flexion (activation du biceps, mouvement vers le haut) et un pour l'extension (activation du triceps, mouvement vers le bas). Pour cela, le bras de l'exosquelette est asservi sur une position fixe avec un correcteur proportionnel dérivé (PD) avec un gain proportionnel élevé pour assurer un comportement le plus rigide possible.

Nous avons procédé comme suit, avec du repos entre chaque étape :

- 5 secondes de contraction maximale du biceps
- 5 secondes de contraction maximale du triceps
- 6 paliers de 8 secondes progressant de 0 à 80% de la contraction maximale du biceps
- 6 paliers de 8 secondes progressant de 0 à 80% de la contraction maximale du triceps

Pour obtenir les contractions maximales l'utilisateur doit saisir l'extrémité du bras du robot. Il doit alors forcer vers le haut (voir Fig. 2.16c) de toute ses forces et maintenir






FIGURE 2.13 – Résultats de la régression pour un participant, pour l'activation du triceps

l'effort pendant cinq secondes pour enregistrer l'activation maximale du biceps (flexion) puis faire la même chose vers le bas (voir Fig. 2.16b) pour enregistrer celle du triceps (extension). C'est le courant au niveau de l'actionneur qui nous permet de mesurer le couple appliqué. Ces valeurs maximales de couples nous servent ensuite pour mettre au point un protocole de paliers de couples. Dans cette situation c'est à l'utilisateur de maintenir une position fixe pendant que l'exosquelette applique différents couples. Le couple appliqué commence à la valeur de compensation de gravité du bras du robot (aucun effort à fournir de la part de l'utilisateur) et augmente cinq fois par paliers de huit secondes pour augmenter jusqu'à 80 % du maximum enregistré. Les transitions entre les paliers sont continues et linéaires et durent une seconde, pour éviter les à-coups. Grâce à cette procédure nous assurons le maintien des niveaux de contractions voulus.

Ensuite, avant d'exploiter les données, nous retirons le premier palier de la séquence d'activation du biceps et les deux premiers de la séquence d'activation du triceps. En effet, ces paliers ne présentent pas d'activation musculaire puisque le bras était au repos. Les enregistrements des maxima sont concaténés avec leur séquence d'activation respective. C'est le résultat de cette concaténation qui est utilisé pour estimer les paramètres du modèle EMG-couple (eq. (2.11)).

Enfin, les paramètres sont estimés avec une régression non-linéaire de Levenberg-Marquardt [Marquardt, 1963]. Sur la Fig. 2.13 les résultats de la régression pour le triceps pour un participant sont présentés. Les étapes présentées dans cette section permettent de déterminer deux sets de paramètres, caractérisant l'activation du biceps et du triceps.

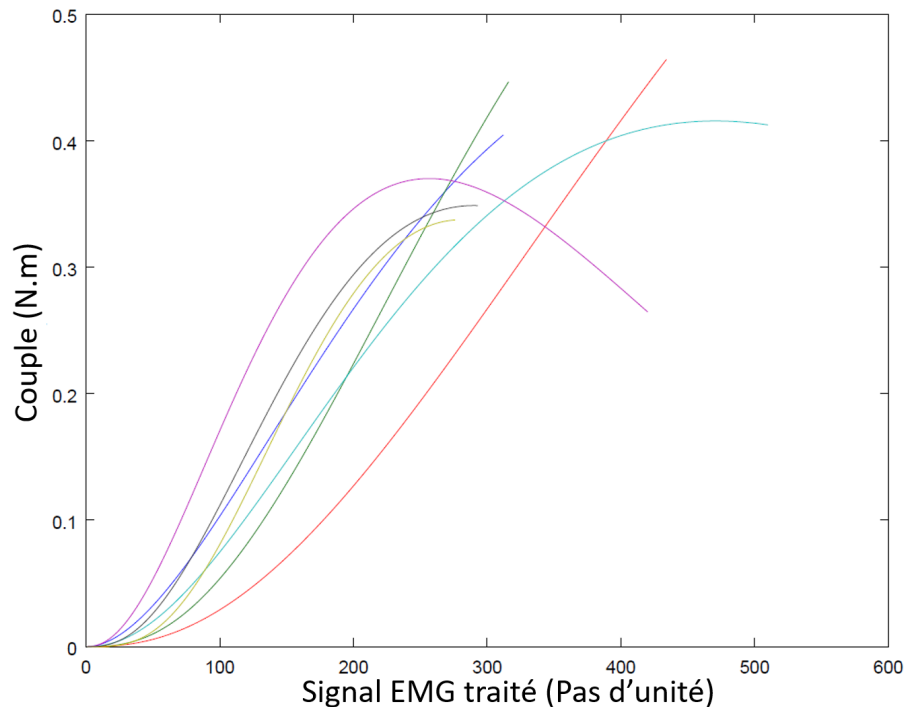


FIGURE 2.14 – Couple modélisé avec l'équation 2.11, en fonction des valeurs EMG 2.10, pour les paramètres de chaque participant

Pendant le fonctionnement c'est la classification 2.3.3 qui indique quel set de paramètres utiliser, suivant que le mouvement est dirigé vers le haut ou bien vers le bas. Sur les Fig. 2.13, 2.14, 2.20a et 2.20b c'est le couple au niveau de l'actionneur qui est représenté.

Sur la Fig. 2.14 nous avons tracé le couple modélisé en fonction de l'activité EMG avec les paramètres estimés pour l'activation du biceps des sept participants (voir sec. 2.4). Le modèle a été tracé jusqu'à l'activation maximale enregistrée pour chaque participant, respectivement. C'est pourquoi toutes les courbes ne s'arrêtent pas au même point.

Tout d'abord, nous pouvons observer que les caractéristiques du signal EMG sont hétérogènes d'un individu à l'autre, ce qui souligne le besoin d'une calibration personnalisée.

Ensuite, nous pouvons voir que pour un des participants (courbe violette) le couple modélisé diminue avec l'augmentation de l'activation EMG. Après observation des données brutes de ce participant, une hypothèse raisonnable est que, lors de l'enregistrement du maximum, il y a eu de la co-contraction, donnant l'impression au participant de fournir plus d'effort mais l'activation du muscle antagoniste réduisait le couple appliqué.

Nous pouvons voir sur la Fig. 2.15, le signal EMG brut des enregistrements des maxima de contraction pour le participant en question (Fig. 2.15a) et d'un autre participant à titre de comparaison (Fig. 2.15b). Nous pouvons voir que, pour le cas du maximum de

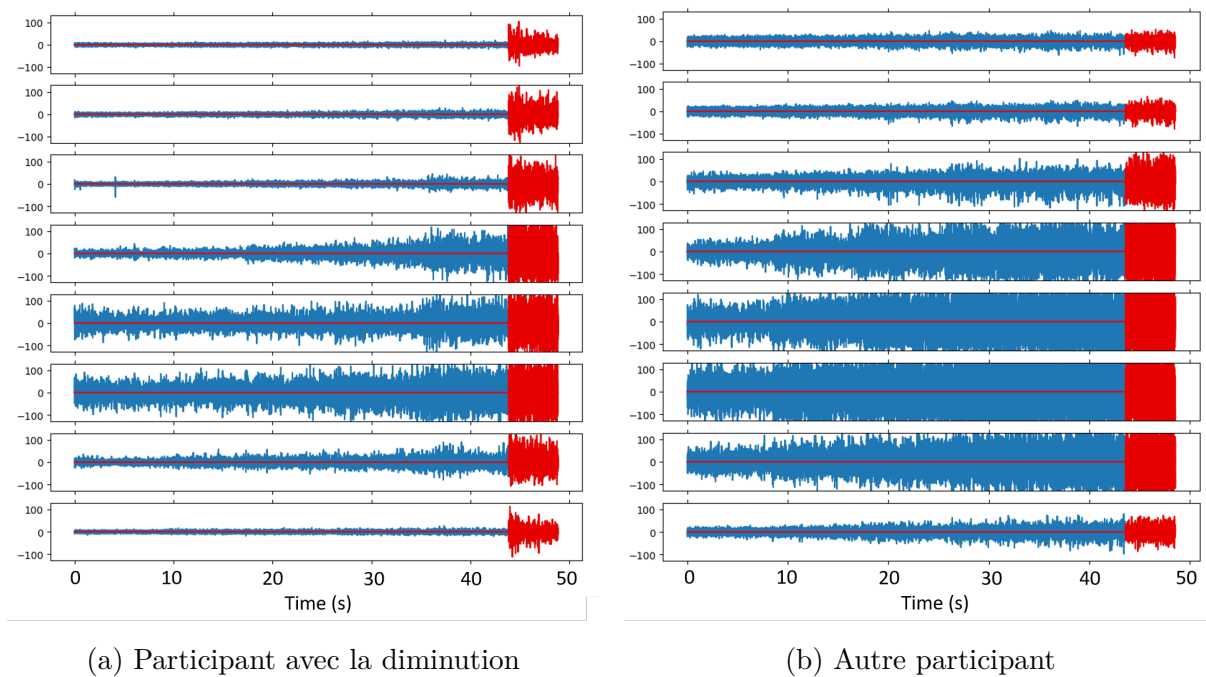


FIGURE 2.15 – Signal EMG brut des enregistrements des maxima, en rouge et des paliers, en bleu.

contraction du biceps, il y a bien une activité au niveau de l'antagoniste (Capteur 1 dans ce cas)

Une solution pour éviter ce genre de comportement serait de vérifier le niveau de co-contraction au moment de l'enregistrement des données et, si c'est au dessus d'un certain seuil, refaire l'étape en question.

### 2.3.3 Estimation de la direction (cf. Fig. 2.11)

#### 2.3.3.1 Conception

Pour estimer la direction de l'effort (de donc dans la plupart du temps la direction de l'intention du mouvement) souhaitée, nous utilisons un réseau de neurones artificiels. Ce réseau a été conçu pour séparer les données en quatre classes : repos, extension du coude, i.e. activation du triceps, flexion du coude, i.e. activation du biceps, et la co-contraction (voir Fig. 2.16). La co-contraction ne donne pas d'information sur la direction du mouvement mais elle a été prise en compte pour avoir un panel de toutes les actions possibles au niveau de l'articulation du coude (1 degré de liberté).

La quantité importante de données nécessaires aux réseaux de neurones afin de pouvoir généraliser représente un inconvénient. Nous cherchons à avoir un système facile à mettre

en place. Aussi, un temps d'enregistrement important pour la calibration irait à l'encontre de cet objectif. C'est pourquoi la spécification de la conception de notre système prend en compte un nombre faible de données et le risque de sur-apprentissage qui y est lié.

De manière similaire à [Gandolla et al., 2017], nous utilisons une fenêtre glissante qui sert d'entrée au réseau de neurones. A la différence de certaines autres approches de classification comme [Cerina et al., 2018] et [Phukpattaranont et al., 2018], il n'y a pas besoin de sélectionner et pré-calculer des caractéristiques du signal [Abbaspour et al., 2020]. Ce sont les couches de convolution qui remplissent cette fonction.

L'architecture du réseau qui a été retenue pour nos premières expériences est présentée sur la Fig. 2.17. Cette conception est inspirée des architectures utilisées en vision par ordinateur comme le "VGG Net" [Simonyan and Zisserman, 2014]. Les premières couches sont des couches de convolutions qui extraient des caractéristiques apprises lors de l'entraînement du réseau. Ensuite les couches de perceptrons (*fully connected layers*), font le tri dans les caractéristiques et les classifient. En vision par ordinateur les convolutions sont en deux dimensions, i.e. leur noyau est une matrice carrée. Dans notre cas, c'est-à-dire avec un signal qui varie au cours du temps, représenté sous forme d'une fenêtre de temps glissante, il est plus pertinent d'utiliser des convolutions à une dimension, i.e. que le noyau est un vecteur. Le traitement est parallélisé pour les huit capteurs du bracelet en partageant les couches de convolutions. L'intérêt est double : d'une part, cela réduit le nombre de poids dans le réseau, ce qui peut réduire le temps de calcul et le risque sur-apprentissage, et, d'autre part, il n'y a à priori pas de raisons d'extraire des caractéristiques différentes d'un capteur à l'autre.

La couche "*Drop out*" n'est active que lors de l'entraînement. Elle annule une proportion fixe de ses entrées de manière aléatoire. C'est aussi une mesure de protection contre le sur-apprentissage. En annulant des entrées de manière aléatoire cela évite que le réseau se repose trop sur certains poids pour faire sa classification, cela favorise la capacité à généraliser.

La couche "*Flattening*" sert à dimensionner la sortie des couches de convolutions pour convenir à la couche "*Fully connected*". Les données passent de deux dimensions à une dimension, d'où le terme "aplanir (*flatten*)".

Nous avons utilisé une fenêtre de trente échantillons<sup>2</sup>, soit 150ms compte tenu de la

---

2. Un échantillon correspond à une acquisition des 8 électrodes du bracelet

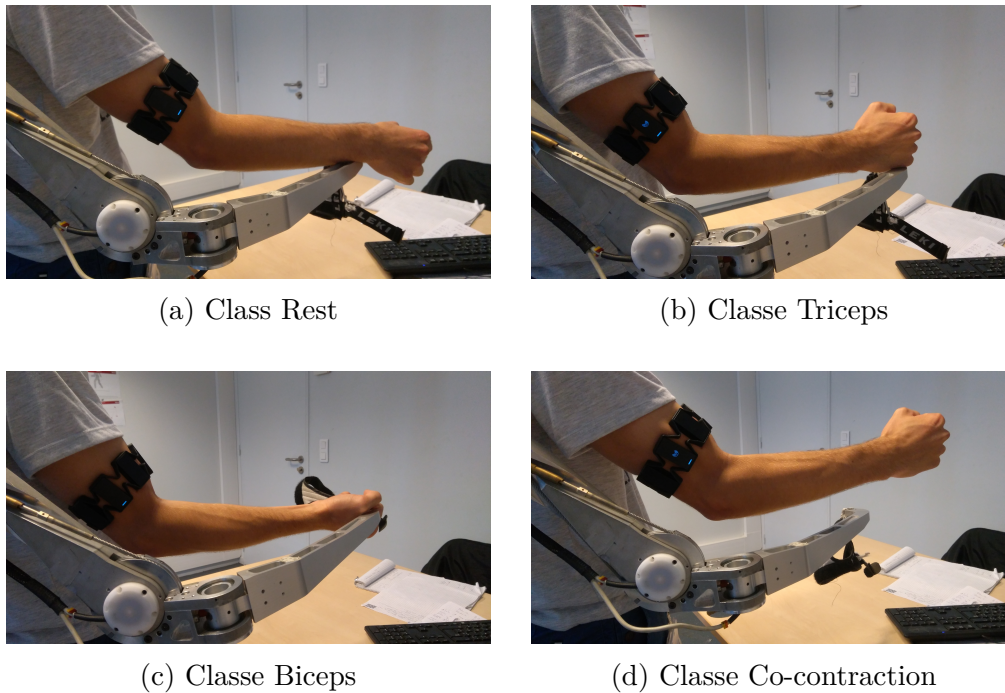


FIGURE 2.16 – Description des quatre classes

fréquence d'acquisition du bracelet (qui est 200Hz). Pour la création de la base de données, nous n'avons pas utilisé d'échantillons qui se superposent partiellement pour réduire le risque de sur-apprentissage.<sup>3</sup>

La base de données d'entraînement est construite à partir d'enregistrement de trente secondes de chaque classe par participant. Nous avons donc une base de données d'environ 800 échantillons pour chaque participant.

Le réseau est implémenté avec Keras [Chollet et al., 2015], une librairie python haut niveau pour l'apprentissage profond qui fonctionne en sur-couche de Tensorflow [Abadi et al., 2015]. L'optimiseur Adam est utilisée pour l'entraînement [Kingma and Ba, 2014], qui est l'un des plus performants à ce jour [Choi et al., 2019]. La fonction de coût est la "categorical cross-entropy" (eq. (2.14)). Les fonctions d'activation sont des "Rectified Linear Units" (ReLU) (eq. (2.12)) entre toutes les couches sauf la dernière qui a une activation "softmax" (eq. (2.13)). L'activation ReLU apporte une solution au problème du gradient qui se dissipe lorsque les couches sont nombreuses (*Vanishing gradient*). L'activation softmax crée une sortie qui peut être assimilée à un vecteur de probabilité (les éléments du vecteur sont compris entre 0 et 1 et leur somme vaut 1).

3. Le sur-apprentissage : le réseau a été capable d'apprendre exactement le set d'entraînement sans pour autant être capable de généraliser. Un indicateur peut être lorsque la précision sur le set d'entraînement est parfaite alors que la précision sur le set très mauvaise.

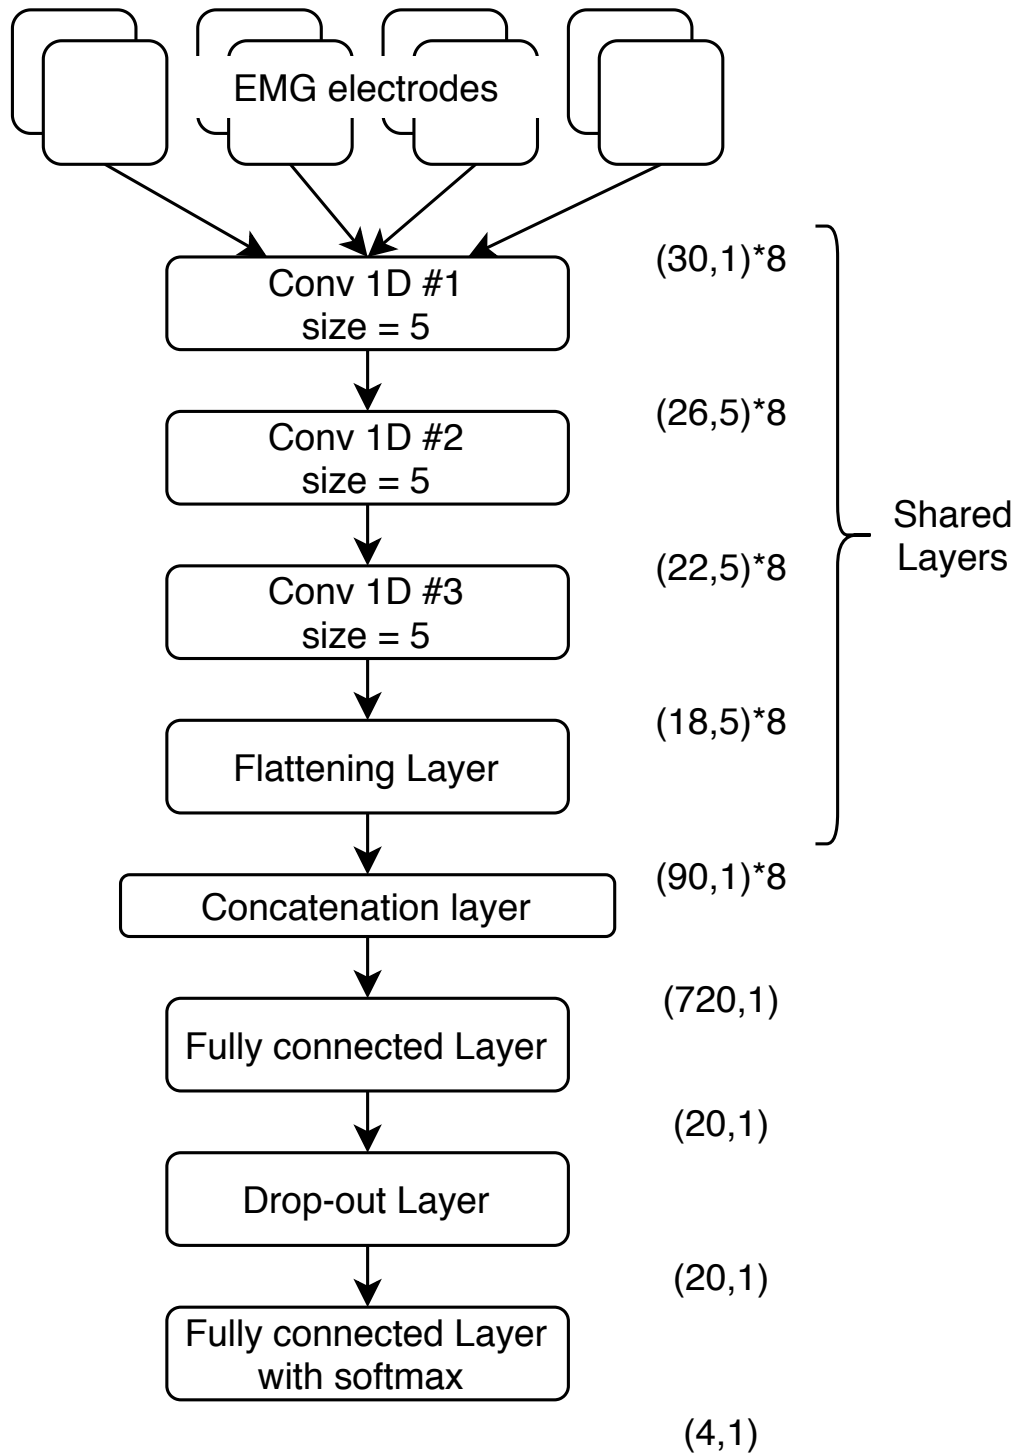


FIGURE 2.17 – Architecture du réseau de neurones pour l'estimation de la direction souhaitée à partir d'EMG (méthode mixte)

$$f_{ReLU}(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{else} \end{cases} \quad (2.12)$$

$$f_{softmax}(x_i) = \frac{e^{x_i}}{\sum_{c=1}^M e^{x_c}} \quad (2.13)$$

$$f_{loss}(p) = - \sum_{i=1}^M y_{o,i} * \log(p_{o,i}) \quad (2.14)$$

- $M$  est le nombre de classes
- $y$  est un indicateur binaire (0 ou 1) indiquant si le label  $i$  de la classe est correcte pour l'observation  $o$
- $p$  est la probabilité prédite que l'observation  $o$  soit de la classe  $i$

### 2.3.3.2 Comparaisons des variations

Différentes approches sont testées pour choisir l'architecture finale. Les variations consistent à tester la même architecture mais pour 3 classes différentes (en réunissant les classes repos et co-contraction dans une même classe) et en essayant deux types de couches finales : une règle softmax classique 2.13 ou une fonction de coût contrastive (CL, *Contrastive Loss* [Qi and Su, 2017]). L'idée d'explorer la situation où les classes Repos et Co-contraction sont réunies vient de la considération que les classes Triceps et Biceps sont les classes vraiment significantes et que les autres ne seraient que du bruit de fond. Avec ce point de vue nous nous rapprochons des problématiques de détection d'erreur et pouvons nous inspirer de leurs solutions. C'est de ce domaine que vient la CL.

L'utilisation initiale de la CL était destinée à la détection d'erreur, c'était donc un problème de classification à deux classes (les cas normaux et les erreurs) avec une abondance d'exemples des cas normaux et une variabilité importante des éléments la classe erreur qui est en général sous-représentée.

L'objectif de la CL n'est donc pas d'estimer des probabilités mais de trouver des caractéristiques de signal et un centre qui permet de séparer les données. Dans la situation à deux classes il n'y a qu'un seul centre, pour les cas normaux. Lors de l'apprentissage l'objectif est de rapprocher les cas normaux du centre de leur classe tout en éloignant les erreurs, d'où la fonction de coût :

$$f_{loss}(d) = y * d + (1 - y) * \max(\text{margin} - d, 0) \quad (2.15)$$

Où  $y$  est un indicateur binaire (0 ou 1) de l'appartenance à la classe normale,  $d$  la distance entre le centre et l'échantillon courant et  $\text{margin}$  est un paramètre qui permet d'éliminer les erreurs suffisamment éloignées.

Lors de l'utilisation, on calcule la distance euclidienne entre la sortie du réseau et le centre appris.

- Si la distance est inférieure à un certain seuil : c'est un cas normal
- Sinon c'est une erreur

Le réglage du seuil permet d'orienter le type d'erreur de classification (les faux positifs et les faux négatifs), en permettant de faire un compromis entre les deux facteurs de qualité d'une tâche de classification : le rappel (eq. (2.16)) et la précision (eq. (2.17)).

$$\text{Rappel} = \frac{TP}{(TP + FN)} \quad (2.16)$$

$$\text{Précision} = \frac{TP}{(TP + FP)} \quad (2.17)$$

Avec :

- TP, les vrais positifs, éléments correctement classifiés
- FP, les faux positifs, éléments estimés comme appartenant à la classe courante à tort.
- FN, les faux négatifs, éléments estimés comme n'appartenant pas à la classe courantes à tort (les oublis)

Nous pouvons étendre cette approche à plusieurs classes. Pour cela on désigne une classe qui sera considérée comme les "erreurs", que l'on appellera classe par défaut (Repos ou Repos + Co-contraction dans notre cas). Et nous utilisons un centre pour chaque autre classe. Cela nous donne un fonction coût calculée de la manière suivante :

$$\begin{cases} f_{lossCi}(d_{Ci}) = y_{Ci} * d_{Ci} + (1 - y_{Ci}) * \max(\text{margin} - d_{Ci}, 0) \\ f_{loss}(d_{Ci}) = \frac{1}{N - 1} * \sum_{i=1}^{N-1} f_{lossCi}(d_{Ci}) \end{cases} \quad (2.18)$$

Où  $y_{Ci}$  est un indicateur binaire (0 ou 1) de l'appartenance à la classe  $i$ ,  $d_{Ci}$  la distance



entre le centre de la classe  $i$  et l'échantillon courant,  $N$  est le nombre de classes (y compris la classe par défaut) et  $margin$  est un paramètre qui permet de discriminer si les éléments de la classe par défaut sont suffisamment éloignées. Dans ce cas le réseau a pour sortie  $d$  qui est le vecteur contenant toutes les distances  $d_{Ci}$ .

On détermine la classe de l'échantillon grâce à  $d_{Cj} = \min(d_{Ci})$  :

- Si  $d_{Cj} < T_{seuil}$  alors l'échantillon est de la classe  $j$ ,
- Si  $d_{Cj} > T_{seuil}$  alors l'échantillon fait partie de la classe par défaut.

Pour chaque participant de l'évaluation section 2.4 nous avons entraîné et testé les différentes variantes de modèles ainsi qu'une approche plus classique qui consiste à extraire des caractéristiques pré-définies et les classer grâce à une machine à vecteur de support (Support Vector Machine, SVM). Les caractéristiques possibles étant très nombreuses [Abbaspour et al., 2020], nous avons choisi d'utiliser les mêmes que celles de l'étude [Mendez et al., 2017] : *Waveform Length* (WL), *Mean Absolute Value* (MAV), *Wilson Amplitude* (WAMP), *Cardinality* (CARD), *Slope Sign Changes* (SSC) et *Zero Crossings* (ZC). Les calculs de ces caractéristiques sont présentés en annexe B.

Les résultats sont présentés dans le tableau 2.2. Les chiffres 3 et 4 réfèrent au nombre de classe utilisées. *Soft* et *CL* réfèrent à la méthode employée pour la classification, *softmax* et *contrastiveloss* respectivement. Les différentes approches présentent des résultats similaires sauf en ce qui concerne *Soft3* qui non seulement a une performance plus faible mais aussi un écart type bien plus élevé. La précision moyenne en pourcentage est indiquée pour les sept personnes ayant participé à la première étude. Des résultats plus détaillés avec plus de participants sont présentés dans la section 4.1.

### 2.3.3.3 Entraînement

Pour entraîner et tester les réseaux présentés dans la section précédente, nous avons enregistré deux échantillons de 30 secondes par classes, un pour la base de données d'entraînement et l'autre pour la base de données de test.

TABLE 2.2 – Comparaisons de la précision des différentes architecture

Méthode	Soft3	Soft4	CL3	CL4	SVM4
Moyenne	91,5	96,4	96,9	97,3	98,7
écart-type	10,4	3,6	3,3	2,8	2,4

La procédure d'enregistrement est la suivante, réalisée deux fois, avec du repos entre chaque étape :

- 30 secondes de contraction du biceps avec des intensités variées (voir sec. 2.3.2.3)
- 30 secondes de contraction du triceps avec des intensités variées (voir sec. 2.3.2.3)
- 30 secondes de repos
- 30 secondes de co-contraction à intensités variées

La Table 2.3 permet de voir les résultats de l'apprentissage en terme de précision, calculée avec eq. (2.19) pour les sept participants. Pour l'entraînement et le calcul de la précision pour chaque participant, nous avons utilisé leurs propres données d'apprentissage et de test respectivement. Nous avons obtenu une précision moyenne de  $96.9 \pm 3.1\%$ . Pour cette évaluation le placement du bracelet est le même lors de l'enregistrement des données de test et des données d'apprentissage.

$$Prec = \frac{1}{N_{classes}} * \sum_{i=1}^{N_{classes}} \frac{n_{true\_positive,i}}{n_{true\_positive,i} + n_{true\_negative,i}} \quad (2.19)$$

Où  $n_{true\_positive,i}$  est le nombre d'échantillons de la classe  $i$  correctement classés,  $n_{true\_negative,i}$  est le nombre d'échantillons classés comme étant de la classe  $i$  à tort et  $N_{classes}$  est le nombre de classes.

TABLE 2.3 – Précisions (eq. (2.19)) obtenues avec les sets de test pour chaque participant avec l'architecture Soft4

Personne	1	2	3	4	5	6	7
Précision	0.999	0.969	0.992	0.928	0.999	0.924	0.974

### 2.3.4 Fusion

Le bloc Fusion (Cf. Fig 2.11) combine les résultats de l'estimation et de la classification pour estimer l'intention de l'utilisateur. Le principe est d'utiliser le résultat de la classification pour sélectionner le set de paramètres à utiliser comme suit :

- Si la classe est le repos ou la co-contraction : alors l'intensité est nulle
- Si la classe est l'activation triceps : l'intensité est alors calculée avec les paramètres du triceps

- Si la classe est l'activation biceps : l'intensité est alors calculée avec les paramètres du biceps

La classe co-contraction n'est pas exploitée. Néanmoins, nous gardons cette classe pour deux raisons. La première est que, avec une approche utilisant un réseau de neurones, il est préférable d'éviter de garder des situations non traitées. En effet, si celle-ci n'était pas incluse dans l'entraînement nous n'aurions pas la possibilité de prévoir le résultat si le classificateur la rencontrait pendant l'utilisation. Ensuite, bien que nous ne l'exploitions pas ici, la co-contraction pourrait servir dans certains cas, par exemple pour changer de mode de contrôle.

## 2.4 Évaluation

### 2.4.1 Protocole

Sept personnes ont participé à la première expérience. Il y avait six hommes et une femme, âgés de 20 à 35 ans.

Les étapes d'enregistrement des données de calibration des sections 2.3.3 et 2.3.2, ont été fusionnées : les données d'entraînement des classes Repos et Co-contraction sont enregistrées sur une base volontaire. Pour les classes Biceps et Triceps nous reprenons les données de calibration du modèle (voir section 2.3.2.3), cela permet d'avoir un panel exhaustif des cas possibles pour ces classes. La calibration nécessite donc trois minutes d'enregistrement.

Pour évaluer le système de détection, chaque candidat doit appliquer des couples variés sur le bout du bras de l'exosquelette. Le robot est contrôlé en position de la même manière que pour l'enregistrement des maxima (cf. section 2.3.2.3). Les participants forcent librement contre l'exosquelette dans les deux directions pendant une minute.

### 2.4.2 Résultats

Sur la Fig. 2.20a les données avant fusion d'un participant sont présentées. La classe est choisie en prenant la classe la plus probable d'après le classificateur, sans seuillage sur la probabilité estimée. Nous pouvons voir que sur la courbe représentant la classe (en vert) il y a beaucoup de commutations lors des transitions entre les efforts vers le haut et

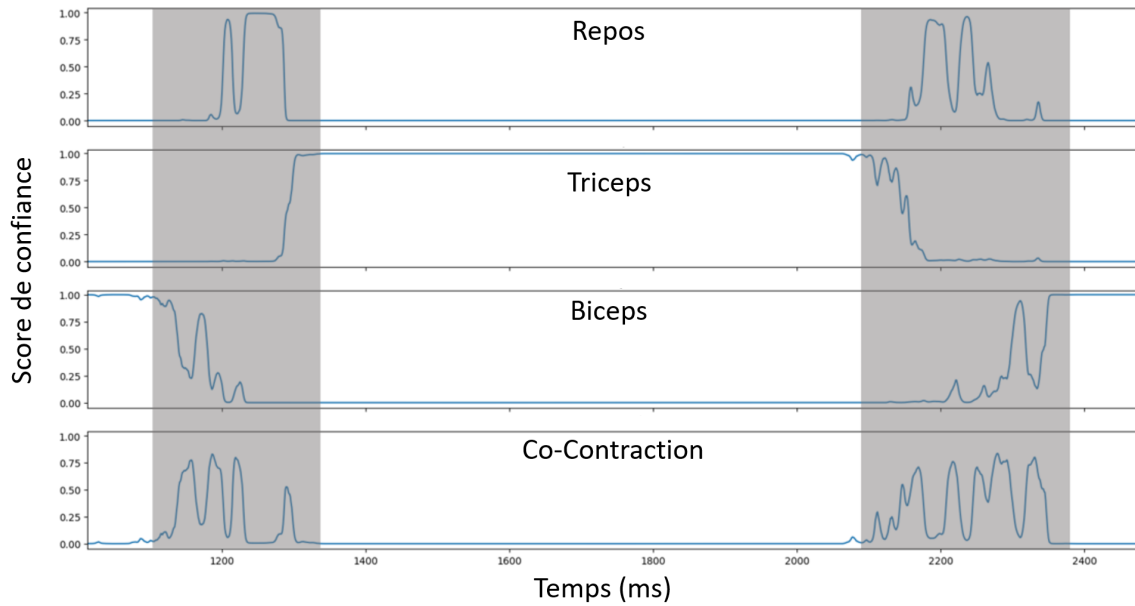


FIGURE 2.18 – Evolution du score de confiance pendant les transitions

les efforts vers le bas. Sur la Fig. 2.18, nous pouvons voir l'évolution de la sortie Softmax du réseau de neurones au cours de deux transitions (zones grisées). Nous pouvons voir que les scores de confiance lors des commutations sont proches les uns des autres. Le choix de la classe en fonction de la valeur maximale conduit à ces commutations intempestives.

Cela peut être expliqué par la méthode de construction de la base de données d'entraînement. En effet nous nous sommes attachés à représenter un panel exhaustif des possibilités pour chaque classe en faisant varier les intensités. Pour des intensités basses les différences entre les classes se réduisent. Par exemple une co-contraction de très faible intensité présente un signal très proche d'une activation biceps ou même d'un état de repos. De plus, les échantillons d'entraînement n'intègrent pas de phases de transition mais uniquement des phases à effort constant. Ainsi, le réseau ne rencontre pas de situation de transition lors de son entraînement (par exemple, des échantillons pour lesquels la première moitié serait du repos et la seconde de la contraction biceps). Nous ne pouvons donc pas prédire le comportement du réseau en présence d'une transition. Cela renforce l'intérêt de garder la taille de la fenêtre glissante aussi réduite que possible pour limiter le délai de transition.

Pour stabiliser la classification nous pouvons envisager plusieurs solutions. Une solution serait de considérer une des classes comme l'état par défaut (la classe repos dans notre cas) et utiliser un seuillage sur la probabilité estimée pour confirmer un changement





FIGURE 2.19 – Comparaison de la classe dominante avec différentes méthodes de stabilisation : MAX, SEUIL et FILTRAGE (les ordonnées représentent la classe choisie : 0 = repos, 1 = Triceps, 2 = Biceps, 3 = Co-contraction)


de classe. Une alternative serait d'utiliser une approche similaire à un filtre moyennant : plutôt que de considérer uniquement l'estimation courante nous utiliserions les  $n$  dernières estimations. La classe courante serait alors la plus représentée dans cet historique. Cependant, cette approche introduirait un déphasage et donc un retard de détection.

Sur la Fig. 2.19, nous comparons la classe obtenue avec différentes approches de traitement de la sortie du réseau. Le premier graphe correspond à la méthode utilisée lors de l'évaluation qui consiste simplement à retenir la classe avec le score de confiance maximal (MAX). Le second graphe est obtenu en effectuant un seuillage sur le score de confiance. Dans ce cas il faut choisir une classe qui doit être la classe "par défaut", lorsque aucune classe ne dépasse le seuil (ou bien définir un nouvel état). Nous avons choisi la classe "repos" comme étant la classe par défaut et un seuil de 85%. Cela veut dire que le réseau doit être sûr à plus de 85% qu'une classe est la bonne pour valider le choix (SEUIL). Enfin, le troisième graphe correspond à un filtrage médian sur une fenêtre de 15 échantillons. La classe choisie est celle ayant eu le plus de meilleur score de confiance sur les 15 derniers choix (FILTRAGE). Nous pouvons voir que ces deux approches tendent à réduire les hésitations au moment des transitions.

Le résultat fusionné de ce même participant est présenté sur la Fig. 2.20b. Une erreur de



(a) Données pré-fusion, en bleu le couple articulaire mesuré, en rouge et cyan le couple estimé à partir du signal EMG (respectivement avec les paramètres du biceps et ceux du triceps), et en vert la classe la plus probable (0 = repos, 1 = triceps, 2 = biceps, 3 = co-contraction)



(b) Données fusionnées, en bleu le couple de l'actionneur, en rouge le couple estimé à partir du signal EMG

FIGURE 2.20 – Résultats de l'évaluation pour un participant

classification pourrait générer un erreur importante et des discontinuités dans l'estimation de l'intensité. C'est pourquoi le rôle du classificateur est crucial. Nous pouvons voir que la faiblesse de la classification réside autour des mouvements d'intensité faible, nous pouvons voir que les zones de fortes variations de la classification sur la classification de la Fig 2.20a ont conduit à des discontinuités sur la Fig. 2.20b.

Dans le tableau 2.4, nous avons calculé les erreurs RMS pour chaque participant entre le couple estimé et le couple articulaire du coude, appliqué à l'exosquelette. Nous avons calculé les erreurs RMS de force équivalente en bout de bras pour obtenir des valeurs plus faciles à interpréter, nous avons donc une erreur équivalente à un un kilogramme en bout de bras ( $8.7 \pm 1.9N$ ).

TABLE 2.4 – Erreurs obtenues au cours de l'expérience d'évaluation

Participant	1	2	3	4	5	6	7
RMS $\tau_{motor}$ (N.m)	0.037	0.062	0.042	0.039	0.062	0.048	0.043
RMS $F_{endeffector}$ (N)	6.8	11.4	7.6	7.1	11.3	8.7	7.9
$\tau_{motor}$ Max (N.m)	0.414	0.264	0.398	0.211	0.254	0.472	0.417

## **2.5 Conclusion**

Dans cette première étude nous avons mis au point et évalué un système de détection d'intention basé EMG. Nous nous sommes concentrés sur des problématiques de facilité de mise en place pour prendre en compte la dimension industrielle de l'application considérée. Le système doit être calibré pour chaque utilisateur et cette calibration dure trois minutes. L'intention de l'utilisateur est estimée sous la forme d'un couple signé.

Nous avons deux objectifs pour poursuivre nos travaux. Le premier est de mettre au point une loi de commande pour l'exosquelette basée sur ce système de détection d'intention pour assister une tâche de lever de charge. Ensuite, pour améliorer l'aspect de la mise en place de ce système nous allons explorer des solutions pour réduire le temps nécessaire à la calibration.

# Étude 2 : Assistance au port de charges

## Sommaire

<b>3.1</b>	<b>Commande des exosquelettes</b>	<b>67</b>
3.1.1	Méthodes basées modèle	67
3.1.2	Méthodes basées bio-sigaux	68
3.1.3	Méthodes basées signaux physiques	69
3.1.4	Méthodes hybrides	69
3.1.5	Synthèse	70
<b>3.2</b>	<b>Commande par intégration</b>	<b>70</b>
3.2.1	Principe et analyse	70
3.2.2	Application aux bras de type BHV2	73
<b>3.3</b>	<b>Évaluation</b>	<b>74</b>
3.3.1	Protocole	75
3.3.2	Résultats et discussion	76
<b>3.4</b>	<b>Conclusion</b>	<b>86</b>

Dans ce chapitre nous présentons notre stratégie d'assistance au port de charges. Notre objectif est de fournir une compensation complète de la charge et permettre aux muscles supportés d'atteindre un état de repos, c'est-à-dire un comportement similaire à la compensation de gravité. Nous commençons par présenter l'état de l'art concernant la commande des exosquelettes. Nous analysons les avantages et limitations de ces différentes approches afin de proposer une loi de commande permettant de pallier à certaines de ces limitations et qui utilise le module présenté dans le chapitre 2. Nous évaluons ensuite notre approche de commande par intégration en utilisant deux situations de contrôle : sans assistance (NoExo), et avec assistance par compensation classique du modèle de gravité (CG).



Une partie des travaux présentés dans ce chapitre ont fait l'objet de la publication  
[Treussart et al., 2020]

## 3.1 Commande des exosquelettes

Nous passons en revue les différentes stratégies de commande des exosquelettes existantes. Nous nous intéressons principalement à la situation d'augmentation des capacités d'un utilisateur ayant toutes ses capacités motrices. Nous pouvons séparer les stratégies de contrôle en trois catégories : les méthodes basées modèle, les méthodes basées bio-sinaux et les méthodes basées signaux physique.

### 3.1.1 Méthodes basées modèle

Il s'agit d'utiliser un modèle dynamique de l'exosquelette pour séparer les effets des composants du robot (en particulier les actionneurs) et les perturbations extérieures. Le robot est ensuite contrôlé seulement en utilisant les informations sur son état (positions, vitesses, accélérations). BLEEX (*Berkeley Lower Extremity Exoskeleton*) est un exemple de commande d'exosquelette basé sur un modèle. Il a été présenté en 2004 [Kazerooni et al., 2005] et c'est le premier exosquelette d'assistance au port de charge, autonome en énergie et fonctionnel. BLEEX est un exosquelette de membre inférieur avec sept degrés de liberté par jambe qui peut porter jusqu'à 75 Kg. Le système de contrôle a une sensibilité élevée aux perturbations extérieures. Cette approche est à l'opposé des stratégies habituelles qui consistent à minimiser cette sensibilité. L'idée est que ces perturbations extérieures proviennent de l'interaction entre le robot et l'utilisateur. Cette approche présente deux inconvénients majeurs. D'une part, il est nécessaire que le modèle dynamique du robot soit très précis, ce qui peut être complexe car certains paramètres doivent être estimés expérimentalement. D'autre part, le système réagirait aussi à des perturbations ne provenant pas de l'utilisateur, entraînant des problèmes de stabilité du système.

Le premier problème à été adressé en utilisant un contrôle dépendant de la phase de marche [Kazerooni et al., 2006], qui alterne entre jambe statique et jambe en mouvement (*stance leg* et *swing leg*).

Comme ces méthodes n'utilisent pas de capteurs permettant d'avoir des informations sur l'environnement de l'exosquelette, les évaluations des interactions avec l'environnement se font par l'estimation des perturbations extérieures. Du point de vue du contrôle cela impose deux choses : (i) le modèle doit être précis pour que l'estimation des perturbations le soit aussi, et (ii) pour contrôler le robot en fonction de ces perturbations

il faut être capable d'envisager toutes les sources possibles et de concevoir le comportement adéquat en réponse à l'avance. Si certaines sources de perturbations ne sont pas envisagées alors le comportement peut être inadéquat (cf ci-avant : le risque d'instabilité de BLEEX).

### 3.1.2 Méthodes basées bio-signeaux

Une partie importante des travaux de commande des exosquelettes à l'aide de bio-signeaux concerne la rééducation ou le regain de mobilité (voir paragraphe 1.3.2.5). Les signaux utilisés sont principalement les EEG et les EMG (section 1.3.4). Les EEG ne sont en général pas considérés pour des applications à destination de personnes valides. Ces signaux sont plus difficiles à exploiter et les capteurs sont potentiellement moins pratiques à mettre en place si on compare avec les signaux EMG. Dans le cadre de l'augmentation d'effort à l'aide de signaux EMG, une stratégie de commande classique est le contrôle proportionnel. Il est utilisé ainsi notamment dans la commande de l'exosquelette HAL [Kawamoto and Sankai, 2005]. Il s'agit de mesurer l'activité électrique des muscles fléchisseurs et extenseurs d'une articulation  $E(t)$  calculée à partir du signal EMG  $u$  sur une fenêtre de temps  $T$  telle que :

$$E(t) = \sqrt{\frac{1}{T} \int_{t-T}^t u^2(t).dt} \quad (3.1)$$

Le couple de contrôle est ensuite calculé comme suit :

$$\tau_{cons} = \alpha * (\hat{\tau}_{flex} - \hat{\tau}_{ext}) \quad (3.2)$$

$$avec \quad \hat{\tau} = a * E(t) + b \quad (3.3)$$

où  $a_{flex}$ ,  $a_{ext}$ ,  $b_{flex}$ ,  $b_{ext}$  sont des paramètres de conversion et  $\alpha$  est le gain du contrôleur.

Ce type d'approche permet d'obtenir des informations sur les actions ou les intentions de l'utilisateur. Avec ces informations nous pouvons envisager de concevoir des stratégies de commande qui s'adaptent au besoin de l'utilisateur en temps réel. Cependant, les bio-signeaux varient d'un individu à l'autre et imposent donc de calibrer le système pour chaque utilisateur.

### 3.1.3 Méthodes basées signaux physiques

Les capteurs d'efforts sont une solution répandue pour la commande de robot en interaction avec l'homme. On parle de commande en impédance ou en admittance en fonction de l'objectif, en impédance si on veut que le robot guide l'humain ou en admittance pour le contraire. La commande en impédance est plutôt utilisée lorsque la trajectoire à suivre est connue. Ce type de commande peut être utilisée avec des guides virtuels ou bien un évitement de zone dangereuse. La commande en admittance reçoit un effort et retourne une position ou une vitesse. C'est la commande utilisée en général pour générer un comportement "transparent" avec des robots équipés d'un capteur d'effort [Lamy, 2011]. L'utilisation la plus directe pour le capteur d'effort est d'y fixer une poignée que l'utilisateur vient saisir. L'inconvénient majeur de cette approche est qu'il n'y a plus de contact direct entre l'opérateur et la charge, la préhension doit alors être assurée par l'exosquelette. Cela peut être avec un crochet multi-usage comme l'exosquelette Sarcos, ou bien un préhenseur spécialement conçu pour la tâche [Yu et al., 2018] (voir Fig. 3.1). Dans le cas où l'exosquelette est, comme le bras humain, redondant, des capteurs d'efforts supplémentaires peuvent permettre de suivre correctement la position du coude. Dans les travaux de [Miller and Rosen, 2010], qui compare l'efficacité du contrôle en admittance dans l'espace articulaire et dans l'espace cartésien, il y a un exemple d'une telle stratégie pour suivre fidèlement le bras humain.




FIGURE 3.1 – Exemple de poignée (a) avec préhenseur spécialisé (b) [Yu et al., 2018]

### 3.1.4 Méthodes hybrides

Il existe aussi des méthodes hybrides, mêlant par exemple capteurs EMG et capteurs d'efforts comme dans les travaux de [Gopura and Kiguchi, 2012]. Dans ces travaux l'ap-

plication envisagée est l'assistance d'une personne avec une faiblesse physique au niveau du membre supérieur. Les capteurs d'efforts sont utilisés pour prendre le relais lorsque le signal EMG devient trop faible.

### 3.1.5 Synthèse

Nous souhaitons assister un utilisateur à porter des charges à l'aide d'un exosquelette de membres supérieurs. Nous partons du principe que nous ne connaissons pas la masse de la charge et nous nous plaçons dans le cadre d'une manipulation directe par l'opérateur (et non via une interface de préhension sur l'exosquelette). Dans ce contexte, les méthodes basées modèle uniquement ne semblent pas adaptées. Les autres types de méthodes sont intéressantes (bio-sinaux et signaux physiques), néanmoins, si les informations des capteurs d'efforts sont très utiles, la conception des capteurs d'efforts aujourd'hui ne permet pas une manipulation directe de la charge (car trop volumineux). C'est pourquoi nous nous sommes concentrés sur une méthode basées bio-sinaux, malgré la nécessité de calibration pour chaque nouvel utilisateur.

## 3.2 Commande par intégration

### 3.2.1 Principe et analyse

Notre objectif est de développer une loi de commande qui se comporterait de la même manière qu'une compensation de gravité (CG). L'objectif est de fournir une compensation complète de la charge et permettre aux muscles soutenus d'atteindre un état de repos, à la différence d'un contrôle de type proportionnel qui réduirait l'effort mais nécessiterait tout de même de maintenir une activité musculaire spécifique [Lenzi et al., 2011, 2012].

Le port de charge assisté par un exosquelette peut être représenté sous la forme d'une boucle de commande (cf. Fig 3.2). Il s'agit d'une boucle de commande en effort dans laquelle la consigne  $F_{des}$  correspond à l'activité musculaire désirée (dans notre cas  $F_{h,des} = 0$ ).  $\tau_{cons}$  est le couple de contrôle appliqué par l'exosquelette.  $F_{inter}$  correspond aux forces d'interactions entre l'utilisateur et le robot.  $V_{muscles}$  est le signal myoélectrique généré par l'activité musculaire et mesuré par le bracelet Myo. Le système que nous voulons contrôler est la paire utilisateur/exosquelette, dans cette paire c'est l'utilisateur qui saisit la charge

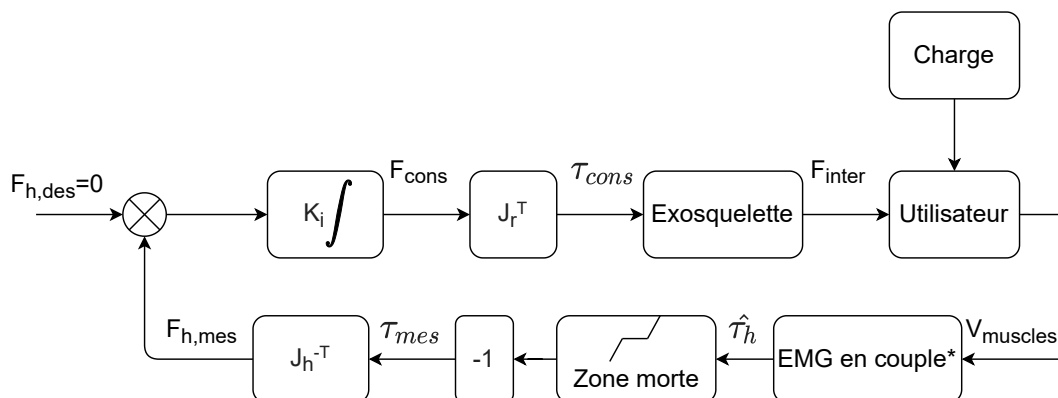


FIGURE 3.2 – Boucle de commande de la méthode proposée.

\*bloc contenant Fig. 2.11

directement avec ses mains.

Pour commander cette paire nous avons choisi d'utiliser une commande par intégration. Le correcteur intégral est largement utilisé en commande en effort, il permet à la fois de compenser la gravité et les frottements, ainsi que de réduire l'inertie [Geffard et al., 2000, Williams and Khatib, 1997].

Dans la suite de ce paragraphe, nous considérerons que :

- le poignet de l'utilisateur n'est pas assisté (ceci est en particulier le cas lorsque l'utilisateur prend la charge directement, et que la liaison humain/exosquelette se fait au niveau du poignet). Ceci signifie qu'uniquement les forces au niveau du poignet sont assistées, et que les moments n'ont pas à être commandés.
- les moments du torseur d'interaction entre l'exosquelette et le poignet de l'utilisateur sont annulés par le fait que la liaison poignet est de type rotule passive (ex. : utilisation d'une dragonne).
- l'exosquelette et le bras humain ont des cinématiques identiques et sont parfaitement synchronisés (notamment le centre de rotation de l'épaule de l'exosquelette est superposé au centre de rotation de l'épaule humaine)
- nous disposons de suffisamment de mesures EMG pour estimer parfaitement les couples de l'épaule et le couple en flexion du coude. C'est à dire que  $F_{mes} = -F_h$ .

Dans le chapitre 2, nous avons vu que les interactions homme-exosquelette peuvent être représentées par les équations 2.1. En faisant l'hypothèse que nous étions en régime quasi-statique, et en décomposant le couple  $\tau_r$  appliqué sur les actionneurs du robot, de la façon suivante :

$$\tau_r = \tau_{rc} + Q_r(\Theta_r) + \tau_{FNL} + b_r \dot{\Theta}_r \quad (3.4)$$

D'où le couple sur les articulation de l'utilisateur :

$$\tau_h = -\tau_{rc} - J_h^t F_e + Q_h(\Theta_h) \quad (3.5)$$

Dans lequel le couple  $\tau_{rc}$  est notre variable de commande. Dans le cas d'un correcteur intégral :

$$\tau_{rc} = J_r^t \cdot \frac{K}{s} (F_{h,des} - F_{mes}) \quad (3.6)$$

Dans notre cas  $F_{h,des} = 0$  et  $F_{mes} = -F_h$  (cf. hypothèses). Et en choisissant un même gain intégral pour toutes les directions, tel que  $K_i = \frac{k_i}{s} \times I_3$ <sup>1</sup>, on obtient :

$$\begin{cases} \tau_h = \frac{s}{k_i + s} \times I_3 \times (-J_h^t F_e + Q_h(\Theta_h)) \\ \tau_{rc} = \frac{k_i}{k_i + s} \times I_3 \times (-J_h^t F_e + Q_h(\Theta_h)) \end{cases} \quad (3.7)$$

D'où les valeurs statiques après convergence : :

$$\begin{cases} \lim_{s \rightarrow 0} \tau_h = 0 \\ \lim_{s \rightarrow 0} \tau_{rc} = -J_h^t F_e + Q_h(\Theta_h) \end{cases} \quad (3.8)$$

Ce qui signifie que, alors qu'il transporte la charge de masse inconnue, l'utilisateur n'a plus à fournir d'effort du tout ( $\tau_h = 0$ ), car le couple de commande  $\tau_{rc}$  compense totalement l'effort extérieur  $F_e$ , et même le poids du bras de l'utilisateur  $Q_h$ .

Bien que l'utilisation d'une zone morte soit courante en contrôle en effort, elle n'est pas représentée en général. Cependant, dans notre cas le bloc de la zone morte est représenté car il s'agit d'un paramètre d'ajustement important. Il permet une utilisation plus efficace du signal EMG avec le correcteur intégral (que nous appellerons DZ-I par la suite, pour Dead Zone Integrator).

Du fait des caractéristiques mentionnées précédemment, le correcteur DZ-I présente ainsi l'avantage de filtrer certaines erreurs du système de détection d'intentions. C'est d'un intérêt crucial dans notre cas, puisque que le système mis au point dans le chapitre

1.  $I_3$  est la matrice identité de taille  $3 \times 3$

2 est moins fiable à faible intensité (voir section 2.4). La zone morte permet d'absorber ce type d'erreur. De plus, si il y a des erreurs isolées avec des intensités plus fortes elles sont absorbées par l'effet de l'intégration.

### 3.2.2 Application aux bras de type BHV2

Du point de vue de la commande, le robot BHV2 est un robot plan avec 2 articulations couplées. La matrice jacobienne est donc une matrice  $3 \times 2$ . Cet exosquelette est principalement dédié au port de charge. Le couplage permet de limiter le nombre de moteurs, et est réglé de façon à ce que la force produite soit principalement verticale lorsque l'avant-bras est à l'horizontal. En ce qui concerne la mesure, nous avons fait le choix de mesurer uniquement le couple du coude de l'utilisateur. Ce qui nous donne une bonne image de la force verticale appliquée lorsque le bras est à environ  $45^\circ$  et l'avant-bras est horizontal (position initiale). Comme pour l'exosquelette, dans cette position, le couple de flexion de l'épaule ne nous apporterait pas plus d'informations (couplage linéaire). Néanmoins, afin d'asservir uniquement l'effort vertical, qui est la seule direction pour laquelle nous avons une bonne mesure dans la position initiale, il est nécessaire de multiplier l'erreur d'asservissement par une matrice de sélection ou un projecteur en effort (Cf. commande hybride position/force [Raibert and Craig, 1981, Perdereau, 1991] ou les projecteurs orthogonaux [Joly, 1997, Fisher and Mujtaba, 1992]). Dans notre cas, nous pouvons nous permettre d'utiliser une matrice de sélection  $S = [0 \ 0 \ 0; 0 \ 1 \ 0; 0 \ 0 \ 0]$ , car tout risque d'instabilité cinématique est évité par l'élimination des couplages en effort via la l'utilisation de dragonnes et du fait de la simplicité de la tâche (gravité toujours verticale).

Le dernier problème est celui de l'utilisation d'un mécanisme cinématiquement contraint, pouvant conduire à un nouveau risque d'instabilité cinématique lors de l'utilisation d'une matrice de sélection sur la boucle d'effort [Zemiti, 2005]. En effet, nous ne respectons pas la condition  $J = SJ$  [Zemiti, 2005] et donc un contact encastré avec une telle matrice de sélection sur la boucle d'effort pourrait induire une instabilité (en effet,  $F_z$  ne peut pas être commandé de façon indépendante de  $F_x$  et  $M_y$ ). Néanmoins, dans notre cas, la cinématique de l'utilisateur compatible avec celle de l'exosquelette, plus l'utilisation des dragonnes, font que les composantes  $F_x$  et  $M_y$  sont nulles, et éliminent donc ce dernier risque.

Le contrôleur DZ-I est particulièrement intéressant dans le cadre d'une utilisation avec



un système robotique réversible. En effet, dans le cas d'assistance au port de charges, lorsque le poids de la charge est compensé (cf équation 3.8), il reste seulement les forces inertielles, les frottements étant faibles par conception (cf. section 2.1.1). Donc, si le seuil de la zone morte est réglé à une valeur suffisamment grande, la charge peut être déplacée sans que le couple d'assistance soit modifié. Le comportement sera donc similaire à une CG classique.

---

**Algorithm 1** Mise à jour de l'assistance
 

---

```

 $F_{cons} \leftarrow 0$ 
while assisting do
  if  $class == triceps$  and  $intensity > threshold$  then
     $F_{cons} \leftarrow F_{cons} - K * (intensity - threshold)$ 
  else if  $class == biceps$  and  $intensity > threshold$  then
     $F_{cons} \leftarrow F_{cons} + K * (intensity - threshold)$ 
  else
     $F_{cons} \leftarrow F_{cons}$ 
  end if
end while

```

---

Le contrôleur DZ-I a deux paramètres à régler (voir algorithme 1) :  $K$  qui est le gain d'intégration et  $threshold$ , le seuil de la zone morte. L'intégration est faite sur la valeur de  $(intensity - threshold)$  plutôt que  $intensity$  pour permettre une évolution plus progressive du couple d'assistance. La valeur de  $threshold$  influence l'intensité des mouvements possibles, sans que l'assistance soit modifiée, et les oscillations autour du couple nul. Cependant, une valeur trop élevée introduirait une erreur statique importante.

D'autre part, dans le cas de l'exosquelette BHV2, contrairement à un exosquelette qui longe le corps, on n'a pas  $J_h^t = J_r^t$ , et nous n'avons pas de capteurs sur l'humain permettant de la calculer. Nous considérons (i) une situation de port de charges et que (ii) l'équilibrage de la charge se fait au début du mouvement, lorsque l'utilisateur s'est peu éloigné de sa position initiale. Nous faisons donc l'approximation que  $J_h^t$  est constant. En effet, une fois la charge compensée l'effet de la zone morte prévient la modification de l'assistance pendant les mouvements de faible intensité.

### 3.3 Évaluation

### 3.3.1 Protocole

Nous avons mis en place un protocole expérimental pour évaluer la stratégie de commande. Dix personnes ont participé à cette expérience (8 hommes and 2 femmes, âgés de  $27.8 \pm 11.6$  ans,  $176 \pm 8$  cm et  $78 \pm 17$  kg).

Tous les participants ont donné leur consentement éclairé pour prendre part à cette étude (voir formulaire E.4).

Les participants doivent soulever et abaisser une charge de 5 kg plusieurs fois. La vitesse d'exécution est laissée libre et il y a trois situations différentes : sans assistance (No-Exo), avec notre stratégie d'assistance (DZ-I) et avec la compensation par modèle de gravité classique (CG).

Les participants sont équipés de sept capteurs EMG (DataLite, Biometrics Ltd, Newport, UK) ciblant des muscles pertinents pour une analyse biomécanique dans le cadre d'une tâche de port de charge : le biceps brachial, le triceps brachial, le deltoïde antérieur, le trapèze, l'érecteur du rachis, le soléaire et le tibial antérieur.

La tâche étant effectuée dans le plan sagittal, et le bracelet Myo étant déjà placé sur le bras droit, les capteurs sont placés uniquement sur la partie gauche du corps. L'objectif des ces mesures est d'avoir une information objective de l'activité musculaire dans les différentes situations, dissociée du signal de commande. Les capteurs EMG sont placés selon les recommandations SENIAM [Hermens et al., 1999] et la fréquence d'échantillonnage est de 1000 Hz

Les participants doivent aussi remplir un questionnaire [Wioland et al., 2019]. Ce questionnaire permet une évaluation subjective du ressenti des participants vis à vis des différentes situations et de vérifier si cela confirme les résultats de l'évaluation objective.

Une répétition de la tâche consiste à (i) lever la charge jusqu'à une marque haute, (ii) abaisser jusqu'à une marque de hauteur moyenne, (iii) ramener de nouveau jusqu'à la marque haute, et enfin, (iv) déposer la charge (voir Fig. 3.3). Pour chaque situation le participant effectue six répétitions de la tâche.

Avant les enregistrements les participants sont autorisés à faire au maximum deux répétitions pour avoir un premier ressenti de l'assistance mais sans avoir le temps de se familiariser avec. Pour cela on considère que les données sont enregistrées sur des utilisateurs novices.

Comme nous l'avons mentionné dans la section 3.2, il y a deux paramètres à régler




FIGURE 3.3 – Environnement de l'expérience

dans le contrôle DZ-I. Cette boucle de commande a été réglée par un expert, c'est à dire quelqu'un habitué à utiliser le système. Celui-ci a réglé le gain avec la plus haute valeur possible sans introduire de dépassement ou d'instabilité. Le seuil a été réglé de manière à permettre aux mouvements de faible intensité de ne pas altérer l'assistance une fois la charge équilibrée. Ces paramètres sont utilisés pour tous les participants lors de l'évaluation présentée dans la section 3.3. Notre hypothèse est que grâce à notre système de détection d'intention qui exprime l'intention sous la forme d'une valeur objective, ce réglage permettra à tous les participants de réaliser la tâche, et ce sans problème d'instabilité du contrôleur. Le gain d'intégration est réglé pour être le plus important possible tout en évitant les problèmes de stabilité. Le seuil de la zone morte est réglé de manière à autoriser des mouvements de faible dynamique sans déclencher un changement d'assistance. A titre d'indication cela correspond à une valeur équivalente à 10N à l'effecteur de l'exosquelette.

### 3.3.2 Résultats et discussion

La Fig. 3.4 présente les enregistrements d'un sujet pour une répétition de la tâche dans chaque situation. Nous pouvons remarquer qu'il y a une activation du biceps tant que la charge est soulevée lors de la situation sans assistance et de manière similaire mais réduite avec l'assistance CG. Pour l'assistance DZ-I, nous pouvons remarquer un pic d'activation

du biceps au moment du lever de charge et un pic d'activation du triceps au moment de son dépôt. Cela correspond à l'augmentation et la diminution de l'assistance qui s'adapte à l'effort de l'utilisateur. En effet, nous pouvons voir au niveau de ces pics une augmentation puis une diminution du couple d'assistance (en bleu). Enfin, nous pouvons voir aussi une activation du triceps en fin de mouvement dans la situation avec l'assistance CG, cela correspond au moment où le participant a déposé la charge et doit contrer l'assistance.

### 3.3.2.1 Performance de la commande


Le couple de référence choisi pour évaluer l'assistance fournie par le correcteur DZ-I est le couple correspondant à la compensation par modèle de gravité classique. Sur la Fig. 3.5, l'erreur RMS moyenne par répétition et par participant, et l'erreur moyenne signée (différence entre le couple d'assistance et le couple de référence) sont affichées. La seconde valeur est calculée pour observer si le contrôleur DZ-I a une tendance à sur-estimer ou sous-estimer l'assistance à fournir. Ces valeurs sont calculées entre le moment où l'objet est soulevé et le moment où il est déposé. Nous pouvons voir que ces valeurs semblent anormalement élevées pour le premier participant. Une analyse des quartiles a permis de l'identifier comme une valeur aberrante. Une hypothèse est que ce participant avait un comportement tendu et contracté, ce qui a rendu difficile le fonctionnement du contrôleur DZ-I. Un tel problème pourrait être résolu en laissant les utilisateurs s'entraîner avec cette assistance.

Si on exclut le premier participant, l'erreur RMS moyenne est de  $0.038 \pm 0.012 N.m$ , ce qui correspond à une erreur de  $6.99 \pm 2.27 N$  au niveau de la main du participant.


En examinant l'erreur moyenne signée, nous pouvons observer que le système n'a pas une tendance systématique inter-individu à sur-estimer ou sous-estimer l'assistance. Cependant nous pouvons observer qu'il semble y avoir une erreur systématique propre à chaque participant. Cette observation nous suggère l'existence d'un paramètre spécifique pour chaque individu.

### 3.3.2.2 Activité musculaire


Les situations No-Exo et CG servent de point de comparaison pour évaluer le contrôleur DZ-I. Nous considérons la situation avec l'assistance CG comme le cas idéal. En effet, au cours de la manipulation avec l'assistance CG, la charge est compensée parfaitement



(a) No Exo



(b) DZI



(c) CG

FIGURE 3.4 – Enregistrement d’une répétition de la tâche pour un participant. En rouge, l’angle du coude est affiché (axe des ordonnées à droite, en degrés), en bleu, le couple d’assistance (axe des ordonnées à gauche, N.m) et les deux courbes vertes sont les niveaux d’activation du biceps et du triceps (clair et foncé respectivement, axe des ordonnées à gauche, normalisé avec la RMC (voir section 3.3.2.2)). Les différents moments clés sont mis en évidence sur les graphiques : en bleu la charge est lâchée, en orange la charge est soulevée à la marque haute et en orange clair la charge est au niveau de la marque moyenne. Pour des raisons de lisibilité nous avons tracé seulement les signaux EMG du biceps et du Triceps.




FIGURE 3.5 – Précision de l’assistance proposée comparée à CG

et donc son impact sur l’activité musculaire est aussi réduit que possible.

Le traitement du signal EMG brut d’évaluation (signal obtenu par les capteurs Data-Lite) est fait selon les recommandations de [Buchanan et al., 2004] et [McDonald et al., 2013]. Nous utilisons d’abord un filtre passe-bande (un filtre butterworth d’ordre sept, bi-directionnel de bande passante [30Hz, 200Hz]). Ensuite le signal est centré, rectifié et enfin filtré par un filtre passe-bas. Le signal obtenu est alors normalisé avec la valeur maximum mesurée au cours de toutes les situations et toutes les répétitions pour un participant (RMC, Contraction Maximum Relative).

Chaque répétition est isolée et sous échantillonnée pour calculer l’activation musculaire moyenne à chaque répétition.

Sur la Fig. 3.6, l’activation moyenne de chaque muscle est présentée, moyennée sur tous les participants. En comparant le contrôleur DZ-I avec la situation No-Exo, les résultats montrent une réduction statistiquement significative de l’activité moyenne du biceps, de l’érecteur du rachis et du deltoïde de  $20 \pm 14\%$ ,  $18 \pm 12\%$  et  $25 \pm 16\%$  respectivement ( $p < 0.001$ ,  $p < 0.05$ , et  $p < 0.001$  respectivement, obtenu avec un t-test). Notre résultat est en accord avec d’autres recherches qui ont montré une diminution de l’activité musculaire du biceps de 20 % en utilisant un exosquelette actif de membre supérieur [Naito et al., 2007, Kobayashi et al., 2009, Muramatsu et al., 2011, Lee et al., 2012]. Cela met en évidence une réduction de l’effort fait par l’opérateur au cours de tâches manuelles [De Looze et al., 2016]. En ce qui concerne l’érecteur du rachis une réduction de 10 à 25 % a été




FIGURE 3.6 – Comparaisons des activations musculaire entre les trois situations (\* :  $p < 0.05$ , \*\*\* :  $p < 0.001$ )

montré pendant des tâches de levage asymétrique avec un exosquelette [Abdoli-E et al., 2006, Abdoli-Eramaki et al., 2007, Abdoli-e and Stevenson, 2008], confirmant la capacité de ces systèmes à prévenir les blessures au niveau du dos. Bien que la réduction soit la plus importante pour le deltoïde, des valeurs comparables ont été obtenues dans la littératures [Muramatsu et al., 2011]. Pour les autres muscles les activités sont similaires, sans différence significative.

En comparant les situations DZ-I et CG, sur les zones avec charge saisie, nous pouvons voir que les activités musculaires sont similaires pour tous les muscles observés. Ceci indique que le correcteur DZ-I est aussi efficace que la compensation théorique parfaite de la charge (CG).

Participant	2	3	4	5	6	7	8	9	10
DZI (% de RMC)	23	49	56	31	25	18	28	59	47
CG (% de RMC)	24	85	48	36	73	69	73	53	77
Difference	01	37	-08	05	48	51	45	-07	30

FIGURE 3.7 – Activation maximale du triceps pendant la dernière phase de la tâche (dépôt de la charge)

Par ailleurs, un autre avantage du correcteur DZ-I comparé à la CG est que l'assistance est basée sur l'effort fourni par l'utilisateur. Grâce à cela le couple d'assistance est réduit lorsque l'objet est relâché, ce qui n'est pas le cas avec une compensation par modèle de gravité classique pour laquelle le couple est maintenu (en l'absence de système de détection de présence charge). Pour évaluer cette différence les activations maximales du triceps en fin de répétition (dépôt de la charge) peuvent être comparées dans les deux situations avec assistance (voir Tableau 3.7). Pour la moitié des participants nous observons une réduction notable du pic d'activation du triceps. Si on exclut le premier participant, considéré comme une valeur aberrante dans la section 3.3.2.1, la différence moyenne entre CG et DZ-I est de  $22 \pm 24\%$  de RMC (un test de Student unidirectionnel nous montre que c'est une différence significative,  $p < 0.05$ ). En observant en détail chaque répétition, nous pouvons remarquer que, dans le cas de la situation CG, les participants ne déposent pas toujours complètement la charge (aucun pic EMG au niveau du triceps au moment où la charge est abaissée sur la table). En effet, nous avons pu observer que, dans certains cas, le participant met la charge en contact de la table mais laisse les poignées de la charge en tension pour limiter l'effort en laissant la charge compenser la CG. Les poignées de la charge étant des sangles la différence entre une charge posée et le cas où la charge touche seulement la table est très visuelle mais nous n'avons pas pu quantifier le bon respect de la consigne au cours des répétitions. Malgré cela nous pouvons quand même observer que le contrôleur DZ-I a une tendance à réduire les contraintes au niveau du triceps comparé au contrôleur CG. Pour confirmer cette tendance il faudra un protocole qui n'indiquera pas de seulement déposer la charge sur la table mais d'ouvrir les mains pour la lâcher complètement.

### 3.3.2.3 Évaluation subjective

Les participants ont répondu à un questionnaire de ressenti après avoir effectué les répétitions dans chaque situation (voir Fig. E.3). Le questionnaire est séparé en trois parties. La première concerne le ressenti général. La seconde concerne la comparaison de la situation No-Exo avec la situation DZ-I. Enfin la dernière concerne la comparaison entre les deux types d'assistance, DZ-I et CG. Les réponses sont données sous la forme d'une échelle de Likert. Les résultats sont synthétisés sur les Fig. 3.8, 3.9 et 3.10.

Le retour général que les participants nous ont fait est que, même si le contrôleur CG






FIGURE 3.8 – Sensation de maîtrise avec les 2 types d'assistance

est plus simple à anticiper et demande moins de concentration, du fait de sa constance, ils se sentent plus efficaces avec le correcteur DZ-I. Ce ressenti est mis en évidence en comparant les sensations de maîtrise de l'exosquelette avec chaque assistance sur la Fig. 3.8. Néanmoins, lorsque les participants ont comparés les performances entre les deux modes de commande CG et DZ-I, les réponses étaient à l'avantage de DZ-I (cf. Fig. 3.10).




FIGURE 3.9 – Impression d'effort réduit avec l'assistance DZI comparée à l'assistance CG

Neuf participants ont l'impression que le correcteur DZ-I réussit à réduire leur effort au niveau des bras comparé à la situation No-Exo, et sept ont ressenti un soulagement au niveau des épaules. En comparant les deux types d'assistance (CG et DZ-I), les participants n'ont en général pas senti de différence en terme d'effort au niveau des cervicales, du dos et des jambes. Sept participants ont ressenti moins d'effort au niveau des bras avec le correcteur DZ-I comparé au contrôleur CG et cinq ont ressenti moins d'effort au niveau des épaules (voir Fig. 3.9). Il faut néanmoins noter qu'un participant a ressenti plus d'effort au niveau du dos.

### 3.3.2.4 Étude de l'impact sur les synergies musculaires

Dans cette section nous nous intéressons aux synergies musculaires et leurs différences en fonction des situations. Notre hypothèse est que la stratégie de commande proposée




FIGURE 3.10 – Impressions de performances comparées entre CG et DZI : Précision = Sensation de plus grande précision pendant la tâche, Efficacité = sensation d’une assistance adaptée, Vitesse = Sensation de vitesse de réactivité de l’assistance. Les réponses sont données en comparant DZI avec CG.

perturberait moins les synergies musculaires que l’assistance CG, par rapport aux synergies observées au cours de la situation sans assistance. Bien qu’il existe plusieurs types de synergies [Chiovetto et al., 2013], nous nous concentrons sur les synergies temporelles. Cela consiste à quantifier les activations simultanées des différents muscles au cours de la tâche.

On appelle  $M$  la matrice  $m \times n$  des signaux EMG ( $m$  le nombre de muscles et  $n$  le nombre de pas de temps pour la tâche). On utilise NMF (Nonnegative Matrix Factorisation) pour décomposer la matrice  $M$  en deux matrices  $W$  et  $H$  (de dimensions respectives  $m \times k$  et  $k \times n$ , où  $k$  est le nombre de synergies, eq.3.9), de manière similaire à [Chiovetto et al., 2013]. La matrice  $W$  représente les niveaux d’activation de muscle par synergie, la matrice  $H$  les fonctions d’activations des synergies au cours de la tâche.

$$M = W * H + \text{residus} \quad (3.9)$$

Le nombre de synergies  $k$  est un paramètre à déterminer. L’objectif est de choisir la plus petite valeur de  $k$  qui permet de reconstruire correctement le signal d’origine. C’est une démarche de réduction de dimension, si  $k = m$  alors  $W = I$  et  $H = M$  est une solution évidente qui n’apporte aucune information. Pour cela nous utilisons comme indicateur le ratio de variance explicable :

$$VAF = 100 * \left(1 - \frac{\|M - W * H\|^2}{\|M - \text{mean}(M)\|^2}\right) \quad (3.10)$$

Sur la Fig. 3.11, les valeurs de VAF pour chaque participant en fonction du nombre de synergie ( $k \in [2, 7]$ ). Pour la suite nous considérons  $k = 3$ , car nous avons  $VAF(3) \geq 90\%$  pour tous les participants. Pour évaluer l’impact notre méthode d’assistance nous utilisons




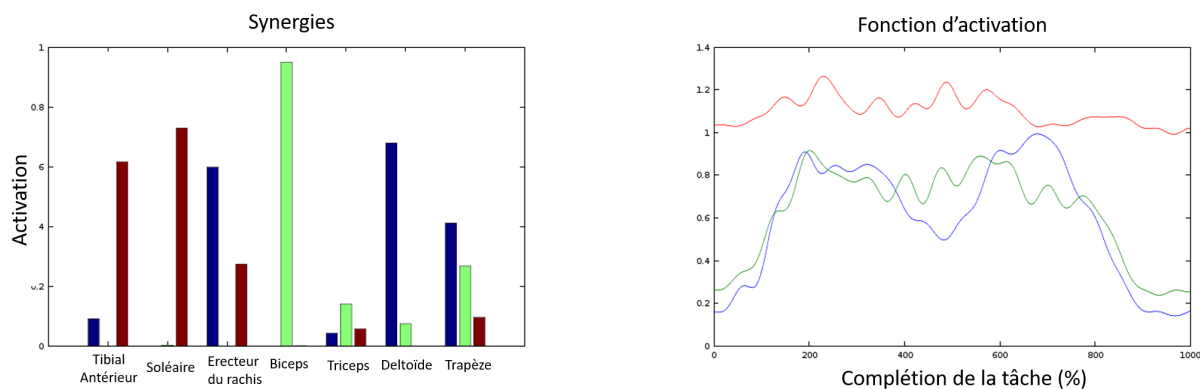
FIGURE 3.11 – Variance explicable en fonction du nombre de Synergies (couleur différente pour chaque participant)

la situation sans assistance comme groupe de contrôle. Sur la Fig. 3.12 des exemples de synergies et leur fonction d'activation respective pour chaque tâche ont été représentées.

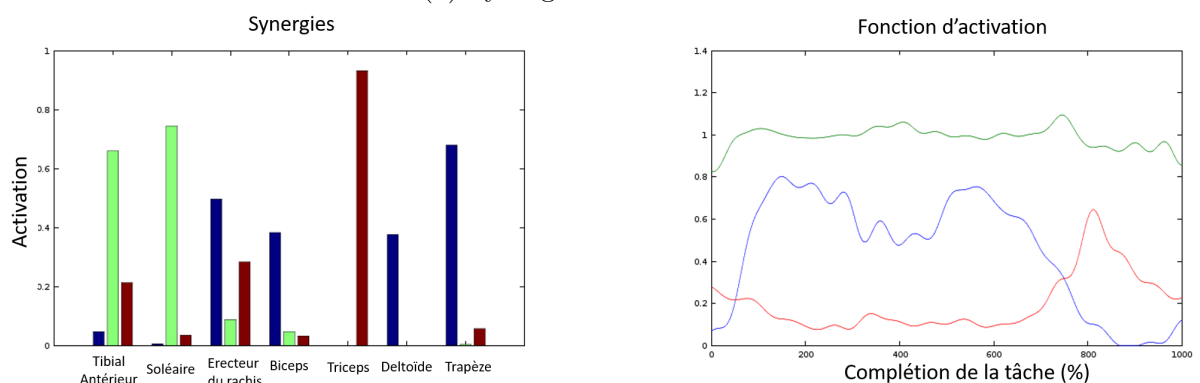
Pour estimer l'impact des modes d'assistance sur les synergies musculaires. Nous utilisons le produit scalaire normalisé comme indicateur de similarité entre deux synergies données (eq. 3.11). L'algorithme NMF ne donne aucune garantie sur l'ordonnement des synergies trouvées. Pour comparer deux situations nous formons des paires à partir des deux groupes de trois synergies en fonction de leur similarité. Nous calculons les similarités des 9 combinaisons possibles, la valeur maximale nous permet de former le processus puis nous recommençons le procédé en excluant les synergies déjà appairées.

$$S = \frac{Syn_1 \cdot Syn_2}{\|Syn_1\| * \|Syn_2\|} \quad (3.11)$$

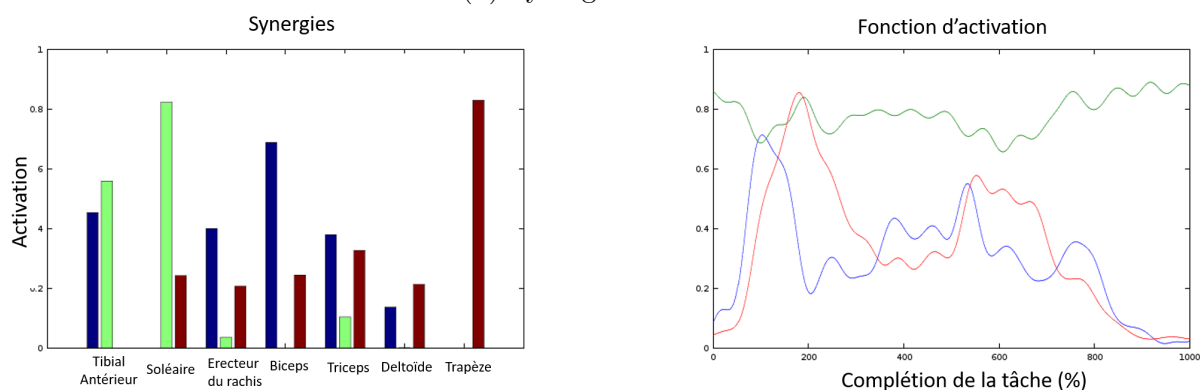
Afin d'estimer l'impact de l'assistance DZ-I, nous comparons le degré de similitudes des synergies avec la situation sans assistance, qui est notre situation de contrôle. Pour avoir une valeur de comparaison, nous faisons la même chose avec l'assistance par compensation de gravité. Les valeurs obtenues pour chaque participant sont présentées sur la Fig. 3.13. Ces valeurs ont été obtenues en faisant la moyenne des résultats pour 5 exécutions de l'algorithme NMF. En excluant le premier participant (cf section 3.3.2.1), nous obtenons des valeurs moyennes de  $0.77 \pm 0.10$  et  $0.63 \pm 0.08$  pour les similitudes entre



(a) Synergies sans assistance



(b) Synergies avec CG



(c) Synergies avec DZI

FIGURE 3.12 – Exemple de Synergies. Les histogrammes sur la gauche représentent les activations des muscles pour chaque synergie (une couleur par synergie). Les courbes de droite représentent les activations des synergies au cours de la tâche. Les couleurs correspondent pour chaque paires histogramme-graphique, c'est-à-dire que la courbe verte représente la synergie affichée avec les barres vertes dans l'histogramme, par exemple.




FIGURE 3.13 – Similitudes des synergies entre les deux types d’assistance et la situation sans assistance

l’assistance DZ-I et sans assistance et les similitudes entre l’assistance CG et sans assistance, respectivement. En faisant un t-test, nous obtenons un t-score de 4.2, ce qui donne  $p < 0.001$  et donc la différence entre les deux groupes est statistiquement significative. Cela veut dire que les synergies musculaires impliquées lors de l’utilisation de l’assistance par intégration sont plus similaires à celle impliquées en l’absence d’assistance que ne le sont celles impliquées avec l’assistance par compensation de gravité. En d’autres termes, la stratégie d’assistance que nous proposons perturbe moins les synergies musculaires que l’assistance par compensation de gravité.

## 3.4 Conclusion

Dans ce chapitre nous avons donc développé et évalué un système de commande d’exosquelette de membre supérieur pour assister au port de charges non connues à priori. Le contrôleur prend pour entrée la sortie du système de détection d’intention décrit dans le chapitre 2, basé sur le signal EMG d’un capteur bas coût. L’évaluation est faite grâce à dix participants, pour comparer différentes situations : une situation sans assistance, pour vérifier qu’une réduction des efforts est bien présente, et une situation avec une assistance

de compensation par modèle de gravité classique, qui est considérée comme l'assistance idéale dans notre cas. Nous observons que le système proposé est capable d'approcher le couple d'assistance idéal avec une erreur de  $0.038 \pm 0.012N.m$  en moyenne, ce qui correspond à  $6.99 \pm 2.27N$  au niveau de l'effecteur du robot.

Nous pouvons donc envisager d'utiliser le contrôleur DZ-I dans un milieu industriel pour assister le port de charge lors de tâches manuelles. Comparée à une méthode de compensation par modèle de gravité classique, charge connue à l'avance, il persiste une erreur de compensation. Néanmoins, les évaluations nous ont permis de constater que cette erreur semble acceptable, et le sera d'autant plus vu le gain au niveau de l'usage. En effet, la contrepartie offerte est que, comme le poids de la charge n'a pas besoin d'être connu l'assistance ne nécessite pas d'être re-calibrée si la charge varie (contrairement à une CG classique). Les étapes de prise/dépose de la charge sont automatiquement prise en charge par la commande.

Nous avons aussi montré que notre système réduit effectivement l'effort physique de l'utilisateur au niveau du biceps, du deltoïde et de l'érecteur du rachis. Bien que l'exosquelette soit fixé sur une potence au cours des essais et non pas porté par l'utilisateur, ces résultats peuvent être transférés à des applications où l'exosquelette de membre supérieur serait posé sur un exosquelette de membre inférieur ou bien attaché à un manipulateur [Yu et al., 2018]. De plus, un questionnaire a permis d'évaluer le ressenti des participants vis à vis de ce nouveau système de commande d'exosquelette.

Le système mis au point est plus adapté à des tâches qui requièrent de porter des charges variées ; comparé à la CG classique qui est particulièrement adaptée pour assister la manipulation d'un outil spécifique pendant une longue durée.

Comme nous l'avons indiqué dans la section 3.3.1, les résultats concernent des utilisateurs novices. De plus, dans le paragraphe 3.3.2, nous avons évoqué la possibilité de prendre en compte un paramètre spécifique aux individus qui expliquerait les erreurs systématiques inter-individuelles. Nous pouvons formuler deux hypothèses. D'une part, ce paramètre influencerait le gain de l'intégrateur. Ce paramètre pourrait être basé sur le temps de réaction de l'utilisateur. D'autre part, il pourrait s'agir de différences interindividuelles dans la manière de se confronter à une nouvelle situation.

Pour explorer ces hypothèses la prochaine étape est de mettre au point un protocole impliquant un grand nombre de répétitions pour observer l'adaptation potentielle de

l'utilisateur ainsi qu'une éventuelle amélioration du ressenti. De plus, il serait pertinent d'explorer le réglage personnalisé des paramètres du contrôleur qui pourrait améliorer la facilité d'utilisation du système, c'est-à-dire réduire le temps d'apprentissage.

Enfin un dernier aspect à explorer est l'amélioration de la calibration qui est, à ce stade, entièrement spécifique à l'utilisateur courant. Pour améliorer le côté pratique du système il faudrait réduire le temps nécessaire à la calibration, qui lors de cette première étape était de 2min30. Une piste possible serait d'exploiter les données d'utilisateurs multiples.

# Étude 3 : Amélioration de la calibration et personnalisation de la commande

---

## Sommaire

<b>4.1 Réduction du temps de calibration</b> . . . . .	<b>90</b>
4.1.1 Entraînement groupé . . . . .	90
4.1.2 Affinage de l'apprentissage . . . . .	93
<b>4.2 Personnalisation du gain</b> . . . . .	<b>95</b>
4.2.1 Simulation de la boucle d'interaction . . . . .	96
4.2.2 Évaluation du temps avant activation . . . . .	103
<b>4.3 Évaluation de la personnalisation du gain</b> . . . . .	<b>108</b>
4.3.1 Protocole . . . . .	108
4.3.2 Résultats et discussion . . . . .	111
<b>4.4 Conclusion</b> . . . . .	<b>116</b>

Dans le **chapitre 4** nous proposons des axes d'amélioration du système complet présenté dans les chapitres **2** et **3**. Le premier axe consiste à réduire le temps de calibration nécessaire du système en s'appuyant sur les données récoltées au cours des expériences précédentes et la capacité de généralisation de réseaux de neurones. Cela permettra au système d'être plus pratique et plus facile à déployer. D'autre part, nous étudions la possibilité de personnaliser le gain d'intégration du système pour créer une commande personnalisée et donc plus intuitive. Nous avons ainsi exploré l'effet du temps avant activation d'un individu (défini section **4.2**) sur la stabilité du système, pour en déduire un gain adapté. Enfin nous étudions expérimentalement l'impact de cette commande personnalisée avec l'aide de 10 participants.



## 4.1 Réduction du temps de calibration

A ce stade la calibration requiert environ trois minutes d'enregistrement de données d'entraînement. Dans ces données, une minute sert exclusivement à l'entraînement du réseau de neurones et les deux autres servent à la fois pour déterminer les paramètres du modèle et pour entraîner le réseau. La procédure de calibration est représentée sur la Fig. 4.1. Notre objectif dans cette section est de limiter la calibration à : (i) une contraction volontaire progressive du biceps jusqu'au maximum possible, maintenu quelques secondes (ii) puis la même chose avec le triceps, comme présenté sur la Fig. 4.2.

### 4.1.1 Entraînement groupé

Une des forces des réseaux de neurones est leur capacité à généraliser. Nous allons tirer parti de cette capacité en utilisant les données collectées au cours des deux premières études. Nous allons entraîner le réseau avec les données de plusieurs participants et le tester avec les données d'un participant qui ne fait pas partie du set d'entraînement.

Nous avons donc les données de 21 personnes (cf. chapitres 2 et 3). Pour vérifier la qualité de ces données nous évaluons la précision des résultats lorsque le réseau est entraîné avec les données d'entraînement d'une personne et testé avec les données de test de cette même personne (voir section 2.3.3). Les résultats sont affichés dans le tableau 4.1. Nous pouvons voir que les données des personnes 6 et 8 semblent présenter un problème. Une analyse des quartiles permet de déterminer que les précisions obtenues pour ces deux personnes sont aberrantes. L'erreur pour plusieurs des structures est de 25%, cela pourrait

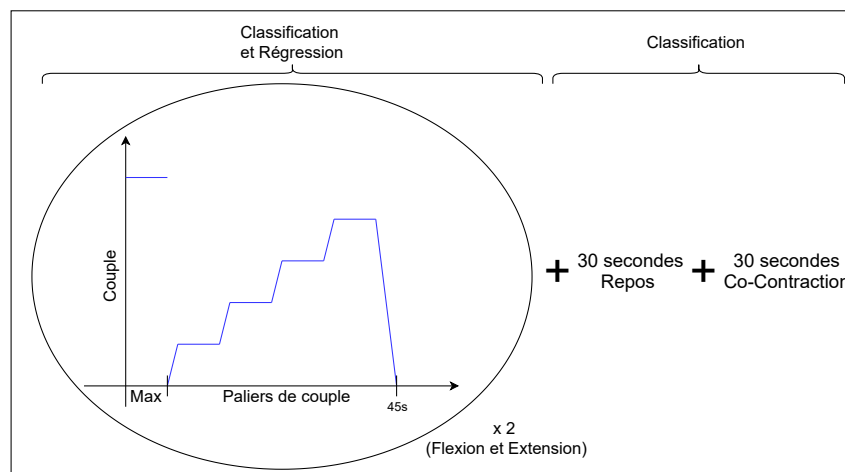


FIGURE 4.1 – Représentation des étapes de la calibration du chapitre 2




FIGURE 4.2 – Représentation de la calibration visée

correspondre à la totalité des données d'une classe. Une hypothèse possible est que l'une des classes ait été mal enregistrée pour ces personnes. Il sera donc peut-être pertinent de ne pas les inclure dans la base de données finale.

train on self	Soft3	Soft4	CL3	CL4	SVM
1	92,2	90,7	95,9	87,8	91,8
2	95,2	100,0	100,0	100,0	100,0
3	87,0	90,9	94,5	85,1	97,6
4	95,5	99,5	94,3	97,7	87,3
5	93,6	95,1	95,7	95,9	95,8
6	83,5	75,0	75,5	75,0	75,0
7	90,5	95,8	96,7	98,0	97,3
8	75,0	74,4	50,0	75,7	77,5
9	98,8	99,0	99,7	100,0	100,0
10	98,4	100,0	100,0	100,0	100,0
11	86,8	85,6	96,6	95,4	91,2
12	95,0	99,9	97,1	99,0	97,0
13	79,6	84,3	100,0	90,0	75,5
14	99,0	99,9	99,1	99,9	100,0
15	95,6	98,1	99,0	98,6	98,1
16	85,1	99,2	91,7	96,0	100,0
17	99,1	94,6	98,6	91,5	93,6
18	90,6	90,7	92,2	89,4	89,7
19	99,3	99,4	100,0	97,9	100,0
20	91,6	90,6	97,0	98,5	99,9
21	71,0	93,2	92,9	99,1	99,4
Moy	90,6	93,1	93,6	93,8	93,6
Std Dev	8,1	7,8	11,3	7,6	8,3

TABLE 4.1 – Précision du réseau entraîné et testé avec les données d'une même personne

Pour cumuler les données des différentes personnes en une même base de donnée nous devons uniformiser l'orientation du bracelet. Pendant les précédentes études le placement n'était pas imposé et les participants devaient positionner eux-mêmes le bracelet avec pour seule consigne qu'il soit légèrement sous la moitié du biceps. Cependant, nous avons

pris soin de noter la position du bracelet sur le bras de l'utilisateur. Cela nous permet, par permutation circulaire, de faire correspondre les canaux de chaque électrode entre eux. Arbitrairement, nous choisissons que l'électrode 1 corresponde à celle placée le plus au dessus du biceps. Cette approximation a une précision d'un demi écart d'électrode, soit  $22.5^\circ$ .

Une fois ce pré-traitement fait nous entraînons le réseau avec les données de 20 personnes et nous le testons sur la personne exclue du set d'apprentissage. c'est un cas particulier de la validation croisée ( *cross-validation* [Stone, 1977]) où il y a autant de blocs de validation que d'échantillons (LOO, *Leave One Out*). Nous n'enlevons pas encore les personnes dont les données semblent aberrantes dans un premier temps. Avec cette première étape nous pouvons confirmer que les données des personnes 6 et 8 sont aberrantes. Nous pouvons constater que les données de la personne 18 semblent poser problème aussi (voir Tableau 4.2).

Groupé	Soft3	Soft4	CL3	CL4	SVM
1	93,8	90,1	87,9	76,9	87,8
2	96,1	97,4	99,7	99,9	98,5
3	95,5	97,2	96,0	94,2	96,9
4	94,0	91,8	85,4	80,1	84,9
5	94,0	97,2	97,0	96,6	95,7
6	83,9	82,9	75,1	75,1	75,2
7	90,2	90,0	94,7	90,6	97,8
8	90,1	75,0	96,6	75,1	74,9
9	99,7	99,5	100,0	100,0	99,4
10	96,8	98,2	99,2	99,6	99,1
11	92,4	95,1	94,7	92,8	91,2
12	99,2	99,8	96,8	98,6	99,5
13	91,8	93,9	97,8	96,8	92,4
14	93,3	91,7	99,6	99,6	90,5
15	91,6	90,8	87,8	80,5	75,2
16	92,4	94,4	99,4	96,8	97,5
17	99,2	94,6	95,6	93,6	99,2
18	87,7	75,0	93,0	75,0	76,3
19	91,1	93,3	91,7	91,3	90,8
20	79,6	84,4	98,5	91,8	88,9
21	85,0	89,4	99,2	99,6	83,5
Moy	92,3	91,5	94,6	90,7	90,3
Std Dev	5,1	7,1	6,1	9,4	8,8

TABLE 4.2 – Précision du réseau entraîné avec les données de 20 personnes et testé avec les données de la personne restante

En observant les matrices de confusion des 3 personnes (Tableau 4.3, D.4 et D.5), nous pouvons voir que les enregistrements des données de la classe co-contraction n’ont pas été faits correctement. C’est pourquoi nous enlevons les données de ces trois personnes pour former notre base de données générique.

198	0	0	0
0	198	0	0
0	0	184	13
0	0	185	13

TABLE 4.3 – Matrice confusion des données de test personne 6

	Soft3	Soft4	CL3	CL4	SVM
Moyenne	93,0	94,5	95,9	93,7	92,7
écart type	4,6	3,6	4,5	6,2	6,8

TABLE 4.4 – Précision du réseau entraîné avec les données de 17 personnes et testé avec les données de la personne restante

En utilisant les 18 personnes retenues pour créer une base de données générique, nous obtenons les résultats résumés dans le tableau 4.4 et détaillés dans le tableau D.7. Avec cette utilisation, nous pouvons voir que l’approche de classification avec un SVM réalise des performances un peu plus faibles et un peu moins stables que les approches avec réseaux de convolutions (cf. tableau 4.4). De plus, nous remarquons aussi que l’approche avec la fonction de coût contrastive CL semble plus indiquée pour une utilisation à 3 classes et la fonction Softmax plus appropriée pour 4 classes. Ce résultat n’est pas surprenant compte tenu du fait que la méthode CL est à l’origine destinée pour des problèmes de classification binaire avec un déséquilibre de représentation entre les 2 classes.

### 4.1.2 Affinage de l’apprentissage

Avec les résultats présentés dans la section précédente nous pouvons supposer qu’il n’y a plus besoin de récolter de nouvelles données pour entraîner le réseau de neurones. Cependant cela ne peut pas s’appliquer à l’estimation des paramètres du modèle EMG/Couple (eq. 2.11) puisque la relation entre le signal EMG et la force déployée est spécifique à chaque individu et ne peut pas être généralisée. Le fait de réaliser des paliers de couple pour la calibration (voir section 2.3.3) servait à obtenir un panel exhaustif et équilibré des classes triceps et biceps pour l’entraînement du réseau. Nous pouvons envisager d’arrêter

de faire les enregistrements de co-contraction et de repos, et revoir le format des données pour estimer les paramètres du modèle (eq. 2.11).

Pour calibrer le modèle nous utilisons une nouvelle approche pour enregistrer les données. L'exosquelette est contrôlé en position et l'utilisateur doit forcer pour aller progressivement jusqu'à son maximum de contraction du biceps puis réduire graduellement avant de forcer dans l'autre sens pour atteindre progressivement son maximum de contraction du triceps. Le tout dure au maximum 15 secondes.

Puisque nous devons enregistrer des données pour calibrer le modèle, nous pouvons aussi exploiter ces données pour adapter l'apprentissage du réseau. La quantité de données étant très réduite, ce n'est pas suffisant pour entraîner complètement le réseau de neurones. Cependant, on peut les utiliser avec un réseau déjà entraîné pour affiner et spécialiser son utilisation, on parle de *fine-tuning*.

Le *fine-tuning* est utilisé lorsqu'il y a trop peu de données dans la base d'apprentissage pour que le réseau puisse généraliser. Il s'agit de l'entraîner sur une base de données plus fournie avec des données de la même modalité (images, son, signal emg, etc...). Cette base de données ne présente pas tout à fait les mêmes classes mais l'idée est que les caractéristiques à extraire soient sensiblement les mêmes. Concrètement cela revient à supposer que les poids des premières couches (les convolutions) conviendront pour d'autres classes. Le réseau est ensuite entraîné sur la base de données voulue avec un taux d'apprentissage très faible ou nul pour les couches de convolution. C'est à dire qu'on autorise seulement la modification des poids des dernières couches pour adapter la classification des caractéristiques [Trivedi, 2016].

Avec la calibration courte, nous pouvons obtenir des échantillons d'activation biceps et triceps. Si l'on veut pouvoir affiner l'apprentissage sans introduire de biais dans le réseau, il faut aussi utiliser des échantillons de repos et de co-contraction. Comme nous voulons limiter au maximum les enregistrements nécessaires pendant la phase de calibration, nous utilisons un sous-échantillonnage de la base de données générique pour ces deux classes.

Nous faisons donc un affinage du réseau avec un mixte des données issues de la calibration et de la base de données générique. Pour tester l'apport de l'affinage, nous entraînons le réseau avec les données de 17 personnes. Puis, avec les données de la dernière personne nous prenons un sous-échantillon des classes biceps et triceps des données d'entraînement (40 échantillons par classe, soit 6 secondes de données) pour ajuster le réseau. Enfin nous

le testons avec les données de test de cette dernière personne. Les résultats sont résumés dans le tableau 4.5 et détaillés dans le tableau D.8. Nous pouvons remarquer que l'affinage de l'apprentissage permet d'améliorer les performances des réseaux.

	Soft3	Soft4	CL3	CL4
Moyenne	95,2	96,7	97,4	96,0
écart type	4,2	3,0	3,8	4,8

TABLE 4.5 – Précision du réseau affiné

## 4.2 Personnalisation du gain

Le second point d'amélioration envisagé pour notre système est de personnaliser le gain de l'intégrateur en fonction du temps avant activation de l'utilisateur.

Nous formulons l'hypothèse que le temps mis par l'opérateur pour réagir au comportement de l'exosquelette, que nous appellerons "temps avant activation", est une variable importante pour la fluidité de l'interaction. L'idée est que l'utilisateur peut avoir un retard de perception sur l'assistance fournie par le robot et donc d'ajustement de son activité musculaire. Cela peut induire des erreurs dues au correcteur intégral que nous utilisons.

Ce temps avant activation est à distinguer de ce qui habituellement référencé comme le temps de réponse et le temps de réflexe<sup>1</sup>. Le temps de réflexe est le délai entre un stimuli et une réponse involontaire à ce stimuli. Le réflexe myotatique en est un exemple : le muscle se contracte après un étirement soudain des fibres tendineuses et musculaires. L'intervalle entre l'étirement et la contraction est le temps de réflexe. Le temps de réponse fait référence au délai entre un stimuli et une réponse volontaire à ce stimuli. Celui-ci peut être séparé en deux phases, le temps de réaction (analyse de l'information) et le temps de mouvement. Par exemple, il s'agit du temps qu'un conducteur met, après avoir vu un piéton sur son trajet, pour appuyer sur le frein. Le temps de réaction est alors le temps que le conducteur met pour comprendre qu'il doit freiner et le temps de mouvement est le délai entre le choix de l'action à faire et sa réalisation.

Le temps avant activation se rapprocherait d'un temps de réflexe dans le sens où le stimulus et le phénomène observé sont localisé au même niveau. Ces différents intervalles

1. Des définitions des ces temps peuvent être trouvées avec [Cordier, 2017] et Neurosciences/Le système moteur : généralités ([https://fr.wikibooks.org/wiki/Neurosciences/Le\\_système\\_moteur:\\_généralités#Les\\_arcs\\_réflexes](https://fr.wikibooks.org/wiki/Neurosciences/Le_système_moteur:_généralités#Les_arcs_réflexes))

de temps sont illustrés sur la Fig. 4.3.

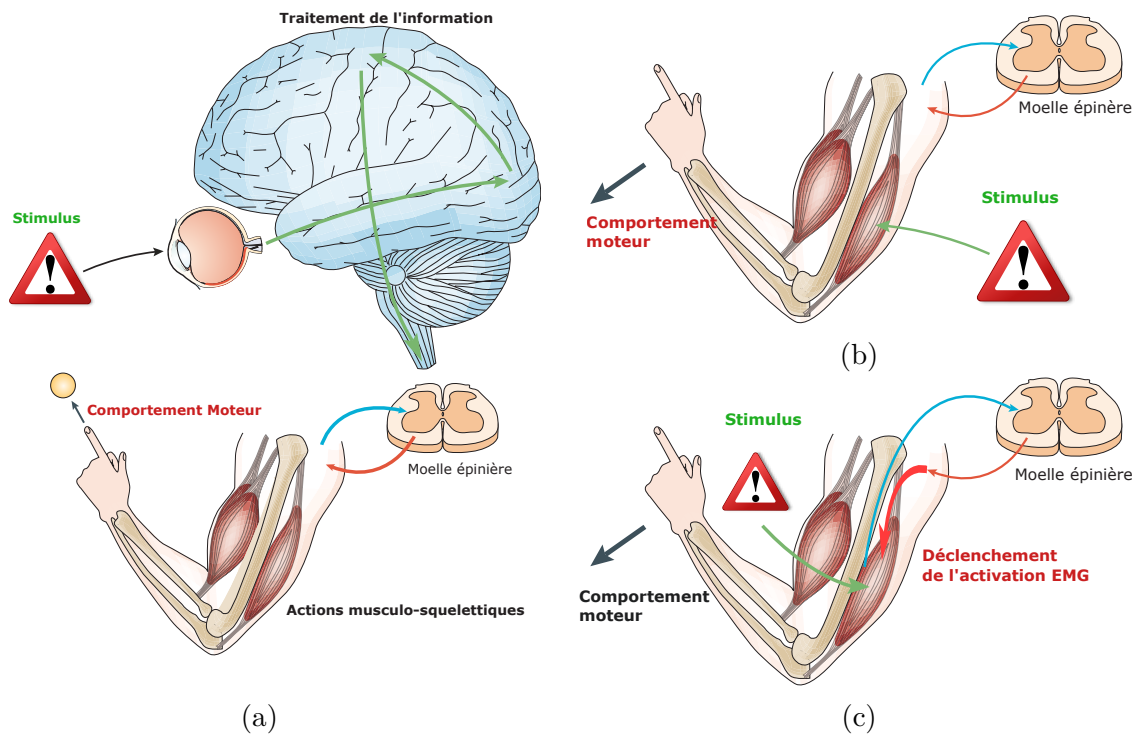


FIGURE 4.3 – Illustrations des temps de réponse, réflexe et avant activation [Scott, 2004]. Le stimulus (en vert) est l’instant de départ et les événements écrits en rouge sont les instants de fin de l’intervalle considéré. (a) Représentation du temps de réponse, (b) représentation du temps de réflexe et (c) représentation du temps avant activation

### 4.2.1 Simulation de la boucle d’interaction

Pour explorer les liens entre le gain et ce temps avant activation de l’utilisateur, nous modélisons la boucle d’interaction pour un lever de charge jusqu’à une position cible.

#### 4.2.1.1 Boucle globale

Dans cette section nous présentons l’implémentation d’une boucle de simulation qui sert à estimer le lien entre le temps avant activation et le réglage du gain. Nous présentons le modèle implémenté dans son ensemble, avant de détailler les composants principaux dans les sections suivantes.

Pour notre modélisation nous formulons l’hypothèse que l’utilisateur et la commande haut niveau par intégrateur sont les deux composants qui impactent le plus le comportement de la boucle de simulation. C’est pourquoi nous négligeons l’impact du contrôle bas niveau de l’exosquelette. Cela revient à considérer que le couple en sortie de l’intégrateur est directement le couple fourni par le robot  $\tau_{exo}$ .




FIGURE 4.4 – Représentation du système simulé

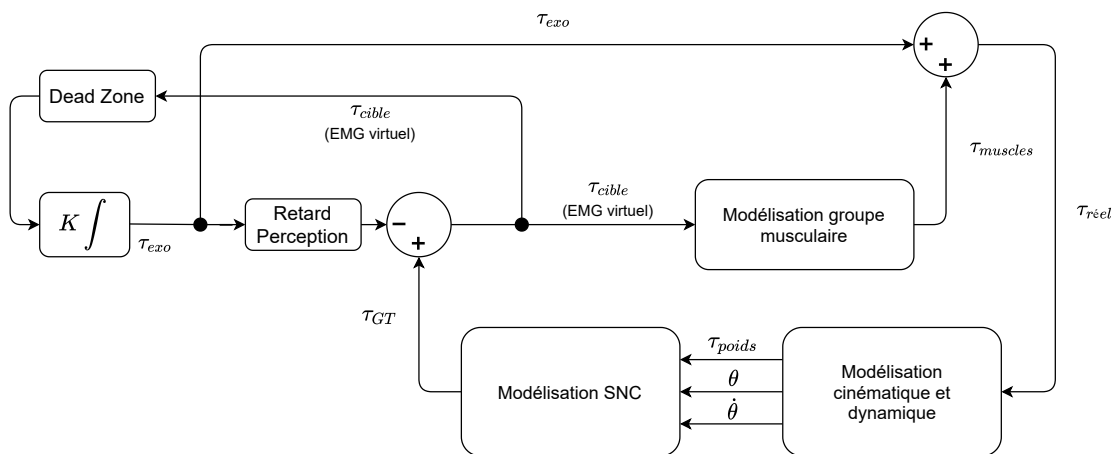


FIGURE 4.5 – Boucle d'interaction



Pour simplifier l'implémentation, nous ne modélisons pas le système de détection d'intention. Sinon, il faudrait aussi mettre au point une méthode de génération de signal EMG naturel en fonction du niveau d'activation. Cela revient donc à considérer que la consigne musculaire  $\tau_{cible}$  est exactement l'estimation qui arrive en entrée de la zone morte. Pour rappel, l'entrée de la zone morte est la sortie de notre module de détection d'intention dans le cas réel. De plus, nous considérons que l'utilisateur s'adapte à l'assistance avec un délai, c'est ici qu'intervient ce que nous appelons le temps avant activation de l'utilisateur. C'est pourquoi nous ne faisons pas directement la soustraction de l'assistance avec la consigne musculaire mais nous appliquons un délai au préalable.

Le système que nous simulons est un système à un degré de liberté, nous considérons que la liaison entre l'exosquelette et l'opérateur est rigide. Nous assimilons donc le système à la représentation Fig. 4.4. Sur la Fig. 4.5, le système est modélisé dans le bloc "Modélisation cinématique et dynamique". Nous modélisons le comportement du système nerveux central (SNC) dans le bloc "Modélisation SNC" et la réponse des muscles à une consigne dans le bloc "Modélisation groupe musculaire". Nous détaillons le contenu et les choix d'implémentation de ces trois blocs dans les sections suivantes.

#### 4.2.1.2 Groupe musculaire

L'objectif de cette section est de modéliser le comportement des muscles du bras (biceps et triceps) en fonction d'une intention de mouvement que nous représentons par un couple cible. La modélisation du comportement des muscles se base sur un modèle présent dans la librairie Simulink de Matlab, implémentée selon les travaux de [Haeufle et al., 2014]. Le modèle le plus utilisé dans la littérature est le modèle de Hill [Winters, 1990, Siebert et al., 2008]. Il est composé de trois éléments :

- Un élément contractile (CE), responsable de la génération de force
- Un élément élastique parallèle (PE), qui crée une force s'opposant à l'allongement du muscle lorsque le muscle est étiré sans contraction
- Un élément élastique série (SE), qui représente les structures tendineuses.

Le modèle que nous utilisons dérive du modèle de Hill et y ajoute en plus une composante visqueuse (SDE). Ce modèle prend comme entrée une activité musculaire et la transforme en force. Ce modèle a une tendance à surestimer la force développée lorsque l'activité musculaire est maximale [Haeufle et al., 2014]. De plus, il fait intervenir plusieurs

paramètres tels que la force maximale, la longueur optimale de l'élément contractile, et la longueur au repos de l'élément élastique série. Néanmoins, dans notre cas nous nous intéressons surtout au comportement général d'un muscle et il est donc cohérent de le choisir et d'utiliser les paramètres par défaut proposés. Notre boucle de simulation étant en couple nous utilisons deux gains en avant et après chaque modèle de muscle pour redimensionner les données :  $K_{couple \rightarrow activité}$  et  $K_{force \rightarrow couple}$ . Pour régler ces gains nous utilisons les données du chapitre 3, dans lequel un lever de charge de 5 kg, représente un couple à l'épaule d'environ 35 N.m pour une activité moyenne du deltoïde antérieur de 0.4 % RMC.

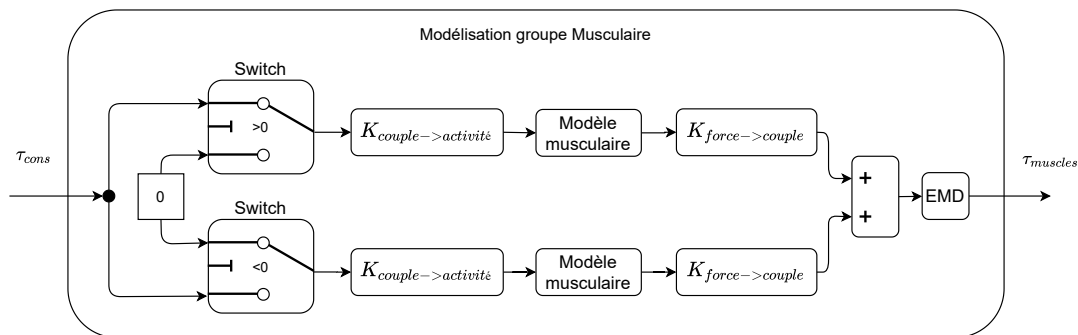


FIGURE 4.6 – Modèle du groupe musculaire

La paire d'interrupteurs en entrée sur la Fig. 4.6 permet de rediriger la consigne selon qu'elle est positive ou négative pour aller vers le bon muscle. Le fait de mettre une consigne de zéro lorsque le muscle n'est pas sollicité permet de ne pas négliger les effets de l'antagoniste lors d'un changement de direction.

#### 4.2.1.3 Modèle cinématique et dynamique

Pour implémenter le modèle dynamique, nous utilisons les équations 4.1 de [Bastide et al., 2018].

$$\begin{cases} M_r \ddot{\Theta}_r + b_r \dot{\Theta}_r + \tau_{FNL} + Q_r(\Theta_r) = \tau_r - \tau_i \\ M_h \ddot{\Theta}_h + J_h^t F_e + b_h \dot{\Theta}_h + Q_h(\Theta_h) = \tau_h + \tau_i \end{cases} \quad (4.1)$$

Nous considérons que la charge à porter, modélisée comme une masse ponctuelle située en bout de bras, est la seule source de force extérieure ( $J_h^t F_e = gm_M l_M \cos(\Theta)$ ). Dans le cas du système présenté sur la Fig. 4.4 et en considérant que les articulations du robot et de l'humain sont confondues, nous pouvons reformuler l'équation telle que :

$$\ddot{\Theta} = \frac{\tau_h + \tau_{rc} - b_h \dot{\Theta} - g(m_h l_h + m_M l_M) \cos(\Theta)}{M_h + M_r + M_M} \quad (4.2)$$

Avec :

$$\tau_r = \tau_{rc} + b_r \dot{\Theta} + \tau_{FNL} + m_r l_r g \cos(\Theta) \quad (4.3)$$

Cette décomposition de  $\tau_r$  fait la distinction entre ce que les outils de commande classiques permettent de compenser ( $b_r \dot{\Theta}$ ,  $\tau_{FNL}$  et  $m_r l_r g \cos(\Theta)$ ) et la contribution de notre système  $\tau_{rc}$ .

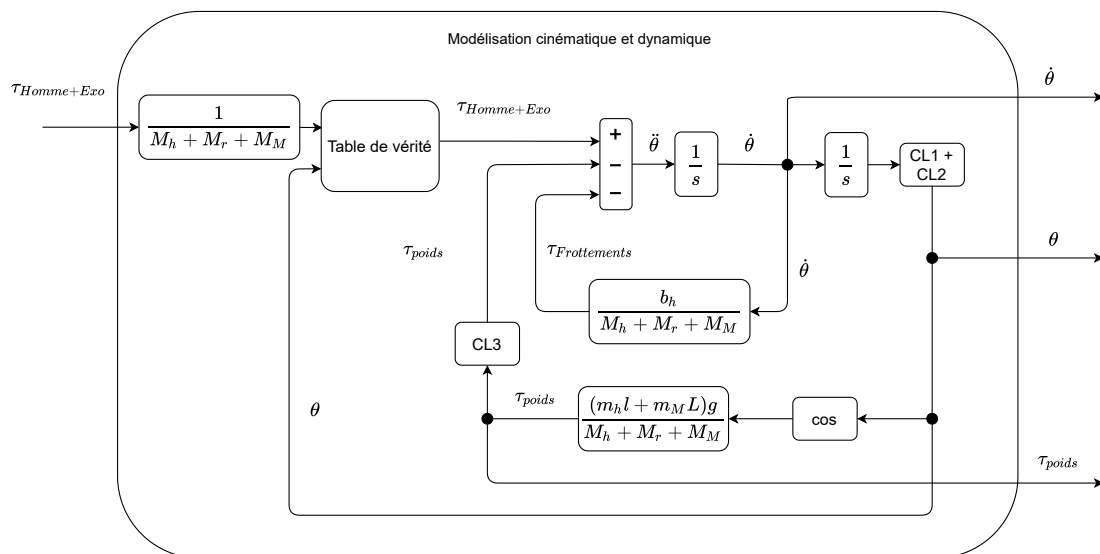


FIGURE 4.7 – Modèle cinématique et dynamique du système

Sur la Fig. 4.7, la table de vérité, couplée à la condition limite CL3, nous sert à imiter une situation où la charge est posée sur une table avant le lever. Cela assure que l'accélération initiale et la vitesse initiale restent à 0 et la position à  $-\frac{\pi}{4}$ , tant que  $\tau_{Homme+Exo}$  n'est pas suffisant pour soulever la charge. Les conditions limites CL1 et CL2 servent à définir les limites articulaires pour contraindre le mouvement entre  $-\frac{\pi}{4}$  et  $\frac{0.9\pi}{2}$  (équivalent aux butées articulaires réelles).

Les paramètres d'inerties du robot et de l'humain ont été calculés en considérant les segments comme des cylindres. Pour les masses et longueurs relatives à l'humain nous avons considéré les données anthropométriques de l'homme moyen [Winter, 2009]. La viscosité ou *damping*, représentée par le paramètre  $b_h$ , est mentionnée et étudiée dans la littérature mais moins évidente à déterminer. [Bennett et al., 1992] ont montré que la valeur de *damping* était imprécise lors du mouvement d'extension du coude. Ils ont

cependant estimé qu'elle était comprise entre 0,4 et 1 N.m.s/rad. Dans une étude de [Adewusi et al., 2012], la viscosité estimée pour le coude était de 25 N.m.s/rad et 8 N.m.s/rad pour l'épaule. Cette étude s'intéressait au comportement du bras face à des vibrations selon l'axe vertical en fonction de deux positions : angle du coude à 90° et bras tendu. On pourrait penser que le niveau de co-contraction a un impact sur la viscosité mais [Lee and Ashton-Miller, 2011] ont montré que celle-ci ne variait pas avec les changements d'intensité de co-contraction au niveau du coude. Dans ces travaux les valeurs estimées étaient entre 1 et 11 N.m.s/rad et concernaient des mouvements volontaires. Le même ordre de grandeur est trouvé par [Lacquaniti et al., 1993], avec des valeurs de 4 à 9 N.m.s/rad. Pour limiter de nombre de paramètres variables la viscosité est fixée à 6 N.m.s/rad, une valeur cohérente au vu des intervalles trouvés par les travaux mentionnés.

#### 4.2.1.4 Modélisation de la consigne musculaire (bloc SNC sur la Fig 4.5)

L'objectif de ce composant (Fig. 4.8) est de modéliser la consigne musculaire qui serait générée pour lever une charge à une position cible. Nous considérons qu'il y a deux objectifs simultanés : la compensation du poids de la charge et le suivi d'une trajectoire cible. La trajectoire cible est calculée en utilisant la théorie du minimum "jerk" [Flash and Hogan, 1985]. Pour cela nous considérons que le temps de mouvement est connu, nous choisissons 1,5 s qui est du même ordre que les premiers soulevés effectués par les participants lors de l'expérience précédente. La trajectoire de référence est obtenue en minimisant le *jerk*, qui est la dérivée temporelle de l'accélération, pendant le mouvement. La consigne de sortie est obtenue en additionnant le couple nécessaire pour compenser le poids de la charge et un couple de suivi de trajectoire calculé en utilisant un correcteur Proportionnel-Dérivé (PD).

#### 4.2.1.5 Résultats

Nous utilisons la simulation présentée pour chercher le lien entre le temps avant activation de l'utilisateur et le réglage du gain. Pour ce faire, pour chaque temps avant activation testé nous cherchons le gain limite avant instabilité  $K_{lim}$ . Nous réalisons des fenêtres de simulation de 10s. Nous savons que le couple utilisateur  $\tau_{muscles}$  doit se stabiliser autour de 0 une fois le mouvement réalisé (l'exosquelette compensant la charge), la position se stabilisant à la valeur cible (Fig. E.7 et E.8) . Comme critère de stabilité nous utilisons

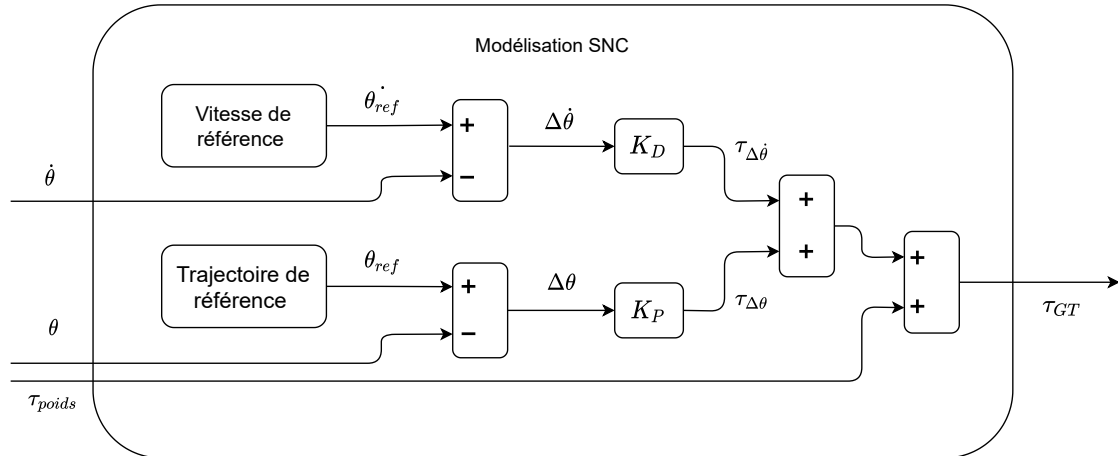


FIGURE 4.8 – Modélisation du SNC

donc l'intégrale du couple utilisateur  $\tau_{muscles}$  entre 5 et 10s, lorsque le mouvement est censé être terminé :

$$Stab_{index} = \int_5^{10} |\tau_{muscles}(t)| dt \quad (4.4)$$

Pour nos simulations nous faisons varier deux paramètres : le gain de l'intégrateur  $K$  de 4.5 à 8.2 avec un pas de 0.05 et le temps avant activation de l'utilisateur  $Tps_{rep}$  de 110 à 210ms avec un pas de 5ms. Les résultats sont présentés sur la Fig. 4.9. La valeur de  $Stab_{index}$  est tracée en fonction du gain de l'intégrateur du temps avant activation de l'utilisateur. La zone bleue basse correspond aux couples  $(K, Tps_{rep})$  pour lesquels le système arrive à se stabiliser. La zone jaune en hauteur correspond à la plage d'instabilité. Nous pouvons voir que la séparation entre les deux zones est bien marquée avec l'indicateur choisi.

L'intersection de la surface avec le plan  $Stab_{index} = 1000 N.m$  nous permet d'obtenir les points représentés sur la Fig 4.10. Ces points représentent les gains limite avant instabilité pour un  $Tps_{rep}$  donné. Nous faisons une régression polynomiale du second degré pour obtenir la courbe  $K_{lim} = f(tp_{s_{rep}})$  4.5 :

$$K_{lim} = 0.0379 \left( \frac{1}{tps_{rep}} \right)^2 + 0.2306 \frac{1}{tps_{rep}} + 3.0344 \quad (4.5)$$

Cette approximation présente une erreur relative de 1,1% et nous sert pour personnaliser le gain pour chaque utilisateur en fonction de leur temps avant activation. La méthode pour adapter le gain est la suivante. Nous avons le gain de confort  $K_{comfort\_exp}$




FIGURE 4.9 – Résultats de la simulation

d'un utilisateur expert. Nous estimons le temps avant activation de cet utilisateur expert et nous en déduisons son gain limite  $K_{lim\_exp}$ . Nous estimons le temps avant activation du nouvel utilisateur et son gain limite  $K_{lim\_user}$ . Le gain de confort du nouvel utilisateur est estimé tel que :

$$K_{comfort\_user} = K_{comfort\_exp} * \frac{K_{lim\_user}}{K_{lim\_exp}} \quad (4.6)$$

## 4.2.2 Évaluation du temps avant activation

### 4.2.2.1 Protocole

Dans cette section nous présentons les résultats d'une expérience préliminaire dont les objectifs sont doubles. D'une part, nous voulons évaluer le temps avant activation dans différentes situations. Et d'autre part, nous voulons mettre au point un protocole de mesure du temps de réaction dont le traitement peut être réalisé de manière automatique, pour que ce protocole puisse être inclus dans la phase de calibration du système.

L'expérience consiste à appliquer des échelons de force avec l'exosquelette aux partici-




FIGURE 4.10 – Relation entre gain limite avant instabilité et temps avant activation

pants tout en mesurant leur activité EMG avec le bracelet Myo. Nous testons le temps de réaction en deux positions différentes (Haute et Basse), avec deux directions différentes (vers le haut et vers le bas) ainsi qu'en charge ou en décharge. La charge est l'application soudaine d'un effort sur la main du participant et la décharge est le retrait soudain de cet effort. Sur la Fig. 4.11, nous avons représenté le déroulement d'un à-coup vers le haut.  $t_{min}$  est le temps minimum avant le déclenchement de la charge ou de la décharge,  $t_{rand}$  est une durée choisie aléatoirement à chaque fois, comprise entre 0 et 3 secondes, pour maintenir l'effet de surprise et empêcher les participants d'anticiper les à-coups. Les participants subissent 20 à-coups par position, 10 vers le haut et 10 vers le bas, mélangés aléatoirement.

#### 4.2.2.2 Résultats et discussion

Cinq personnes ont participé à cette expérience. Pour traiter les données nous avons deux approches, utiliser le signal cumulé des électrodes (eq. (2.10)), ou bien le signal individuel de chaque électrode. Nous avons calculé plusieurs indicateurs potentiels. Notre but est de trouver une mesure qui permettrait de distinguer les individus tout en ayant une faible variabilité au cours des différents essais et des différentes situations (direction,

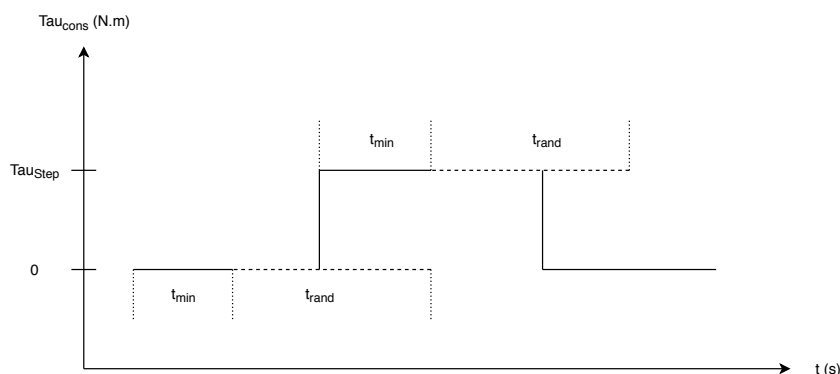


FIGURE 4.11 – Schéma d’une impulsion pour estimer le temps avant activation

position) pour une même personne. Les traitements sont réalisés entre le moment du déclenchement du changement (charge ou décharge) et une demi-seconde après (durée suffisante pour enregistrer l’activation musculaire quelque soit la personne).

Nous cherchons à trouver la pente la plus importante. Pour cela, nous calculons l’intégrale de la dérivée entre les changements de signe avec le signal EMG cumulé et filtré. Le début (Départ) et la fin (Pic  $EMG_f$ ) de cette pente sont considérés comme des indicateurs potentiels. Nous utilisons aussi le point de dérivé maximal de cette plus grande pente comme un autre indicateur (Dérivée max). Un exemple des ces indicateurs est présenté sur la Fig. 4.12.

Avec le signal EMG cumulé brut nous évaluons deux autres indicateurs. Le premier est la valeur maximale du signal ( $\text{Max } EMG_r$ ) après le déclencheur, toujours sur une fenêtre d’une demi-seconde. Le second est l’écart positif maximal entre le signal EMG à l’instant  $t$  et les cinq précédents échantillons ( $\Delta \text{Max } EMG_r$ ) (Exemple Fig.E.5).

Avec les signaux des capteurs traités de manière individuelle, nous utilisons le temps avant le déclenchement pour déterminer la valeur maximale au repos mesurée par ce capteur. Ensuite, nous déterminons l’instant après le déclenchement quand le signal dépasse la valeur max de repos de plus de 15% (cf. Fig 4.13). Nous utilisons cette valeur obtenue du capteur placé juste au-dessus du biceps (1 Capteur Biceps) comme un indicateur ainsi que la moyenne des valeurs obtenues des trois capteurs au dessus du biceps (3 Capteur Biceps) (Exemple Fig.E.6). Les calculs de ces indicateurs sont présentés ci-après.

Soient  $ti_{D+}$  et  $ti_{D-}$ , les instants de changement de signe de la dérivée du signal EMG cumulé filtré  $EMG_f$  de négatif vers positif et positif vers négatif respectivement.  $t_{trig}$  est l’instant du déclenchement de l’à-coup.  $tmax_{D+}$  et  $tmax_{D-}$  sont tels que :






FIGURE 4.12 – Indicateurs de temps avant activation extraits du signal  $EMG_f$ .




FIGURE 4.13 – Indicateur de temps avant activation extrait du signal  $EMG_{chan_i}$  d'un capteur seul

$$\int_{t_{maxD+}}^{t_{maxD-}} EMG_f . dt = \max_{ti \in [t_{trig}, t_{trig} + 0.5]} \left( \int_{ti_{D+}}^{ti_{D-}} EMG_f . dt \right) \quad (4.7)$$

Avec l'équation 4.7, nous pouvons faire le lien avec les indicateurs définis ci-avant de la manière suivante :

$$\begin{cases} \text{Départ} = t_{maxD+} \\ \text{Pic}EMG_f = t_{maxD-} \\ \text{Dérivé}max = \operatorname{argmax}_{t \in [\text{Départ}, \text{Pic}EMG_f]} \left( \frac{dEMG_f}{dt} \right) \end{cases} \quad (4.8)$$

Si on nomme  $EMG_r$  le signal EMG cumulé brut :

$$\begin{cases} \text{Max}EMG_r = \operatorname{argmax}_{t \in [t_{trig}, t_{trig} + 0.5]} (EMG_r) - t_{trig} \\ \Delta \text{Max}EMG_r = \\ \operatorname{argmax}_{t \in [t_{trig}, t_{trig} + 0.5]} (\text{Max}_{ti \in [t-5, t]} (EMG_r(t) - EMG_r(ti))) - t_{trig} \end{cases} \quad (4.9)$$

Soit  $EMG_{chan_i}$  le signal EMG brut d'un capteur du bracelet :

$$\text{MaxRest}_i = \max_{t \in [0, t_{trig}]} (\text{abs}(EMG_{chan_i})) \quad (4.10)$$

$$tReact_i = \operatorname{argmin}_{t \in [t_{trig}, t_{trig} + 0.5]} (\text{abs}(EMG_{chan_i}(t)) > 1.15 * \text{MaxRest}_i) - t_{trig} \quad (4.11)$$

Pour cette expérience le bracelet est toujours placé de telle sorte que le capteur 0 soit au-dessus du biceps donc :

$$\begin{cases} 1\text{CapteurBiceps} = tReact_0 \\ 3\text{CapteursBiceps} = \frac{1}{3}(tReact_0 + tReact_7 + tReact_1) \end{cases} \quad (4.12)$$

Parmi les indicateurs calculés ceux qui présentent la plus faible variabilité sont les "3 Capteurs Biceps" et "1 Capteur Biceps" (Voir tableau D.10 et D.11). L'indicateur "3 Capteurs Biceps" présente aussi l'intérêt de varier peu d'une situation à l'autre pour un même individu (Position et Direction). Et si on le moyenne sur les quatre situations pour

une même personne il permet de bien différencier les participants (Voir Tableau D.9).

## 4.3 Évaluation de la personnalisation du gain

### 4.3.1 Protocole

Les simulations présentées dans la section précédente nous ont permis de formuler une méthode d'adaptation du gain en fonction d'un critère objectif : le temps avant activation de l'utilisateur. Dans cette section nous évaluons l'impact de cette adaptation de manière expérimentale. Nous mettons en place un protocole expérimental pour comparer les effets de l'assistance avec un gain générique et un gain personnalisé. Les tests sont réalisés avec 10 participants (taille :  $177,2 \pm 8,4\text{cm}$  , poids :  $77,8 \pm 20,2\text{kg}$ , age :  $24,1 \pm 1,4$ ).

Pour chaque participant nous faisons la calibration réduite présentée dans la section 4.1, en y ajoutant 6 à-coups (3 vers le haut et 3 vers le bas) pour estimer le temps avant activation. La tâche à accomplir est la même que pour l'expérience précédente (section 3.3). Les participants réalisent 50 répétitions de la tâche avec chaque gain et une charge de 7 kg et les répétitions sont séparées en 5 séries de 10 répétitions. Avant chacune de ces deux situations les participants font 20 répétitions de la tâche sans assistance avec une charge de 2kg, c'est une situation de référence. Pour assurer un comportement uniforme de la part des participants l'exosquelette est fixé au sol et la position verticale des participants par rapport au robot est ajustée grâce à des marchepieds. Une fois les deux modes de commande utilisés, ils répondent à un questionnaire de ressenti divisé en trois sections : deux sections avec des questions relatives à chaque mode de commande et une section avec des questions portant sur la comparaison des deux modes de commande.

Pour évaluer l'activité musculaire nous utilisons les mêmes électrodes que dans la section 3.3.1, placées sur les muscles suivant : biceps, triceps, deltoïde, trapèze, érecteur du rachis.

Pour évaluer la précision des participants au cours de la réalisation de la tâche nous traçons en temps réel la courbe de la position articulaire de l'épaule avec des repères correspondant aux positions haute et moyenne. Cela permet de visualiser clairement et sans influence du point de vue la position actuelle et les positions cibles (Fig. 4.14).

Un changement notable au niveau du matériel entre ces expérimentations et celles du chapitre 3 est l'utilisation d'une nouvelle interface physique entre l'exosquelette et l'utili-




FIGURE 4.14 – Affichage des indicateurs

sateur (voir Fig. 4.15). Nous n'utilisons plus une dragonne souple avec une attache souple elle aussi, ce qui pouvait parfois engendrer des à-coups lors du lever. En remplacement, nous utilisons une attache rigide fixée au bout du bras de l'exosquelette avec deux liaisons pivots. L'objectif est de supprimer le délai qui peut être introduit par le temps de mise en tension des parties souples de l'ancienne interface.



FIGURE 4.15 – Comparaison de la nouvelle (à droite) et de l'ancienne (à gauche) attache

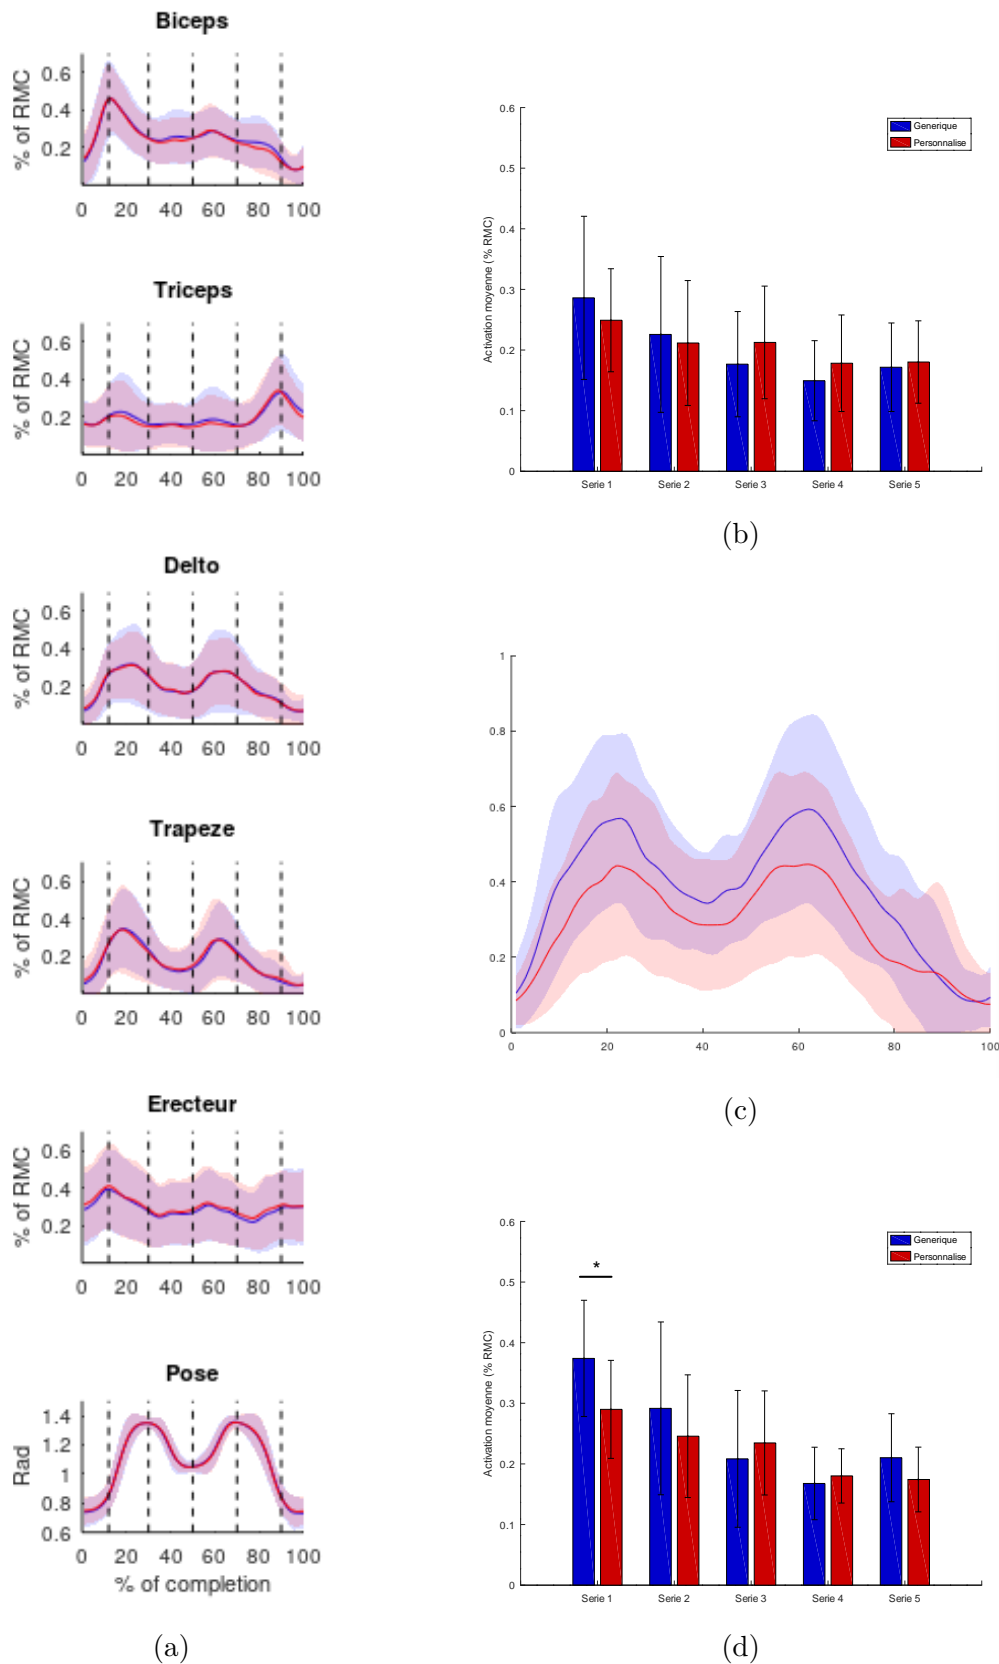


FIGURE 4.16 – Résultats obtenus avec les signaux EMG : (a) Activité musculaire moyenne avec le gain générique en bleu et avec le gain personnalisé en rouge, (b) Activité moyenne du deltoïde pour les 10 participants au cours de chaque série, (c) Activité moyenne du deltoïde pour la première série de 10 (pour le gain générique en bleu et en rouge pour le gain personnalisé) et (d) Activité moyenne du deltoïde antérieur pour la première situation de chaque participants (5 avec le mode personnalisé et 5 avec le mode générique)

## 4.3.2 Résultats et discussion

### 4.3.2.1 Activité musculaire

Les activités moyennes pour chaque muscle en fonction du pourcentage de complétion de la tâche sont représentées sur la Fig. 4.16a. Les activités musculaires sont exprimées en pourcentage de la contraction relative maximale (RMC), de manière similaire au chapitre précédent. La position articulaire est aussi représentée pour mettre en parallèle les étapes de la tâche et l'activité musculaire. Le tracé bleu représente la moyenne pour tous les participants et pour les cinq séries de 10 mouvements lorsque le gain générique est utilisé. La zone bleue représente l'écart-type. Les couleurs rouges représentent les mêmes valeurs mais concernant les situations avec le gain personnalisé. Nous pouvons remarquer qu'il n'y a pas de différence d'activité musculaire entre gain personnalisé et gain générique sur l'ensemble des répétitions. On repère bien un pic d'activité du biceps juste avant le mouvement et un pic d'activation triceps à la fin de la tâche qui permettent de réguler l'assistance fournie.

Nous observons les activations moyennes pour tous les participants par séries de dix répétitions pour analyser le facteur d'adaptation des candidats. Les activités moyennes du deltoïde sont représentées sur l'histogramme 4.16b, on peut remarquer une diminution de l'activité moyenne au cours des répétitions. Les p-valeurs obtenues à la suite d'un test de Student unidirectionnel (*one-tail*) sont rapportées dans les tableaux 4.6. Nous pouvons voir que pour les deux situations il y a une différence significative de l'activité moyenne du deltoïde entre la première série et les deux dernières. L'activité du deltoïde passe de  $28.6 \pm 13.5\%$  RMC à  $17.2 \pm 7.3\%$  RMC avec le gain générique et de  $24.9 \pm 8.5\%$  RMC à  $18.0 \pm 6.8\%$  RMC avec le gain personnalisé. On observe une situation similaire pour le trapèze (Fig. E.9). Cependant, la différence est significative seulement pour la situation avec le gain généralisé entre la première et la cinquième série (de  $22.1 \pm 9.0\%$  RMC à  $14.7 \pm 6.6\%$  RMC,  $p\_value < 0.05$ ).

Maintenant, nous nous intéressons exclusivement à la toute première série de répétitions pour chaque participant. Pour cinq d'entre eux cela correspond à la situation avec le gain générique et pour les autres, avec le gain personnalisé. Avec ces considérations nous remarquons qu'il y a une différence significative au niveau de l'activité moyenne du deltoïde ( $p\_value < 0.05$ ). Nous pouvons voir cette différence sur le graphique Fig. 4.16c ( $37.4 \pm 9.5\%$  RMC et  $29.0 \pm 8.0\%$  RMC). Par contre, cette différence ne se maintient

Série	1	2	3	4	5
1		0.15955	0.02229	0.00496	0.01479
2			0.16524	0.05603	0.13104
3				0.21952	0.44463
4					0.75782

(a) Gain générique

Série	1	2	3	4	5
1	0	0.19294	0.18523	0.03506	0.03025
2	0	0	0.50862	0.21415	0.21592
3	0	0	0	0.19331	0.19297
4	0	0	0	0	0.52356

(b) Gain personnalisé

TABLE 4.6 – Tableau des p-valeurs obtenues suite à des tests de Student entre les séries de répétitions


pas au cours des séries. Nous pouvons le constater en regardant l'activité moyenne de chaque série pour la première situation réalisée par les participants (Fig. 4.16d). A titre d'exemple, l'activité moyenne de la cinquième série est tracée sur la Fig. E.10.

### 4.3.2.2 Précision

Avec les données articulaires de l'exosquelette nous pouvons aussi évaluer la précision des participants pour atteindre chacune des trois positions. Si on considère l'ensemble des séries il n'y a pas de différence significative entre l'utilisation des deux gains comme nous pouvons le voir sur la Fig. 4.17a. De manière similaire à l'activité EMG, nous pouvons observer une amélioration de la performance au cours des répétitions. Cette amélioration est statistiquement significative entre la première et la cinquième série, pour les deux occurrences où la position haute est visée et dans les deux situations. La précision varie de  $2.02 \pm 0.74$  cm à  $1.59 \pm 0.33$  cm avec le gain générique et de  $2.29 \pm 0.71$  cm à  $1.59 \pm 0.29$  cm pour le gain personnalisé, lors de la première visée de la cible haute. Et elle va de  $1.97 \pm 1.14$  cm à  $1.27 \pm 0.28$  cm pour le gain générique et de  $1.71 \pm 0.87$  cm à  $1.26 \pm 0.47$  pour le gain personnalisé, lors de la seconde visée de la cible haute (Figs. 4.17b et 4.17d). Nous pouvons aussi remarquer que l'écart-type diminue aussi fortement.


### 4.3.2.3 Questionnaire

Nous utilisons un questionnaire de ressenti pour comparer l'impact des différents gains sur les utilisateurs [Wioland et al., 2019] [Maurice et al., 2020]. Le questionnaire est composé de deux types de questions : des questions sur l'assistance sont posées à la fin de chacune des situations et des questions sur la comparaison des deux situations, posées à la fin des expériences. Les questions sont notées entre 0 et 10, 5 étant la réponse neutre lorsque cela est pertinent. Nous n'expliquons pas aux participants dans quel ordre interviennent les situations ni quelles peuvent être les différences entre les deux situations,



(a) Précision moyenne pour chaque position cible

(b) Précision pour chaque série, pour la première position



(c) Précision pour chaque série, pour la deuxième position

(d) Précision pour chaque série, pour la troisième position

FIGURE 4.17 – Résultats obtenus avec les positions articulaires

pour éviter d'introduire un biais expérimental. Pour la même raison, au moment de poser les questions nous utilisons les termes de "Situation 1" et "Situation 2", en fonction de l'ordre chronologique pour les participants.

Les réponses moyennes et leurs écart-types sont reportées sur la Fig. 4.18. Ces questions sont divisées en trois catégories : questions générales, questions sur les affects et questions sur l'évolution au cours du temps. Nous distinguons aussi deux sous-catégories : les questions positives (exemple : "Je trouve agréable de travailler avec l'assistance") et les questions négatives (exemple : "Je trouve angoissant de travailler avec l'assistance"). La liste détaillée des questions est reportée dans le tableau D.12. Pour analyser les réponses au questionnaire nous utilisons le test de Wilcoxon de rang signé. En comparant les réponses pour chaque situation, seule la première question présente une différence statistiquement






FIGURE 4.18 – Réponses aux questions générales du tableau D.12. En bleu pour le gain générique et en rouge pour le gain personnalisé, les lignes pointillées verticales séparent les différentes catégories de question ainsi que les questions positives (+) et les questions négatives (-)

significative. Cette question porte sur la facilité de prise en main de l'assistance. Les participants trouvent l'assistance avec gain personnalisé légèrement plus facile à prendre en main.

Les réponses aux questions de comparaison entre les deux modes de commande sont sur la Fig. 4.19. Pour les questions 2 à 7 du tableau 4.7, la réponse 5 indique que le participant ne ressent pas de différence entre les deux situations sur le point en question. Il y a un écart significatif avec cette valeur neutre pour deux questions, celle concernant la facilité de prise en main (3) et celle concernant la concentration requise pour l'utilisation de l'assistance (5). Les moyennes des résultats sont  $5.8 \pm 1.1$  et  $4.5 \pm 0.8$ , respectivement. Dans les deux cas l'écart est à l'avantage de l'assistance avec le gain personnalisé. Il est jugé plus facile à prendre en main, ce qui rejoint la différence remarquée dans la première partie du questionnaire et elle requiert moins de concentration.

1	J'ai ressenti une différence entre DZI générique et DZI perso
2	Je trouve que je contrôle mieux mes mouvements avec DZI perso que DZI générique
3	Je trouve que DZI perso est plus facile à prendre en main que DZI générique
4	Je trouve que que je suis plus libre de mes mouvements avec DZI perso que avec DZI générique
5	Je trouve que que j'ai besoin de plus de concentration avec DZI perso que avec DZI générique
6	Je trouve que que DZI perso est plus pertinent que DZI générique
7	Je préfère travailler avec DZI perso que DZI générique

TABLE 4.7 – Les questions sur la comparaison des deux situations




FIGURE 4.19 – Réponses aux questions de comparaison du tableau 4.7

#### 4.3.2.4 Synthèse

En croisant les résultats des sections précédentes nous pouvons faire deux constats. D'une part, d'une manière générale, l'assistance mise au point est facile à prendre en main. Les réponses aux deux premières questions du tableau D.12 confirment ce ressenti de la part des participants. Les critères d'évaluation objectifs permettent de renforcer cette idée. Au cours des deux situations nous observons une décroissance de l'activité du deltoïde antérieur ainsi qu'une amélioration de la précision en ce qui concerne la visée de la cible haute.

D'autre part, nous pouvons conclure que la personnalisation du gain favorise la prise en main du système de contrôle. En effet, sur la Fig. 4.18, la seule question qui présente une différence significative entre les différents gains utilisés concerne la facilité de prise

en main. De plus, dans les questions de comparaison des deux situations ici encore, lors de l'utilisation du gain personnalisé, le système est jugé plus facile à prendre en main et nécessitant moins de concentration. Ces réponses sont supportées par l'activité du deltoïde antérieur lors du premier contact avec le système d'assistance. Celle-ci est significativement plus faible pour les cinq participants commençant avec le gain personnalisé que pour les cinq commençant avec le gain générique.

## 4.4 Conclusion

Dans ce chapitre nous avons proposé des modifications sur deux aspects du système d'assistance. D'un côté, une simplification et une réduction de l'étape de calibration, pour rendre le système plus facile à mettre en place. Et d'autre part, nous avons étudié l'impact de la personnalisation du paramètre de commande sur les utilisateurs.

Pour le premier point nous avons tiré parti de la base de données récoltées avec les deux premières études. L'apprentissage sur la base de données, avec une étape d'affinage sur un échantillon faible de données du participant, est une alternative au moins aussi précise que la procédure présentée dans le chapitre 2. Cette approche présente l'avantage de nécessiter peu de nouvelles données pour entraîner la détection de direction à un nouvel utilisateur. En couplant cette méthode avec une calibration du modèle de l'intensité basée sur une contraction volontaire et progressive vers les maxima, nous avons réduit le temps d'enregistrement nécessaire pour la calibration du module de détection d'intention complet de 2 minutes 30 secondes à 15 secondes.

Concernant la personnalisation de la commande, nous avons implémenté une simulation de la boucle d'interaction entre l'utilisateur et l'exosquelette commandé avec le système mis au point. L'objectif était d'étudier l'influence du gain de l'intégrateur et du temps avant activation de l'utilisateur sur la stabilité du système. Nous avons pu mettre en évidence le lien entre gain limite avant instabilité et temps avant activation de l'utilisateur. Nous avons ensuite mis au point une méthode pour déterminer le temps avant activation de l'utilisateur afin d'adapter le gain en fonction. Enfin, nous avons fait participer dix personnes pour comparer les effets de l'utilisation d'un gain générique et un gain personnalisé. Cette expérience nous permet de constater que le système est assez intuitif puisque nous observons une amélioration significative au cours des répétitions. Nous avons

aussi pu voir que l'activité du deltoïde antérieur est plus faible en commençant avec le gain personnalisé. Cela permet de dire, en accord avec les résultats du questionnaire, que la personnalisation du gain facilite la prise en main du système.

D'autres travaux se sont intéressés à la personnalisation de systèmes de commande. Dans le cadre de la rééducation à la marche, il est important de prendre en compte les spécificités inter-individuelles afin de proposer une assistance pertinente et adaptée [Rose et al., 2020, Chinimilli et al., 2019]. Yin et al. ont proposé une méthode d'adaptation de la commande d'un exosquelette de cheville. L'approche proposée utilise un modèle biomécanique qui est affiné en ligne à l'aide de logique floue [Yin et al., 2019]. La personnalisation de la commande a aussi été appliquée dans le domaine de la téléopération. Yang et al. exploitent le signal EMG afin de d'adapter les gains de la commande en ligne [Yang et al., 2017]. Yang et al. proposent une approche personnalisée en deux temps : (i) une suppression des tremblements de l'utilisateur grâce à un SVM et (ii) une modification du gain en ligne basée sur l'activité musculaire de l'utilisateur. Les auteurs montrent que cette approche améliore les performances de la commande par rapport à des méthodes conventionnelles. Cette amélioration est caractérisée par une erreur RMS réduite et un retour d'effort moins important. Nos travaux et nos résultats dans ce chapitre s'alignent avec l'objectif général de la personnalisation, qui apparaît dans les travaux cités ci-avant, et qui serait : "une amélioration des interactions homme-robot par la prise en compte des différences inter-individuelles".

On peut aussi aborder une autre approche pour exploiter la simulation. Plutôt que d'envisager la personnalisation de la commande, nous pouvons utiliser la simulation pour définir un gain limite universel qui ne présenterait aucun risque d'instabilité, quelque soit l'utilisateur. Les réponses aux questions générales concernant la situation avec le gain générique montrent une réception plutôt favorable de la part des participants. Cela veut dire que le gain générique, bien que n'étant pas le plus adapté, convient et permet de réaliser la tâche. Nous avons donc le choix entre améliorer l'intuitivité du système ou simplifier la calibration.

Enfin, nous avons proposé une méthode d'adaptation du gain basée sur des résultats de simulation. Une expérimentation complémentaire pourrait être de mesurer les temps avant activation des participants et de les laisser régler le gain selon leur préférence. Cela permettrait de potentiellement confirmer notre proposition de réglage ou de proposer une

règle de paramétrage empirique en établissant une relation entre le temps avant activation et le gain choisi.

# Conclusions

---

## 5.1 Contributions

L'objectif principal de cette thèse était de proposer et d'étudier une commande intuitive d'un exosquelette actif, permettant d'assister un opérateur dans des tâches de port de charges, incluant les phases de prise et de dépose de la charge. Afin, d'apporter le côté intuitif, nous nous sommes orientés vers des solutions basées sur la détection de l'intention de l'utilisateur. Après avoir passé en revue les différentes alternatives possibles pour capter les intentions de l'utilisateur, nous avons opté pour les signaux électromyographiques.

Les signaux EMG sont spécifiques à chaque individu, ils peuvent s'apparenter à un bruit d'amplitude et fréquence variables, et dépendent aussi du positionnement sur le corps de l'utilisateur. Aussi, nos premiers travaux ont été de : (i) mettre au point un système de traitement pour rendre le signal EMG exploitable dans le cadre de la commande d'un exosquelette et (ii) de proposer une méthode de calibration pratique et rapide pour tenir compte du contexte industriel envisagé. Dans le chapitre 2, nous avons présenté nos choix pour implémenter un module de détection d'intention. Une approche hybride, composée de deux parties, a été conçue. Un modèle fait le lien entre le couple déployé et l'activité musculaire afin de rendre la sortie du module indépendante de l'utilisateur. Un réseau de neurones artificiels permet de discriminer parmi les différentes actions possibles au niveau du coude afin de déterminer la direction du mouvement voulue. Le système a été testé avec 7 participants et, il présentait une précision du même ordre de grandeur que ce qui figurait dans la littérature. L'apport de notre méthode concerne essentiellement l'aspect pratique de la mise en place et de l'utilisation d'un système EMG pour l'estimation d'un couple.

Dans le chapitre 3, nous avons proposé une stratégie de commande d'un exosquelette de membres supérieurs pour assister au port de charges de masse inconnue. Assister

l'utilisateur sans connaître la charge à transporter autorise une plus grande flexibilité d'utilisation du système (il n'y a pas besoin de référencer toutes les charges potentielles). L'objectif principal était de reproduire le comportement d'une assistance de compensation par modèle de gravité classique, mais en se privant de la connaissance du poids de la charge. Le signal EMG avait déjà été utilisé dans le cadre de la commande d'exosquelette pour l'augmentation de force de l'utilisateur. La commande de type proportionnel est une méthode répandue mais celle-ci ne permet pas d'avoir une situation où le robot fournirait une assistance permettant le repos musculaire de l'utilisateur, tout en permettant une assistance fluide, sur des tâches dynamiques. C'est pourquoi nous avons implémenté un contrôleur de type intégrateur. La valeur de consigne était nulle, représentant l'objectif de soulager l'utilisateur de tout effort. Le système d'assistance que nous avons proposé a été comparé à une compensation par modèle de gravité classique et à une situation sans assistance sur une tâche de lever de charge. Dix utilisateurs novices ont participé à l'évaluation et nous avons pu mettre en évidence deux points. Tout d'abord, notre système induisait une activité moyenne équivalente à celle induite avec la compensation par modèle de gravité classique. Ensuite, les situations avec assistance étaient caractérisées par une activité significativement réduite pour le deltoïde antérieur, l'érecteur du rachis et le biceps par rapport à la situation sans assistance. Nous avons vu dans le chapitre 1 que les efforts importants et/ou répétés peuvent être une cause d'apparition des TMS et que ceux-ci touchaient en grande partie les membres supérieurs. L'assistance proposée permet donc de réduire ce facteur de risque pour le coude et l'épaule. Par ailleurs, notre approche étant adaptative, le système ne sur-sollicite pas les muscles antagonistes, comme cela serait le cas avec un exosquelette passif.

Le système a été conçu en considérant une utilisation industrielle. Afin de correspondre mieux à ce contexte, nous avons ensuite souhaité améliorer notre système avec deux objectifs : (i) rendre le système plus pratique vis-à-vis de son déploiement et (ii) augmenter la facilité de prise en main du système par de nouveaux utilisateurs en réduisant le temps d'apprentissage (c'est-à-dire améliorer l'aspect intuitif du système). Nous avons exploré ces deux axes dans le chapitre 4. Pour améliorer l'aspect pratique de notre système nous avons décidé d'exploiter les capacités de généralisation des réseaux de neurones et de créer une base de données d'entraînement avec les données de plusieurs utilisateurs, récoltées au cours des premières expériences. Grâce à cela nous avons réduit la quantité de don-

nées nouvelles nécessaires pour calibrer le système de détection d'intention. En combinant cette base de données avec une technique d'affinage de l'apprentissage nous avons pu réduire le temps d'enregistrement des données de calibration à 15 secondes. D'autre part, nous avons évalué l'impact de la personnalisation du gain de l'intégrateur. Comme critère de personnalisation nous avons choisi le temps avant activation, que nous avons défini comme le délai entre une perturbation et la réponse à cette perturbation, perçue au niveau du signal EMG. L'idée était que ce temps de réponse est lié au temps que l'utilisateur met à s'adapter aux changements d'assistance et peut donc influencer sur la stabilité de la boucle d'interaction exosquelette-utilisateur. Pour déterminer l'influence du temps avant activation et du gain sur le système nous avons implémenté une simulation de la boucle d'interaction dans le cas d'un lever de charge. A partir des résultats de la simulation nous avons pu proposer une méthode d'adaptation du gain en fonction de l'utilisateur. Nous avons ensuite mis en place un protocole expérimental afin d'évaluer l'influence de cette adaptation du gain. Ce protocole a impliqué 10 participants novices qui ont dû effectuer des répétitions d'une tâche de lever de charge dans deux situations : avec un gain générique et avec un gain personnalisé. Le nombre de répétitions était plus important que l'expérience précédente pour pouvoir observer l'évolution au cours du temps de nos critères d'observation (précision et activité EMG). Nous avons pu observer une diminution de l'activité du deltoïde antérieur au cours des répétitions pour chaque situation. De manière similaire les participants gagnaient en précision au cours des répétitions. En observant la série de répétitions correspondant au premier contact avec l'assistance (générique pour cinq personnes et personnalisée pour les cinq autres), nous avons pu remarquer une activité significativement plus faible dans le cadre de l'assistance avec gain personnalisé. Ce résultat, associé aux résultats du questionnaire de comparaison nous permet de conclure que la personnalisation du gain facilite la prise en main de l'assistance et donc améliore son aspect intuitif. Les résultats de la simulation et des questions de ressenti générales ont permis de formuler une interprétation alternative. Même si la personnalisation du gain améliore la prise en main du système, les participants ont pu réaliser la tâche avec le gain générique et ont été globalement satisfaits par l'assistance. Ce qui permet de conclure qu'il est possible de choisir un gain convenant à tous les utilisateurs, si le souhait est de simplifier la procédure de calibration.

Pour résumer, nous avons proposé et validé un système de pilotage d'exosquelette



permettant d'assister un utilisateur au port de charges de masse inconnue. Ce système est basé sur l'utilisation des signaux EMG et une méthode de calibration permet d'assurer le bon fonctionnement du système pour un nouvel utilisateur. Enfin des travaux sur la personnalisation du système ont permis de mettre en valeur deux applications possibles : favoriser une calibration courte avec un système générique ou bien améliorer l'intuitivité du système en ajoutant une étape à la calibration. Ces travaux permettent d'envisager des applications concrètes, comme par exemple dans le secteur de la logistique où les charges à manipuler sont variées.

## 5.2 Perspectives

Au cours de ces travaux de recherche, nous avons utilisé l'exosquelette de membres supérieurs BHV2. Il avait deux caractéristiques importantes : un seul degré de liberté actionné par bras et une architecture dite réversible, ou transparente. Cet exosquelette était utilisé pour assister un utilisateur lors du port de charges.

Le premier axe de poursuite de ces travaux concernerait la personnalisation de la commande. Une approche complémentaire à notre méthode basée simulation pourrait être de mesurer les temps avant activation des participants et de les laisser régler le gain selon leur préférence. Les résultats d'une telle étude permettrait d'établir un lien entre gain choisi et temps avant activation. Ce lien pourrait permettre de valider la personnalisation utilisant la simulation proposée dans le chapitre 4.

Ensuite, il pourrait être intéressant de valider notre stratégie d'assistance avec un exosquelette possédant plusieurs DDL actionnés. Dans le cadre d'une commande en effort cartésienne notre approche serait responsable de la compensation de la charge sur l'axe vertical.

De plus, la commande conçue ne permet la commande que d'un seul DDL. Pour améliorer la versatilité de cette approche et contrôler plus de DDL, il faudrait être capable d'acquérir plus d'informations. Pour cela, des capteurs supplémentaires seraient nécessaires. Des solutions de capteurs EMG haute définition intégrés dans du textile (ex : Mshirt de Myontec) pourraient permettre d'envisager une mesure de l'activité musculaire au niveau de l'épaule, rapide et facile à mettre en place.

D'autre part, l'utilisation d'un exosquelette permet de s'affranchir des problèmes liés à

la préhension de la charge. En contrepartie, nécessairement, l'assistance fournie ne peut pas soulager les doigts (ni les poignets). Il serait pertinent d'étudier la validité de notre système de commande avec un cobot. Un cas d'application de type "troisième bras" permettrait l'utilisateur de lâcher la charge si celle-ci est compensée correctement. Dans ce contexte l'utilisateur n'aurait pas de retour direct sur les efforts appliqués par le robot et il serait peut-être alors nécessaire de fournir des solutions alternatives pour avoir un retour (ex : un retour haptique par vibration, cf. myotact).

Enfin, notre système a été implémenté et testé avec un exosquelette transparent. Pour envisager une portabilité de la stratégie d'assistance à plus de robots, il serait nécessaire d'en observer le fonctionnement avec un système non transparent, afin de savoir si cela fait partie des pré-requis indispensables à la stabilité et à la performance du système. En effet, le risque est alors de manquer de dynamique pour compenser efficacement les frottements.

Atteindre ces objectifs de recherche nous rapprocherait de la possibilité de concevoir un système d'assistance intuitif pour la réalisation de tâches complexes, avec un exosquelette ou un cobot.

# Communications scientifiques

---

## Conférences internationales avec comité de revue

Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Controlling an exoskeleton with emg signal to assist load carrying: a personalized calibration. In *2019 International Conference on Mechatronics, Robotics and Systems Engineering (MoRSE)*, pages 246–252. IEEE, 2019

Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Controlling an upper-limb exoskeleton by emg signal while carrying unknown load. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, pages 9107–9113. IEEE, 2020

## Brevets

Franck Geffard and Benjamin Treussart. Patent: Method for controlling an exoskeleton. 2020. WO2019EP85731 20191217

## Séminaires nationaux

Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Poster : étude et conception d’un système de pilotage intuitif d’un cobot pour la réalisation de tâches complexes. In *Journée FéDeV 2018*, a

Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Présentation : Controlling an upper-limb exoskeleton by emg signal while carrying unknown load. In *Journée FéDeV 2019*, b

Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Présentation : Personnalisation d’un système de contrôle d’exosquelette de membre supérieur basé sur le signal emg. In *Journée FéDeV 2020*, c

Ashley Hill, Clément Rolinat, Benjamin Treussart, and Franck Geffard. Présentation : Ia et robotique au cea. In *Journée ROBOTIQUE et INTELLIGENCE ARTIFICIELLE*, 2020

# Bibliographie

---

- Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Ian Goodfellow, Andrew Harp, Geoffrey Irving, Michael Isard, Yangqing Jia, Rafal Jozefowicz, Lukasz Kaiser, Manjunath Kudlur, Josh Levenberg, Dandelion Mané, Rajat Monga, Sherry Moore, Derek Murray, Chris Olah, Mike Schuster, Jonathon Shlens, Benoit Steiner, Ilya Sutskever, Kunal Talwar, Paul Tucker, Vincent Vanhoucke, Vijay Vasudevan, Fernanda Viégas, Oriol Vinyals, Pete Warden, Martin Wattenberg, Martin Wicke, Yuan Yu, and Xiaoqiang Zheng. TensorFlow : Large-scale machine learning on heterogeneous systems, 2015. URL <https://www.tensorflow.org/>. Software available from tensorflow.org.
- Sara Abbaspour, Maria Lindén, Hamid Gholamhosseini, Autumn Naber, and Max Ortiz-Catalan. Evaluation of surface emg-based recognition algorithms for decoding hand movements. *Medical & Biological Engineering & Computing*, 58(1) :83–100, 2020.
- Mohammad Abdoli-e and Joan M Stevenson. The effect of on-body lift assistive device on the lumbar 3d dynamic moments and emg during asymmetric freestyle lifting. *Clinical Biomechanics*, 23(3) :372–380, 2008.
- Mohammad Abdoli-E, Michael J Agnew, and Joan M Stevenson. An on-body personal lift augmentation device (plad) reduces emg amplitude of erector spinae during lifting tasks. *Clinical Biomechanics*, 21(5) :456–465, 2006.
- Mohammad Abdoli-Eramaki, Joan M Stevenson, Susan A Reid, and Timothy J Bryant. Mathematical and empirical proof of principle for an on-body personal lift augmentation device (plad). *Journal of biomechanics*, 40(8) :1694–1700, 2007.
- S Adewusi, S Rakheja, and P Marcotte. Biomechanical models of the human hand-arm to simulate distributed biodynamic responses for different postures. *International Journal of Industrial Ergonomics*, 42(2) :249–260, 2012.
- Mark A Aizerman. Theoretical foundations of the potential function method in pattern recognition learning. *Automation and remote control*, 25 :821–837, 1964.

- Arash Ajoudani, Andrea Maria Zanchettin, Serena Ivaldi, Alin Albu-Schäffer, Kazuhiro Kosuge, and Oussama Khatib. Progress and prospects of the human–robot collaboration. *Autonomous Robots*, pages 1–19, 2018.
- Mariam Al Harrach, Vincent Carriou, Sofiane Boudaoud, Jeremy Laforet, and Frederic Marin. Analysis of the semg/force relationship using hd-semg technique and data fusion : A simulation study. *Computers in biology and medicine*, 83 :34–47, 2017.
- Sebastian Amsuess, Ivan Vujaklija, Peter Goebel, Aidan D Roche, Bernhard Graimann, Oskar C Aszmann, and Dario Farina. Context-dependent upper limb prosthesis control for natural and robust use. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 24(7) :744–753, 2015.
- Marcelo H Ang, Wei Lin, and Ser-Yong Lim. A walk-through programmed robot for welding in shipyards. *Industrial Robot : An International Journal*, 1999.
- P. K. Artemiadis and K. J. Kyriakopoulos. Emg-based control of a robot arm using low-dimensional embeddings. *IEEE Transactions on Robotics*, 26(2) :393–398, 2010. doi: 10.1109/TRO.2009.2039378.
- Panagiotis Artemiadis. Emg-based robot control interfaces : past, present and future. *Advances in Robotics & Automation*, 1(02) :10–12, 2012.
- Panagiotis K Artemiadis and Kostas J Kyriakopoulos. An emg-based robot control scheme robust to time-varying emg signal features. *IEEE Transactions on Information Technology in Biomedicine*, 14(3) :582–588, 2010a.
- Panagiotis K Artemiadis and Kostas J Kyriakopoulos. An emg-based robot control scheme robust to time-varying emg signal features. *IEEE Transactions on Information Technology in Biomedicine*, 14(3) :582–588, 2010b.
- Hamza Baali, Aida Khorshidtalab, Mostefa Mesbah, and Momoh JE Salami. A transform-based feature extraction approach for motor imagery tasks classification. *IEEE journal of translational engineering in health and medicine*, 3 :1–8, 2015.
- Simon Bastide, Nicolas Vignais, Franck Geffard, and Bastien Berret. Interacting with a “transparent” upper-limb exoskeleton : A human motor control approach. In *2018*

- IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 4661–4666. IEEE, 2018.
- Haris Begovic, Guang-Quan Zhou, Tianjie Li, Yi Wang, and Yong-Ping Zheng. Detection of the electromechanical delay and its components during voluntary isometric contraction of the quadriceps femoris muscle. *Frontiers in physiology*, 5, 2014.
- Alim Louis Benabid, Thomas Costecalde, Andrey Eliseyev, Guillaume Charvet, Alexandre Verney, Serpil Karakas, Michael Foerster, Aurélien Lambert, Boris Morinière, Neil Abroug, et al. An exoskeleton controlled by an epidural wireless brain–machine interface in a tetraplegic patient : a proof-of-concept demonstration. *The Lancet Neurology*, 18(12) :1112–1122, 2019.
- DJ Bennett, JM Hollerbach, Y Xu, and IW Hunter. Time-varying stiffness of human elbow joint during cyclic voluntary movement. *Experimental Brain Research*, 88(2) : 433–442, 1992.
- Niels Birbaumer, Thomas Elbert, Anthony G Canavan, and Brigitte Rockstroh. Slow potentials of the cerebral cortex and behavior. *Physiological reviews*, 70(1) :1–41, 1990.
- Robert Bogue. Exoskeletons—a review of industrial applications. *Industrial Robot : An International Journal*, 2018.
- Lester S Borden Jr and Paul M Kozlowski. Robotic-assisted laparoscopic radical prostatectomy : an objective assessment and review of the literature. *TheScientificWorld-JOURNAL*, 6, 2006.
- Thomas S Buchanan, David G Lloyd, Kurt Manal, and Thor F Besier. Neuromusculoskeletal modeling : estimation of muscle forces and joint moments and movements from measurements of neural command. *Journal of applied biomechanics*, 20(4) :367–395, 2004.
- Stephen Butterworth. On the theory of filter amplifiers. *Wireless Engineer*, 7(6) :536–541, 1930.
- Hua Cao. *Modélisation et évaluation expérimentale de la relation entre le signal EMG de surface et la force musculaire*. PhD thesis, Université de Technologie de Compiègne, 2010.

- Peter R Cavanagh and Paavo V Komi. Electromechanical delay in human skeletal muscle under concentric and eccentric contractions. *European journal of applied physiology and occupational physiology*, 42(3) :159–163, 1979.
- Luca Cerina, Giuseppe Franco, Pierandrea Cancian, and Marco D Santambrogio. Robustness of surface emg classifiers with fixed-point decomposition on reconfigurable architecture. In *2018 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW)*, pages 146–153. IEEE, 2018.
- Manish Chauhan, Nikhil Deshpande, Claudio Pacchierotti, Leonardo Meli, Domenico Prattichizzo, Darwin G Caldwell, and Leonardo S Mattos. A robotic microsurgical forceps for transoral laser microsurgery. *International journal of computer assisted radiology and surgery*, 14(2) :321–333, 2019.
- Bing Chen, Hao Ma, Lai-Yin Qin, Fei Gao, Kai-Ming Chan, Sheung-Wai Law, Ling Qin, and Wei-Hsin Liao. Recent developments and challenges of lower extremity exoskeletons. *Journal of Orthopaedic Translation*, 5 :26–37, 2016.
- Prudhvi Tej Chinimilli, Zhi Qiao, Seyed Mostafa Rezayat Sorkhabadi, Vaibhav Jhavar, Iat Hou Fong, and Wenlong Zhang. Automatic virtual impedance adaptation of a knee exoskeleton for personalized walking assistance. *Robotics and Autonomous Systems*, 114 :66 – 76, 2019. ISSN 0921-8890. doi: <https://doi.org/10.1016/j.robot.2019.01.013>. URL <http://www.sciencedirect.com/science/article/pii/S092188901830558X>.
- Enrico Chiovetto, Bastien Berret, Ioannis Delis, Stefano Panzeri, and Thierry Pozzo. Investigating reduction of dimensionality during single-joint elbow movements a case study on muscle synergies. *Frontiers in computational neuroscience*, 7 :11, 2013.
- Dami Choi, Christopher J Shallue, Zachary Nado, Jaehoon Lee, Chris J Maddison, and George E Dahl. On empirical comparisons of optimizers for deep learning. *arXiv preprint arXiv :1910.05446*, 2019.
- François Chollet et al. Keras. <https://keras.io>, 2015.
- J Edward Colgate, Michael Peshkin, and Stephen H Klostermeyer. Intelligent assist devices in industrial applications : a review. In *Proceedings 2003 IEEE/RSJ International*

*Conference on Intelligent Robots and Systems (IROS 2003)*(Cat. No. 03CH37453), volume 3, pages 2516–2521. IEEE, 2003.

Frédérique Cordier. Le temps de réaction, qu'est-ce que c'est?, 2017. URL <http://accs.ens-lyon.fr/accs/thematiques/neurosciences/outils-numeriques/temps-de-reaction-investigation-variabilite-et-traitements-statistiques-des-donnees-comprendre-1/le-temps-de-reaction-quest-ce-que-cest>.

C DaSalla, J Kim, and Y Koike. Robot control using electromyography (emg) signals of the wrist. *Applied Bionics and Biomechanics*, 2(2) :97–102, 2005.

Olivier David, François-Xavier Russotto, Max Da Silva Simoes, and Yvan Measson. Collision avoidance, virtual guides and advanced supervisory control teleoperation techniques for high-tech construction : framework design. *Automation in construction*, 44 : 63–72, 2014.

Michiel P De Looze, Tim Bosch, Frank Krause, Konrad S Stadler, and Leonard W O'Sullivan. Exoskeletons for industrial application and their potential effects on physical work load. *Ergonomics*, 59(5) :671–681, 2016.

Sander Dieleman and Benjamin Schrauwen. End-to-end learning for music audio. In *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 6964–6968. IEEE, 2014.

Laura Dipietro, Angelo M Sabatini, and Paolo Dario. A survey of glove-based systems and their applications. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 38(4) :461–482, 2008.

Emanuel Donchin, Kevin M Spencer, and Ranjith Wijesinghe. The mental prosthesis : assessing the speed of a p300-based brain-computer interface. *IEEE transactions on rehabilitation engineering*, 8(2) :174–179, 2000.

Conseil du patronat du Québec. Transformation métallurgiques : manutention, 2020. URL <https://www.cpq.qc.ca/fr/capsules-sst/transformation-metallurgique-manutention/>.

Julie Dumora. *Contribution à l'interaction physique homme-robot : Application à la co-manipulation d'objets de grandes dimensions*. PhD thesis, Montpellier 2, 2014.



- FactoryLab. Precise handling of heavy loads + 80 kg (manipres project). 2018. URL <https://www.youtube.com/watch?v=qSUw0HwV8q4>.
- William D Fisher and M Shahid Mujtaba. Hybrid position/force control : a correct formulation. *The International journal of robotics research*, 11(4) :299–311, 1992.
- Tamar Flash and Neville Hogan. The coordination of arm movements : an experimentally confirmed mathematical model. *Journal of neuroscience*, 5(7) :1688–1703, 1985.
- Christian Fleischer, Andreas Wege, Konstantin Kondak, and Günter Hommel. Application of emg signals for controlling exoskeleton robots. *Biomedizinische technik*, 51(5/6) :314–319, 2006.
- Marta Gandolla, Simona Ferrante, Giancarlo Ferrigno, Davide Baldassini, Franco Molteni, Eleonora Guanziroli, Michele Cotti Cottini, Carlo Seneci, and Alessandra Pedrocchi. Artificial neural network emg classifier for functional hand grasp movements prediction. *Journal of International Medical Research*, 45(6) :1831–1847, 2017.
- Philippe Garrec. Design of an anthropomorphic upper limb exoskeleton actuated by ball-screws and cables. *Bulletin of the Academy of Sciences of the Ussr-Physical Series*, 72(2) :23, 2010.
- Philippe Garrec, Yann Perrot, Dominique Ponsort, and Aurelie Riglet. Patent : Exoskeleton arm having an actuator. 2012. US9375325B2.
- Franck Geffard and Benjamin Treussart. Patent : Method for controlling an exoskeleton. 2020. WO2019EP85731 20191217.
- Franck Geffard, Claude Andriot, Alain Micaelli, and Guillaume Morel. On the use of a base force/torque sensor in teleoperation. In *Proceedings 2000 ICRA. Millennium Conference. IEEE International Conference on Robotics and Automation. Symposia Proceedings (Cat. No. 00CH37065)*, volume 3, pages 2677–2683. IEEE, 2000.
- Franck Geffard, Philippe Garrec, Gérard Piolain, Marie-Anne Brudieu, Jean-François Thro, Alain Coudray, and Eric Lelann. Tao2000 v2 computer-assisted force feedback telemanipulators used as maintenance and production tools at the areva nc-la Hague fuel recycling plant. *Journal of Field Robotics*, 29(1) :161–174, 2012.

- Yanjuan Geng, Liang Chen, Lan Tian, and Guanglin Li. Comparison of electromyography and mechanomyogram in control of prosthetic system in multiple limb positions. In *Proceedings of 2012 IEEE-EMBS International Conference on Biomedical and Health Informatics*, pages 788–791. IEEE, 2012.
- Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- RARC Gopura and Kazuo Kiguchi. Application of surface electromyographic signals to control exoskeleton robots. *Applications of EMG in Clinical and Sports Medicine*, pages 69–94, 2012.
- Muhammad Ahsan Gull, Shaoping Bai, and Thomas Bak. A review on design of upper limb exoskeletons. *Robotics*, 9(1) :16, 2020.
- JMP Gunasekara, RARC Gopura, TSS Jayawardane, and SWHMTD Lalitharathne. Control methodologies for upper limb exoskeleton robots. In *2012 IEEE/SICE International Symposium on System Integration (SII)*, pages 19–24. IEEE, 2012.
- DFB Haeufle, M Günther, A Bayer, and S Schmitt. Hill-type muscle model with serial damping and eccentric force–velocity relation. *Journal of biomechanics*, 47(6) :1531–1536, 2014.
- Martin Hägele, Walter Schaaf, and Evert Helms. Robot assistants at manual workplaces : Effective co-operation and safety aspects. In *Proceedings of the 33rd ISR (international symposium on robotics)*, volume 7, 2002.
- Elwood Henneman. Relation between size of neurons and their susceptibility to discharge. *Science*, 126(3287) :1345–1347, 1957.
- Hermie J Hermens, Bart Freriks, Roberto Merletti, Dick Stegeman, Joleen Blok, Günter Rau, Cathy Disselhorst-Klug, and Göran Hägg. European recommendations for surface electromyography. *Roessingh research and development*, 8(2) :13–54, 1999.
- Ashley Hill, Clément Rolinat, Benjamin Treussart, and Franck Geffard. Présentation : Ia et robotique au cea. In *Journée ROBOTIQUE et INTELLIGENCE ARTIFICIELLE*, 2020.

- Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8) :1735–1780, 1997.
- Neville Hogan. A review of the methods of processing emg for use as a proportional control signal. *Biomedical engineering*, 11(3) :81–86, 1976.
- Petar Horki, Teodoro Solis-Escalante, Christa Neuper, and Gernot Müller-Putz. Combined motor imagery and ssvep based bci control of a 2 dof artificial upper limb. *Medical & biological engineering & computing*, 49(5) :567–577, 2011.
- Ryo Hosoda and Gentiane Venture. Human elbow joint torque estimation during dynamic movements with moment arm compensation method. *IFAC Proceedings Volumes*, 47(3) :12305–12310, 2014.
- Xiaogang Hu, William Z Rymer, and Nina L Suresh. Control of motor unit firing during step-like increases in voluntary force. *Frontiers in human neuroscience*, 8 :721, 2014.
- L Imrani, S Boudaoud, K Kyiyoka, J Laforet K Lepeti and, and F Marin. Evaluation of motor abilities with aging using hd-semg and imu data. *14th International Congress of the European Union Geriatric Medicine Society, Berlin, Germany*, 2018.
- INRS. Troubles musculo-squelettiques - statistiques, 2015. URL <http://www.inrs.fr/risques/tms-troubles-musculosquelettiques/statistiques.html>.
- Airi Ishizuka, Ayanori Yorozu, and Masaki Takahashi. Driving control of a powered wheelchair considering uncertainty of gaze input in an unknown environment. *Applied Sciences*, 8(2) :267, 2018.
- Mark Ison, Ivan Vujaklija, Bryan Whitsell, Dario Farina, and Panagiotis Artemiadis. Simultaneous myoelectric control of a robot arm using muscle synergy-inspired inputs from high-density electrode grids. In *2015 IEEE International Conference on Robotics and Automation (ICRA)*, pages 6469–6474. IEEE, 2015.
- Ji-Hoon Jeong, Keun-Tae Kim, Dong-Joo Kim, and Seong-Whan Lee. Decoding of multi-directional reaching movements for eeg-based robot arm control. In *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 511–514. IEEE, 2018.

- Luc Joly. *Commande hybride position/force pour la téléopération : une approche basée sur des analogies mécaniques*. PhD thesis, Paris 6, 1997.
- Kyung Kwon Jung, Joo Woong Kim, Hyun Kwan Lee, Sung Boo Chung, and Ki Hwan Eom. Emg pattern classification using spectral estimation and neural network. In *SICE, 2007 Annual Conference*, pages 1108–1111. IEEE, 2007.
- Hiroaki Kawamoto and Yoshiyuki Sankai. Power assist method based on phase sequence and muscle force condition for hal. *Advanced Robotics*, 19(7) :717–734, 2005.
- Hami Kazerooni, J-L Racine, Lihua Huang, and Ryan Steger. On the control of the berkeley lower extremity exoskeleton (bleex). In *Proceedings of the 2005 IEEE international conference on robotics and automation*, pages 4353–4360. IEEE, 2005.
- Hami Kazerooni, Ryan Steger, and Lihua Huang. Hybrid control of the berkeley lower extremity exoskeleton (bleex). *The International Journal of Robotics Research*, 25(5-6) : 561–573, 2006.
- Wisama Khalil and J Kleinfinger. A new geometric notation for open and closed-loop robots. In *Proceedings. 1986 IEEE International Conference on Robotics and Automation*, volume 3, pages 1174–1179. IEEE, 1986.
- Asifullah Khan, Anabia Sohail, Umme Zahoor, and Aqsa Saeed Qureshi. A survey of the recent architectures of deep convolutional neural networks. *arXiv preprint arXiv :1901.06032*, 2019.
- Diederik P Kingma and Jimmy Ba. Adam : A method for stochastic optimization. *arXiv preprint arXiv :1412.6980*, 2014.
- Hiroshi Kobayashi, Takamitsu Aida, and Takuya Hashimoto. Muscle suit development and factory application. *International Journal of Automation Technology*, 3(6) :709–715, 2009.
- Peter Konrad. A practical introduction to kinesiological electromyography, noraxon inc, 2005.
- Francesco Lacquaniti, M Carrozzo, and NA Borghese. Time-varying mechanical behavior of multijointed arm in man. *Journal of neurophysiology*, 69(5) :1443–1464, 1993.

- Xavier Lamy. *Conception d'une interface de pilotage d'un cobot*. PhD thesis, 2011.
- L'Assurance Maladie. Risques professionnels : Rapport annuel, 2017. URL [https://assurance-maladie.ameli.fr/sites/default/files/cnam-drp\\_rapport\\_de\\_gestion\\_2017\\_vdef\\_pour\\_mise\\_en\\_ligne\\_web.pdf](https://assurance-maladie.ameli.fr/sites/default/files/cnam-drp_rapport_de_gestion_2017_vdef_pour_mise_en_ligne_web.pdf).
- L'Assurance Maladie. Comprendre les troubles musculo-squelettiques, 2019. URL <https://www.ameli.fr/essonne/assure/sante/themes/tms/comprendre-troubles-musculosquelettiques>.
- L'Assurance Maladie. Les tms dans votre secteur d'activité, 2020. URL <https://www.ameli.fr/essonne/entreprise/sante-travail/risques/troubles-musculosquelettiques-tms/secteurs-activite>.
- Yann LeCun, Léon Bottou, Yoshua Bengio, and Patrick Haffner. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11) :2278–2324, 1998.
- Heedon Lee, Wansoo Kim, Jungsoo Han, and Changsoo Han. The technical trend of the exoskeleton robot system for human power assistance. *International Journal of Precision Engineering and Manufacturing*, 13(8) :1491–1497, 2012.
- Yunju Lee and James A Ashton-Miller. The effects of gender, level of co-contraction, and initial angle on elbow extensor muscle stiffness and damping under a step increase in elbow flexion moment. *Annals of biomedical engineering*, 39(10) :2542, 2011.
- Tommaso Lenzi, SMM De Rossi, Nicola Vitiello, and Maria Chiara Carrozza. Proportional emg control for upper-limb powered exoskeletons. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 628–631. IEEE, 2011.
- Tommaso Lenzi, Stefano Marco Maria De Rossi, Nicola Vitiello, and Maria Chiara Carrozza. Intention-based emg control for powered exoskeletons. *IEEE transactions on biomedical engineering*, 59(8) :2180–2190, 2012.
- Min Li, Yi Zhang, Hui Zhang, and Huo Sheng Hu. An eeg based control system for intelligent wheelchair. In *Applied Mechanics and Materials*, volume 300, pages 1540–1545. Trans Tech Publ, 2013.

- Dennis R Louie and Janice J Eng. Powered robotic exoskeletons in post-stroke rehabilitation of gait : a scoping review. *Journal of neuroengineering and rehabilitation*, 13(1) :53, 2016.
- Maria Makarov. *Contribution à la modélisation et la commande robuste de robots manipulateurs à articulations flexibles. Applications à la robotique interactive*. PhD thesis, 2013.
- Donald W Marquardt. An algorithm for least-squares estimation of nonlinear parameters. *Journal of the society for Industrial and Applied Mathematics*, 11(2) :431–441, 1963.
- Víctor Martínez-Cagigal, Javier Gomez-Pilar, Daniel Álvarez, and Roberto Hornero. An asynchronous p300-based brain-computer interface web browser for severely disabled people. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(8) : 1332–1342, 2017.
- P. Maurice, J. Čamernik, D. Gorjan, B. Schirrmeister, J. Bornmann, L. Tagliapietra, C. Latella, D. Pucci, L. Fritzsche, S. Ivaldi, and J. Babič. Objective and subjective effects of a passive exoskeleton on overhead work. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(1) :152–164, 2020. doi: 10.1109/TNSRE.2019.2945368.
- Pauline Maurice, Jernej Čamernik, Daša Gorjan, Benjamin Schirrmeister, Jonas Bornmann, Luca Tagliapietra, Claudia Latella, Daniele Pucci, Lars Fritzsche, Serena Ivaldi, et al. Objective and subjective effects of a passive exoskeleton on overhead work. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(1) :152–164, 2019.
- Alison C McDonald, Kia Sanei, and Peter J Keir. The effect of high pass filtering and non-linear normalization on the emg–force relationship during sub-maximal finger exertions. *Journal of Electromyography and Kinesiology*, 23(3) :564–571, 2013.
- Irene Mendez, Bo Winther Hansen, Christine Marie Grabow, Erik Joannes Leivsgard Smedegaard, Nanna Bloch Skogberg, Xenia Jørgensen Uth, Astrid Bruhn, Bo Geng, and Ernest Nlandu Kamavuako. Evaluation of the myo armband for the classification of hand motions. In *2017 International Conference on Rehabilitation Robotics (ICORR)*, pages 1211–1214. IEEE, 2017.

- Roberto Merletti and P Di Torino. Standards for reporting emg data. *J Electromyogr Kinesiol*, 9(1) :3–4, 1999.
- Levi Makaio Miller and Jacob Rosen. Comparison of multi-sensor admittance control in joint space and task space for a seven degree of freedom upper limb exoskeleton. In *2010 3rd IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics*, pages 70–75. IEEE, 2010.
- Ministère du Travail. Troubles musculo-squelettiques, 2010.  
URL <https://travail-emploi.gouv.fr/sante-au-travail/prevention-des-risques-pour-la-sante-au-travail/article/troubles-musculo-squelettiques>.
- Antoine Muller, Charles Pontonnier, Xavier Robert-Lachaine, Georges Dumont, and André Plamondon. Motion-based prediction of external forces and moments and back loading during manual material handling tasks. *Applied ergonomics*, 82 :102935, 2020.
- Yoshiki Muramatsu, Hiroyuki Kobayashi, Yutaka Sato, He Jiaou, Takuya Hashimoto, and Hiroshi Kobayashi. Quantitative performance analysis of exoskeleton augmenting devices–muscle suit–for manual worker. *International Journal of Automation Technology*, 5(4) :559–567, 2011.
- Junpei Naito, Goro Obinata, Atsushi Nakayama, and Kazunori Hase. Development of a wearable robot for assisting carpentry workers. *International Journal of Advanced Robotic Systems*, 4(4) :48, 2007.
- Wyatt S Newman and Yuandao Zhang. Stable interaction control and coulomb friction compensation using natural admittance control. *Journal of robotic systems*, 11(1) : 3–11, 1994.
- Robert W Norman and Paavo V Komi. Electromechanical delay in skeletal muscle under normal movement conditions. *Acta Physiologica Scandinavica*, 106(3) :241–248, 1979.
- L Paredes-Madrid and P Gonzalez De Santos. Dataglove-based interface for impedance control of manipulators in cooperative human–robot environments. *Measurement Science and Technology*, 24(2) :025005, 2013.

- Agnès Parent-Thirion, Isabella Biletta, Jorge Cabrita, Oscar Vargas, Greet Vermeulen, Aleksandra Wilczynska, and Mathijn Wilkens. *Sixth European Working Conditions Survey : Overview Report*. Eurofound (European Foundation for the Improvement of Living and Working . . . , 2016.
- Sungman Park, Yeongtae Jung, and Joonbum Bae. Interactive and intuitive control interface for a tele-operated robot (avatar) system. In *Advanced Intelligent Mechatronics (AIM), 2017 IEEE International Conference on*, pages 241–246. IEEE, 2017.
- Véronique Perdereau. *Contribution à la commande hybride force-position. Application à la coopération de deux robots*. PhD thesis, Paris 6, 1991.
- Pornchai Phukpattaranont, Sirinee Thongpanja, Khairul Anam, Adel Al-Jumaily, and Chusak Limsakul. Evaluation of feature extraction techniques and classifiers for finger movement recognition using surface electromyography signal. *Medical & biological engineering & computing*, pages 1–13, 2018.
- Robert Prueckl and Christoph Guger. A brain-computer interface based on steady state visual evoked potentials for controlling a robot. *Bio-Inspired Systems : Computational and Ambient Intelligence*, pages 690–697, 2009.
- Ganna Pugach, Artem Melnyk, Olga Tolochko, Alexandre Pitti, and Philippe Gaussier. Touch-based admittance control of a robotic arm using neural learning of an artificial skin. In *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 3374–3380. IEEE, 2016.
- Ce Qi and Fei Su. Contrastive-center loss for deep neural networks. 07 2017.
- Marc H Raibert and John J Craig. Hybrid position/force control of manipulators. 1981.
- Gennaro Raiola, Susana Sanchez Restrepo, Pauline Chevalier, Pedro Rodriguez-Ayerbe, Xavier Lamy, Sami Tliba, and Freek Stulp. Co-manipulation with a library of virtual guiding fixtures. *Autonomous Robots*, 42(5) :1037–1051, 2018.
- Ehsan Rashedi, Sunwook Kim, Maury A Nussbaum, and Michael J Agnew. Ergonomic evaluation of a wearable assistive device for overhead work. *Ergonomics*, 57(12) :1864–1874, 2014.



- Daran Ravden and John Polich. On p300 measurement stability : habituation, intra-trial block variation, and ultradian rhythms. *Biological psychology*, 51(1) :59–76, 1999.
- Brice Rebsamen, Cuntai Guan, Haihong Zhang, Chuanchu Wang, Cheeleong Teo, Marcelo H Ang, and Etienne Burdet. A brain controlled wheelchair to navigate in familiar environments. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 18(6) :590–598, 2010.
- Susana Sánchez Restrepo, Gennaro Raiola, Pauline Chevalier, Xavier Lamy, and Daniel Sidobre. Iterative virtual guides programming for human-robot comanipulation. In *2017 IEEE International Conference on Advanced Intelligent Mechatronics (AIM)*, pages 219–226. IEEE, 2017.
- S Rivière, C Martinaud, Y Roquelaure, and J Chatelot. Estimation de la sous-déclaration des troubles musculo-squelettiques : Mise à jour pour 2011 dans onze régions françaises. *Bull épidémiologique Hebd*, 18 :373–8, 2018.
- L. Rose, M. C. F. Bazzocchi, and G. Nejat. End-to-end deep reinforcement learning for exoskeleton control. In *2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 4294–4301, 2020. doi: 10.1109/SMC42975.2020.9283306.
- F Rosenblatt. A probabilistic model for information storage and organization in the brain, american psychological association, 1958.
- David E Rumelhart, Geoffrey E Hinton, and Ronald J Williams. Learning representations by back-propagating errors. *nature*, 323(6088) :533–536, 1986.
- Baltej Singh Rupal, Sajid Rafique, Ashish Singla, Ekta Singla, Magnus Isaksson, and Gurvinder Singh Virk. Lower-limb exoskeletons : Research trends and regulatory guidelines in medical and non-medical applications. *International Journal of Advanced Robotic Systems*, 14(6) :1729881417743554, 2017.
- Wondae Ryu, Byungkil Han, and Jaehyo Kim. Continuous position control of 1 dof manipulator using emg signals. In *2008 Third International Conference on Convergence and Hybrid Information Technology*, volume 1, pages 870–874. IEEE, 2008.
- Stephen H Scott. Optimal feedback control and the neural basis of volitional motor control. *Nature Reviews Neuroscience*, 5(7) :532–545, 2004.

- Tobias Siebert, Christian Rode, Walter Herzog, Olaf Till, and Reinhard Blickhan. Non-linearities make a difference : comparison of two common hill-type models with real muscle. *Biological cybernetics*, 98(2) :133–143, 2008.
- Miguel Simão, Nuno Mendes, Olivier Gibaru, and Pedro Neto. A review on electromyography decoding and pattern recognition for human-machine interaction. *IEEE Access*, 7 :39564–39582, 2019.
- Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv :1409.1556*, 2014.
- M Solomonow, R Baratta, M Bernardi, B Zhou, Y Lu, M Zhu, and S Acierno. Surface and wire emg crosstalk in neighbouring muscles. *Journal of Electromyography and Kinesiology*, 4(3) :131–142, 1994.
- Mervyn Stone. An asymptotic equivalence of choice of model by cross-validation and akaike’s criterion. *Journal of the Royal Statistical Society : Series B (Methodological)*, 39(1) :44–47, 1977.
- Sim Kok Swee and Lim Zheng You. Fast fourier analysis and eeg classification brainwave controlled wheelchair. In *2016 2nd International Conference on Control Science and Systems Engineering (ICCSSE)*, pages 20–23. IEEE, 2016.
- Nahema Sylla, Vincent Bonnet, Frédéric Colledani, and Philippe Fraisse. Ergonomic contribution of able exoskeleton in automotive industry. *International Journal of Industrial Ergonomics*, 44(4) :475–481, 2014.
- Mahmoud Tavakoli, Carlo Benussi, and Joao Luis Lourenco. Single channel surface emg control of advanced prosthetic hands : A simple, low cost and efficient approach. *Expert Systems with Applications*, 79 :322–332, 2017.
- Jean Theurel, Kevin Desbrosses, Terence Roux, and Adriana Savescu. Physiological consequences of using an upper limb exoskeleton during manual handling tasks. *Applied ergonomics*, 67 :211–217, 2018.
- Dennis C Tkach, Aaron J Young, Lauren H Smith, Elliott J Rouse, and Levi J Hargrove. Real-time and offline performance of pattern recognition myoelectric control using a

- generic electrode grid with targeted muscle reinnervation patients. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(4) :727–734, 2014.
- Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Poster : étude et conception d’un système de pilotage intuitif d’un cobot pour la réalisation de tâches complexes. In *Journée FéDeV 2018*, a.
- Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Présentation : Controlling an upper-limb exoskeleton by emg signal while carrying unknown load. In *Journée FéDeV 2019*, b.
- Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Présentation : Personnalisation d’un système de contrôle d’exosquelette de membre supérieur basé sur le signal emg. In *Journée FéDeV 2020*, c.
- Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Controlling an exoskeleton with emg signal to assist load carrying : a personalized calibration. In *2019 International Conference on Mechatronics, Robotics and Systems Engineering (MoRSE)*, pages 246–252. IEEE, 2019.
- Benjamin Treussart, Franck Geffard, Nicolas Vignais, and Frédéric Marin. Controlling an upper-limb exoskeleton by emg signal while carrying unknown load. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, pages 9107–9113. IEEE, 2020.
- A Trivedi. Deep learning part 2 : Transfer learning and fine-tuning deep convolutional neural networks, 2016.
- Khalil Ullah and Jung-Hoon Kim. A mathematical model for mapping emg signal to joint torque for the human elbow joint using nonlinear regression. In *ICARA 2009*, pages 103–108. IEEE, 2009.
- Jessica Beltran Ullauri, Luka Peternel, Barkan Ugurlu, Yoji Yamada, and Jun Morimoto. On the emg-based torque estimation for humans coupled with a force-controlled elbow exoskeleton. In *2015 International Conference on Advanced Robotics (ICAR)*, pages 302–307. IEEE, 2015.

- ViaPrévention. Connaissances – la manutention manuelle de charges, 2016.  
URL [https://www.viaprevention.com/wp-content/uploads/2016/10/D-1045-1-ViaPrevention-Guide\\_Manutention.pdf](https://www.viaprevention.com/wp-content/uploads/2016/10/D-1045-1-ViaPrevention-Guide_Manutention.pdf).
- Valentin Vielzeuf. *Apprentissage neuronal profond pour l'analyse de contenus multimodaux et temporels*. PhD thesis, Normandie Université, 2019.
- Christopher R Wagner, Nicholas Stylopoulos, Patrick G Jackson, and Robert D Howe. The benefit of force feedback in surgery : Examination of blunt dissection. *Presence : teleoperators and virtual environments*, 16(3) :252–262, 2007.
- David Williams and Oussama Khatib. Improved force control for conventional arms using wrist-based torque feedback. In *Experimental Robotics IV*, pages 516–525. Springer, 1997.
- David A Winter. *Biomechanics and motor control of human movement*. John Wiley & Sons, 2009.
- Jack M Winters. Hill-based muscle models : a systems engineering perspective. In *Multiple muscle systems*, pages 69–93. Springer, 1990.
- L Wioland, L Debay, and JJ Atain-Kouadio. Acceptation des exosquelettes par les opérateurs : étude. *130 Avril*, page 45, 2019.
- Chenguang Yang, Jing Luo, Yongping Pan, Zhi Liu, and Chun-Yi Su. Personalized variable gain control with tremor attenuation for robot teleoperation. *IEEE Transactions on Systems, Man, and Cybernetics : Systems*, 48(10) :1759–1770, 2017.
- K. Yin, K. Xiang, M. Pang, J. Chen, P. Anderson, and L. Yang. Personalised control of robotic ankle exoskeleton through experience-based adaptive fuzzy inference. *IEEE Access*, 7 :72221–72233, 2019. doi: 10.1109/ACCESS.2019.2920134.
- Ho Yu, Il Seop Choi, Kyung-Lyong Han, Jae Yeon Choi, Goobong Chung, and Jinho Suh. Development of a upper-limb exoskeleton robot for refractory construction. *Control Engineering Practice*, 72 :104–113, 2018.
- Han Yuan and Bin He. Brain–computer interfaces using sensorimotor rhythms : current state and future perspectives. *IEEE Transactions on Biomedical Engineering*, 61(5) : 1425–1435, 2014.

- Felix E Zajac. Muscle and tendon properties models scaling and application to biomechanics and motor. *Critical reviews in biomedical engineering*, 17(4) :359–411, 1989.
- Nabil Zemiti. *Commande en effort des systèmes robotiques pour la chirurgie mini-invasive*. PhD thesis, 2005.
- Xiaolong Zhai, Beth Jelfs, Rosa HM Chan, and Chung Tin. Self-recalibrating surface emg pattern recognition for neuroprosthesis control based on convolutional neural network. *Frontiers in neuroscience*, 11 :379, 2017.
- Qin Zhang, Runfeng Liu, Wenbin Chen, and Caihua Xiong. Simultaneous and continuous estimation of shoulder and elbow kinematics from surface emg signals. *Frontiers in neuroscience*, 11 :280, 2017.
- Danhua Zhu, Jordi Bieger, Gary Garcia Molina, and Ronald M Aarts. A survey of stimulation methods used in ssvp-based bcis. *Computational intelligence and neuroscience*, 2010, 2010.
- Yves Zimmermann, Alessandro Forino, Robert Riener, and Marco Hutter. Anyexo : A versatile and dynamic upper-limb rehabilitation robot. *IEEE Robotics and Automation Letters*, 4(4) :3649–3656, 2019.

# Comparaisons des performances des filtres moyenneurs, RMS et Butterworth

Nous avons pris en compte deux paramètres pour choisir le filtre : le temps de réponse du filtre à un échelon et la capacité à lisser le signal 2.10. En ce qui concerne le temps de réponse nous utilisons la métrique *temps de réponse à 5%*. Pour la capacité de lissage nous utilisons le spectrogramme du signal filtré. Notre critère est que, pour un signal lisse, les hautes fréquences sont moins représentées. Ces critères sont représentés sur la Fig. ???. Nous avons comparé un filtre de Butterworth avec une fenêtre de 200 échantillons et un filtre RMS et moyennant avec un fenêtre de 70 échantillons qui donne une visuel assez proche (sur la Fig. A.2). Nous pouvons voir sur les spectrogrammes A.1 que le filtre Butterworth parvient mieux à lisser le signal avec en plus un meilleur temps de réponse à 5 % A.3.




FIGURE A.1 – Spectrogrammes




FIGURE A.2 – Visuel des filtrage




FIGURE A.3 – Temps de réponse à un échelon

# Calculs des caractéristiques choisies pour le SVM

---

Pour un échantillon de taille  $N$  les caractéristiques se calculent comme suit :

$$WL = \sum_{i=1}^N |x_i - x_{i-1}| \quad (\text{B.1})$$

$$MAV = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (\text{B.2})$$

$$WAMP = \sum_{i=1}^N f(|x_i - x_{i-1}|) \quad (\text{B.3})$$

$$f(x) = \begin{cases} 1 & \text{si } x > T \\ 0 & \text{sinon} \end{cases}$$

$$CARD = \text{card}_{i \in [1, N]}(x_i) \quad (\text{B.4})$$

$$SSC = \sum_{i=1}^{N-1} f[|(x_i - x_{i-1}) * (x_i - x_{i+1})|] \quad (\text{B.5})$$

$$ZC = \sum_{i=1}^N f(-x_i * x_{i-1}) \quad (\text{B.6})$$

$$f(x) = \begin{cases} 1 & \text{si } x > 0 \\ 0 & \text{sinon} \end{cases}$$



# Exploration : Régression avec un CNN

---

Dans cette section nous explorons la possibilité de réaliser l'ensemble de la détection d'intention avec des méthodes d'apprentissage profond, c'est à dire, à la fois la classification et l'estimation de l'intensité. Dans ce cas, le réseau prend en charge les fonctions de la Fig 2.11. Pour ce faire nous utilisons trois architecture différentes (voir Fig. C.1), dérivées de celle présentée sur la Fig. 2.17. Le nombre de neurones dans la dernière couche est mis à 1 et sans fonction d'activation pour adopter une forme correspondant à un problème de régression. La différence d'un modèle à l'autre est la première couche complètement connectée. Dans le premier cas, elle a été conservée (Dense), dans le second cas, remplacée par une couche de RNN, et dans le dernier cas, remplacée par une couche LSTM.<sup>1</sup>

Dans un premier temps nous évaluons l'influence de la taille de la fenêtre glissante servant d'entrée au réseau sur la précision de la régression. Pour rappel, cette fenêtre est de 30 échantillons pour la classification de la section 2.3.3. Pour cela nous utilisons un enregistrement de une personne qui force sur le bras de l'exosquelette librement pendant cinq minutes. Nous utilisons les premières trois minutes trente secondes pour comme données d'entraînement et le reste comme données de test.

Les résultats de l'entraînement pour le modèle avec la couche LSTM et des longueurs de fenêtre glissante variées sont présentés sur la Fig. C.2. Les résultats avec les autres modèles sont similaires dans le sens où plus la fenêtre est longue, plus la sortie semble lissée. Les erreurs RMS sont reportées sur la tableau C.1. A titre de comparaison l'erreur obtenue avec la méthode du chapitre 2 (méthode MIXTE) sur le même jeu de données est de  $24.910^{-3}N.m$ .

---

1. *Reccurent Neural Network* (RNN) et *Long Short Term Memory* (LSTM) sont deux architectures de réseaux récurrents définie dans la section 2.2.1.3

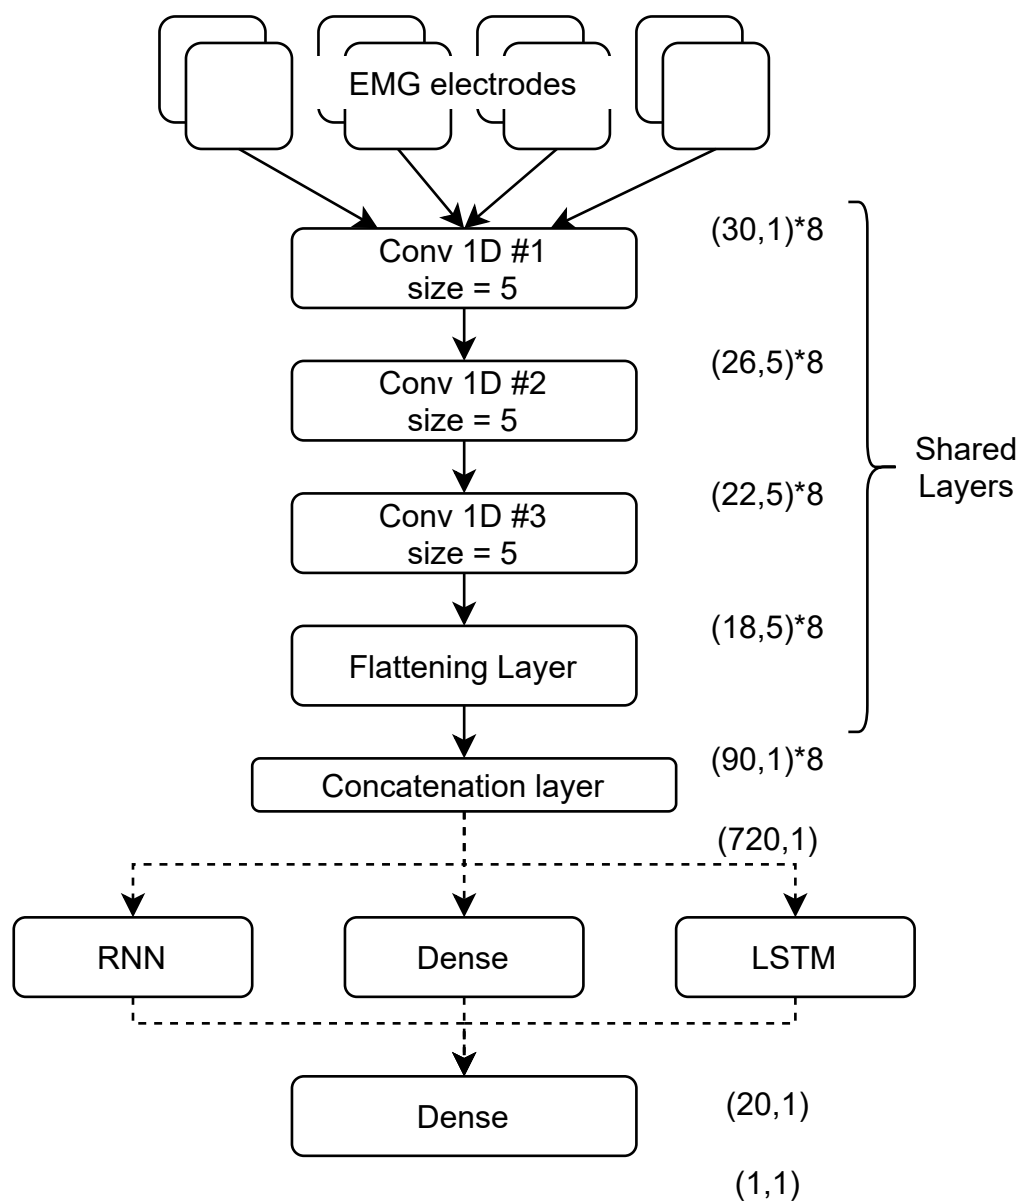



FIGURE C.1 – Architecture du réseau de neurones pour l'estimation du couple appliqué à partir d'EMG



VI

FIGURE C.2 – Résultats de l'apprentissage du modèle avec LSTM en fonction de la longueur de la fenêtre glissante. De bas en haut 15, 30, 50, 100, 200 échantillons et le résultats obtenus avec la méthode MIXTE 2.11

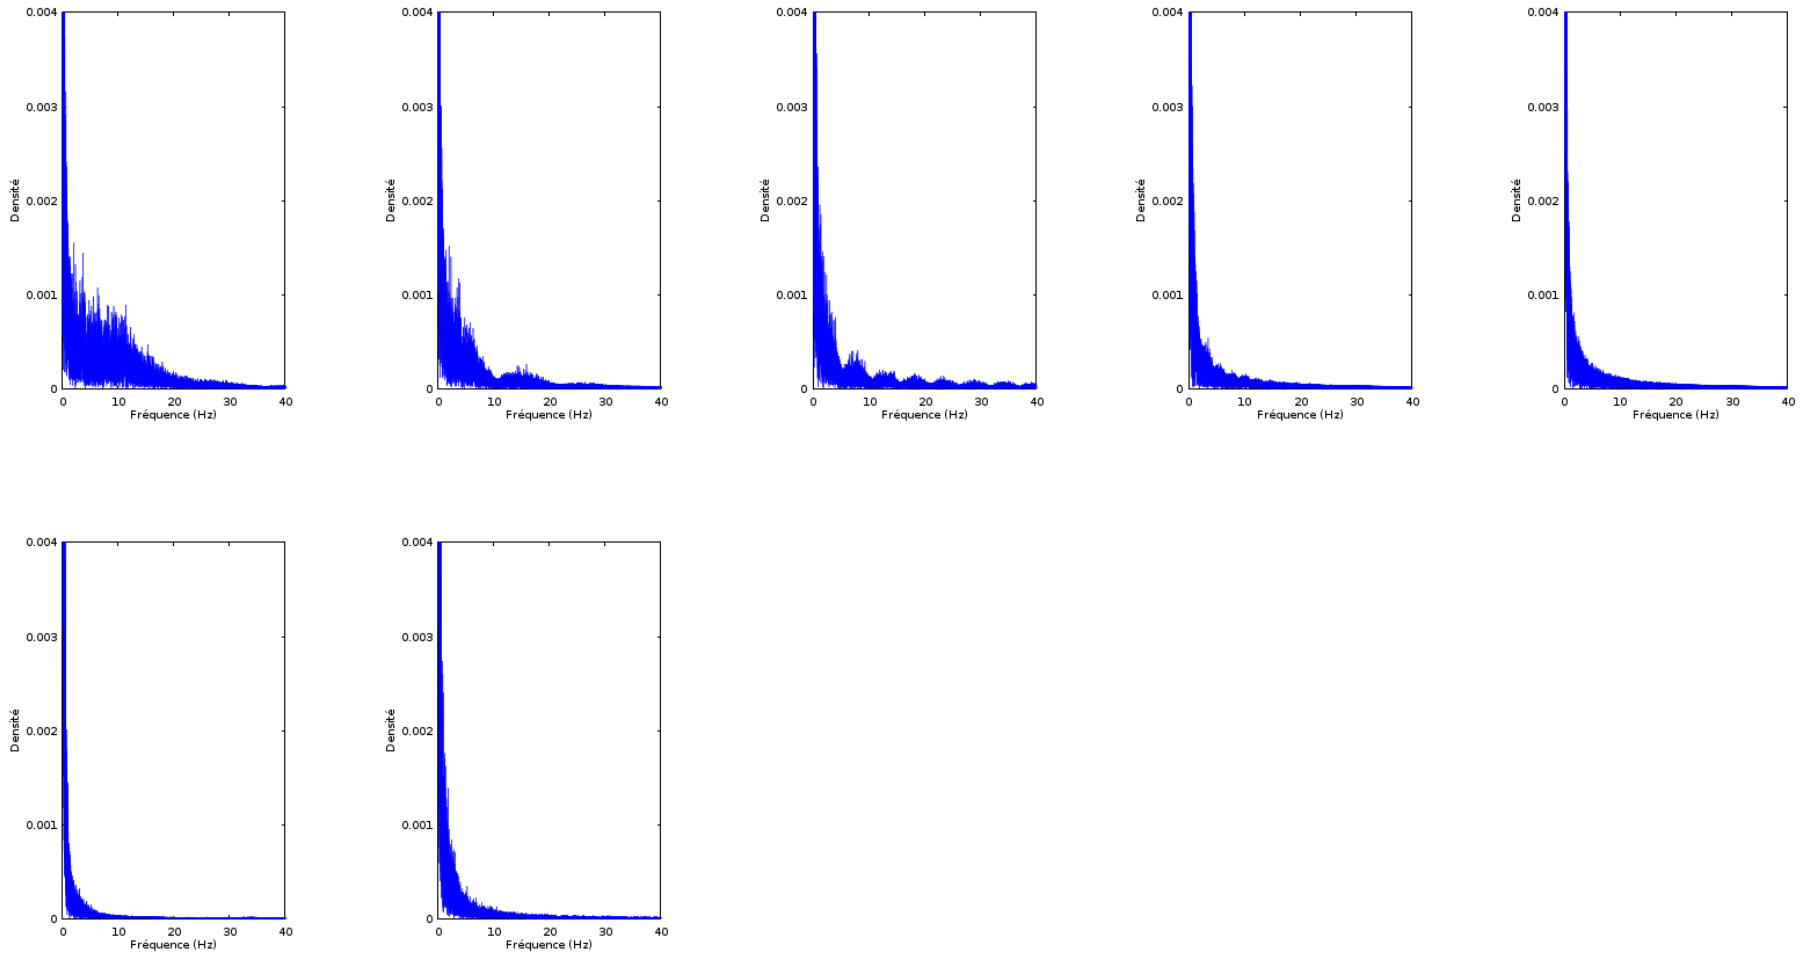


FIGURE C.3 – Répartitions des fréquences des estimations représentées Fig. C.2(De gauche à droite 15, 30, 50, 100, 200 échantillons, en bas à droite le signal original et en bas à gauche le filtrage avec le modèle)

Il est intéressant de noter que les différents modèles présentent une évolution similaire en fonction de la longueur de fenêtre. Les réseaux avec un composante récurrentes semblent capable de mieux profiter de l’allongement de la fenêtre alors que la performance du modèle traditionnel semble stagner pus vite.

Nous avons mis au point une autre approche pour quantifier la qualité de l’estimation en observant la décomposition fréquentielle du signal de sortie. Différents spectrogrammes sont représentés sur la Fig. C.3. Ceux correspondants aux estimations de la Fig. C.2 sont sur la première ligne, la taille de fenêtre allant en augmentant de gauche à droite. Les spectrogrammes du couple réel (cible) et de l’estimation avec la méthode MIXTE sont sur la deuxième ligne. Pour quantifier cette informations nous déterminons une fréquence limite  $F_{lim}$  C.1. Nous utilisons cette fréquence pour quantifier le bruit restant en intégrant le spectrogramme obtenu lors des différentes conditions au delà de  $F_{lim}$  C.2. Ces valeurs sont rapportées dans le tableau C.2. Il semble que l’augmentation de l’effet de lissage qui accompagne l’augmentation de la taille de fenêtre atteint un plafond assez vite, ce qui est pertinent. En effet, lorsque la fenêtre est de 200 échantillons cela représente une seconde de données, ce qui est suffisamment long pour que les premiers échantillons ne soient pas utiles dans le calcul du couple. A titre de comparaison, ces calculs ont pour résultat 0.32 pour le couple mesuré et 0.34 avec la méthode MIXTE alors que la valeur la plus faible dans le tableau est 0.57, pour RNN et Dense.

$$\int_0^{F_{lim}} Spectro.df = 0.9 * \int Spectro.df \quad (C.1)$$

$$bruit = \int_{F_c}^{F_{max}} Spectro.df \quad (C.2)$$

Nous évaluons aussi l’influence de la quantité de données utilisées pour l’entraînement pour les trois modèles et une seule longueur de fenêtre. Les résultats sont présentés dans

TABLE C.1 – Erreurs RMS pour les différents modèles et longueur de fenêtre glissante ( $10^{-3} N.m$ ). Pour comparaison : méthode MIXTE,  $24.9 * 10^{-3} N.m$

Longueur de la fenêtre	15	30	50	100	200
Dense	47,4	39,4	36,4	35,8	36,3
LSTM	45,2	38,8	37,6	33,0	31,9
RNN	47,5	37,0	34,7	31,0	34,4

TABLE C.2 – Intégrale des spectrogrammes au-delà de la fréquence limite  $F_{lim}$ . Pour comparaison : Couple mesuré, 0,32 et méthode MIXTE, 0,34

Longueur de la fenêtre	15	30	50	100	200
Dense	1,69	0,64	0,61	0,62	0,57
RNN	1,29	0,68	0,81	0,57	0,57
LSTM	2,29	0,66	0,61	0,59	0,61

les tableaux C.3 et C.4. Nous pouvons noter que même s'il y a une diminution de la performance, le réseau reste capable de converger.

Sur la Fig. C.4, une comparaison entre la méthode MIXTE (du chapitre 2) et une des méthodes les plus performantes proposée dans cette annexe (architecture avec couche Dense et une fenêtre d'entrée de 200 échantillons, Dense200). Les approches offrent des performances équivalentes.

Nous pouvons constater qu'une méthode de détection d'intention basée uniquement sur un réseau de neurones peut aussi convenir. Cette méthode présente cependant certains inconvénients. Tout d'abord, le fait de faire un traitement de bout en bout avec un réseau de neurones fait du système une sorte de "boite noire". C'est à dire qu'on ne sait pas exactement ce qu'il se passe entre l'entrée et la sortie. Tant que la sortie est celle attendue cela n'est pas un problème, mais si ce n'est pas le cas cela rend compliqué d'expliquer d'où vient l'erreur. D'autre part, il semble que le seul paramètre de contrôle sur notre sortie soit la taille de la fenêtre glissante utilisée, permettant de lisser plus ou moins la sortie en augmentant ou diminuant la taille de la fenêtre respectivement. Cependant, le lien entre lissage et taille n'est pas explicite et doit être déterminé empiriquement. C'est pourquoi, l'approche MIXTE avec un filtre de Butterworth semble préférable en terme de clarté d'effet des paramètres. Néanmoins, ce type d'approches, avec un réseau gérant de bout en bout la régression, peut être envisagé dans des cas plus complexes où le découpage proposé en différentes classes ne serait plus pertinent.

TABLE C.3 – Erreurs RMS en fonction de la quantité de données ( $10^{-3}N.m$ ). <sup>(1)</sup> Les données ne proviennent pas du même enregistrement mais d'un enregistrement fait séparément (même placement d'électrodes)

Quantité de données	2'30"	1'	30"	30" <sup>(1)</sup>	15" <sup>(1)</sup>
Dense	37,1	40,1	25,5	45,4	38,1
RNN	40,7	35,5	34,9	47,6	38,4
LSTM	36,2	41,0	38,8	48,6	40,9

TABLE C.4 – Intégrale du spectrogramme. 0.39 et 0.32

Quantité de données	2'30"	1'	30"	30"(1)	15"(1)
Dense	0,56	0,94	0,88	0,68	0,77
RNN	0,53	0,90	0,91	0,70	0,81
LSTM	0,56	1,28	0,85	0,72	0,82

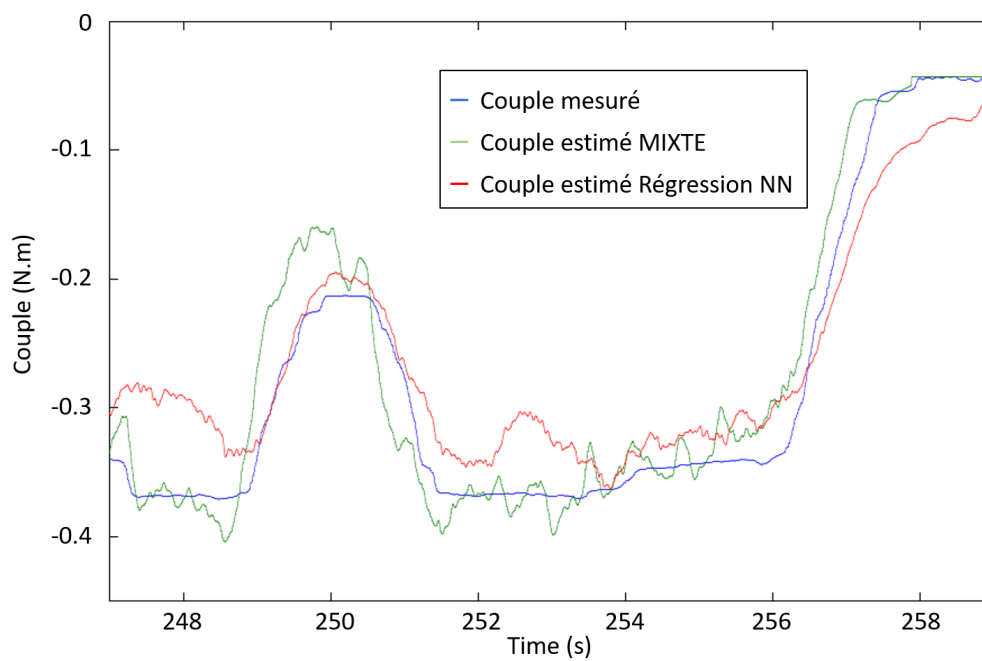


FIGURE C.4 – Comparaison des estimations avec les méthodes MIXTE et Dense200

# Tables

Capteurs	1	2	3	4	5	6	7	8
Repos	0.86	0.90	0.94	0.88	0.90	0.90	0.88	0.88
Palier Triceps	12.74	12.28	8.76	3.72	2.60	2.77	5.03	16.14
Max Triceps	47.62	40.28	32.26	10.54	4.24	5.90	22.24	69.96
Palier Biceps	4.24	5.30	5.95	14.90	22.70	30.11	11.33	4.59
Max Biceps	17.81	27.50	36.01	60.81	55.94	56.97	32.65	18.98
Co-contraction	14.67	21.94	17.19	10.65	16.96	23.40	12.67	20.96

TABLE D.1 – Activation moyenne par capteur d'un participant sans co-contraction

Capteurs	1	2	3	4	5	6	7	8
Repos	0.83	0.90	1.03	0.86	0.89	0.89	0.82	0.79
Palier Triceps	52.73	39.14	37.76	23.80	11.08	8.50	11.38	44.02
Max Triceps	71.59	71.98	53.19	53.49	12.96	13.38	35.03	75.16
Palier Biceps	11.77	12.61	20.33	39.40	52.01	61.75	40.41	14.01
Max Biceps	15.29	17.26	42.59	67.53	74.06	74.91	67.92	20.44
Co-contraction	25.49	33.67	42.66	32.84	43.36	58.88	47.46	33.12

TABLE D.2 – Activation moyenne par capteur du participant avec co-contraction

197	0	0	0
4	318	0	1
7	43	267	6
0	0	0	198

TABLE D.3 – Matrice confusion des données d'entraînement personne 6

197	0	0	0
0	197	0	0
0	0	196	0
74	122	0	0

TABLE D.4 – Matrice confusion personne 8



199	0	0	0
0	199	0	0
0	0	199	0
107	1	90	1

TABLE D.5 – Matrice confusion personne 18

	Soft3	Soft4	CL3	CL4
Moyenne	91,8	95,3	97,1	96,1
écart type	7,6	5,0	2,6	4,5

TABLE D.6 – Précision du réseau entraîné et testé sur la même personne

	Soft3	Soft4	CL3	CL4	SVM
1	88,2	93,1	86,2	77,2	87,8
2	96,1	98,1	99,7	99,7	98,5
3	96,3	96,0	97,6	95,0	96,9
4	93,9	92,8	85,6	81,5	84,9
5	96,8	97,3	97,2	95,9	95,7
6	88,5	91,3	98,3	98,2	97,8
7	99,8	99,9	99,6	100,0	99,4
8	97,4	98,2	99,5	90,4	99,1
9	89,5	94,2	94,0	94,3	91,2
10	99,3	99,6	98,0	98,5	99,5
11	90,8	93,7	99,4	91,7	92,4
12	94,3	96,8	99,7	99,4	90,5
13	91,5	93,6	90,8	96,2	75,2
14	90,0	93,2	98,2	92,8	97,5
15	98,5	95,4	96,5	93,2	99,2
16	90,9	93,4	91,4	92,8	90,8
17	84,6	86,2	97,7	90,7	88,9
18	86,8	89,0	97,5	99,7	93,5
Moyenne	93,0	94,5	95,9	93,7	92,7
écart type	4,6	3,6	4,5	6,2	6,8

TABLE D.7 – Précision du réseau entraîné avec les données de 17 personnes et testés sur la dernière

	Soft3	Soft4	CL3	CL4
1	83,6	88,5	84,4	88,7
2	93,5	99,6	100,0	100,0
3	92,6	97,8	97,6	96,3
4	96,3	93,8	93,8	80,5
5	97,1	96,3	97,2	95,9
6	97,9	98,3	98,3	98,2
7	99,7	100,0	100,0	100,0
8	98,7	100,0	100,0	99,6
9	89,8	97,8	95,2	96,2
10	99,2	99,4	96,8	98,2
11	90,8	95,3	99,5	97,8
12	95,5	94,8	99,7	97,2
13	97,3	97,4	99,1	100,0
14	95,1	94,0	98,2	95,6
15	100,0	96,8	100,0	95,8
16	92,7	93,6	94,8	92,7
17	96,8	97,3	99,2	96,3
18	97,4	99,5	98,9	99,7
Moyenne	95,2	96,7	97,4	96,0
écart type	4,2	3,0	3,8	4,8

TABLE D.8 – Précision du réseau ajusté

Participant	Position	Direction		3 Capteurs Biceps	Moyenne	t pose	t dir	t inter participant
1	Haute	Haut	Moyenne	162,5	156,4	0,693	0,826	-3,861
			écart type	20,9	4,5			-6,764
		Bas	Moyenne	153,3		0,036		4,873
			écart type	28,6			-2,454	
	Basse	Haut	Moyenne	157,0			0,621	
		écart type	14,0					
2	Haute	Haut	Moyenne	175,4	183,3	-1,547	1,468	1,064
			écart type	28,7	21,6			5,808
		Bas	Moyenne	157,1		-2,727		2,779
			écart type	26,9				
	Basse	Haut	Moyenne	194,6			-0,640	
		écart type	27,0					
3	Haute	Haut	Moyenne	183,9	175,6	1,497	0,655	9,036
			écart type	35,9	7,8			3,609
		Bas	Moyenne	175,3		-0,259		
			écart type	21,1				
	Basse	Haut	Moyenne	165,3			-1,313	
		écart type	16,0					
4	Haute	Haut	Moyenne	131,0	139,8	-1,205	-2,346	-5,981
			écart type	9,8	9,8			
		Bas	Moyenne	153,5		1,893		
			écart type	28,7				
	Basse	Haut	Moyenne	139,8			0,652	
		écart type	20,8					
5	Haute	Haut	Moyenne	162,3	163,2	-0,693	0,188	
			écart type	37,0	7,6			
		Bas	Moyenne	159,3		0,142		
			écart type	34,2				
	Basse	Haut	Moyenne	174,1			1,092	
		écart type	39,6					
		Bas	Moyenne	157,3				
		écart type	28,6					

TABLE D.9 – Résultats des t-tests

Participant	Position	Direction							1 Capteur	3 Capteurs
				Depart	Pic $EMG_f$	Dérivée max	Max $EMG_r$	$\Delta$ Max $EMG_r$	Biceps	Biceps
1	Haute	Haut	Moyenne	55,0	239,0	148,5	278,5	258,0	162,5	162,5
			écart type	39,9	48,1	36,4	101,1	93,5	27,6	20,9
		Bas	Moyenne	58,0	234,0	149,0	302,5	267,0	144,0	153,3
			écart type	32,6	57,4	30,9	76,9	95,7	9,7	28,6
	Basse	Haut	Moyenne	104,0	275,5	208,0	302,5	307,0	154,5	157,0
			écart type	10,8	40,5	28,8	86,1	96,2	19,6	14,0
		Bas	Moyenne	30,0	196,0	128,0	203,0	196,5	146,0	152,9
			écart type	25,2	27,2	14,6	44,7	49,7	25,9	15,7
2	Haute	Haut	Moyenne	132,5	330,0	260,5	372,0	374,5	183,5	175,4
			écart type	89,2	75,8	78,1	99,5	107,1	33,1	28,7
		Bas	Moyenne	66,0	233,0	191,5	257,5	228,0	159,0	157,1
			écart type	65,3	51,7	46,6	80,8	59,9	38,7	26,9
	Basse	Haut	Moyenne	147,0	322,0	246,0	344,5	353,5	159,5	194,6
			écart type	78,7	67,0	87,1	80,7	82,1	21,9	27,0
		Bas	Moyenne	126,5	281,5	222,0	332,5	321,5	215,0	206,1
			écart type	115,9	104,9	82,2	68,0	87,2	71,2	50,0
3	Haute	Haut	Moyenne	94,5	285,5	215,0	314,0	327,0	170,5	183,9
			écart type	44,1	56,8	28,7	79,6	96,9	40,1	35,9
		Bas	Moyenne	85,0	269,5	202,0	303,5	288,5	190,0	175,3
			écart type	67,9	33,8	47,2	35,1	66,4	34,7	21,1
	Basse	Haut	Moyenne	107,0	297,0	259,5	339,0	340,0	141,0	165,3
			écart type	80,9	68,7	73,8	82,4	75,2	14,3	16,0
		Bas	Moyenne	113,0	305,5	257,0	371,0	351,5	175,5	178,0
			écart type	102,0	67,2	71,2	82,7	72,0	23,6	26,2

TABLE D.10 – Résultats de l'expérience préliminaire partie 1

Participant	Position	Direction		Depart	Pic $EMG_f$	Dérivée max	Max $EMG_r$	$\Delta$ Max $EMG_r$	1 Capteur Biceps	3 Capteurs Biceps
4	Haute	Haut	Moyenne	55,5	225,5	157,5	296,5	270,0	125,0	131,0
		écart type	24,9	25,1	20,3	114,8	118,0	12,9	9,8	
	Basse	Bas	Moyenne	26,0	220,5	149,0	290,5	285,5	152,5	153,5
		écart type	18,4	35,1	40,1	81,2	103,4	21,8	28,7	
	Haute	Haut	Moyenne	52,5	245,0	178,5	243,5	253,5	134,0	139,8
		écart type	30,1	30,5	32,2	63,8	91,2	20,4	20,8	
Basse	Bas	Moyenne	32,0	220,5	168,5	280,0	272,5	130,5	134,8	
	écart type	17,8	16,2	36,9	77,5	82,1	15,7	12,5		
5	Haute	Haut	Moyenne	109,0	307,5	238,5	350,0	317,0	167,5	162,3
		écart type	55,3	59,8	38,3	65,3	71,7	34,8	37,0	
	Basse	Bas	Moyenne	94,5	261,0	214,5	273,0	265,0	161,0	159,3
		écart type	67,3	33,2	36,2	49,7	49,6	50,0	34,2	
	Haute	Haut	Moyenne	138,5	336,0	264,5	340,0	382,0	175,0	174,1
		écart type	72,9	65,3	49,0	71,2	91,2	49,3	39,6	
Basse	Bas	Moyenne	22,5	234,0	164,0	257,5	252,5	168,5	157,3	
	écart type	23,4	51,6	46,1	47,1	47,7	36,1	28,6		

TABLE D.11 – Résultats de l'expérience préliminaire partie 2

1	Je trouve que l'assistance X est facile à prendre en main
2	Je trouve que l'assistance X est facile à utiliser
3	Je trouve que j'ai un bon contrôle de mes mouvements avec l'assistance X
4	Je trouve que j'ai besoin de me concentrer pour utiliser l'assistance X
5	Je trouve que je suis à l'aise pour bouger avec l'assistance X
6	L'assistance X m'a fait changer mon comportement pour effectuer la tâche (comparé à sans assistance)
7	Je trouve que l'assistance X m'assiste correctement
8	Je trouve que je suis efficace pour effectuer la tâche avec l'assistance X
9	Je trouve angoissant de travailler avec l'assistance X
10	Je trouve que travailler avec l'assistance X est agréable
11	J'aime travailler avec l'assistance X
12	Je trouve que mon contrôle de l'assistance X s'est amélioré
13	Je trouve que je m'habituais à l'assistance X
14	Je trouve que j'ai appris à bien utiliser l'assistance X
15	D'une manière générale, les sensations lors de l'utilisation de l'assistance X s'amélioraient
16	Je me sentais en sécurité en utilisant l'assistance X
17	Je me sentais plus en sécurité en utilisant l'assistance X à la fin de l'essai que au début
18	J'aurais préféré que l'assistance soit plus rapide

TABLE D.12 – Les questions sur l'assistance (posées une fois pour chaque assistance)

# Figures

**Dénombrement du nombre de nouvelles victimes par tableau de MP (triés par nombres de cas décroissants) et indice de fréquence des TMS**

	2013	2014	2015	2016	2017
<b>57</b> Affections périarticulaires provoquées par certains gestes et postures de travail	<b>36 252</b> – 3,7 %	<b>36 779</b> 1,5 %	<b>36 236</b> – 1,5 %	<b>35 083</b> – 3,2 %	<b>34 869</b> – 0,6 %
<b>98</b> Affections chroniques du rachis lombaire provoquées par la manutention manuelle de charges lourdes	2 867 – 10,2 %	2 995 4,5 %	2 891 – 3,5 %	2 661 – 8,0 %	2 688 1,0 %
<b>79</b> Lésions chroniques du ménisque	508 2,8 %	486 – 4,3 %	524 7,8 %	454 – 13,4 %	491 8,1 %
<b>97</b> Affections chroniques du rachis lombaire provoquées par des vibrations de basses et moyennes fréquences transmises par le corps entier	459 – 5,6 %	462 0,7 %	495 7,1 %	474 – 4,2 %	428 – 9,7 %
<b>69</b> Affections provoquées par les vibrations et chocs transmis par certaines machines-outils, outils et objets et par les chocs itératifs du talon de la main sur des éléments fixes	148 2,1 %	130 – 12,2 %	135 3,8 %	115 – 14,8 %	92 – 20,0 %
<b>Total</b>	<b>40 234</b> – 4,1 %	<b>40 852</b> 1,5 %	<b>40 281</b> – 1,4 %	<b>38 787</b> – 3,7 %	<b>38 568</b> – 0,6 %
<b>Nombre de salariés (pour les 9 CTN et les bureaux)</b>	<b>18 649 775</b> – 0,1 %	<b>18 615 687</b> – 0,2 %	<b>18 775 282</b> 0,9 %	<b>18 855 161</b> 0,4 %	<b>19 146 029</b> <sup>13</sup> 1,5 %
<b>Indice de fréquence</b>	<b>2,16</b> – 4,0 %	<b>2,19</b> 1,7 %	<b>2,15</b> – 2,2 %	<b>2,06</b> – 4,1 %	<b>2,01</b> – 2,1 % <sup>14</sup>

Données nationales AT/MP issues des bases annuelles SGE TAPR sur les neuf CTN, compte spécial, bureaux et sièges sociaux, et catégories professionnelles particulières.

FIGURE E.1 – Evolution du nombre de cas de TMS INRS [2015]




FIGURE E.2 – Représentations graphiques de trois fonctions d'activation

SUJET N° :

## Questionnaire

Basé sur un questionnaire de l'INRS et l'échelle de Likert (à 5 niveaux).

Votre âge : .....

sexe : .....

taille : .....

**Utilisation :** Remplir les cases avec :

1 = pas du tout d'accord / 2 = plutôt pas d'accord / 3 = moyennement d'accord / 4 = plutôt d'accord / 5 = tout à fait d'accord.

	1	2	3	4	5
- Exosquelette en général algorithme 1 et algorithme 2					
Faciliter de mise en place	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Rapidité d'apprentissage	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
- Algorithme 1					
Facilité d'utilisation	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Facilité des mouvements	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Pas de sensation d'empêchement	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Contrôle des gestes	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
- Algorithme 2					
Facilité d'utilisation	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Facilité des mouvements	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Pas de sensation d'empêchement	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Contrôle des gestes	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

**Performance :** Remplir les cases avec :

1 = beaucoup moins important / 2 = moins important / 3 = identique / 4 = plus important / 5 = beaucoup plus important

	1	2	3	4	5
- Algorithme 1 par rapport au sens exosquelette					
Vitesse d'action	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Efficacité / soutien	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Qualité / précision	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>



- Algorithme 1 par rapport Algorithme 2

	1	2	3	4	5
Vitesse d'action	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Efficacité / soutien	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Qualité / précision	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

**Modification comportement :** Remplir les cases avec :

1 = pas du tout d'accord / 2 = plutôt pas d'accord / 3 = moyennement d'accord / 4 = plutôt d'accord / 5 = tout à fait d'accord.

- Algorithme 1 par rapport au sans exosquelette

	1	2	3	4	5
Maintien du comportement / capacité	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Changement du comportement / nouvelles compétences	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

- Algorithme 1 par rapport Algorithme 2

	1	2	3	4	5
Maintien du comportement / capacité	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Changement du comportement / nouvelles compétences	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

**Dimension des affects :** Remplir les cases avec :

1 = pas du tout d'accord / 2 = plutôt pas d'accord / 3 = moyennement d'accord / 4 = plutôt d'accord / 5 = tout à fait d'accord.

	1	2	3	4	5
C'est agréable de réaliser la tâche avec	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
J'ai confiance en l'exosquelette	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Travailler avec me rendait de l'anxiété	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

**Impact sur les efforts :** (cocher)

Algorithme 1 par rapport au sans exosquelette :

Tableau des efforts	Sans changement	Diminution/Disparition	Apparition/aggravation
Cervical			
Epaules			
Bras/Avant-bras			
Dois			
Membres inférieurs			

Algorithme 1 par rapport à l'algorithme 2 :

Tableau des efforts	Sans changement	Diminution/Disparition	Apparition/aggravation
Cervical			
Epaules			
Bras/Avant-bras			
Dois			
Membres inférieurs			

**Conclusion :**

	Favorable	moyennement favorable	peu favorable	Défavorable
Exosquelette avec algorithme 1	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Exosquelette avec algorithme 2	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

FIGURE E.3 – Questionnaire de Ressenti de l'étude 2

## NOTICE D'INFORMATION ET CONSENTEMENT ECLAIRE

---

**Titre du projet :** Quantification des performances de l'exosquelette BHV2

**Chercheur titulaire responsable scientifique du projet :**

Franck Geffard (franck.geffard@cea.fr) - Chercheur au CEA-List Nano Innov

Arnaud Deflers (arnaud.deflers@aliceadsl.fr) - M1 ISMH Paris-Saclay

Thomas Lorcy (thomasaxo@gmail.com) - M1 ISMH Paris-Saclay

Benjamin Treussart (benjamin.treussart@cea.fr) - Doctorant CEA-List Nano Innov

**Lieu de la recherche :**

CEA-List Nano Innov, 8 Avenue de la Vauve, 91120 Palaiseau

**But du projet de recherche :**

Etudier et comparer les performances de l'exosquelette BHV2 dans différents modes lors d'une tâche de port de charge.

**Ce que l'on attend de vous :**

Vous participerez à une expérience dans laquelle vous devrez réaliser une série de mouvement d'élévation des bras en portant une charge de 7 kg sous différentes modalités :

- Avec l'exosquelette fonctionnant sous un algorithme 1
- Avec l'exosquelette fonctionnant sous un algorithme 2
- Sans exosquelette

Avec 2 séries de 3 séquences pour chaque mode en vitesse libre et 2 séries de 3 séquences en vitesse imposée.

Vous allez devoir, dans tous les modes, vous positionner selon la posture imposée lors de la tâche. Vous devrez attraper des deux mains une charge de 7 kg au niveau de votre bassin et venir l'élever légèrement au-dessus de la tête. Vos mouvements seront enregistrés à l'aide de capteurs EMG servant à quantifier l'activité musculaire et d'une caméra vidéo. Il nous faudra au préalable vous placer les capteurs EMG sur le corps aux endroits suivants : trapèze supérieur, lombaires, deltoïde antérieur, biceps, triceps, tibial antérieur et soléaire. A la fin de l'expérience, vous remplirez un questionnaire ergonomique sur votre ressenti lors de l'utilisation de l'exosquelette et des différents modes.

**Vos droits de vous retirer de la recherche à tout moment :**

Votre contribution à cette recherche est totalement volontaire, vous pourrez vous en retirer ou cesser votre participation à tout moment. Votre décision de participer, de refuser de participer ou de cesser votre participation n'aura aucun effet sur une quelconque note, votre statut ou vos relations futures avec l'institut de recherche CEA-List Nano Innov ou l'université Paris-Saclay.

**Vos droits à la confidentialité et au respect de la vie privée :**

Les données recueillies seront traitées avec la confidentialité la plus entière, votre identité sera masquée à l'aide d'un numéro aléatoire, aucuns autre renseignement ne pourra révéler votre identité. Toutes les données seront gardées dans un endroit sécurisé et seuls le responsable scientifique et les chercheurs adjoints y auront accès. Le stricte anonymat des données rend impossible la rectification ou la suppression des informations après la fin de votre participation.

**Bénéfices de l'étude :**

Les avantages attendus de cette recherche sont d'obtenir des données sur les différents modes de l'exosquelette afin de comparer les performances entre les différents algorithmes de programmation, de mener une étude ergonomique sur son utilisation et de quantifier son intérêt dans une tâche de port de charge. Ces résultats pourront contribuer à améliorer la connaissance des exosquelettes actifs, et de la plus-value qu'ils peuvent apporter dans l'industrie.

Les résultats seront renseignés dans un mémoire de stage, et seront peut être repris pour étoffer une future thèse ou étude plus poussée.

**Risques possibles de l'étude :**

Cette recherche peut comprendre des risques liés à la manutention et au port de charge. Selon l'Article R.4541-9 du Code du travail, le déplacement d'une charge de 7 kg est jugé acceptable et est en dessous des limites préconisées par le CMSM, organisme traitant de la santé du travail et de la prévention des risques professionnels. Un autre risque possible lors de la manipulation peut être un dysfonctionnement de l'exosquelette, si cela se produit, un bouton d'arrêt d'urgence est présent sur l'engin.

Voir feuille de décharge pour les autres risques moins probables.

**Diffusion :**

Cette recherche n'a pour l'instant pas vocation à être diffusée ailleurs que dans le mémoire de stage, elle rentre dans le cadre du stage de recherche du M1 ISMH.

**Vos droits de poser des questions :**

Vous pouvez poser des questions au sujet de la recherche avant, pendant et après votre participation en communiquant avec Thomas Lorcy (thomasaxo@gmail.com) ou Arnaud Deflers (arnaud.deflers@aliceadsl.fr).

**Consentement à la participation :**

En signant le formulaire de consentement, vous certifiez que vous avez lu et compris les renseignements ci-dessus, que le chercheur a répondu à vos questions de façon satisfaisante et qu'il vous a avisé que vous étiez libre d'annuler votre consentement ou de vous retirer de cette recherche à tout moment, sans préjudice.

**A remplir par le participant :**

J'ai lu et compris les renseignements ci-dessus et j'accepte de plein gré de participer à cette recherche.

Date. Nom. Prénom. Signature :

**A remplir par l'expérimentateur :**

Date, Nom, Prénom, Signature :

---

Un exemplaire de ce document vous est remis, un autre exemplaire est conservé par l'expérimentateur.

FIGURE E.4 – Consentement éclairé de l'étude 2




FIGURE E.5 – Indicateurs de temps de réponse sur le signal non filtré. En bleu le signal rectifié non filtré, en vert le déclenchement de l'à-coup, en cyan -  $\Delta \text{Max } EMG_r$  et en rouge -  $\text{Max } EMG_r$




FIGURE E.6 – Indicateurs de temps de réponse sur le signal de chaque électrode




FIGURE E.7 – Réponse à un gain trop important




FIGURE E.8 – Réponse stable (gain suffisamment faible)




FIGURE E.9 – Activité moyenne du trapèze pour les 10 participants au cours de chaque série




FIGURE E.10 – Activité moyenne du deltoïde pour la cinquième série

**Titre :** Étude et conception d'un système de pilotage intuitif d'exosquelette pour l'assistance au port de charges

**Mots clés :** Exosquelette, Commande, Electromyographie, Intelligence artificielle, Cobotique

**Résumé :** Les troubles musculo-squelettiques (TMS) sont les premières causes de maladies professionnelles en France. Ils peuvent notamment apparaître suite à un port de charges, particulièrement critiques en raison des efforts intenses et répétés que cette tâche nécessite. Une solution pour prévenir l'apparition des TMS est d'assister physiquement les travailleurs afin de réduire l'effort engendré. Les exosquelettes apparaissent comme un des outils les plus prometteurs pour fournir cette assistance. Cependant, leur commande est un des verrous limitant leur mise en fonction dans l'industrie. C'est sur ce point que ce travail de recherche s'est focalisé. Ainsi une stratégie de commande d'un exosquelette de membres supérieurs pour l'assistance au port de charge sans connaissance à priori de la masse a été développée et intégrée. L'originalité de ce travail de recherche vient de l'estimation de l'intention en effort de l'utilisateur via son activité musculaire, estimée grâce à des capteurs électromyographiques, et de son utilisation dans la commande en effort d'un exosquelette. Ceci permet notamment de compenser le poids de charges non connues

à priori. Ce système de détection d'intention est basé sur une méthode hybride intégrant un modèle du couple développé en fonction de l'activité musculaire et un réseau de neurones artificiels. Le système de commande a ensuite été évalué avec dix utilisateurs. Il a été constaté que cette méthode induisait : (i) des performances équivalentes à une assistance par compensation de gravité classique (avec connaissance à priori de la charge), mais aussi(ii) une réduction de l'activité musculaire du participant. L'impact de la personnalisation des paramètres (gain du contrôleur) sur les utilisateurs a également été analysé, et ce travail a démontré que cette personnalisation facilite la prise en main intuitive du système. Au cours des développements une attention particulière a été de proposer une approche facilement déployable sur le terrain, afin de tenir compte de l'orientation industrielle des applications. En effet, ce travail de recherche ouvre des perspectives d'applications pour les exosquelettes actifs dédiés au port de charges, comme par exemple dans le secteur de la logistique où les charges à manipuler sont variées.

**Title :** Design and study of a system to control intuitively an exoskeleton in order to assist load carrying

**Keywords :** Exoskeleton, Control, Electromyography, Artificial Intelligence, Cobotic

**Abstract :** Musculoskeletal disorders (MSD) are the leading cause of occupational disease in France. MSDs may appear after carrying loads, this task being particularly critical because of the intense and repeated efforts that it requires. One solution to prevent the appearance of MSDs is to physically assist workers in order to reduce the effort involved. Exoskeletons appear to be one of the most promising tools for providing this assistance. However, their control is one of the locks slowing down their deployment in the industry. This doctoral project aims to investigate control and command of an exoskeleton in interaction with an operator. Thus, a strategy to control an upper-limb exoskeleton for load carrying assistance, without prior knowledge of the mass, was developed and integrated. The originality of this research work lies in two points. The first one is the estimation of the user's intention as a torque via his muscular activity, measured with electromyographic sensors. And the second one is the use of this estimated intention in the effort control of an exoskeleton. This approach makes possible to compensate the weight of loads that are not known beforehand. This intention detection

system is based on a hybrid method integrating a model of the torque applied according to the muscular activity and an artificial neural network, in order to evaluate the direction of the movement intended. The control system was then evaluated through an experimental protocol with ten participants. It was found that this method induced : (i) performances equivalent to a classical gravity compensation assistance (with prior knowledge of the load), but also (ii) a reduction of the participant's muscular activity (biceps, anterior deltoid, and erector spinae). Finally, a method of personalization of the control system based on the user's response time was designed. The impact of the personalization of the parameters (controller gain) on the users was also analyzed, and this work demonstrated that this personalization facilitates the intuitive handling of the system. During development, particular attention was given to proposing an approach that could be easily deployed in the workplace, in order to take into account the industrial orientation of the applications. Indeed, this research work opens up new application perspectives for active exoskeletons dedicated to load carrying, such as in professional logistic area.