

Mise au point et validation d'une approche terrain de prédiction des chargements au dos basée sur des données de laboratoire

Alain Delisle
François Thénault
André Plamondon
Hakim Mecheri

RAPPORTS
SCIENTIFIQUES

R-1164-fr



NOS RECHERCHES travaillent pour vous !

Solidement implanté au Québec depuis 1980, l'Institut de recherche Robert-Sauvé en santé et en sécurité du travail (IRSST) est un organisme de recherche scientifique reconnu internationalement pour la qualité de ses travaux.

Mission

Dans l'esprit de la Loi sur la santé et la sécurité du travail (LSST) et de la Loi sur les accidents du travail et les maladies professionnelles (LATMP), la mission de l'IRSST est de :

Contribuer à la santé et à la sécurité des travailleuses et travailleurs par la recherche, l'expertise de ses laboratoires, ainsi que la diffusion et le transfert des connaissances, et ce, dans une perspective de prévention et de retour durables au travail.

Pour en savoir plus

Visitez notre site Web ! Vous y trouverez une information complète et à jour. De plus, toutes les publications éditées par l'IRSST peuvent être téléchargées gratuitement. www.irsst.qc.ca

Pour connaître l'actualité de la recherche menée ou financée par l'IRSST, abonnez-vous gratuitement :

- au magazine *Prévention au travail*, publié conjointement par l'Institut et la CNESST (preventionautravail.com)
- au bulletin électronique [InfoIRSST](#)

Dépôt légal

Bibliothèque et Archives nationales du Québec, 2022
ISBN 978-2-89797-234-9 (PDF)

© Institut de recherche Robert-Sauvé
en santé et en sécurité du travail, 2022

IRSST - Direction des communications, de la veille
et de la mobilisation des connaissances
505, boul. De Maisonneuve Ouest
Montréal (Québec)
H3A 3C2
Téléphone : 514 288-1551
publications@irsst.qc.ca
www.irsst.qc.ca

Mise au point et validation d'une approche terrain de prédiction des chargements au dos basée sur des données de laboratoire

Alain Delisle¹, François Thénault¹, André Plamondon², Hakim Mecheri²

¹ Université de Sherbrooke

² IRSST

RAPPORTS
SCIENTIFIQUES

R-1164-fr



Avis de non-responsabilité

L'IRSST ne donne aucune garantie relative à l'exactitude, la fiabilité ou le caractère exhaustif de l'information contenue dans ce document.

En aucun cas l'IRSST ne saurait être tenu responsable pour tout dommage corporel, moral ou matériel résultant de l'utilisation de cette information.

Notez que les contenus des documents sont protégés par les législations canadiennes applicables en matière de propriété intellectuelle.

Cette publication est disponible en version PDF sur le site Web de l'IRSST.



ÉVALUATION PAR DES PAIRS

Conformément aux politiques de l'IRSST, les résultats des travaux de recherche publiés dans ce document ont fait l'objet d'une évaluation par des pairs.

TABLE DES MATIÈRES

SOMMAIRE	V
INTRODUCTION	1
Pertinence et importance du sujet.....	1
1. ÉTAT DES CONNAISSANCES	2
1.1 Les approches actuelles	2
1.2 Genèse de l'approche proposée	3
2. OBJECTIFS DE RECHERCHE	5
3. MÉTHODOLOGIE	6
3.1 Présentation des données utilisées.....	7
3.1.1 Caractéristiques dérivées du signal EMG	8
3.1.2 Caractéristiques dérivées de la cinématique.....	8
3.1.3 Le moment en L5/S1	10
3.2 Prétraitement des données	11
3.3 Construction des jeux de données	12
3.3.1 Sélection des intrants	12
3.3.2 Partition des données.....	13
3.4 Génération des réseaux de neurones	14
3.4.1 Réseau à délai temporel (RDT)	15
3.4.2 Réseau de neurones récurrents à mémoire court terme et long terme (LSTM)	15
3.5 Analyse de la performance	17
4. RÉSULTATS	19
4.1 Comparaison des deux types de réseau	19
4.2 Influence des sources de données et de certaines variables	19
4.3 Performance du réseau LSTM final.....	25
5. DISCUSSION	26
CONCLUSION	30
BIBLIOGRAPHIE	31

ANNEXE A	38
A.1 Description des tâches et des données disponibles	38
ANNEXE B	40
B.1 Statistiques descriptives des intrants cinématiques	40
ANNEXE C	41
C.1 Statistiques descriptives des intrants électromyographiques.....	41
ANNEXE D	44
D.1 Identification automatique des artEfacts des signaux électromyographiques	44

LISTE DES TABLEAUX

Tableau 1.	Caractéristiques dérivées des signaux EMG	9
Tableau 2.	Centiles des indicateurs de performance de la prédiction des moments selon le réseau à délai temporel (RDT) et le réseau à mémoire court terme long terme (LSTM)	19
Tableau 3.	Centiles des indicateurs de performance de la prédiction des moments en L5/S1 selon la source de données	20
Tableau 4.	Centiles des indicateurs de performance de la prédiction des moments en L5/S1 selon le sexe	21
Tableau 5.	Centiles des indicateurs de performance de la prédiction des moments en L5/S1 selon l'expertise	21
Tableau 6.	Écart moyen (écart type) de prédiction (en N m) selon les différentes classes d'amplitude du moment	23
Tableau 7.	Indicateurs de performance pour le réseau final	25
Tableau 8.	Description des tâches et des données disponibles pour les différentes études	38
Tableau 9.	Statistiques descriptives des intrants cinématiques pour l'ensemble des données et selon chaque étude (Plamondon <i>et al.</i> , 2010 ; Plamondon <i>et al.</i> , 2012, Delisle <i>et al.</i> , 2016)	40
Tableau 10.	Statistiques descriptives de chacune des caractéristiques des signaux électromyographiques utilisées lors de la prédiction des moments au dos pour l'ensemble des données et selon chaque étude (Plamondon <i>et al.</i> , 2010 ; Plamondon <i>et al.</i> , 2012, Delisle <i>et al.</i> , 2016). La description des variables est donnée au tableau 1.	41
Tableau 11.	Quantification des artefacts EMG	46
Tableau 12.	Indice de performance des modèles	48
Tableau 13.	Proportion (nombre de portions) de signaux identifiée comme artefact (VP) ou bon signal (VN) selon différentes combinaisons de modèles	49

LISTE DES FIGURES

Figure 1.	Les principales étapes de la démarche réalisée.....	6
Figure 2.	Distribution du nombre de sujets (Nb sujets), du nombre d'essais (Nb essais) et de la durée de manutention (Nb min) à travers les trois études.	7
Figure 3.	Distribution des trois composantes du moment en L5/S1 selon les différentes études, sources de données.....	10
Figure 4.	Distribution du moment à prédire A) en flexion latérale, et B) en flexion-extension, selon le sexe et l'expertise des participants.	11
Figure 5.	Répartition des données pour la validation externe et l'entraînement (entraînement et validation interne).....	14
Figure 6.	Illustration et caractéristiques techniques des deux réseaux de neurones comparés.	17
Figure 7.	Scores Topsis médian (50 ^e centile) selon les jeux de données, le sexe et l'expertise.....	22
Figure 8.	Illustration de la prédiction du moment en flexion/extension (FE-LSTM) et du moment en flexion latérale (FL-LSTM) du réseau LSTM en comparaison à la mesure critère (FE et FL).	24
Figure 9.	Illustration de la prédiction du moment en flexion extension (FE-LSTM) et du moment en flexion latérale (FL-LSTM) par le réseau LSTM final pour une tâche de levers à une main, en comparaison à la mesure critère du moment en L5/S1 (FE et FL).....	25
Figure 10.	Exemple d'un signal corrompu.	49
Figure 11.	Exemple d'un signal en apparence de bonne qualité.	50

SOMMAIRE

Les troubles musculosquelettiques (TMS) et particulièrement ceux au bas du dos affectent de nombreux travailleuses et travailleurs chaque année au Québec (Vézina *et al.*, 2011). Le chargement mécanique au bas dos est reconnu comme un facteur de risque pouvant mener au développement de maux de dos, et la manutention de charges peut occasionner des chargements importants et répétés. La façon habituelle de quantifier le chargement au dos des individus est d'estimer le moment qui s'exerce à l'articulation lombo-sacrée (L5/S1). L'estimation de ce moment se fait généralement en laboratoire et nécessite la connaissance de la position et de l'orientation de chacun des segments de la personne ainsi que la charge externe qui s'exerce sur elle, soit aux mains ou aux pieds. Cette approche, de type laboratoire, nécessite beaucoup d'instrumentation et peut difficilement s'appliquer en milieu de travail.

Cette étude s'inscrit dans la continuité des travaux de recherche de l'IRSST sur la manutention visant, entre autres, la quantification du chargement mécanique au bas du dos en milieu de travail. L'objectif poursuivi est de développer et valider une approche permettant d'estimer le moment en L5/S1 à partir des mesures d'un nombre restreint de capteurs sur la personne manutentionnaire afin de limiter l'encombrement de celle-ci. Grâce à des techniques d'apprentissage machine (réseau de neurones artificiels), les données de Delisle *et al.* (2016), de Plamondon *et al.* (2012) et de Plamondon *et al.* (2010) menés en laboratoire ont servi à élaborer une approche capable d'estimer le moment en L5/S1, en ne nécessitant que la mesure des mouvements du tronc et du bassin et de l'activité musculaire des extenseurs du dos.

Deux types de réseaux de neurones ont été comparés afin d'identifier le plus performant. Un réseau de neurones récurrents à mémoire court terme et long terme a été retenu, non seulement en raison d'une performance supérieure, mais aussi en raison de sa rapidité d'exécution. Un algorithme permettant d'automatiser le contrôle de qualité des signaux représentant l'activité musculaire a également été développé afin de faciliter l'utilisation future de l'approche.

Les résultats révèlent que l'approche permet d'expliquer 80 % de la variance du moment en L5/S1, en comparaison avec un modèle de référence de type laboratoire, avec une erreur quadratique moyenne de l'ordre de 21 N m. Il s'agit d'une performance très acceptable pour une approche de ce type, Cette approche peut être utilisée tant auprès de femmes que d'hommes manutentionnaires lors des manutentions des boîtes de zéro à 23 kg sur une distance de moins de 1,5 mètre, manipulées à des hauteurs variées entre le sol et les épaules, sans restreindre les déplacements de pieds.

INTRODUCTION

L'estimation du chargement au dos est une nécessité lorsqu'il y a lieu d'évaluer les risques musculosquelettiques d'une tâche de manutention ou encore lors de la mesure de l'exposition physique de travailleurs. Cette estimation n'est pas simple et nécessite généralement des instruments de mesure uniquement disponibles en laboratoire. Le développement de nouveaux instruments de mesure terrain et des logiciels destinés à traiter un grand nombre de données permettent d'envisager une évaluation des chargements au dos directement sur le terrain. Fort de l'expérience acquise avec l'utilisation des réseaux de neurones artificiels (RNA) dans une étude de Delisle *et al.*, 2016, ce projet vise l'amélioration de l'approche utilisée dans cette étude et une plus grande généralisation. En effet, l'approche utilisée par Delisle *et al.*, (2016) basée sur un entraînement de chaque réseau de neurones destiné à estimer le moment au bas du dos sur une base individuelle s'était révélée très prometteuse pour certains individus, mais décevante pour d'autres. De plus, cette approche individuelle nécessitait une procédure de calibrage alourdissant son utilisation en contexte de travail réel. Dans l'objectif de permettre l'estimation du chargement au bas du dos en continu en situation réelle de travail, l'exploitation de l'ensemble des données recueillies au cours de différents projets subventionnés antérieurement par l'IRSST (Delisle *et al.*, 2016 ; Plamondon *et al.*, 2012 ; Plamondon *et al.*, 2010) a été explorée. Cette procédure apparaissait comme une alternative prometteuse pour entraîner un RNA générique intégrant une variabilité d'individus (en termes de sexe et d'expérience) et de tâches de manutentions (masses de boîtes, hauteur d'élévation et d'abaissement). Un tel RNA générique ne requerrait aucun calibrage individuel, le rendant beaucoup plus simple d'utilisation.

Pertinence et importance du sujet

Les troubles musculosquelettiques (TMS) et particulièrement ceux de la région lombaire affectent de nombreux travailleurs québécois (Vézina *et al.*, 2011). Selon cette enquête menée en 2007-2008, 9 % des travailleurs au Québec rapportaient des TMS au dos liés à leur emploi principal, assez souvent ou tout le temps. Cette proportion augmente à 17 % pour ceux qui affirmaient être exposés souvent ou tout le temps à la manutention de charges lourdes. Selon les données de la CNESST, de 2013 et 2017, les lésions de type TMS reliées à la manutention représentaient 16,5 % (75 921 cas) de l'ensemble des lésions professionnelles sur cette période (Boucher *et al.*, 2019) avec des débours s'élevant à plus 770 millions de dollars. Dans près de 57 % des cas, les efforts excessifs en soulevant quelque chose ou en tenant, transportant, brandissant des objets constituaient le genre d'accident évoqué. Toujours sur cette période de 5 ans, les lésions au dos reliées à la manutention représentaient 10,5 % (48 599 cas) de l'ensemble des lésions professionnelles, soit 64 % des lésions reliées à la manutention. Ces quelques données sont en accord avec les constats des revues de la littérature qui associent la manutention de charges au développement des TMS au dos (par exemple : Hoogerdoorn *et al.*, 2000; National Research Council, 2001).

1. ÉTAT DES CONNAISSANCES

1.1 Les approches actuelles

Des études biomécaniques ont démontré que l'exposition répétée à des chargements d'un niveau inférieur à celui pouvant affecter subitement les tissus peut conduire à des fractures de fatigue des plateaux vertébraux ou à des atteintes aux disques (Brinckmann *et al.*, 1998 ; Callaghan et McGill, 2001). Il est de plus établi que la tolérance des tissus varie dans le temps en fonction des charges répétées auxquelles ils sont soumis. À mesure que le chargement cumulé augmente, la tolérance des tissus diminuerait, ce qui réduirait la marge de sécurité disponible et accroîtrait le risque de blessures. Ainsi, tous les chargements sur les tissus, qu'ils soient maximums ou non, et leur cumul dans le temps, peuvent révéler des informations importantes pour mieux comprendre les liens avec les atteintes aux tissus et les prévenir (Waters, Yeung, Genaidy, Callaghan, Barriera-Viruet et Dedeens, 2006 ; Waters, Yeung, Genaidy, Callaghan, Barriera-Viruet, Abdallah et Kumar, 2006).

Une façon de quantifier le chargement au dos des travailleurs est de mesurer en continu les moments nets qui s'exercent sur les trois axes anatomiques à l'articulation L5/S1 (Gagnon, 2003). La sommation vectorielle du moment net exprimé dans le référentiel du bassin serait un bon indicateur de chargement sur la colonne, même pour des tâches avec une forte composante asymétrique (van Dieën et Kingma, 2005). Le calcul de ces moments nécessite la connaissance de la position et de l'orientation de chacun des segments du corps du travailleur ainsi que de la charge externe qui s'exerce sur lui, soit aux mains ou aux pieds. Ces moments peuvent être décomposés en 4 termes d'importances relatives (Équation 1 ; Plamondon *et al.*, 1996). Les moments nets calculés en laboratoire par la méthode de dynamique inverse, avec l'utilisation de systèmes optoélectroniques et de capteurs de forces aux pieds ou aux mains, sont considérés comme la référence.

Équation 1.

$$\vec{M}_{L5S1} = \underbrace{- \sum_{r=1}^n \vec{e}_{L5S1} \times \vec{F}_r}_{\text{Terme 1}} - \underbrace{\sum_{r=1}^N \vec{M}_r}_{\text{Terme 2}} - \underbrace{\sum_{i=1}^k \vec{e}_{L5S1} \times m_i \vec{g}}_{\text{Terme 3}} + \underbrace{\sum_{i=1}^k \vec{e}_{L5S1} \times m_i \vec{a}_i + \sum_{i=1}^k \frac{d}{dt} (I_i \vec{\omega}_i)}_{\text{Terme 4}}$$

Où le Terme 1 représente les moments dus aux forces et aux torques externes, le Terme 2 représente les moments dus au poids des segments, le Terme 3 représente les moments dus aux forces d'accélération linéaires des segments et le Terme 4 représente

les moments dus aux accélérations de rotation des segments ; et où $e_{\vec{L}5S1}$, représente les bras de levier des forces par rapport à l'articulation L5/S1. En général, le terme 1 contribue majoritairement au moment total, suivi du terme 2, 3 puis 4.

1.2 Genèse de l'approche proposée

La grande majorité des recherches qui quantifie les chargements au dos s'effectue en laboratoire. La suite consiste à développer des méthodes qui permettront de mesurer ces chargements sur le terrain. Pour cela, l'instrumentation doit être minimale pour ne pas interférer avec la tâche et le modèle proposé doit minimiser la perte de précision et de validité. La réussite de cette étape permettrait de quantifier rapidement l'exposition des travailleurs, d'identifier les tâches à risque, de révéler les expositions trop longues ou de réagencer des postes de travail. Le but serait de désamorcer en amont de potentiels épisodes de mal de dos ou de mesurer objectivement les effets des interventions ergonomiques et ainsi optimiser le rendement.

Différentes approches terrain existent, mais chacune d'elle présente des limites, soit en termes de temps de traitement, de difficultés d'instrumentation, d'interférence de l'instrumentation avec la tâche, de validité ou de fiabilité de la mesure (Wong *et al.*, 2015).

L'approche ambulatoire la plus prometteuse actuellement est l'utilisation de modèle biomécanique utilisant des senseurs inertiels (IMU) (Kim et Nussbaum, 2014 ; Robert-Lachaine *et al.*, 2017). Les données cinématiques (CIN) générées par ce type de senseur sont l'orientation du segment sur lequel il est fixé ainsi que plusieurs mesures dérivées comme l'accélération du centre de masse et la vitesse angulaire du segment. Un modèle complet du corps requiert cependant une instrumentation plus encombrante et un calibrage plus exigeant, ce dernier pouvant être une source d'erreur supplémentaire (Miezial *et al.*, 2016). L'environnement dans lequel évolue le travailleur est aussi important, puisque les senseurs sont sensibles aux perturbations électromagnétiques. Si ce type de système permet d'obtenir l'orientation des segments, il ne fournit pas d'information sur la position de ces derniers ($e_{\vec{L}5S1}$ de l'équation 1) ni sur les forces externes (Terme 1 de l'équation 1). Mesurer ces forces sur le terrain n'est pas facile et a été tenté à l'aide de chaussures instrumentées (Faber *et al.*, 2010) ou à l'aide d'un appareillage imposant (Marras *et al.*, 2010) qui dénature la tâche.

Les approches utilisant l'électromyographie de surface (EMG) sont, pour la majorité, associées à des modèles biomécaniques du plus simple (Cholewicki *et al.*, 1995) au plus complexe (Gagnon *et al.*, 2016). Quelques chercheurs ont exploré cette approche pour une application terrain, mais cela exigeait une calibration intensive (Dolan *et al.*, 2001), soit les tâches effectuées étaient très standardisées et non représentatives de la réalité (Granata et Marras, 1995), soit d'autres intrants étaient nécessaires (Jia *et al.*, 2011).

L'attrait de l'EMG est toujours de mise, car le chargement au dos est en relation avec l'amplitude de l'EMG des muscles du dos (Abdoli *et al.*, 2006 ; Arjmand et Shirazi-Adl, 2006). Par contre l'EMG comporte de nombreux facteurs confondants. La relation entre

l'EMG et la force est modulée par la relation force-vitesse-longueur, la fatigue, la morphologie de la personne, la complexité géométrique du modèle, le type de filtre utilisé et le type de normalisation, entre autres (De Luca, 1997, Devaprakash *et al.*, 2016). Lorsque combiné avec des approches de type « intelligence artificielle », l'EMG permet une grande variété d'applications, comme piloter des prothèses, reconnaître le langage des signes, estimer le niveau de fatigue et même évaluer les moments de force articulaires (Chowdhury *et al.*, 2013, Peng *et al.*, 2015).

Parmi la multitude de méthodes que l'on peut classer dans la catégorie intelligence artificielle, les réseaux de neurones artificiels (RNA) sont considérés comme des « approximateurs universels » si on leur présente les bons intrants et une quantité suffisante de données (Bishop, 2006). Ils sont utilisés pour estimer la fatigue (Rogers et MacIsaac, 2010), prédire l'orientation de la colonne vertébrale (Gholipour et Arjmand, 2016), déterminer les moments au coude (Peng *et al.*, 2015), aux segments inférieurs (Ardestani *et al.*, 2014 ; Favre *et al.*, 2012) et même aux dos (Parkinson et Callaghan, 2009). La plupart de ces études nécessitaient cependant la force externe dans leurs intrants, ce qui limite leur application terrain. La fusion de différentes approches et de méthodologies pour une mesure sur le terrain semble incontournable (Wong *et al.*, 2015).

Dernièrement, la fusion de deux sources de données (EMG-CIN) pour estimer les moments nets au dos lors de tâches de manutention a été réalisée par Delisle *et al.* (2016). Ce dernier projet était subdivisé en trois étapes. Les chercheurs ont d'abord évalué la faisabilité d'une approche individualisée RNA-EMG-CIN pour estimer les moments nets en comparaison à un modèle de référence par dynamique inverse. Les variables EMG provenaient de 6 muscles du tronc et les variables CIN du tronc d'un système optoélectronique. Le RNA était entraîné pour chaque individu (sujet dépendant) et la validation était faite avec les mêmes individus (sujet spécifique) effectuant les mêmes tâches (tâche spécifique), mais sur des essais n'ayant pas servi à l'entraînement. Delisle *et al.* (2016) ont ensuite développé un modèle à dynamique inverse ambulatoire avec des senseurs inertiels pour obtenir les variables CIN, et une caisse instrumentée pour calibrer la relation RNA-EMG-CIN au moment net, nécessaire à l'utilisation terrain de l'approche. Enfin, ils ont évalué la performance de cette approche RNA-EMG-CIN pour prédire le moment net lors de tâches de manutentions libres. La validation a été effectuée sur les mêmes sujets (sujet spécifique) sur des tâches (transferts de 24 boîtes de 11 et 16 kg, avec et sans fatigue musculaire) différentes de celles ayant servi à l'entraînement (transfert d'une caisse instrumentée avec poignées, de 9 et 18 kg, sans fatigue musculaire). Dans ces conditions, les moments prédits expliquaient en moyenne 50 % de la variance de ceux obtenus avec le modèle de référence. Cette performance mitigée, avec la contrainte de devoir calibrer le modèle avec une caisse instrumentée pour chaque participant, a conduit à une réévaluation de l'approche et à un nouveau développement dans le cadre de cette recherche.

2. OBJECTIFS DE RECHERCHE

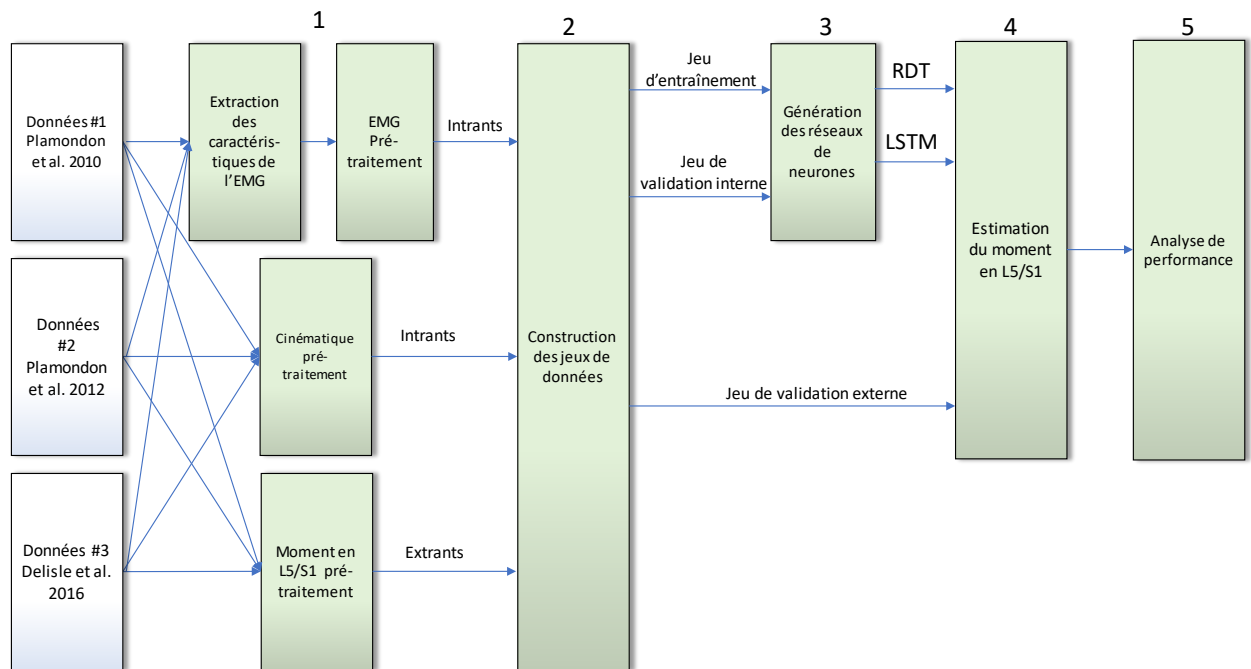
L'objectif principal était de développer et valider une approche pour estimer les moments au dos, simple d'utilisation et basée sur un réseau de neurones générique. Étant donnée la nature « approximateur universel » des réseaux de neurones, un remaniement des intrants et l'augmentation de la quantité de données d'entraînement devraient permettre d'améliorer les performances de cette approche. À cette fin, les données des projets de Delisle *et al.* (2016), de Plamondon *et al.* (2012) et de Plamondon *et al.* (2010) ont été utilisées. Construire un seul réseau de neurones générique permettra d'augmenter la quantité de données disponibles pour l'entraînement, d'inclure une plus grande variété de tâches et d'individus, et d'assurer une meilleure généralisation de la prédiction du réseau.

3. MÉTHODOLOGIE

La méthodologie poursuivie comportait plusieurs étapes. Elles sont représentées de manière schématisée à la figure 1. À partir des données recueillies lors de trois projets antérieurs, de Delisle *et al.* (2016), de Plamondon *et al.* (2012) et de Plamondon *et al.* (2010), des prétraitements ont d'abord été effectués sur les signaux électromyographiques (EMG), sur les données cinématiques et les moments en L5/S1 ont été calculés. Le prétraitement des signaux EMG a fait l'objet d'un développement novateur d'une approche automatisée de détection de problèmes dans les signaux (annexe D). Une extraction d'un ensemble restreint de caractéristiques pour représenter le signal EMG comme intrants a été effectuée et les autres intrants déterminés. Différents jeux de données ont ensuite été créés afin de générer et valider les réseaux de neurones et, finalement, apprécier leur performance pour estimer le moment en L5/S1. Deux types de réseau de neurones ont d'abord été comparés. À la lumière de leur performance, un seul réseau a été retenu. Pour ce dernier, de nouveaux jeux de données ont été créés pour l'entraîner, le valider et évaluer sa performance finale (reprise des étapes 3 à 5).

Figure 1. Les principales étapes de la démarche réalisée.

Note : L'étape 1 réfère au prétraitement des données, l'étape 2 à la construction des jeux de données incluant la sélection des intrants les plus pertinents, l'étape 3 concerne la génération des deux réseaux de neurones comparés dans un premier temps, soit le réseau à délai temporel (RDT) et le réseau à mémoire court terme et long terme (LSTM), quant à leur performance à estimer le moment en L5/S1 (étape 4 et 5). Une fois le réseau final ciblé, les étapes 2 à 5 ont été reprises pour apprécier sa performance.



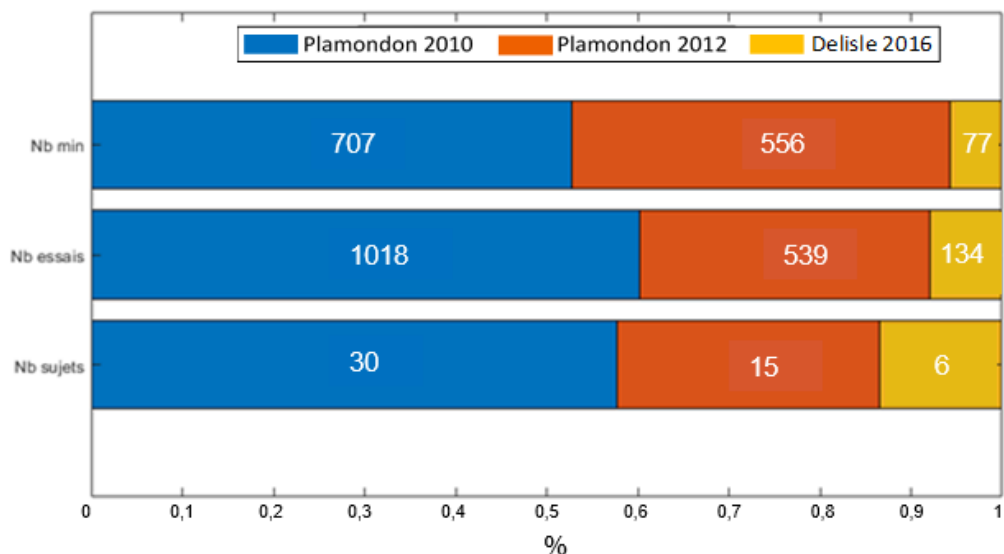
Dans les sections qui suivent, les données sources utilisées sont brièvement présentées, puis les caractéristiques extraites des signaux électromyographiques et des données cinématiques qui ont été considérées comme intrants potentiels aux modèles sont décrites. Vient ensuite la description des différentes étapes schématisées à la figure 1 et menant à la génération des réseaux de neurones et à l'analyse de leur performance pour l'estimation des moments en L5/S1.

3.1 Présentation des données utilisées

L'utilisation des données de trois études antérieures permet d'avoir une grande richesse en termes de tâches de manutention, d'expertise des manutentionnaires, du sexe des manutentionnaires, de même qu'en termes de fatigue musculaire. Ces trois études ont en commun des données de signaux électromyographiques du muscle longissimus bilatéralement, le moment net à L5/S1 calculé par dynamique inverse ainsi que des variables cinématiques décrivant l'attitude du tronc et du bassin, pouvant être déterminées soit par un système optoélectronique ou par des senseurs inertiels. La figure 2 illustre la contribution des différentes études en termes du nombre de sujets, d'essais et de la longueur des acquisitions. Ainsi, 51 participants ayant effectué un total de 1691 essais fournissent 1340 minutes de manutention. La longueur moyenne des essais était de 47,54 (85,55) secondes.

Sur l'ensemble des sujets, 37 % étaient des femmes et 63 % des hommes. L'expertise est divisée en 59 % d'expert et 41 % de novice. Les caractéristiques des tâches et les données disponibles pour chacune des études sont décrites à l'annexe A.

Figure 2. Distribution du nombre de sujets (Nb sujets), du nombre d'essais (Nb essais) et de la durée de manutention (Nb min) à travers les trois études.



3.1.1 Caractéristiques dérivées du signal EMG

Avant de décrire les caractéristiques, rappelons que tous les signaux EMG ont été enregistrés de la même manière dans les trois études. Des électrodes étaient apposées bilatéralement à la surface du dos des participants pour enregistrer les signaux du muscle longissimus au niveau L1 (3 cm latéralement à la ligne médiale dorsale). Des électrodes différentielles préamplifiées à la source (gain : 1000) et ayant une bande passante de 20 à 500 Hz (Delsys, Boston, Ma.) ont été utilisées. Les signaux ont été enregistrés à une fréquence de 1024 Hz et numérisés à l'aide d'une carte d'acquisition analogue numérique 12-bits (PCI-6071E, National Instrument, Austin, TX).

Afin de représenter l'EMG sous diverses facettes, un vecteur de caractéristiques doit être extrait du signal. Ces caractéristiques représentent un nombre inférieur de variables qui sont plus informatives que l'ensemble complet du signal EMG brut d'origine. Avec la popularité grandissante de l'apprentissage machine, le nombre de caractéristiques qu'il est possible d'utiliser pour extraire l'information de signaux biomédicaux augmente considérablement chaque année (Fulcher et Jones, 2017). Il apparaît que le choix des caractéristiques est dépendant du problème à l'étude, du jeu de données disponibles et qu'une combinaison optimale améliore la prédiction d'un modèle. Plus spécifiquement pour l'EMG, les travaux de Phinyomark, Khushaba, Ibanez-Marcelo, *et al.* (2018) ont permis d'avancer dans la compréhension de différentes familles de caractéristiques du signal EMG. En plus des 14 caractéristiques identifiées par ces derniers, les caractéristiques décrites par Phinyomark, Khushaba et Scheme, 2018 (L-moment) et par Kushaba *et al.*, 2011 (paquet d'ondelettes) ont également été considérées comme intrants EMG potentiels. Elles représentent les caractéristiques les plus souvent utilisées dans la littérature pour exprimer l'information significative du signal EMG. Il faut noter que certaines de ces caractéristiques produisent plus d'une valeur, portant ainsi le nombre total de caractéristiques à 52 valeurs par muscle. Le tableau 1 présente une description sommaire de ces caractéristiques selon la classification de Phinyomark, Khushaba, Ibanez-Marcelo, *et al.* (2018).

3.1.2 Caractéristiques dérivées de la cinématique

Les deux senseurs inertiels, ou les deux corps rigides dans le cas du système optoélectronique (l'un fixé au niveau de la jonction C7/T1 et l'autre sur le bassin au milieu des épines iliaques postéro-supérieures), permettent d'obtenir 3 mesures d'angle du tronc (deux angles selon la procédure de Grood et Suntay, 1983 et l'axe hélicoïdal), une mesure de la vitesse angulaire du tronc et le calcul du terme statique de la contribution du poids du tronc au moment en L5/S1 sur les axes longitudinal, transversal et sagittal du bassin. Ces variables représentent donc 7 caractéristiques dérivées de la cinématique, mesurées soit par des senseurs inertiels (MT, Xsens technologies B.V., Enschede, Pays-Bas ; Delisle *et al.*, 2016) ou par un système optoélectronique (Optotrak 3020, Norther Digital inc., Waterloo, Canada; Plamondon *et al.*, 2010 ; Plamondon *et al.*, 2012). À travers les trois jeux de données, seule la distribution du premier angle de Grood et

Suntay (1983) autour de l'axe transverse du bassin (en flexion-extension) diffère de façon significative avec les autres sources de données, la distribution de données de Delisle *et al.* (2016) étant différentes des deux autres et révélant de plus grandes flexions du tronc. La description statistique des intrants cinématiques est présentée en annexe B.

Tableau 1. Caractéristiques dérivées des signaux EMG

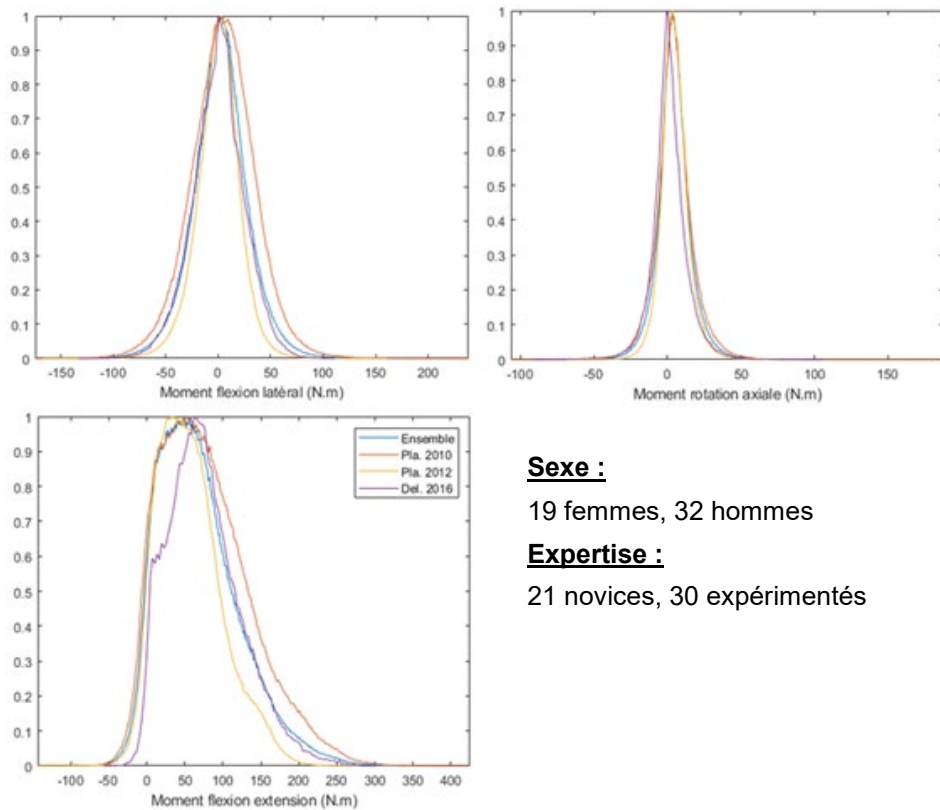
Abréviation	Description	Paramètre	N	Référence
Puissance et amplitude du signal				
ARV	Valeur moyenne absolue	Na	1	Hudgins <i>et al.</i> , 1993
DASDV	Valeur absolue de la différence de l'écart type	Na	1	Phinyomark <i>et al.</i> , 2014
DMAV	Valeur de la différence absolue moyenne	Na	1	Phinyomark <i>et al.</i> , 2014
LM *	L-moment	normalisé	4	Phinyomark <i>et al.</i> , 2018b
Domaine fréquentiel et complexité non-linéaire				
ZC	Croisement de zéro	Seuil = 0	1	Hudgins <i>et al.</i> , 1993
WL *	Longueur d'onde	Na	1	Hudgins <i>et al.</i> , 1993
WAMP *	Amplitude de Willison	Seuil = 0,002	1	Zardoshti-Kermani <i>et al.</i> , 1995
SSC	Changement de signe de la pente	Seuil = 0	1	Hudgins <i>et al.</i> , 1993
MFL *	Longueur fractale maximale	Kmax = 5	1	Arjunan <i>et al.</i> , 2010
SP *	Entropie échantillonnée	m = 2, r = 0,2	2	Richman <i>et al.</i> , 2000
Domaine fréquentiel				
MSWP *	Paquet d'ondelettes multi-échelles	Daubechie 4, niveau 3	15	Kushaba <i>et al.</i> , 2011
Série temporelle				
AR *	Valeur auto-régressive	Ordre 6	6	Zardoshti-Kermani <i>et al.</i> , 1995
Groupe unique				
HIST	Histogramme	Classes de 0,13 [-0,52 à 0,52]	9	Zardoshti-Kermani <i>et al.</i> , 1995
FTDD *	Fusion des descripteurs du domaine temporel	Na	6	Al-Timemy <i>et al.</i> , 2016
KURT *	Coefficient d'asymétrie	Na	1	Thongpanja <i>et al.</i> , 2016
SKEW *	Coefficient d'aplatissement	Na	1	Thongpanja <i>et al.</i> , 2016
		N total	52	

*Indique les caractéristiques retenues à la prochaine étape. Voir l'annexe C pour la liste détaillée.

3.1.3 Le moment en L5/S1

La figure 3 illustre la distribution des moments (extrants ou moments à prédire par les réseaux de neurones) selon les différentes sources de données utilisées. Un profil légèrement différent du moment en flexion-extension pour l'étude de Delisle *et al.* (2016) est observé, les valeurs inférieures à 50 N m étant moins fréquentes. Une différence au niveau de l'angle de flexion-extension autour de l'axe transverse du bassin a également été observée (voir section précédente). Ces différences pourraient s'expliquer par des tâches ou des façons différentes de réaliser la tâche.

Figure 3. Distribution des trois composantes du moment en L5/S1 selon les différentes études, sources de données.



Sexe :


19 femmes, 32 hommes

Expertise :

21 novices, 30 expérimentés

La figure 4 présente un sommaire de ces distributions pour le moment en flexion latérale et le moment en flexion/extension, lorsque les données sont regroupées selon le sexe ou l'expertise.

Figure 4. Distribution du moment à prédire A) en flexion latérale, et B) en flexion-extension, selon le sexe et l'expertise des participants.



3.2 Prétraitement des données

Les données EMG ont été soumises à l'algorithme de classification permettant d'identifier les portions de signal avec artefact, développé pour ce projet et détaillé à l'annexe D. Sur l'ensemble des jeux de données, 61 minutes de signal ont été identifiées comme

problématiques et retirées, ce qui représente 4,5 % de l'ensemble des signaux disponibles.

Les essais n'étant pas tous de même longueur, il était préférable de segmenter les essais les plus longs afin de limiter la taille des matrices d'intrants. Le seuil de longueur maximal a été fixé à 500 échantillons (16,66 s) et la longueur la plus courte d'un essai était de 124 échantillons (4,13 s). Une fois que le modèle est déterminé, il n'y a aucune contrainte sur la longueur des essais lors de la prédiction. À noter qu'un essai pouvait comporter plus d'une manutention de caisse et qu'il incluait les périodes où aucune caisse n'était supportée dans les mains.

Les intrants et les extrants ont ensuite été inspectés individuellement pour détecter d'éventuelles données aberrantes. Aucune n'a été détectée sur les intrants EMG, augmentant le niveau de confiance dans la méthode automatique utilisée. Lorsqu'une donnée aberrante était détectée sur un intrant cinématique ou un extrant, l'essai entier était supprimé. Au final, le nombre total de minutes de manutention disponible s'élève à 1216 minutes, ce qui représente un rejet cumulé inférieur à 10 %.

3.3 Construction des jeux de données

3.3.1 Sélection des intrants

Afin de diminuer la dimensionnalité du réseau, améliorer la prédiction et gagner en temps d'entraînement, une sélection des intrants les plus pertinents doit être effectuée. Deux approches sont possibles à cette étape, la réduction ou la sélection des intrants. La réduction permet de représenter les caractéristiques dans un nouvel espace, au détriment de la perte d'interprétation de ces dernières ; la sélection tente de conserver les plus significatives. La volonté de conserver les données cinématiques intactes a orienté notre choix vers la sélection des intrants. Les premières simulations ont été réalisées avec l'entièreté des intrants et les résultats décevants ont confirmé qu'une sélection s'imposait.

Les intrants décrits aux sections 3.1.1 et 3.1.2 ont servi comme base de départ pour cette partie. Comme deux muscles sont utilisés (2 électrodes), le nombre de caractéristiques basées sur l'EMG est doublé, portant le nombre total à 111 (7 basées sur la cinématique, 104 basées sur l'EMG). Dans les paragraphes suivants, le décompte des caractéristiques sera présenté pour un seul muscle, mais sera systématiquement appliqué aux deux.

Dans un premier temps, une analyse de corrélation entre les intrants a été effectuée. Ceux démontrant un coefficient de détermination supérieur à 0,9 ont été soumis à une sélection. Toutes les variables cinématiques ont été conservées dans cette première sélection et 13 caractéristiques basées sur l'EMG ont été rejetées.

Par la suite, une analyse de l'importance de chacun des intrants restants a été effectuée à l'aide d'un ensemble de « forêts d'arbres décisionnels » (i.e. : *random forests*; Breiman, 2001). Brièvement, cet algorithme crée de nombreux arbres décisionnels à l'aide de sous-

ensembles de données ainsi qu'une sélection aléatoire des caractéristiques à chaque étape. Le retrait d'une caractéristique associée à une hausse de l'erreur d'un modèle permet de classer par ordre d'importance les caractéristiques. Cette analyse a été effectuée avec différentes latences temporelles de 0 à moins 4 échantillons. Parmi les avantages de cette technique, aucune présomption n'est requise sur la distribution des données, les interactions et les non-linéarités entre les caractéristiques sont prises en compte et la méthode offre une certaine robustesse, car l'échantillonnage est différent pour chaque arbre décisionnel (Lagomarsino *et al.*, 2017). Encore une fois, aucune caractéristique liée à la cinématique n'a été écartée et 14 caractéristiques liées à l'EMG ont été retirées. Au final, ce sont 25 caractéristiques basées sur l'EMG qui ont été retenues. Les statistiques descriptives de ces caractéristiques sont présentées en annexe C. Les paramètres utilisés pour cet algorithme étaient l'utilisation de l'entièreté des données, la construction de 100 modèles à chaque niveau et un minimum de 4 prédicteurs par niveau.

3.3.2 Partition des données

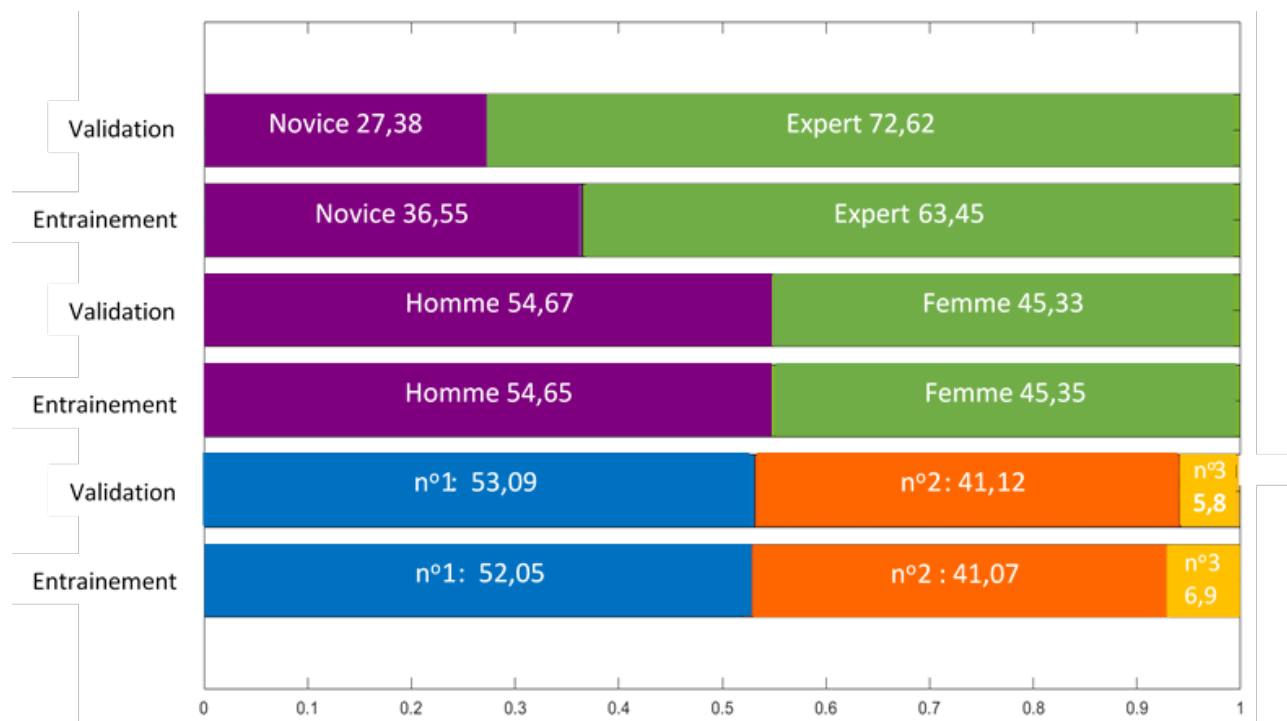
L'ensemble des participants ont été séparés dans trois catégories : 1) les données d'entraînement; 2) les données de validation interne; 3) les données de validation externe. Les données d'entraînement servent à l'ajustement des pondérations et biais des réseaux. Les données de validation internes sont également utilisées lors de l'entraînement pour arrêter l'apprentissage du réseau lorsque ce dernier semble sur apprendre. Le réseau évalue régulièrement sa performance sur les données de validation internes. Si la performance se détériore pendant n itérations consécutives, l'apprentissage est arrêté (n est variable selon le type de réseau). Les données de validation externes sont des participants et essais qui n'ont jamais été présentés aux réseaux dans l'entraînement ou la validation interne. La performance finale du réseau est évaluée sur les données de validation externe. Un total de 23 participants a été réservé aléatoirement pour la validation externe : 13 de l'étude sur les manutentionnaires expert-novice (Plamondon *et al.*, 2010), 7 de l'étude sur les femmes manutentionnaires (Plamondon *et al.*, 2012) et 3 de l'étude de Delisle *et al.* (2016). Cela représente environ 55 % des données réservées à l'entraînement et de validation interne, le restant pour la validation externe. La subdivision des données d'entraînement et de validation interne est décrite dans les paragraphes présentant les deux approches testées.

Cette partition est inhabituelle en apprentissage machine, où une partition 85 % - 15 % sont usuelles. Le choix de n'utiliser seulement que 55 % des données pour l'entraînement est lié aux capacités de calcul disponibles et à la sélection des approches testées (section 3.4). Cela va permettre également une analyse plus robuste des limites de l'approche puisque les données de validation externes sont aussi variées que celles d'entraînement. Une fois l'analyse de la performance des réseaux terminée, un réseau final sera construit et validé avec une partition de 85 % - 15 %.

Les proportions de données provenant des différentes études sont assez similaires pour les données d'entraînement et de validation (figure 5), mais la proportion de données provenant de l'étude de Delisle *et al.* (2016) est beaucoup plus faible. Les proportions d'hommes et de femmes dans les données d'entraînement et de validation externe sont semblables, malgré le fait que, de façon globale, les hommes représentent une proportion légèrement plus grande des données. Un déséquilibre entre les données d'entraînement et de validation est cependant observé quant à l'expertise. En effet, une plus forte proportion de novices est présente dans les données d'entraînement comparativement aux données de validation, même si la proportion d'experts domine dans les deux cas. Ce léger déséquilibre pourrait se refléter dans les résultats et possiblement contribuer à une performance moindre du modèle chez les experts.

Figure 5. Répartition des données pour la validation externe et l'entraînement (entraînement et validation interne).

Note : Les proportions sont présentées selon l'expertise (novice, expert), selon le sexe (Femme, Homme) des participants et selon les études de provenance des données (n°1 : Plamondon *et al.*, 2010 ; n°2 : Plamondon *et al.*, 2012 ; n°3 : Delisle *et al.*, 2016).



3.4 Génération des réseaux de neurones

La prédiction des moments à L5/S1 fait partie des problèmes de régression temporelle. La séquence temporelle doit être préservée puisque les échantillons précédents contiennent de l'information sur la prédiction à l'instant t_0 . L'approche classique, qui a été utilisée dans les tests préliminaires, est celle d'un réseau de neurones à délai temporel. L'avancement

rapide des connaissances et des outils disponibles dans le domaine de l'apprentissage machine et l'apprentissage profond ont fait ressortir un autre type de réseau : le réseau de neurones récurrents à mémoire court terme et long terme ou LSTM pour *long short-term memory* (Hochreiter et Schmidhuber, 1997). Ces deux approches sont disponibles dans la boîte à outils *deep learning toolbox* de Mathworks (2016) et ont été utilisées pour prédire les moments à L5/S1.

Les caractéristiques techniques des réseaux et leurs hyperparamètres à ajuster sont différents pour les deux réseaux. L'ajustement des hyperparamètres est un facteur primordial dans la performance d'un réseau. Cependant, il n'existe aucune directive sur l'ajustement puisque cela dépend des données utilisées, tant des intrants que des extrants.

3.4.1 Réseau à délai temporel (RDT)

Un réseau à délai temporel est un réseau classique d'entraînement par en avant (*feedforward*) excepté pour l'ajout d'un certain nombre d'intrants précédents l'intrant à t_0 (Waibel *et al.*, 1989). Les principaux paramètres à ajuster pour ce type de réseau sont le nombre de couches, le nombre de neurones dans ces couches et le délai temporel. Le nombre de couches était fixe avec une seule couche cachée puisque les tests préliminaires n'ont pas démontré d'amélioration avec un nombre de couches supérieur à un. Le nombre de neurones a été déterminé en utilisant une grille de recherche grossière (de 10 à 60 par pas de 5) puis fine (de 12 à 20 par pas de 1). Le délai temporel a été fixé à 5 échantillons, car l'information apportée par l'EMG ne semble pas pertinente au-delà du délai électromécanique. Un délai de 5 échantillons représente 166 ms. Les valeurs rapportées dans la littérature pour le délai électromécanique des muscles du tronc sont inférieures à 150 ms (van Dieën *et al.*, 1991). Toutes les simulations ont été testées sur les données de validation externes. Ce type de réseau est très exigeant en termes de puissance de calcul. Un ordinateur de type serveur possédant 8 processeurs (Intel Xeon E5-2650) et 170 Gb de mémoire vive a été utilisé. Malgré cela, seule la moitié des essais disponibles pouvaient être utilisés pour l'entraînement, le reste étant utilisé pour la validation interne. Même avec une portion des données, une simulation prenait entre 24 et 72 heures pour converger. Pour pallier ce problème, et s'assurer d'une bonne généralisation, la prédiction finale de ce réseau est basée sur 10 simulations qui couvraient l'ensemble des essais disponibles. Pour ce réseau, seuls le moment en flexion extension et le moment en flexion latéral faisaient partie des extrants. La prédiction du moment en rotation axiale n'était pas assez bonne et alourdissait l'architecture du réseau. L'architecture finale de ce réseau comprenait 16 neurones dans la couche intermédiaire (figure 6a).

3.4.2 Réseau de neurones récurrents à mémoire court terme et long terme (LSTM)

Ce type de réseau fait partie des nouvelles générations de réseaux récurrents. Leur particularité est qu'ils ont la capacité de retenir de l'information pendant l'apprentissage.

Brièvement, chaque neurone, appelé ici unité, reçoit l'intrant présent ainsi que le résultat et l'état de l'unité précédente. Chaque unité peut enlever ou ajouter de l'information à l'aide de portes de contrôle. Ces portes de contrôle (intrant, oubli, état de l'unité et extrant) sont gérées par une fonction d'activation sigmoïdale. La succession d'unités permet de retenir l'information passée présentée par les intrants.

Pour exploiter pleinement ce type de réseau, il doit être combiné de façon séquentielle avec d'autres types de réseau. Les paramètres à ajuster sont donc beaucoup plus nombreux pour cet empilement de réseau. Les principaux sont le nombre de neurones dans les différents réseaux, la variation du facteur d'apprentissage, le taux de mise à zéro de certains neurones pour éviter le surentraînement, la taille du nombre d'essais par itération, le nombre d'époques et trois paramètres de mise à jour du gradient (direction de la pente sur la surface de solution).

Une plus grande part aléatoire est présente pour ce type de réseau, notamment au niveau des couches de mise à zéro, de la fonction d'apprentissage et de l'initialisation des biais et pondérations. La reproduction des résultats étant plus variable, le réseau donnant les meilleurs résultats de performance sur les données de validation externe a été retenu, à travers de nombreuses simulations.

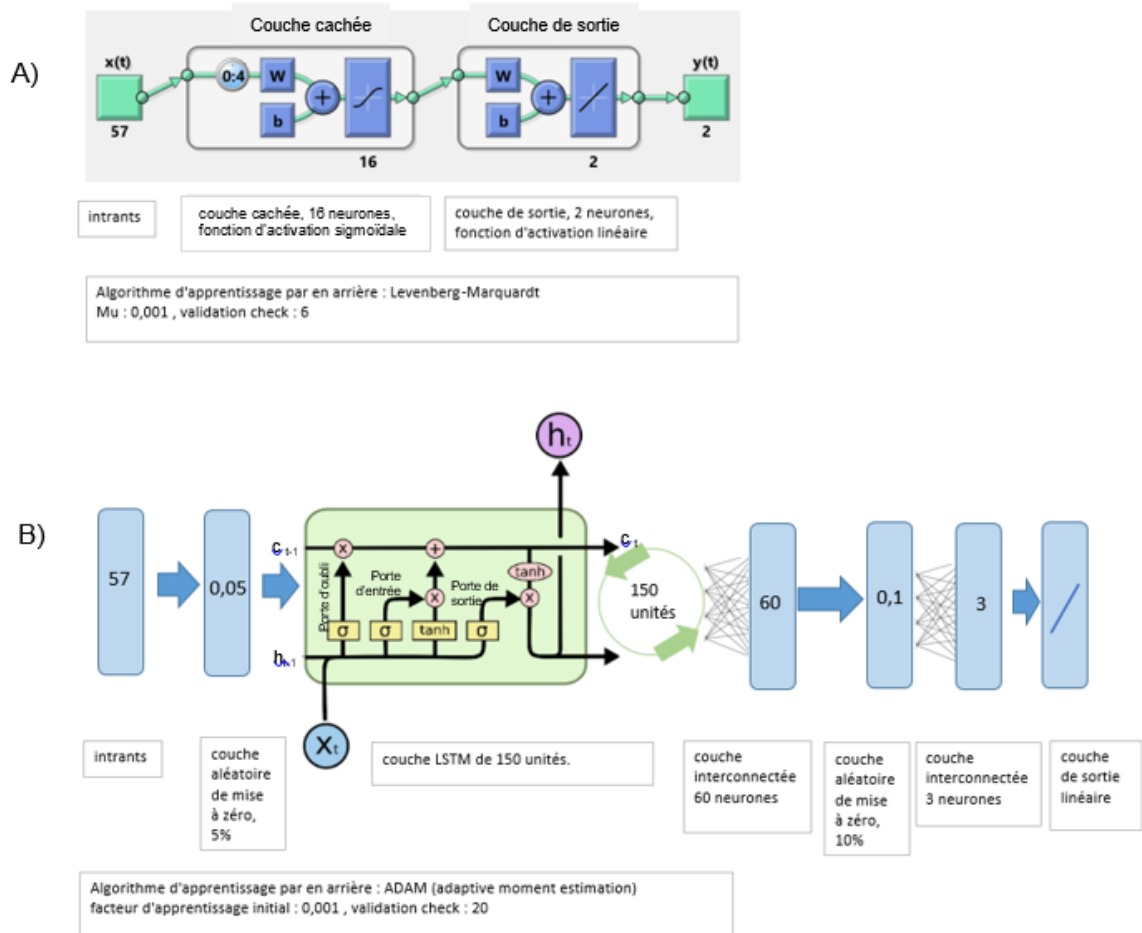
Les premières simulations par grille de recherche ont permis de définir l'ordre des couches, une plage de travail pour le taux de remise à zéro, le nombre d'unités et le nombre de neurones dans la couche intermédiaire. Par la suite, le taux de remise à zéro, le nombre d'unités, le nombre de neurones dans les couches intermédiaires, le nombre d'essais par itération, le facteur d'apprentissage et les paramètres de mise à jour du gradient ont été variés. Certaines combinaisons donnaient des résultats similaires ; parmi ces dernières, la plus simple a été retenue. L'architecture finale est présentée à la figure 6b.

Le nombre d'époques maximal a été fixé à 120, et la patience à 20 (nombre maximal d'époques où la fonction de perte ne diminue pas). Ces deux paramètres déterminent l'arrêt de l'entraînement. À la fin de l'entraînement, l'inspection visuelle de la fonction de perte et du critère de performance permettait de déterminer si le réseau pouvait être réentraîné là où il avait arrêté. Le cas échéant, les paramètres de mise à jour du gradient étaient modifiés et la première couche de mise à zéro était supprimée avant de réentraîner le réseau.

La capacité de mémoire de ce type de réseau offre la possibilité de présenter une portion des données à chaque itération. Une époque représente ici la présentation complète du jeu de données en n itérations. Cela permet d'utiliser un ordinateur normal, puisque ce n'est pas l'ensemble des données qui doivent être chargées en mémoire pour ajuster les biais et pondérations. Les simulations convergeaient entre 2 h et 8 h sur un poste conventionnel (8 processeurs Intel i7 4770, 32 Gb de mémoire vive). Aux fins de comparaison avec le RDT, une première version du réseau a été élaborée en utilisant la

même partition de données pour l'entraînement et la validation que le RDT (55 – 45). Dans un deuxième temps, un réseau final a été entraîné, en respectant un ratio 85-15, plus usuel pour ce type de réseau.

Figure 6. Illustration et caractéristiques techniques des deux réseaux de neurones comparés.Note : A) réseau à délai temporel (RDT) et B) réseau de neurones récurrents à mémoire court terme, long terme (LSTM).



3.5 Analyse de la performance

Afin de décrire la performance, des réseaux à estimer les moments en L5/S1, la racine carrée de l'erreur quadratique moyenne (RMS), le coefficient de détermination (R^2) et les écarts maximums entre les valeurs estimées et les valeurs mesurées par le modèle à dynamique inverse ont été utilisés comme indicateurs. Les valeurs du 5^e, 25^e, 50^e, 75^e et 95^e centile de ces indicateurs ont été utilisées pour présenter les performances. De plus, pour combiner ces indicateurs de performances, tant du moment en extension que du moment en flexion latérale, une analyse de décision multicritères TOPSIS (*technique for*

order of preference by similarity to ideal solution, Hwang et Yoon, 1981) a été utilisée. Cette méthode permet d'obtenir une mesure de distance euclidienne à un critère optimal. Le résultat est un score compris entre 0 et 1, permettant de classer les résultats en synthétisant tous les critères de performance (RMS, R^2 , écarts maximums, tant pour le moment en flexion/extension que le moment en flexion latérale). Cette méthode et ses dérivées s'appliquent à de nombreux domaines de recherche et gagne en popularité année après année (Behzadian *et al.*, 2012).

Pour explorer la sensibilité de la méthode proposée à certaines variables liées à l'exécution des tâches, différents critères ont été dérivés et une comparaison effectuée entre les données du 5^e centile et du 95^e centile de leur distribution. Une absence de différence significative entre le niveau d'erreur (score Topsis) associé à deux centiles très éloignés permet d'écarter l'influence d'une variable sur le résultat. Les critères dérivés sont : a) l'indice de symétrie, pour vérifier si une proportion plus importante d'une composante du moment influence la prédiction (le 5^e centile signifie une plus petite proportion du moment en flexion-extension par rapport au moment résultant, donc une plus grande composante asymétrique du moment) ; b) l'indice de chargement, pour vérifier si l'amplitude du moment résultant influence la prédiction ; et c) l'indice de variabilité du chargement, la seconde dérivée du moment résultant, pour vérifier si les variations plus abruptes du moment influencent la prédiction. Ces indices sont calculés pour chacun des essais de la manière suivante :

$$\text{Indice de symétrie : } \left(\frac{\sum_n^1 \text{MFE}^2}{\sum_n^1 \text{MR}} \right)^{\frac{1}{2}}$$

$$\text{Indice de chargement : } \left(\frac{\sum_n^1 \text{MR}}{n} \right)^{\frac{1}{2}}$$

$$\text{Indice de variabilité du chargement : } \left(\frac{\sum_n^1 \ddot{\text{MR}}}{n} \right)^{\frac{1}{2}}$$

où MFE indique le moment en flexion-extension, MR indique le moment résultant.

Enfin, la capacité de l'approche proposée à prédire le moment en L5/S1 pour des tâches différentes de celles ayant servi à l'entraînement a été explorée pour quatorze essais de lever à une seule main d'une caisse lourde (18 kg) et d'une caisse légère (9 kg) disponibles dans le jeu de données de Delisle *et al.* (2016). Les participants devaient soulever une caisse placée à leur droite, saisie à une seule main par une poignée à 40 cm du sol, et revenir en position debout. Cette tâche de lever latéral à une seule main contraste avec toutes les autres tâches ayant servi dans l'entraînement impliquant des levers à deux mains.

4. RÉSULTATS

4.1 Comparaison des deux types de réseau

Les valeurs de centile décrivant les performances du réseau à délai temporel (RDT) et du réseau à mémoire court terme, long terme (LSTM) sont présentées au tableau 2. De façon générale, les performances des deux réseaux sont assez similaires, mais le réseau LSTM performe légèrement mieux dans la prédiction du moment en flexion-extension et le RDT performe légèrement mieux pour le moment en flexion latérale.

Considérant que le réseau LSTM démontre une meilleure performance sur la prédiction des moments en flexion-extension et que ces derniers représentent plus de 88 % du moment résultant, il semble avantageux d'utiliser ce type de réseau. Un autre point important est que le temps d'entraînement du réseau LSTM est beaucoup plus court et nécessite moins de ressources matérielles. Il est donc plus facile de réentraîner le réseau avec de nouvelles données ou tester différentes partitions. Pour ces raisons, la suite de l'analyse des résultats est présentée uniquement pour le LSTM.

Tableau 2. Centiles des indicateurs de performance de la prédiction des moments selon le réseau à délai temporel (RDT) et le réseau à mémoire court terme long terme (LSTM)

Centile	Réseau ¹	RMS (N m)		R ²		Écart maximal (N m)	
		Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension
5 ^e	RDT	9,1	15,3	0,205	0,444	29,7	43,0
	LSTM	9,4	14,5	0,187	0,460	30,6	42,7
25 ^e	RDT	12,8	20,4	0,453	0,663	42,4	58,0
	LSTM	13,1	19,1	0,429	0,696	42,8	56,5
50 ^e	RDT	16,0	25,4	0,596	0,764	53,0	73,7
	LSTM	16,2	23,8	0,573	0,794	54,0	71,2
75 ^e	RDT	19,9	32,8	0,703	0,833	66,5	95,9
	LSTM	20,2	30,1	0,692	0,855	66,9	91,4
95 ^e	RDT	27,5	46,3	0,824	0,901	91,4	137,8
	LSTM	27,4	41,7	0,821	0,914	93,1	132,9

4.2 Influence des sources de données et de certaines variables

La performance du réseau varie légèrement selon les sources de données (tableau 3), selon le sexe des participants (tableau 4) et selon l'expertise des participants à l'étude (tableau 5). De façon générale, la RMS absolue est plus petite (donc meilleure performance) chez les femmes et les experts, comparativement aux hommes et aux novices respectivement, et ce, tant pour le moment en flexion latérale que le moment en flexion/extension. Toutefois, le coefficient de détermination (R²) est plus élevé (donc

meilleure performance) chez les hommes que chez les femmes, tant pour le moment en flexion latérale que le moment en flexion/extension. Les novices démontrent aussi un coefficient de détermination plus élevé que les experts, mais seulement pour le moment en flexion latérale. Rappelons que l'étude de Plamondon *et al.* (2010) incluait exclusivement des hommes, experts et novices, l'étude de Plamondon *et al.* (2012) incluait uniquement des femmes avec expérience et l'étude de Delisle *et al.* (2016) incluait des femmes et des hommes, tous novices.

Tableau 3. Centiles des indicateurs de performance de la prédiction des moments en L5/S1 selon la source de données

Centile	Source	RMS (N m)		R ²		Écart maximal (N m)	
		Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension
5 ^e	Plamondon 2010	11,7	16,4	0,364	0,522	36,8	47,7
	Plamondon 2012	8,7	13,5	0,123	0,460	28,2	40,5
	Delisle 2016	8,7	14,4	0,141	0,124	23,6	39,9
25 ^e	Plamondon 2010	14,8	21,5	0,529	0,723	48,5	66,0
	Plamondon 2012	11,2	17,1	0,331	0,696	37,5	50,8
	Delisle 2016	12,1	20,8	0,339	0,454	39,8	54,6
50 ^e	Plamondon 2010	17,7	26,5	0,633	0,808	59,6	81,6
	Plamondon 2012	13,9	21,0	0,474	0,786	47,1	60,6
	Delisle 2016	16,3	24,5	0,480	0,591	55,2	69,4
75 ^e	Plamondon 2010	21,2	33,9	0,721	0,866	72,4	101,9
	Plamondon 2012	18,0	25,4	0,618	0,845	59,1	74,2
	Delisle 2016	21,2	35,5	0,620	0,735	71,8	91,9
95 ^e	Plamondon 2010	27,5	43,3	0,825	0,920	97,4	145,0
	Plamondon 2012	26,4	33,6	0,798	0,910	79,0	108,9
	Delisle 2016	34,6	59,3	0,859	0,858	97,7	145,5

Tableau 4. Centiles des indicateurs de performance de la prédiction des moments en L5/S1 selon le sexe

Centile	Sexe	RMS (N m)		R ²		Écart maximal (N m)	
		Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension
5 ^e	Homme	11,6	16,4	0,359	0,495	36,6	47,5
	Femme	8,7	13,5	0,123	0,423	28,1	40,6
25 ^e	Homme	14,8	21,6	0,527	0,717	48,5	66,4
	Femme	11,3	17,3	0,330	0,672	37,6	51,0
50 ^e	Homme	17,8	26,8	0,632	0,807	60,0	82,2
	Femme	14,0	21,2	0,474	0,778	47,4	60,8
75 ^e	Homme	21,5	34,3	0,721	0,865	73,1	103,2
	Femme	18,1	25,5	0,615	0,840	59,4	74,8
95 ^e	Homme	28,5	43,9	0,827	0,920	97,9	146,6
	Femme	25,9	34,3	0,802	0,907	79,6	107,7

Tableau 5. Centiles des indicateurs de performance de la prédiction des moments en L5/S1 selon l'expertise


Centile	Expertise	RMS (N m)		R ²		Écart maximal (N m)	
		Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension
5 ^e	Novice	11,4	15,8	0,247	0,362	34,3	45,9
	Expert	9,1	14,2	0,172	0,503	29,9	41,9
25 ^e	Novice	14,3	21,0	0,495	0,637	48,0	63,3
	Expert	12,5	18,5	0,410	0,714	41,3	54,9
50 ^e	Novice	17,0	26,3	0,629	0,776	59,3	77,6
	Expert	15,9	23,0	0,550	0,798	52,0	68,6
75 ^e	Novice	20,8	34,2	0,733	0,852	74,1	97,9
	Expert	19,9	28,6	0,672	0,856	64,9	88,9
95 ^e	Novice	28,3	44,4	0,839	0,917	104,0	138,8
	Expert	27,2	40,3	0,803	0,913	88,8	129,9

L'analyse à partir du score Topsis (figure 7) montre que la prédiction pour les données de Plamondon *et al.* (2012) était meilleure que pour les autres études, que la prédiction pour les femmes était meilleure que pour les hommes, et que la prédiction pour les experts était meilleure que pour les novices.

Lorsque l'on s'intéresse aux indicateurs dérivés pour considérer l'influence de certaines variables liées à l'exécution des tâches, il s'avère que l'asymétrie du chargement lors de l'exécution influence peu la performance de prédiction, mais que l'amplitude du chargement et la variabilité du chargement influencent la performance de prédiction. En effet, des différences significatives ont été observées entre le 5^e centile et 95^e centile du score Topsis pour l'indice de chargement et l'indice de variabilité du chargement, révélant

une meilleure prédiction pour des moments moins élevés et une difficulté à prédire les variations rapides du moment.

Figure 7. Scores Topsis médian (50^e centile) selon les jeux de données, le sexe et l'expertise.



Note : Les barres d'erreur représentent le 5^e et le 95^e centile des scores Topsis. a) ANOVA, $F(2,2833) = 87,96$ $p < 0,001$, Pla.2012 >> Pla.2010 et Del. 2016 ; b) Test-t pour groupe indépendant $t(2834) = 13,73$, $p < 0,001$; c) Test-t pour groupe indépendant, $t(2834) = 6,16$, $p < 0,001$.

Afin de mieux caractériser l'erreur associée à l'amplitude du moment, les moments de référence ont été subdivisés en 10 classes d'intensité (du 10^e au 90^e centile), et l'écart moyen de prédiction a été calculé pour chacune de ces classes (tableau 6). L'écart moyen demeure relativement modeste entre le 10^e et le 90^e centile, mais pour les moments d'une valeur supérieure au 90^e centile ou inférieure au 10^e centile, l'écart moyen est clairement plus important. Les valeurs négatives représentent une sous-estimation du moment et les valeurs positives, une surestimation.

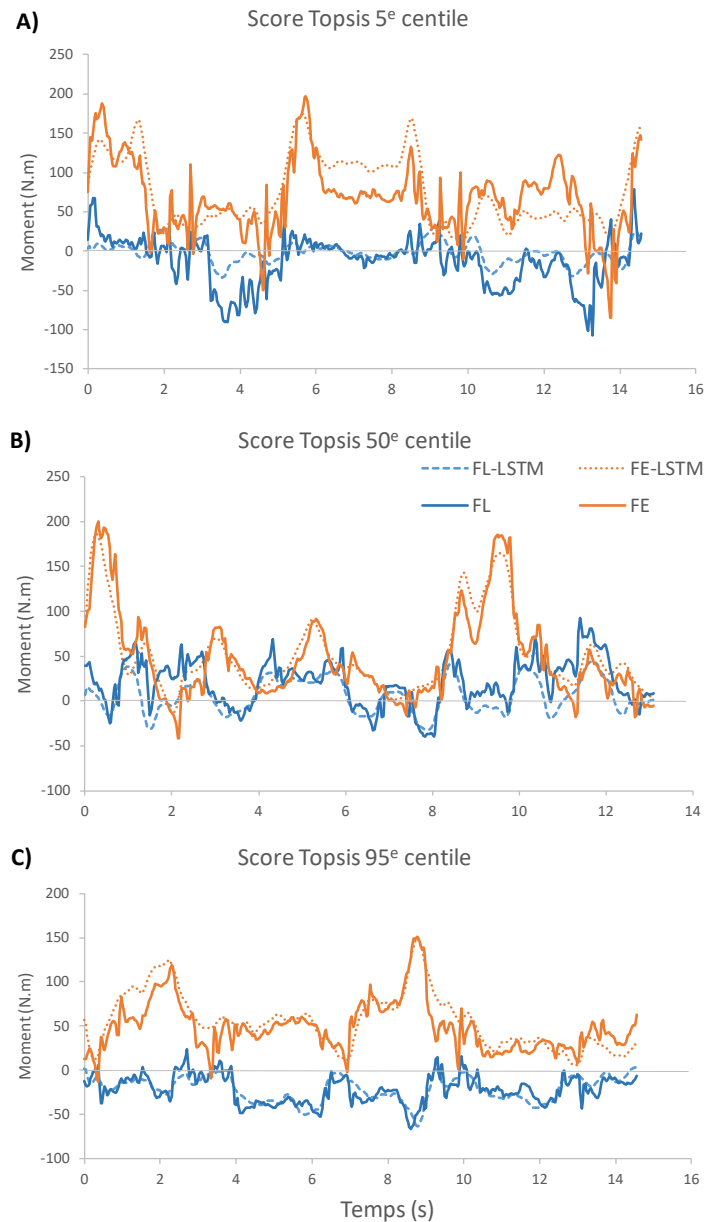
Afin d'illustrer la performance du réseau LSTM à prédire les moments en L5/S1, la figure 8 présente des cas pour des niveaux d'erreur correspondant au 5^e, 50^e et 95^e centile du score Topsis. Rappelons qu'un essai près du 95^e centile du score Topsis illustre un essai près des meilleures performances, alors qu'un essai aux environs du 5^e centile est près des moins bonnes performances.

Tableau 6. Écart moyen (écart type) de prédiction (en N m) selon les différentes classes d'amplitude du moment

Classe	Flexion latérale	Flexion - extension
< 10 ^e centile	6,7 (7,0)	19,6 (17,0)
≥ 10 ^e et < 20 ^e	4,2 (7,2)	8,23 (16,0)
≥ 20 ^e et < 30 ^e	1,7 (7,6)	4,41 (17,0)
≥ 30 ^e et < 40 ^e	-0,4 (8,1)	1,99 (19,0)
≥ 40 ^e et < 50 ^e	-2,6 (8,8)	0,014 (22,0)
≥ 50 ^e et < 60 ^e	-4,9 (9,6)	-1,63 (23,0)
≥ 60 ^e et < 70 ^e	-7,5 (11,0)	-3,5 (24,0)
≥ 70 ^e et < 80 ^e	-10,8 (12,0)	-5,69 (26,0)
≥ 80 ^e et < 90 ^e	-15,6 (14,0)	-9,65 (29,0)
≥ 90 ^e centile	-28,0 (20,0)	-29,4 (36,0)

Figure 8. Illustration de la prédiction du moment en flexion/extension (FE-LSTM) et du moment en flexion latérale (FL-LSTM) du réseau LSTM en comparaison à la mesure critère (FE et FL).

Note : A) un cas correspondant au 5^e centile ; B) un cas correspondant au 50^e centile ; C) un cas correspondant au 95^e centile du score Topsis. Les trois cas illustrés comportent au moins deux levés de caisse avec des portions sans caisse dans les mains.



4.3 Performance du réseau LSTM final

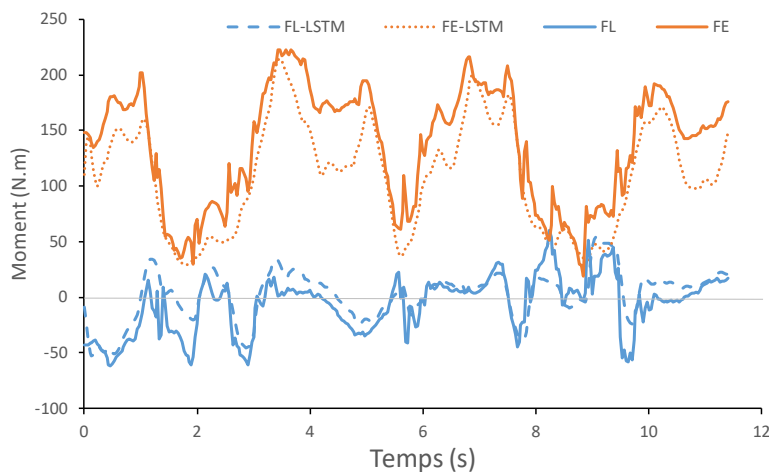
En maximisant la quantité de données d'entraînement, c'est-à-dire en prenant 45 sujets pour l'entraînement et 7 pour la validation externe, tous les indicateurs de performance s'améliorent (tableau 7). Le niveau de performance atteint pour le moment en flexion-extension est très satisfaisant, démontrant une erreur RMS médiane de 20,6 N m et expliquant près de 82 % de la variance.

Lorsque ce réseau est utilisé pour estimer le moment en L5/S1 pour des levers d'une caisse à une seule main et n'ayant pas été utilisés dans l'entraînement, les valeurs du 5^e, 50^e et 95^e centile du score Topsis obtenues sont de 0,53, 0,63 et 0,71, respectivement. La figure 9 illustre un exemple d'une prédiction avec un score Topsis de l'ordre du 50^e centile.

Tableau 7. Indicateurs de performance pour le réseau final.

Centile	RMS (N m)		R ²		Écart maximal (N m)		Score Topsis
	Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension	Flexion latérale	Flexion - extension	
5 ^e	9,6	13,5	0,258	0,535	31,2	41,7	0,703
25 ^e	12,1	17,3	0,458	0,741	40,5	53,6	0,764
50 ^e	14,0	20,6	0,595	0,816	48,9	63,9	0,797
75 ^e	16,9	25,3	0,698	0,868	59,2	78,7	0,828
95 ^e	23,1	34,0	0,812	0,924	81,8	104,1	0,866

Figure 9. Illustration de la prédiction du moment en flexion extension (FE-LSTM) et du moment en flexion latérale (FL-LSTM) par le réseau LSTM final pour une tâche de levers à une main, en comparaison à la mesure critère du moment en L5/S1 (FE et FL).



5. DISCUSSION

L'objectif principal de cette recherche était de développer et valider une approche pour estimer le moment au bas du dos (au niveau L5/S1), simple d'utilisation et basée sur un réseau de neurones générique. Le réseau de neurones développé permet l'estimation du moment en L5/S1 simplement à partir d'informations cinématiques provenant de deux segments (tronc et bassin) et de l'activité musculaire des extenseurs du tronc. Ainsi, il permet l'estimation du moment au dos à partir de deux senseurs (un sur le tronc et un second sur le bassin) et deux électrodes de surface placées bilatéralement sur le muscle longissimus, avec une erreur RMS médiane de 21 N m pour le moment en extension.

Le chargement mécanique au dos a été identifié comme un facteur de risque important pour les maux de dos (Coenen *et al.*, 2014, Da Costa et Vieira, 2010; National Research Council 2001). Plusieurs études de laboratoires se sont d'ailleurs intéressées à l'étude des chargements au dos lors d'activités de manutention simulée (par exemple : Delisle *et al.*, 1999 ; Kingma *et al.*, 1996 ; Plamondon *et al.*, 1996 ; Plamondon *et al.*, 2010). Au-delà de comprendre les chargements au dos associés à des tâches de manutention simulées en laboratoire, l'étude de l'effet d'interventions réalisées en milieu de travail pour tenter de réduire les chargements au dos nécessite des approches pouvant être utilisées en contexte réel de manutention, tout comme les études épidémiologiques documentant la relation exposition – effet sur la santé des travailleuses et travailleurs. Les méthodes utilisées en laboratoire exploitant des systèmes de capture du mouvement optoélectronique performant, souvent combinés à des plateformes de force, sont malheureusement inutilisables dans les milieux de travail. Des études ont été réalisées en milieu de travail utilisant l'analyse vidéo pour estimer le chargement au dos (par exemple Coenen *et al.* 2013), mais elles demeurent peu nombreuses, probablement dû au temps nécessaire à l'analyse image par image ou aux problématiques d'occlusion des caméras en contexte réel. Pour contourner cette difficulté, d'autres études ont utilisé des systèmes de mesure portable par les travailleurs, mais parfois trop encombrants (par exemple : Marras *et al.*, 2010). Plus récemment, le développement de senseurs inertiels permettant la mesure de l'orientation des segments de manière ambulatoire laisse présager la possibilité d'une utilisation en milieu de travail. Les développements de la présente étude s'inscrivent dans cette logique de développer une méthode ambulatoire peu encombrante pour estimer le chargement au dos en continu en milieu de travail. Le fait de nécessiter que deux senseurs inertiels (dos et bassin) et deux capteurs pour l'activité électromyographique des longissimus constitue une simplification considérable en comparaison à d'autres approches qui nécessitent plusieurs senseurs pour mesurer la cinématique de nombreux segments du corps et parfois pour mesurer les forces externes (par exemple : Faber *et al.*, 2020). L'approche permet l'estimation du moment en L5/S1 en continu, que la personne ait la charge dans les mains ou non. C'est également un avantage important par rapport à d'autres approches qui nécessitent la détermination des instants où la charge est entièrement supportée par l'individu (par exemple : Muller *et al.*, 2020), étape qui peut nécessiter l'utilisation de la vidéo en surplus et demander beaucoup

de temps pour déterminer ces événements. Le niveau d'erreur de l'ordre de 21 N m (environ 10 % des valeurs maximales) est légèrement supérieur et le coefficient de détermination de l'ordre de 0,8 est légèrement inférieur aux résultats rapportés dans les études de Faber *et al.* (2020) et de Muller *et al.* (2020) qui utilisaient toutes les deux un système de senseurs inertiels sur tous les segments du corps et dans le cas de Faber *et al.* (2020) intègre des souliers instrumentés pour mesurer les forces au sol.

Les résultats démontrent par ailleurs que l'approche aurait tendance à surestimer les valeurs minimales (inférieure au 10^e centile) et à sous-estimer les valeurs maximales (supérieures au 90^e centile). Il ne faudrait donc pas utiliser l'approche pour quantifier les chargements maximaux associés à différentes activités de manutention. Toutefois, l'approche demeure tout à fait pertinente pour estimer le chargement cumulé.

Les résultats révèlent également que l'approche performe beaucoup mieux pour l'estimation du moment à L5/S1 en flexion/extension qu'en flexion latérale. Différentes raisons peuvent expliquer ce résultat. D'une part, les deux seuls muscles utilisés pourraient ne pas représenter adéquatement l'activité musculaire associée à un moment de flexion latérale. D'autre part, il se pourrait que les tâches étudiées et utilisées pour l'entraînement n'aient pas engendré de variation d'amplitude suffisamment importante pour permettre une meilleure prédiction. De façon similaire, la composante de moment en rotation axiale est toujours assez faible pendant des tâches de manutention où les déplacements de pieds ne sont pas limités. De plus, dans les études de validation des modèles à dynamique inverse 3D, la composante en rotation axiale est celle qui démontre la plus grande incertitude (Faber *et al.*, 2016 ; Plamondon *et al.*, 1996). Ainsi, même l'estimation de cette composante avec le modèle utilisé comme critère de comparaison comporte une certaine incertitude qui pourrait en partie expliquer la difficulté à la prédire. C'est en raison de cette incertitude et de la faible amplitude du moment en rotation axiale que ce dernier a été exclu des prédictions.

L'importante base de données utilisées pour entraîner le réseau de neurones rend possible l'estimation du chargement au dos pour une certaine variété de tâches de manutention. L'approche est applicable tant pour des femmes que des hommes, expérimentés ou non en manutention, qui transfèrent (montées et descentes) des boîtes sur une distance d'environ un mètre, d'une variété de masse (de 0 kg à 23 kg), à des hauteurs pouvant varier entre le sol et la hauteur des épaules, sans obligation de garder les pieds fixes au sol. La capacité de l'approche à estimer les moments en L5/S1 dans d'autres conditions de manutention ne peut être appréciée, faute de la disponibilité de données associées à de telles conditions. Bien que l'estimation du moment en L5/S1 pour une tâche de manutention à une seule main, n'ayant pas été utilisée dans l'entraînement, a démontré des résultats intéressants, le fait que les individus qui ont effectué cette tâche étaient aussi dans la base de données ayant servi à l'entraînement du réseau empêche de généraliser l'approche à d'autres tâches effectuées par d'autres individus. Néanmoins, la validation externe réalisée auprès de participants n'ayant pas été considérés dans l'entraînement permet d'avancer que l'approche est généralisable à d'autres individus qui

effectuent des tâches similaires à celles étudiées. De plus, advenant que d'autres données pour d'autres types de manutention deviennent disponibles, elles pourraient être intégrées aux données actuelles sans nécessairement exiger un réentraînement complet du réseau de neurones, et permettre l'estimation du moment en L5/S1 pour ces autres activités de manutention. L'approche pourrait ainsi devenir autoapprenante et évolutive.

Les cinq variables cinématiques requises peuvent aisément être déterminées à l'aide de deux senseurs inertiels, ou tout autre moyen permettant de déterminer ces variables. D'ailleurs, la base de données utilisée pour développer l'approche incluait des variables cinématiques provenant en partie d'un système optoélectronique et en partie de senseurs inertiels. L'approche n'est donc pas limitée à l'utilisation d'une seule méthode de mesure pour la détermination des variables cinématiques.

Le fait d'utiliser l'électromyographie de surface comme intrant au réseau pourrait constituer un défi d'utilisation important, considérant les difficultés que peut représenter le contrôle de la qualité des signaux et les traitements préalables habituellement nécessaires pour extraire les variables électromyographiques d'intérêt. Un effort important du présent projet a donc porté sur l'automatisation de ce processus. En effet, une démarche automatisée de contrôle de la qualité des signaux a été développée (annexe D), facilitant grandement l'utilisation de l'approche proposée. L'approche ayant été développée avec les signaux de la base de données disponible, il est difficile de se prononcer sur la possibilité de la généraliser à d'autres types d'électrodes utilisées sur d'autres muscles, lors de la réalisation d'activités différentes. Des analyses préliminaires laissent toutefois anticiper qu'elle puisse être utilisée dans d'autres contextes. De telles méthodes d'automatisation font également l'objet de développements constants dans la littérature scientifique (par exemple : Ostensvik *et al.*, 2019), particulièrement dans le domaine du contrôle de prothèses à partir de l'activité musculaire (par exemple : Ijaz et Choi, 2018), facilitant grandement l'utilisation de l'électromyographie de surface. Il est également permis de croire que l'utilisation de réseaux de neurones d'apprentissage profond, similaire à celui utilisé dans la présente étude, permettront éventuellement l'utilisation des signaux électromyographiques bruts directement, sans traitement préalable. Il s'agirait d'une autre possibilité de développement à envisager, toujours à partir des données déjà disponibles.

Il est intéressant de mentionner que l'approche démontre une certaine robustesse pour estimer le chargement au dos en continu pour des manutentions répétées. En effet, parmi les données utilisées, certaines provenaient de tâches répétées ayant conduit à une fatigue musculaire (Plamondon *et al.*, 2012). Il est possible que le réseau ait appris à accorder moins de poids aux signaux électromyographiques dans ces situations, mais il est également possible que certaines des caractéristiques du signal électromyographique utilisées ne soient pas sensibles à la fatigue musculaire et permettent une estimation stable du chargement au dos. Cette question n'a pas fait l'objet d'une analyse approfondie, et la limite de fatigue ou la durée limite pendant laquelle la prédiction est valable est malheureusement inconnue.

Comme c'est le cas avec plusieurs systèmes de mesures ambulatoires basés sur des senseurs inertiels, la facilité de mesurer des données en continu ne donne pas nécessairement d'information sur l'activité de travail qui est réalisée. Quelle activité est réalisée lorsque le moment en L5/S1 est particulièrement soutenu ? Le développement de méthodes de reconnaissance de l'activité humaine constitue probablement une prochaine étape importante pour l'utilisation de telles approches en milieu de travail. Dans ce type d'application, les techniques d'apprentissage machine, similaires à celle utilisée dans la présente étude, peuvent avoir une contribution intéressante (par exemple : Golestani et Moghaddam, 2020). Il s'agirait en quelque sorte d'ajouter une couche supplémentaire au présent réseau de neurones pour permettre cette reconnaissance. Des algorithmes visant la reconnaissance des activités humaines de tous les jours ont été proposés, mais peu traitent de la reconnaissance des activités de travail ou de manutention.

CONCLUSION

Un réseau de neurones récurrents à mémoire court terme long terme a été développé et validé pour estimer le chargement au bas du dos lors de tâches de manutention. Cette approche est la seule du genre à prédire le moment de flexion - extension à L5/S1 avec un minimum de senseurs (2 pour la cinématique du tronc et du bassin et 2 pour l'activité musculaire des extenseurs du tronc) donc peu encombrante, et ne requérant aucune calibration, avec une erreur médiane de 21 N m. Ce niveau d'erreur est tout à fait acceptable pour ce genre d'approche capable de prédire le chargement au dos en continu, sans nécessiter de connaître si l'objet manipulé est en contact ou non avec l'environnement et sans restreindre les mouvements de pieds.

L'approche semble particulièrement indiquée pour l'estimation du chargement cumulé à L5/S1 en flexion - extension, lors de l'exécution de tâches de manutention de boîtes sans poignées, de masses variées (jusqu'à 23 kg), manipulées à différentes hauteurs (entre le sol et les épaules) sur une distance de déplacement d'environ 1,5 mètre, tant pour des femmes que des hommes, de niveaux d'expérience variés.

La capacité de l'approche à prédire le moment en flexion - extension à L5/S1 pour des tâches de manutention complètement différentes de celles décrites dans cette étude reste à démontrer, tout comme la durée maximale pendant laquelle la prédiction est valable, en lien avec une possible fatigue musculaire. De plus, elle ne devrait pas être utilisée dans l'objectif d'estimer les valeurs maximales de moment en extension.

BIBLIOGRAPHIE

- Abdoli-E, M., Agnew, M. J. et Stevenson, J. M. (2006). An on-body personal lift augmentation device (plad) reduces EMG amplitude of erector spinae during lifting tasks. *Clinical Biomechanics*, 21(5), 456-465.
- Al-Timemy, A. A., Khushaba, R. N., Bugmann, G., et Escudero, J. (2016). Improving the performance against force variation of EMG controlled multifunctional upper-limb prostheses for transradial amputees. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 24(6), 650-661.
- Andrews, S., Huerta, I., Komura, T., Sigal, L. et Mitchell, K. (2016, 12-13 décembre). *Real time physics based motion capture with sparse sensors* [Communication]. European Conference on Visual Media Production (CVMP '16), Londres, Angleterre.
- Ardestani, M. M., Zhang, X., Wang, L., Lian, Q., Liu, Y., He, J. et Jin, Z. (2014). Human lower extremity joint moment prediction: A wavelet neural network approach. *Expert Systems with Applications*, 41(9), 4422-4433.
- Arjmand, N. et Shirazi-Adl, A. (2006). Model and in vivo studies on human trunk load partitioning and stability in isometric forward flexions. *Journal of Biomechanics*, 39(3), 510-521.
- Arjunan, S. P. et Kumar, D. K. (2010). Decoding subtle forearm flexions using fractal features of surface electromyogram from single and multiple sensors. *Journal of Neuroengineering and Rehabilitation*, 7, article 53.
- Arslan, Y. Z., Adli, M. A., Akan, A. et Baslo, M. B. (2010). Prediction of externally applied forces to human hands using frequency content of surface EMG signals. *Computer Methods and Programs in Biomedicine*, 98(1), 36-44.
- Behzadian, M., Otaghsara, K., Yazdani, M., et Ignatius, J. (2012). A state-of-the-art survey of TOPSIS applications. *Expert systems with applications*, 39(17), 13051-13069.
- Bishop, C. (2006). *Pattern recognition and machine learning*. Springer.
- Boucher, A., Duguay, P., Prud'homme, P. et Busque, M.-A. (2019). *Lésions professionnelles acceptées qui sont des TMS reliés à la manutention, Québec, 2013 à 2017*. IRSST. [Données non publiées]
- Breiman, L. (2001) Random forests. *Machine Learning*, 45, 5-32.
- Brinckmann, P., Frobin, W., Biggemann, M., Tillotson, M., Burton, K., Burke, C. et Zerlett, G. (1998). Quantification of overload injuries to thoracolumbar vertebrae and discs in persons exposed to heavy physical exertions or vibration at the workplace. Part II: Occurrence and magnitude of overload injury in exposed cohorts. *Clinical Biomechanics*, 13(Supplement 2), S1-S36.
- Callaghan, J. P. et McGill, S. M. (2001). Intervertebral disc herniation: Studies on a porcine model exposed to highly repetitive flexion/extension motion with compressive force. *Clinical Biomechanics*, 16(1), 28-37.

- Chang, C. C. et Lin, C. J. (2011) LIBSVM : A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3), article 27.
- Cholewicki, J., McGill, S. M. et Norman, R. W. (1995). Comparison of muscle forces and joint load from an optimization and EMG assisted lumbar spine model: Towards development of a hybrid approach. *Journal of Biomechanics*, 28(3), 321-331.
- Chowdhury, R. H., Reaz, M. B., Ali, M. A., Bakar, A. A., Chellappan, K. et Chang, T. G. (2013). Surface electromyography signal processing and classification techniques. *Sensors*, 13(9), 12431-12466.
- Coenen, P., Kingma, I., Boot, C. R. L., Bongers, P. M. et van Dieën, J. H. (2013). Inter-rater reliability of a video-analysis method measuring low-back load in a field situation. *Applied Ergonomics*, 44(5), 828-834.
- Coenen, P., Kingma, I., Boot, C. R. L., Bongers, P. M. et van Dieën, J. H. (2014). Cumulative mechanical low-back load at work is a determinant of low-back pain. *Occupational and Environmental Medicine*, 71(5), 332-337.
- Da Costa, B. R. et Vieira, E. R. (2010). Risk factors for work-related musculoskeletal disorders: A systematic review of recent longitudinal studies. *American Journal of Industrial Medicine*, 53(3), 285-323.
- De Luca, C. J. (1997). The use of surface electromyography in biomechanics. *Journal of Applied Biomechanics*, 13(2), 135-163.
- De Vries, W. H. K., Veeger, H.E.J., Baten, C. T. M. et Van der Helm, F.C.T. (2016). Can shoulder joint reaction forces be estimated by neural networks? *Journal of Biomechanics*, 49(1), 73-79.
- Delisle, A., Gagnon, M., et Desjardins, P. (1999). Kinematic analysis of footstep strategies in asymmetrical lifting and lowering tasks. *International Journal of Industrial Ergonomics*, 23, 451-460.
- Delisle, A., Plamondon, A., Gagnon, D., Larivière, C., Thénault, F., Michaud, F. et Rouat, J. (2016). *Estimation du chargement au dos : développement d'une méthode ambulatoire intégrant la cinématique du dos et de l'électromyographie* (Rapport n° R-904). IRSST.
- Devaprakash, D., Weir, G. J., Dunne, J. J., Alderson, J. A. et Donnelly, C. J. (2016). The influence of digital filter type, amplitude normalisation method, and co-contraction algorithm on clinically relevant surface electromyography data during clinical movement assessments. *Journal of Electromyography and Kinesiology*, 31, 126-135.
- Dolan, P., Kingma, I., De Looze, M. P., van Dieën, J. H., Toussaint, H. M., Baten, C. T., Adams, M. A. (2001). An EMG technique for measuring spinal loading during asymmetric lifting. *Clinical Biomechanics*, 16(Supplement 1), S17-S24.
- Faber, G. S., Kingma, I., Martin Schepers, H., Veltink, P. H. et van Dieën, J. H. (2010). Determination of joint moments with instrumented force shoes in a variety of tasks. *Journal of Biomechanics*, 43(14), 2848-2854.

- Faber, G. S., Chang, C. C., Kingma, I., Dennerlein, J. T. et van Dieën, J. H. (2016). Estimating 3D L5/S1 moments and ground reaction forces during trunk bending using a full-body ambulatory inertial motion capture system. *Journal of Biomechanics*, 49(6), 904-912.
- Faber, G. S., Kingma, I., Chang, C. C., Dennerlein, J. T. et van Dieën, J. H. (2020). Validation of a wearable system for 3D ambulatory L5/S1 moment assessment during manual lifting using instrumented shoes and an inertial sensor suit. *Journal of Biomechanics*, 102, article 109671.
- Farina, D. et Merletti, R. (2000). Comparison of algorithms for estimation of EMG variables during voluntary isometric contractions. *Journal of Electromyography and Kinesiology*, 10(5), 337-349.
- Favre, J., Hayoz, M., Erhart-Hledik, J. C. et Andriacchi, T. P. (2012). A neural network model to predict knee adduction moment during walking based ground reaction force and anthropometric measurements. *Journal of Biomechanics*, 45(4), 692-698.
- Faust, O., Hagiwara, Y., Hong, T. J., Lih, O. S. et Acharya, U. R. (2018). Deep learning for healthcare applications based on physiological signals: A review. *Computer Methods and Programs in Biomedicine*, 161, 1-13.
- Fraser, G. D., Chan, A. D. C., Green J. R. et MacIsaac, D. T. (2014). Automated biosignal quality analysis for electromyography using a one-class support vector machine. *IEEE Transactions on Instrumentation and Measurement*, 63(12), 2919-2930.
- Fulcher, B. D. et Jones, N. S. (2017). hctsa: A computational framework for automated time-series phenotyping using massive feature extraction. *Cell Systems*, 5(5), 527-531.
- Gagnon, D., Plamondon, A. et Larivière, C. (2016). A biomechanical comparison between expert and novice manual materials handlers using a multi-joint EMG-assisted optimization musculoskeletal model of the lumbar spine. *Journal of Biomechanics*, 49(13), 2938-2945.
- Gagnon, M. (2003). The efficacy of training for three manual handling strategies based on the observation of expert and novice workers. *Clinical Biomechanics*, 18(7), 601-611.
- Gholipour, A. et Arjmand, N. (2016). Artificial neural networks to predict 3D spinal posture in reaching and lifting activities: Applications in biomechanical models. *Journal of Biomechanics*, 49(13), 2946-2952.
- Golestani, N. et Moghaddam, M. (2020). Human activity recognition using magnetic induction-based motion signals and deep recurrent neural networks. *Nature Communications*, 11, article 1551.
- Granata, K. P. et Marras, W. S. (1995). An EMG-assisted model of trunk loading during free-dynamic lifting. *Journal of Biomechanics*, 28(11), 1309-1317.
- Grood, E. S. et Suntay, W. J. (1983). A joint coordinate system for the clinical description of three-dimensional motions: Application of the knee. *Journal of Biomechanical Engineering*, 105(2), 136-144.

- Hochreiter, S. et Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Hoogendoorn, W. E., Bongers, P. M., de Vet, H. C., Douwes, M., Koes, B. W., Miedema, M. C., . . . Bouter, L. M. (2000). Flexion and rotation of the trunk and lifting at work are risk factors for low back pain: Results of a prospective cohort study. *Spine*, 25(23), 3087-3092.
- Howarth, S. J. et Callaghan, J. P. (2010). Quantitative assessment of the accuracy for three interpolation techniques in kinematic analysis of human movement. *Computer Methods in Biomechanics and Biomedical Engineering*, 13(6), 847-855.
- Hudgins, B., Parker, P. et Scott, R. N. (1993). A new strategy for multifunction myoelectric control. *IEEE Transactions on Biomedical Engineering*, 40(1), 82-94.
- Hwang, C. L. et Yoon, K. P. (1981). *Multiple attribute decision making: Methods and applications*. Springer-Verlag.
- Ijaz, A. et Choi, J. (2018). Anomaly detection of electromyographic signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(4), 770-779.
- Jia, B., Kim, S. et Nussbaum, M. A. (2011). An EMG-based model to estimate lumbar muscle forces and spinal loads during complex, high-effort tasks: Development and application to residential construction using prefabricated walls. *International Journal of Industrial Ergonomics*, 41(5), 437-446.
- Kim, S. et Nussbaum M. A. (2014). An evaluation of classification algorithms for manual material handling tasks based on data obtained using wearable technologies. *Ergonomics*, 57(7), 1040-1051.
- Khushaba, R. N., Kodagoa, S., Lal, S. et Dissanayake, G. (2011). Driver drowsiness classification using fuzzy wavelet packet based feature extraction algorithm. *IEEE Transaction on Biomedical Engineering*, 58(1), 121-131.
- Lagomarsino, D., Tofani, V., Segoni, S., Catani, F. et Casagli, N. (2017). A tool for classification and regression using random forest methodology: Application to landslide susceptibility mapping and soil thickness modeling. *Environmental Modeling & Assessment*, 22(3), 201-214.
- Mannan, M. M. N., Kamran, M. A. et Jeong, M. Y. (2018). Identification and removal of physiological artifacts from electroencephalogram signals: A review. *IEEE Access*, 6, 30630-30652.
- Marateb, H. R., Rojas-Martínez, M., Mansourian, M., Merletti, R. et Mañanas V. M. A. (2012) Outlier detection in high-density surface electromyographic signals. *Medical & Biological Engineering & Computing*, 50(1), 79-89.
- Marras, W. S., Lavender, S. A., Ferguson, S. A., Splittstoesser, R. E., Yang, G. et Schabo, P. (2010). Instrumentation for measuring dynamic spinal load moment exposures in the workplace. *Journal of Electromyography and Kinesiology*, 20(1), 1-9.

- Mathworks. (2016). MATLAB [Logiciel]. Mathworks.
- McCool, P., Fraser, G. D., Chan, A. D. C., Petropoulakis, L. et Soraghan, J. J. (2014). Identification of contaminant type in surface electromyography (EMG) signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(4), 774-783.
- Miezial, M., Taetz, B. et Bleser, G. (2016). On inertial body tracking in the presence of model calibration errors. *Sensors*, 16(7), article 1132.
- Milijakovic, M. (2017, 22-26 mai). *Brief review of self-organizing maps* [Communication]. 2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), Opatija, Croatie.
- Muller, A., Pontonnier, C., Robert-Lachaine, X., Dumont, G. et Plamondon, A. (2020) Motion-based prediction and moments and back loading during manual materials handling tasks. *Applied Ergonomics*, 82, article 102935.
- National Research Council. (2001). *Musculoskeletal disorders and the workplace*. National Research Council and Institute of Medicine.
- Nazmi N., Abdul Rahman, M. A., Yamamoto, S., Ahmad, S. A., Zamzuri, H. et Mazlan, S. A. (2016). A review of classification techniques of EMG signals during isotonic and isometric contractions. *Sensors*, 16(8), article 1304.
- Ostensvik, T., Belbo, H. et Veiersed, K. B. (2019). An automatic pre-processing method to detect and reject signal artefacts from full-shift field-work sEMG recordings of bilateral trapezius activity. *Journal of Electromyography and Kinesiology*, 46, 49-54.
- Pappu, V. et Pardalos, P. N. (2014). High dimensional data classification. Dans F. Aleskerov, B. Goldengorin et P. M. Pardalos (édit.), *Clusters, orders, and trees: Methods and application* (p. 119-150). Springer.
- Parkinson, R. J. et Callaghan, J. P. (2009). The use of artificial neural networks to reduce data collection demands in determining spine loading: A laboratory based analysis. *Computer Methods in Biomechanics and Biomedical Engineering*, 12(5), 511-522.
- Peng, L., Hou, Z.-G. et Wang, W. A. (2015). Dynamic EMG-torque model of elbow based on neural networks. Dans *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. (p. 2852-2855). IEEE.
- Phinyomark, A., Quaine, F., Charbonnier, S., Serviere, C., Tarpin-Bernard, F. et Laurillau, Y. (2014). Feature extraction of the first difference of EMG time series for EMG pattern recognition. *Computer Methods and Programs in Biomedicine*, 117(2), 247-256.
- Phinyomark, A., Khushaba, R. N., Ibanez-Marcelo, E., Patania, A., Scheme, E. et Petri, G. (2018). Navigating features: A topologically informed chart of electromyographic features space. *Journal of the Royal Society Interface*, 14(137).
- Phinyomark, A., Khushaba, R. N. et Scheme, E. (2018) Feature extraction and selection for myoelectric control based on wearable EMG sensors. *Sensor*, 18(5), article 1615.

- Plamondon, A., Gagnon, M. et Desjardins, P. (1996). Validation of two 3-d segment models to calculate the net reaction forces and moments at the L5/s1 joint in lifting. *Clinical Biomechanics*, 11(2), 101-110.
- Plamondon, A., Denis, D., Bellefeuille, S., Delisle, A., Gonella, M., Salazar, E., . . . Nastasia, I. (2010). *Manutention : comparaison des façons de faire entre les experts et les novices* (Rapport n° R-663). IRSST.
- Plamondon, A., Denis, D., Larivière, C., Delisle, A., Gagnon, D., St-Vincent, M. et Nastasia, I. (2012). *Les femmes manutentionnaires : un point de vue biomécanique et ergonomique* (Rapport n° R-757). IRSST.
- Quitadamo, L. R., Cavrini, F., Sberini, L., Riillo, F., Bianchi, L., Seri, S. et Saggio, G. (2017). Support vector machines to detect physiological patterns for EEG and EMG-based human-computer interaction: A review. *Journal of Neural Engineering*, 14(1), article 011001.
- Richman, J. S. et Moorman, J. R. (2000). Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology: Heart and Circulatory Physiology*, 278(6), H2039-H2049.
- Robert-Lachaine, X., Mecheri, H., Larue, C. et Plamondon, A. (2017). Validation of inertial measurement units with an optoelectronic system for whole-body motion analysis. *Medical & Biological Engineering & Computing*, 55(4), 609-619.
- Rogers, D. R. et Maclsaac, D. T. (2010). Training a multivariable myoelectric mapping function to estimate fatigue. *Journal of Electromyography and Kinesiology*, 20(5), 953-960.
- Tian, J., Azarian, M. H. et Pecht, M. (2014, 8-10 juillet). *Anomaly detection using self-organizing maps-based K-nearest neighbor algorithm* [Communication]. European Conference of the Prognostics and Health Management Society. Nantes, France.
- Thongpanja, S., Phinyomark, A., Quaine, F., Laurillau, Y., Limsakul, C. et Phukpattaranont, P. (2016). Probability density functions of stationary surface EMG signals in noisy environments. *IEEE Transactions on Instrumentation and Measurement*, 65(7), 1547-1557.
- van Dieën, J. H. et Kingma, I. (2005). Effects of antagonistic co-contraction on differences between electromyography based and optimization based estimates of spinal forces. *Ergonomics*, 48(4), 411-426.
- van Dieën, J. H., Thissen, C. E. A. M., Van de Ven, A. J. G. M. et Toussaint, H. M. (1991). The electro-mechanical delay of the erector spinae muscle: Influence of rate of force development, fatigue and electrode location. *European Journal of Applied Physiology and Occupational Physiology*, 63(3-4), 216-222.
- Vézina, M., Cloutier, E., Stock, S., Lippel, K., Fortin, É., Delisle, A., . . . Prud'homme, P. (2011). *Enquête québécoise sur des conditions de travail, d'emploi, et de santé et de sécurité du travail (EQCOTESST)* (Rapport n° R-691). IRSST.

- Waibel, A., Hanazawa, T., Hinton, G., Shikano, K. et Lang, K. (1989). Phoneme recognition using time delay neural networks. *IEEE Transactions on Acoustics, Speech and Signal Processing*, 37(3), 328-339.
- Waters, T., Yeung, S., Genaidy, A., Callaghan, J., Barriera-Viruet, H. et Deddens, J. (2006). Cumulative spinal loading exposure methods for manual materials handling tasks. Part 1: Is cumulative spinal loading associated with lower back disorders? *Theoretical Issues in Ergonomics Science*, 7(2), 113-130.
- Waters, T., Yeung, S., Genaidy, A., Callaghan, J., Barriera-Viruet, H., Abdallah, S. et Kumar, S. (2006). Cumulative spinal loading exposure methods for manual material handling tasks. Part 2: methodological issues and applicability for use in epidemiological studies. *Theoretical Issues in Ergonomics Science*, 7(2), 131-148.
- Wong C., Zhang Z. Q., Lo, B. et Yang, G. Z. (2015). Wearable sensing for solid biomechanics: A review. *IEEE Sensors Journal*, 15(5), 2747-2760.
- Zardoshti-Kermani, M., Wheeler, B. C., Badie, K. et Hashemi, R. M. (1995). EMG feature evaluation for movement control of upper extremity prostheses. *IEEE Transactions on Rehabilitation Engineering*, 3(4), 324-333.

ANNEXE A

A.1 Description des tâches et des données disponibles

Tableau 8. Description des tâches et des données disponibles pour les différentes études

Projet	Participants	Tâches	Variables disponibles
Delisle <i>et al.</i> , 2016	4 femmes inexpérimentées 2 hommes inexpérimentés Expérience en manutention de moins de 3 mois ; âge moyen : 20,6 ans ; masse moyenne : 69,6 kg ; taille moyenne 1,74 m	Transferts à 90° (abaïsser, lever et transférer horizontalement) caisse avec poignées de 9 kg et de 18 kg. Transferts à 180° (abaïsser, monter (3 hauteurs)) caisse avec poignées de 9 kg et de 18 kg. Transfert d'une palette de 24 boîtes sans poignée, aller-retour : 12 boîtes de 11 kg, 12 boîtes de 16 kg x 2 reprises (les 24 premières et les 24 dernières analysées de 96 manutentions).	<ul style="list-style-type: none"> Variables cinématiques du tronc Électromyographie de surface (6 paires de muscles du tronc) Moment de force en L5/S1
Plamondon <i>et al.</i> , 2010	15 hommes inexpérimentés : Années d'expérience moyenne : 0,5 ; âge moyen : 25 ans ; Taille moyenne : 1,75 m ; Masse moyenne : 74,2 kg. 15 hommes expérimentés Années d'expérience moyenne : 15,4 ; Âge moyen : 38,1 ; Taille moyenne : 1,71 m ; Masse moyenne : 75,9 kg.	Transfert à 90° d'un convoyeur vers un diable de 4 caisses (aller-retour) : <ul style="list-style-type: none"> 15 kg, centrée 23 kg, centrée 15 kg fragilisée 15 kg décentrée 4 hauteurs, 2 reprises Total : 64 manutentions. Transfert à 180° du diable vers le convoyeur des 4 mêmes caisses (aller-retour) <ul style="list-style-type: none"> 4 hauteurs, 2 reprises Total : 64 manutentions. 	<ul style="list-style-type: none"> Variables cinématiques du tronc Électromyographie de surface (6 paires de muscles du tronc) Moment de force en L5/S1
		Transferts d'une palette de 24 caisses de 15 kg, à cadence libre (les 49 à 72 ^e de 24 boîtes). Transferts d'une palette de 24 caisses de 15 kg, à cadence imposée (les 193 à 216 ^e de 240 boîtes) Total : 48 manutentions analysées / 240 effectuées.	<ul style="list-style-type: none"> Variables cinématiques du tronc Électromyographie de surface (1 paire de muscles du tronc : longissimus) Moment de force en L5/S1

Projet	Participants	Tâches	Variables disponibles
Plamondon <i>et al.</i> , 2012	15 femmes expérimentées Années d'expérience : 7,3 Age moyen : 41,1 ans ; Masse moyenne : 66,8 kg ; taille moyenne : 1,62 m	<p>Transfert à 90° d'un convoyeur vers un diable de 4 caisses (aller-retour) :</p> <ul style="list-style-type: none"> • une caisse de 15 kg • une caisse de 10 kg • une caisse de 15 kg fragilisée • une caisse de 15 kg décentrée • 4 hauteurs, 2 essais • Total 64 manutentions. <p>Transfert à 180° d'un convoyeur vers un diable des mêmes 4 caisses (aller-retour) :</p> <ul style="list-style-type: none"> • 4 hauteurs, 2 essais • Total 64 manutentions. 	<ul style="list-style-type: none"> • Variables cinématiques du tronc • Électromyographie de surface (6 paires de muscles du tronc) • Moment de force en L5/S1
		<p>Transfert d'une palette de 24 caisses de 15 kg, à cadence libre (les 49 à 72^e de 24 boîtes).</p> <p>Transfert d'une palette de 24 caisses de 15 kg, à cadence imposée (les 97 à 120^e de 240 manutentions).</p> <p>Transfert d'une palette de 24 caisses de 10 kg, à cadence libre (les 145 à 168^e de 240 manutentions).</p> <p>Transfert d'une palette de 24 caisses de 10 kg, à cadence imposée (les 193 à 216^e de 240 boîtes)</p> <p>Total : 96 manutentions analysées / 240 effectuées.</p>	<ul style="list-style-type: none"> • Variables cinématiques du tronc • Électromyographie de surface (1 paire de muscles du tronc : longissimus) • Moment de force en L5/S1

ANNEXE B

B.I Statistiques descriptives des intrants cinématiques

Tableau 9. Statistiques descriptives des intrants cinématiques pour l'ensemble des données et selon chaque étude (Plamondon *et al.*, 2010 ; Plamondon *et al.*, 2012, Delisle *et al.*, 2016)

	Vélocité angulaire (rad/sec)	Angle d'inclinaison tronc/bassin (°)	Angle de torsion tronc/bassin (°)	Angle axe helicoidal (rad)	Moment dû au tronc /sag. (N m)	Moment dû au tronc / long. (N m)	Moment dû au tronc / trans. (N m)
Moy. (É.-T.)	-0,004 (0,521)	-0,079 (11,8)	0,95 (4,17)	0,27 (0,189)	0,32 (14,2)	0,33 (5,13)	36,75 (30,5)
	-0,005 (0,53)	-2,07 (7,15)	-0,01 (4,11)	0,26 (0,196)	0,78 (16,3)	0,13 (5,53)	40,98 (33,9)
	-0,004 (0,537)	-2,65 (6,8)	1,83 (2,98)	0,27 (0,186)	-0,71 (10,5)	0,27 (3,54)	30,15 (24,5)
	0,003 (0,294)	32,72 (17,8)	3,08 (7,74)	0,29 (0,155)	3,26 (15,4)	2,34 (8,76)	45,10 (27,6)
Médi-ane	-0,0015	-1,19	1,04	0,238	0,23	0,08	31,28
	-0,006	-1,50	0,091	0,236	0,85	0,03	34,99
	0,002	-2,00	1,83	0,236	-0,46	0,06	25,15
	0,004	29,6	3,19	0,257	2,19	1,22	46,89
Mini- mum	-9,640	-40,52	-34,863	-0,324	-88,02	-50,67	-67,96
	-5,485	-37,014	-34,863	-0,244	-88,02	-42,44	-42,37
	-9,640	-40,52	-29,363	-0,324	-50,23	-22,87	-31,26
	-2,334	-11,39	-33,33	0,099	-73,83	-50,67	-67,96
Maxi- mum	7,444	86,10	45,61	0,889	117,50	70,89	167,72
	5,116	29,15	23,31	0,889	117,5	42,58	167,72
	7,444	29,29	34,50	0,785	74,50	24,55	119,95
	2,217	86,10	45,61	0,750	89,06	70,89	154,39

ANNEXE C

C.I Statistiques descriptives des intrants électromyographiques

Tableau 10. Statistiques descriptives de chacune des caractéristiques des signaux électromyographiques utilisées lors de la prédiction des moments au dos pour l'ensemble des données et selon chaque étude (Plamondon *et al.*, 2010 ; Plamondon *et al.*, 2012, Delisle *et al.*, 2016). La description des variables est donnée au tableau 1.

	WL	AR1	AR2	AR3	AR4	AR5	AR6
moyenne (É.-T.)	2,7758 (2,3)	-1,4844 (0,294)	1,292 (0,422)	-1,0661 (0,407)	0,86162 (0,345)	-0,52603 (0,251)	0,24394 (0,123)
	3,2988 (2,66)	-1,4611 (0,314)	1,2995 (0,437)	-1,0898 (0,417)	0,88128 (0,354)	-0,53014 (0,256)	0,24254 (0,127)
	2,3129 (1,69)	-1,5029 (0,265)	1,279 (0,4)	-1,0506 (0,392)	0,84782 (0,335)	-0,52115 (0,248)	0,24374 (0,119)
	1,5239 (1,32)	-1,5545 (0,279)	1,315 (0,442)	-0,97392 (0,397)	0,7913 (0,312)	-0,52419 (0,219)	0,25666 (0,111)
médiane	2,0805	-1,5088	1,2832	-1,0591	0,85669	-0,5335	0,24931
	2,4657	-1,4886	1,2949	-1,0837	0,87355	-0,53476	0,24928
	1,8539	-1,5208	1,2692	-1,0493	0,85099	-0,53041	0,24766
	1,0844	-1,5837	1,2892	-0,91349	0,78052	-0,54227	0,26018
minimum	-2,3456	-3,2415	-1,6394	-5,4855	-1,7215	-2,6824	-0,78133
	-2,3456	-3,2415	-1,3284	-5,4855	-1,7215	-2,6824	-0,78133
	-0,48251	-3,049	-1,6394	-3,9455	-1,673	-2,4218	-0,68356
	0,26051	-2,8018	-0,66876	-3,9161	-0,81073	-1,9259	-0,23162
maximum	43,44	0,090799	5,2337	2,1428	4,1827	1,3931	1,1142
	43,44	0,090799	5,2337	1,8153	4,1827	1,3931	1,1142
	21,061	0,037528	4,1093	2,1428	3,3935	1,2911	1,0045
	16,1	-0,38146	3,8855	0,97064	3,1286	0,52885	0,76739

	FTDD5	FTDD6	MSWP1	MSWP7	MSWP12	MSWP13	MSWP14	MSWP15	SP1	SP2
Moyenne (écart type)	-0,9938 (0,00902)	-0,90165 (0,087)	-3,4483 (0,896)	-4,3033 (0,772)	-5,4798 (0,881)	-4,7239 (0,822)	-4,2735 (0,786)	-4,4002 (0,796)	2,0897 (0,125)	1,5129 (0,291)
	-0,99336 (0,00987)	-0,90097 (0,0946)	-3,3476 (0,887)	-4,1185 (0,743)	-5,3448 (0,857)	-4,5722 (0,804)	-4,0904 (0,759)	-4,22 (0,772)	2,0877 (0,126)	1,5545 (0,297)
	-0,99402 (0,00826)	-0,90768 (0,0713)	-3,5078 (0,881)	-4,4439 (0,732)	-5,572 (0,869)	-4,8466 (0,805)	-4,4066 (0,744)	-4,5439 (0,761)	2,0934 (0,124)	1,471 (0,281)
	-0,99586 (0,00549)	-0,86833 (0,105)	-3,8799 (0,905)	-4,8943 (0,763)	-5,9791 (0,9)	-5,1611 (0,788)	-4,8981 (0,77)	-4,9326 (0,775)	2,0817 (0,124)	1,4455 (0,252)
Médiane	-0,99715	-0,92425	-3,3881	-4,3146	-5,4428	-4,7113	-4,2808	-4,4038	2,1192	1,5116
	-0,99714	-0,92695	-3,2951	-4,1375	-5,305	-4,5636	-4,1131	-4,231	2,1174	1,5543
	-0,99703	-0,92435	-3,4383	-4,4358	-5,5376	-4,8253	-4,3982	-4,5279	2,1229	1,4704
	-0,99791	-0,8905	-3,8046	-4,955	-5,9412	-5,2033	-4,9524	-4,9983	2,1097	1,4598
Minimum	-1,0393	-1,1456	-7,3778	-7,465	-9,6121	-8,4635	-7,6861	-7,9893	0,69929	-0,23638
	-1,0318	-1,1456	-6,7559	-6,9228	-9,0864	-7,8809	-6,8386	-7,143	0,69929	-0,23638
	-1,0393	-1,1041	-7,3778	-7,465	-9,6121	-8,4635	-7,6861	-7,9893	0,91476	-0,15365
	-1,0108	-1,0241	-6,3398	-6,5775	-8,9051	-7,3514	-6,8606	-7,0918	1,0364	0,2648
Maximum	-0,88299	0,29328	-0,31221	-1,1744	-1,383	-1,3698	-0,98178	-0,97602	2,814	2,8521
	-0,89979	0,29328	-0,31221	-1,1744	-1,383	-1,3698	-0,98178	-0,97602	2,814	2,8244
	-0,88299	-0,03754	-0,38335	-1,7719	-2,0168	-2,0833	-1,5173	-1,7858	2,7728	2,8521
	-0,93012	-0,081744	-1,204	-1,9447	-2,6902	-2,3732	-1,79	-2,0927	2,5594	2,3588

	LM1	LM2	LM3	LM4	KURT	SKEW	WAMP	MFL
Moyenne (écart type)	-8,9269e-06 (0,0021)	0,025462 (0,0233)	-0,001388 (0,00298)	0,0042985 (0,00413)	4,0091 (1,66)	-0,26959 (0,532)	111,26 (13,8)	2,6213 (2,33)
	-2,9072e-06 (0,00225)	0,028121 (0,0262)	-0,0016293 (0,00324)	0,0048252 (0,00468)	4,0624 (1,68)	-0,29567 (0,521)	113,8 (10,9)	3,0409 (2,68)
	-1,7544e-05 (0,00201)	0,023505 (0,0198)	-0,0011119 (0,0027)	0,0038661 (0,0034)	3,9524 (1,63)	-0,22444 (0,545)	109,56 (15,3)	2,2521 (1,78)
	-2,0879e-06 (0,00123)	0,016544 (0,0145)	-0,0012143 (0,00219)	0,0028192 (0,00272)	3,9425 (1,57)	-0,34979 (0,508)	101,59 (17,5)	1,6037 (1,44)
Médiane	-1,3704e-06 -5,8351e-07	0,018667 0,02046	-0,00054955 -0,00068572	0,0031484 0,0035414	3,5491 3,5982	-0,23613 -0,2567	115 116,79	1,9465 2,2985
	-2,1691e-06 -2,2457e-06	0,017799 0,012321	-0,00041089 -0,00052042	0,0029184 0,0019803	3,4971 3,5	-0,19853 -0,30408	113,64 106,32	1,7329 1,14
Minimum	-0,053914 -0,053914	-0,03648 -0,03648	-0,090421 -0,090421	-0,010916 -0,010916	-12,265 -7,9604	-5,6427 -5,1226	0 9,1679	-1,4952 -1,4952
	-0,052524 -0,034675	-0,012723 -0,0019096	-0,070506 -0,038422	-0,0084378 -0,0023602	-12,265 -2,9948	-5,6427 -4,3601	0 30,872	-0,26246 0,17448
Maximum	0,061053 0,061053	0,4145 0,4145	0,029818 0,029818	0,087977 0,087977	41,787 34,014	4,5218 4,2484	132,14 132,14	48,005 48,005
	0,044676 0,05365	0,25396 0,15322	0,020914 0,018379	0,06874 0,05224	41,787 32,361	4,5218 3,3764	131,41 127	18,566 14,892

ANNEXE D

D.I Identification automatique des artEfacts des signaux électromyographiques

Introduction

Grâce aux avancées technologiques, il est de plus en plus aisé d'enregistrer les signaux électromyographiques (EMG) sur de longues périodes. Or, ces signaux EMG peuvent facilement être influencés par de nombreuses sources de contamination, que l'on nomme ici artefacts, d'où l'importance de s'assurer de la qualité des signaux enregistrés et d'éliminer ces artefacts. Considérant la quantité importante de données que peuvent générer les outils de collectes modernes, des procédures automatisées de contrôle de qualité des signaux sont grandement souhaitables. En effet, l'approche traditionnelle de contrôle de la qualité par la visualisation des signaux EMG bruts devient impraticable avec de telles quantités de données.

La détection d'artefact n'est pas exclusive à l'EMG mais s'applique aux signaux biomédicaux en général, notamment à l'électroencéphalographie, où l'on retrouve un grand nombre de publications présentant une grande diversité de méthodes utilisant l'apprentissage machine (Faust *et al.*, 2018 ; Mannan *et al.*, 2018). Les recherches actuelles sur la classification des signaux EMG sont principalement en lien avec la reconnaissance de patrons moteurs pour supporter des interfaces personne-machine (Nazmi *et al.*, 2016). Les études se concentrant sur les artefacts se divisent entre l'identification du type d'artefact (Fraser *et al.*, 2014 ; McCool *et al.*, 2014) ou bien seulement la détection (Ijaz et Choi, 2018 ; Marateb *et al.*, 2012). L'approche retenue et présentée dans cette annexe est la détection des artefacts via des approches d'apprentissage machine.

Les artefacts

Plusieurs types de problèmes peuvent survenir lors d'une collecte de signaux EMG. Les artefacts les plus courants surviennent lorsque l'électrode bouge ou se décolle de la peau (« spike »). Les tâches de manutention sont très propices à ce type d'artefact, car l'amplitude de mouvement est très grande. La saturation des signaux (amplitude du signal dépassant la limite fixée par l'amplificateur), le décrochage (déviation de la ligne de base) et le bruit électromagnétique environnant sont d'autre type d'artefacts courants. Les procédures habituelles de traitement du signal (filtre passe-bande, notch) ne suffisent pas pour corriger les portions de signal affectées.

Méthodologie

Les paragraphes suivants décrivent les étapes successives implantées afin d'automatiser la détection et le nettoyage des artefacts EMG. Toutes les étapes ont été implantées avec le logiciel Matlab (*MathWorks, 2016*).

Prétraitement

Les signaux EMG ont été inspectés dans le domaine fréquentiel, puis dans le domaine spatial. Un premier sous-ensemble de sujets (27 sujets pour 32 essais) a servi à l'entraînement. Un deuxième sous-ensemble (13 sujets pour 14 essais) a servi à la validation interne comme support à l'entraînement. Finalement un troisième sous-ensemble (8 sujets pour 23 essais) a servi à la validation externe. Le deuxième sous-ensemble partageait des sujets avec le premier alors que le troisième sous-ensemble ne comportait aucun sujet présent dans les deux premiers ensembles. La sélection des sujets et des essais favorisait ceux qui présentaient des artefacts après une première inspection visuelle rapide. Dans chaque sous-ensemble, 2/3 des sujets présentaient des artefacts dans leurs essais. Bien que l'identification des artefacts soit plus facile sur un signal non filtré, il a été décidé d'appliquer deux filtres standards sur les données (filtre passe-bande (20-500Hz) et notch à 60 Hz et les harmoniques) car cela permettait de corriger certaines portions des signaux automatiquement.

Identification et segmentation

Une interface maison permettait d'afficher, par fenêtre de deux secondes, le signal brut et filtré simultanément ainsi que le moment à L5/S1 pour aider à la décision de classer une portion du signal comme artefact. Chaque artefact était ensuite extrait dans une fenêtre fixe de 125 ms. Si l'artefact était plus long que 125 ms, il était scindé en plusieurs sous-fenêtres de 125 ms. Le choix de la taille de la fenêtre est un paramètre important dans la qualité des caractéristiques extraites par la suite (Farina et Merletti, 2000). La décision d'utiliser une fenêtre relativement courte est basée sur la distribution de la longueur des artefacts identifiés (tableau 3.1), dont 85 % étaient inférieurs à 125 ms. De plus, lorsque les artefacts sont de courte durée, la proportion du bon signal contenu dans la fenêtre augmente, par exemple pour le 10^e centile, plus de la moitié du signal de la fenêtre est bon. Également dans le but d'interpoler les portions du signal jugées comme mauvaises, une fenêtre courte est plus avantageuse (Howarth et Callaghan, 2010). Par la suite, sur les mêmes sujets, des portions de signal qualifiées comme bonnes ont été extraites aléatoirement pour apparier la quantité d'artefacts extraite. Ces deux types de fenêtres définissent les classes : artefact versus bon signal.

Tableau 11. Quantification des artefacts EMG

	EMG total (min)	artefacts initiaux (N)	artefacts post- segmentation (< 0,125 s) (N)
Entraînement	100	675	762
Validation interne	56	208	228
Validation externe	67	503	552
Total	223	1386	1542
Somme en secondes			131,48

Centiles de la longueur des artefacts (s)

Centile	5	10	25	50	75	90	95
seconde	0,0415	0,0491	0,0645	0,0844	0,1059	0,1351	0,1781

Les méthodes de classification

De nombreuses méthodes existent pour catégoriser des données. Lorsque la complexité du problème est importante, les deux méthodes qui ressortent le plus dans la littérature sont : l'analyse discriminante linéaire ou quadratique (LDA) et la machine à vecteur de support (support vector machine : SVM). Une approche LDA suppose que les classes ont la même covariance et qu'elles sont distribuées normalement, ce qui n'est pas le cas avec les caractéristiques extraites dans cette étude. Considérant les avantages que présente la SVM (Quitadamo *et al.*, 2017), cette dernière a donc été retenue en utilisant la librairie la plus populaire : libsvm (Chang et Lin, 2011). D'autres méthodes alternatives ont également été implantées, celles basées sur les réseaux de neurones artificiels (RNA) et celles sur les réseaux de Kohonen ou SOM (*self organizing map*, ou carte auto-organisatrice) (Ijaz et Choi, 2018). Les approches SVM et RNA sont supervisées, c'est-à-dire que l'entraînement a lieu en présence de la réponse, alors que l'approche SOM est non supervisée, le réseau est entraîné sans connaître la réponse.

Quelques tests ont été effectués afin de réduire la dimension des données (le nombre de caractéristiques), soit en transformant les données dans un nouveau référentiel (PCA, ICA) ou bien en sélectionnant un nombre de caractéristiques moindres, basés sur une mesure de performance. Étant donné que les performances finales étaient systématiquement moindres et que deux des trois méthodes (SVM et SOM versus RNA) utilisées ne souffraient pas d'une dimensionnalité importante, il a été décidé de conserver l'ensemble des caractéristiques (MilijkoVIC, 2017 ; Pappu et Pardalos, 2014), présentées au tableau 1.

Machine à vecteur de support (SVM)

Le but de la méthode est de trouver une frontière dans un espace à n dimensions qui va maximiser la séparabilité des classes à l'aide de vecteurs de support (les caractéristiques). Le noyau de transformation (kernel) était une fonction à base radiale qui permet d'augmenter la séparabilité des classes. Pour éviter un surapprentissage et obtenir une meilleure généralisation, deux paramètres doivent être ajustés : C et gamma. C'est un facteur de régularisation qui pénalise les mauvaises classifications et gamma définit l'inverse du rayon d'influence de chacun des échantillons sélectionnés par le modèle comme vecteurs de support. Il n'y a pas de consensus sur les valeurs respectives de C et gamma puisqu'elles dépendent du type de données. Les procédures standards pour identifier les bonnes valeurs ont été appliquées en faisant varier ces deux paramètres sur une grille grossière (C : -5 à +5, gamma : -10 à +5, par pas de 1) puis fine de recherche (pas de 0,1). Ainsi, des combinaisons de C et gamma ont été testés et les meilleurs modèles retenus pour être soumis aux données de validation internes (croisées à 6 plis) et déterminer le meilleur modèle. Les valeurs de C et de gamma retenues sont respectivement 0,7292 et 0,0712. La prédiction finale de cette méthode est binaire dans un cas à deux classes.

Réseau de neurones

Un réseau de neurones avec deux couches (25 neurones dans la première et 2 dans la seconde) a été utilisé. Le choix du nombre de neurones a été déterminé en faisant varier le nombre de neurones entre 5 et 50 par pas de 1. L'algorithme d'entraînement était celui du gradient conjugué, mis à l'échelle avec rétropropagation ; les fonctions d'activations étaient sigmoïdale pour la couche cachée et exponentielle normalisée pour la couche de sortie. Une fois le nombre de neurones fixé, le modèle final a été construit avec une validation croisée à 10 plis. Les modèles accédaient aux données de validation internes pour arrêter l'entraînement en cas de surapprentissage. Le modèle final a été construit en moyennant les biais et les pondérations des 10 modèles issus de la validation croisée. La prédiction finale de cette méthode est une probabilité d'appartenir à une des deux classes.

Carte auto-organisatrice

L'objectif de cette méthode est d'obtenir une représentation simple (2d ou 3d) de données possédant une grande dimensionnalité en regroupant des caractéristiques qui sont semblables (par exemple : distance euclidienne). Le résultat est une carte dans laquelle différentes grappes doivent être séparées. Puisque la réponse est connue, les neurones répondant à une des deux classes étaient identifiés (> 50 %), ceux répondant aux deux classes dans une proportion égale étaient écartés. Pour cette méthode, les données d'entraînement et de validation interne ont été concaténées. Les paramètres de ce réseau ont été fixés à 225 neurones (Tian *et al.*, 2014). Lors de la phase d'agencement (itération 1 à 1000), le taux d'apprentissage était 0,9 et la distance de voisinage était de cinq

neurones et lors de la phase d'ajustement (itération 1001 à 5000) ces paramètres étaient progressivement diminués à 0,02 et un neurone, respectivement.

Évaluation des méthodes de classification

Chacune des méthodes a été évaluée avec les données de validation externes (sujet et essais non présents pendant l'entraînement) comportant 552 fenêtres d'artefacts et 552 fenêtres de bon signal. L'indice de performance est rapporté en comptant le nombre de vrais positifs (VP : artefact) et vrais négatifs (VN : bon signal) qui représentent la concordance entre la prédiction du modèle et l'appartenance à une classe et le nombre de faux positifs (FP) et faux négatifs (FN) qui représentent une mauvaise prédiction du modèle. La précision, la spécificité et la sensibilité sont alors calculées comme suit :

$$\text{Précision} = (VP+VN) / (VP+VN+FP+FN)$$

$$\text{Sensibilité} = VP / (VP+FN)$$

$$\text{Spécificité} = VN / (VN+FP)$$

La sensibilité mesure la performance lors de l'identification des artefacts, alors que la spécificité rapporte la performance dans l'identification du bon signal.

Résultats

Les résultats sont rapportés pour chacun des modèles, puis lorsque ces derniers sont groupés. Le tableau 12 rapporte les valeurs pour les 3 modèles et montre que l'ensemble des modèles ont une précision supérieure à 97 % et qu'ils affichent une meilleure spécificité que sensibilité.

Tableau 12. Indice de performance des modèles

	Précision (%)	Sensibilité (%)	Spécificité (%)
SVM	97,2	96,7	97,7
SOM	97,0	94,8	99,3
RNA	97,6	96,6	98,6

Une analyse de concordance entre les modèles démontre qu'il est avantageux de combiner les trois modèles (tableau 13). Même en identifiant une portion de signal comme mauvaise alors qu'elle ne l'est pas, une interpolation de 125 ms ne nuit pas à la reconstruction des données. Ainsi en combinant les trois modèles, la précision atteint 99 %, la sensibilité 99,6 % et la spécificité 98,4 %.


Tableau 13. Proportion (nombre de portions) de signaux identifiées comme artefact (VP) ou bon signal (VN) selon différentes combinaisons de modèles

	Identifié par 3 modèles	Identifié par 2 modèles	Identifié par 1 seul modèle	Identifié par aucun modèle
VP (artefacts)	92,9 % (513/552)	96,2 % (531/552)	98,4 % (543/552)	1,6 % (9/552)
VN (bon signal)	97,3 % (537/552)	98,7 % (545/552)	98,9 % (546/552)	0,4 % (2/552)

Une évaluation supplémentaire a été menée pour observer si les prédictions des modèles étaient généralisables sur différents systèmes, muscles, fréquence d'échantillonnage et type de tâche. Ces données ont été visualisées au préalable pour identifier les artefacts le cas échéant.


Deux exemples sont présentés pour le muscle trapèze supérieur, enregistré en condition de travail réel, avec des électrodes circulaires (Micro-EMG, OTbiolab), à une fréquence d'acquisition de 1000 Hz. Dans le premier exemple (figure 10), un enregistrement de 17 minutes est présenté pour le trapèze supérieur non dominant, dont le signal était tellement problématique qu'il avait été rejeté. La méthode automatique de détection rejette quant à elle 60,2 % du signal, conservant les parties ou des périodes de très faibles intensités (inactivité) sont présentes.

Figure 10. Exemple d'un signal corrompu.



La partie supérieure présente le signal brut et la partie inférieure présente le signal filtré et traité avec l'algorithme de détection d'artefacts indiquant les portions de signal problématiques en rouge, les portions de bon signal en vert. On constate que seules des portions de très faible intensité sont identifiées comme bon signal, tel qu'on s'y attendait. Le deuxième exemple (figure 11) présente l'enregistrement de 17 minutes pour le trapèze dominant de la même tâche que dans l'exemple précédent. Ce fichier a été soumis à l'identification des artefacts. Le nombre de segments identifiés comme mauvais est de 602. La précision de la prédiction est de 94,89 %, avec une sensibilité de 67,3 % et une spécificité de 98,9 %. Il apparaît que la méthode a identifié des artefacts réels qui n'avaient pas été perçus à l'analyse visuelle, mettant en évidence la subjectivité lors de l'identification des artefacts par un expert (laisser passer un petit artefact lorsqu'il est proche d'un gros).

Figure 11. Exemple d'un signal en apparence de bonne qualité.



Note : La partie supérieure gauche présente le signal brut, la partie inférieure gauche présente le signal filtré et traité avec l'algorithme d'identification des artefacts. L'encadré à droite présente un agrandissement d'une portion du signal. Le bon signal est identifié en vert, et le signal avec artefacts en rouge. L'algorithme permet la détection d'artefacts difficilement perceptible à l'œil nu.

Conclusion

L'automatisation de l'étape de vérification des signaux EMG, habituellement effectuée par analyse visuelle, procurerait un gain de temps considérable lorsque les temps de collecte s'allongent, comme il est possible de le faire pour de nombreuses applications. Une approche automatisée capable de détecter les anomalies des signaux électromyographiques a été introduite. Chacun des modèles implantés performe très bien sur des signaux EMG des muscles extenseurs du dos lors de tâches de manutention. La combinaison des trois modèles s'est avérée accroître la performance des méthodes utilisées individuellement et permet d'atteindre une performance remarquable. Les résultats présentés dans la section précédente ont tous été obtenus à partir de signaux électromyographiques mesurés avec le même type d'électrode (Delsys, Boston, Ma) sur les mêmes muscles (longissimus à L1). Toutefois, des analyses supplémentaires démontrent également de très bonnes performances sur des données variées (muscles différents, type d'électrodes différentes, intensités de contraction différentes, durées de contractions différentes) augmentant ainsi le niveau de confiance dans l'utilisation de la méthode proposée. Les modèles sont disponibles sous forme de fonctions Matlab et peuvent être obtenus en contactant [François Thénault](#).

La principale limite est que l'on ne peut pas prédire la justesse de la prédiction sur des artefacts non présents durant l'entraînement. Ainsi, bien que la méthode semble fonctionner pour d'autres muscles et d'autres types d'électrodes, il est peu probable que la méthode puisse identifier des types d'artefacts auxquels elle n'a pas été exposée pendant l'entraînement.