



HAL
open science

Estimation des forces de réaction au sol à partir des mesures de semelles instrumentées

Amal Kammoun

► **To cite this version:**

Amal Kammoun. Estimation des forces de réaction au sol à partir des mesures de semelles instrumentées. Biomécanique [physics.med-ph]. Université d'Orléans, 2024. Français. NNT : 2024ORLE1038 . tel-04891871

HAL Id: tel-04891871

<https://theses.hal.science/tel-04891871v1>

Submitted on 16 Jan 2025

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

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

UNIVERSITÉ D'ORLÉANS

**ÉCOLE DOCTORALE Mathématiques, Informatique, Physique Théorique et
Ingénierie des Systèmes - MIPTIS**

**PRISME - Laboratoire Pluridisciplinaire de Recherche en Ingénierie des
Systèmes et Mécanique Energétique**

THÈSE présentée par :

Amal KAMMOUN

soutenue le : 16 octobre 2024

pour obtenir le grade de : **Docteur de l'Université d'Orléans**

Discipline/ Spécialité : Sciences et Technologies Industrielles

Estimation des forces de réaction au sol à partir des mesures de semelles instrumentées

THÈSE dirigée par :

M. RAVIER Philippe
M. BUTTELLI Olivier

Professeur des universités, Université d'Orléans
Professeur des universités, Université d'Orléans

RAPPORTEURS :

M. CHIEMENTIN Xavier
M. RIVET Bertrand

Professeur des universités, Université de Reims
Maître de conférences, Université de Grenoble

JURY :

M. RAVIER Philippe
M. BUTTELLI Olivier
M. CHIEMENTIN Xavier
M. RIVET Bertrand
M. ZARE MAHMOUDABADI Mohsen

Professeur des universités, Université d'Orléans
Professeur des universités, Université d'Orléans
Professeur des universités, Université de Reims, Président
Maître de conférences, Université de Grenoble
Maître de conférences, Université de Technologie de
Belfort-Montbéliard

INVITÉ :

M. PLESSIS Pascal

Directeur technique et commercial chez Emka Electronique

Remerciements

Je souhaite exprimer ma gratitude à mon directeur de thèse, M. Philippe Ravier, Professeur à l'IUT de Chartres et responsable de l'équipe de traitement du signal au sein du laboratoire PRISME de l'Université d'Orléans, pour m'avoir accueilli au sein de son équipe. Je lui suis également reconnaissant pour le temps considérable qu'il m'a accordé, ainsi que pour ses qualités pédagogiques et scientifiques. J'ai énormément appris à ses côtés et je lui adresse toute ma reconnaissance pour cela.

Je tiens à exprimer mes sincères remerciements à mon co-directeur de thèse, M. Olivier Buttelli, Professeur à l'Université d'Orléans et spécialisé en biomécanique, physiologie musculaire et ergonomie. Son attention constante envers mes travaux, ses conseils avisés et son écoute attentive ont été essentiels à la réussite de cette thèse. Son énergie et sa confiance ont été des moteurs pour moi, et j'ai pris un réel plaisir à collaborer avec lui.

J'adresse de sincères remerciements à mon encadrant industriel, M. Maxime Godart, pour son aide et ses remarques précieuses tout au long de la thèse. Je remercie également M. Pascal Plessie et tous les membres d'Emka-Electronique pour leur soutien. Leurs remarques, leur franchise et leur gentillesse ont été autant d'éléments qui m'ont permis d'atteindre mes objectifs.

Je tiens à exprimer ma profonde gratitude envers les membres du jury de ma thèse d'avoir accepté de participer à l'évaluation de ce travail.

Je tiens à remercier tous les membres du laboratoire PRISME pour leur aide et leur bonne humeur. Nous avons partagé de bons moments ensemble.

Je souhaite remercier spécialement la société TEA basée à Nancy ainsi que M. Giovanni Arbelaez, chercheur à l'Université de Lorraine, de nous avoir permis d'emprunter la semelle Moticon.

Enfin, je souhaite notamment remercier mon mari Mohamed, mes parents Mohamed et Samira, mes deux frères Akram et Aymen, et mes beaux-parents Nabil et Lobna pour leur soutien.

Table des matières

Liste des acronymes	5
Introduction générale.....	6
Chapitre 1 Estimation de la force de réaction au sol au moyen de semelles de pression.....	8
1.1 La force de réaction au sol (Ground Reaction Force, GRF).....	8
1.2 Intérêt de la détermination de la GRF	8
1.3 Principe de la détermination de la GRF	9
1.3.1 Technologies des semelles de pression	9
1.4 Estimation de la GRF à partir des mesures de pression	10
1.5 Positionnement et innovation	12
Chapitre 2 Matériels et méthodes.....	14
2.1. Introduction	14
2.2 Matériels.....	14
2.3 Protocole.....	16
2.4 Démarche de travail pour le traitement des données.....	19
2.4.1 Prétraitement des données	20
2.4.2 Autres traitements.....	22
2.4.2.1 Estimation de la vitesse de la marche normale et lente	23
2.4.2.2 Calcul du nombre d'échantillons pour les six activités	23
2.5 Méthodes de Réduction de Dimension (RD).....	24
2.5.1 Méthodes de sélection de caractéristiques.....	25
2.5.1.1 Méthode de filtrage	25
2.5.1.1.1 Mutual Information (MI).....	26
2.5.2 Méthodes d'extraction de caractéristiques	28
2.5.2.1 Méthode de Principal Component Analysis (PCA).....	28
2.6 Méthodes de Machine Learning (ML) pour estimer les composantes de la GRF.....	29
2.6.1 Méthodes de Supervised Machine Learning (SML)	29
2.6.1.1 K-Nearest Neighbors (KNN).....	29
2.6.1.2 Support Vector Regression (SVR)	30
2.6.1.3 Least Squares (LS)	31
2.6.1.4 Random Forest (RF).....	32
2.6.2 Méthodes de Deep Learning (DL).....	34
2.6.2.1 Artificial Neural Network (ANN)	34
2.6.2.1.1 Wavelet Neural Network (WNN).....	36

2.6.2.2 Recurrent Neural Network (RNN)	37
2.6.2.2.1 Long Short-Term Memory (LSTM).....	37
2.6.2.2.2 Gated Recurrent Unit (GRU)	37
2.6.2.2.3 Bidirectional Recurrent Neural Network (BRNN).....	38
2.6.2.3 Convolutional Neural Network (CNN)	39
2.7 Diagramme de démarche de travail pour estimer les composantes de la GRF	40
2.7.1 Division des données.....	41
2.7.2 Modélisation de ML avec l'approche de validation croisée Leave One Subject Out (LOSO)	41
2.7.3 Métriques.....	42
2.8 Conclusion.....	42
Chapitre 3 Impact des méthodes de normalisation sur la PCA sur la précision de l'estimation des composantes de la GRF.....	43
3.1 Introduction	43
3.2 Les méthodes de normalisation	43
3.3 Architectures et paramètres optimaux des modèles PCA-ANN et PCA-SVR.....	45
3.4. Résultats	46
3.5 Discussion	48
3.6 Conclusion.....	48
Chapitre 4 Sélection des capteurs de pression de la semelle pour l'estimation des composantes de la GRF par la méthode ANN à travers l'étude de la PCA	50
4.1 Introduction	50
4.2 Les trois stratégies pour sélectionner les capteurs importants après PCA pour l'estimation des composantes de la GRF.....	51
4.2.1 Exemple de la procédure de sélection des capteurs pour le pied droit avec la semelle Moticon pour les 3 stratégies	53
4.3 Modélisation de PCA-ANN et validation de la modélisation ANN avec la sélection des capteurs les plus importants	55
4.4 Résultats	56
4.5 Discussion	60
4.6 Conclusion.....	62
Chapitre 5 Comparaison de la précision de l'estimation des composantes de la GRF entre les méthodes d'apprentissage automatique supervisé et d'apprentissage profond à l'aide d'une semelle de pression.....	63
5.1 Introduction	63
5.2 Détermination de l'architecture et les paramètres optimaux des méthodes de SML et DL.....	63
5.3 Résultats	65
5.4 Discussion	69
5.5 Conclusion.....	70

Chapitre 6 Comparaison de la précision de l'estimation des composantes de la GRF entre 13 méthodes de Machine Learning avec ou sans méthode de réduction de dimension à l'aide d'une semelle de pression..	71
6.1 Introduction	71
6.2 Détermination de l'architecture et des paramètres optimaux des méthodes de ML et RD-ML.....	72
6.3 Résultats de l'estimation des composantes de la GRF pour les méthodes de ML et ML-RD.....	82
6.3.1 Discussion	82
6.3.2 Performance des six activités en utilisant la méthode de ML ou ML-RD recommandée	84
6.4 Conclusion.....	85
Chapitre 7 Conclusion et perspective	87
Annexe I : Moyenne \pm écart type de RMSE (R) entre les composantes estimées et mesurées avec la semelle Moticon pour PCA-ANN, PCA-LS et PCA-SVR pour l'ensemble de données de test pour les activités de marche	89
Annexe II : Moyenne \pm écart-type du RMSE (R) entre les composantes de la GRF estimées et mesurées des deux pieds avec la semelle Moticon pour les méthodes de DL / SML pour l'ensemble de données de test pour les six activités.....	92
Annexe III : Les allures des composantes de la GRF estimées par la méthode RF et mesurées par la plateforme pour un essai des six activités pour la stratégie intrasujet en utilisant la semelle Moticon.....	95
Annexe IV : Les valeurs de RMSE (R) entre les composantes de la GRF estimées avec 13 méthodes de ML avec ou sans méthode de RD et les composantes mesurées des deux pieds pour les deux semelles ..	97
Bibliographie.....	103

Liste des acronymes

AdaGrad	Adaptive Gradient
Adam	Adaptive Moment
ANN	Artificial Neural Network
BLSTM	Bidirectional Long Short-Term Memory
BGRU	Bidirectional Gated Recurrent Unit
BRNN	Bidirectional Recurrent Neural Network
BW	Body Weight
CNN	Convolutional Neural Network
CoP	Center of Pressure
DL	Deep Learning
DS	Decimal Scaling
GRF	Ground Reaction Force
GRU	Gated Recurrent Unit
IMU	International Mathematical Union
Inters	Intersujet
Intras	Intrasujet
KNN	K-Nearest Neighbors
KPCA	Kernel Principal Component Analysis
LOSO	Leave One Subject Out
LI	Length of the Insole
LLNF	Locally Linear Neuro Fuzzy
LSTM	Long Short-Term Memory
Med	Médiane
MI	Mutual Information
ML	Machine Learning
MM_[-1,1]	Min-Max dans la plage [-1, 1]
MM_[0,1]	Min-Max dans la plage [0, 1]
MLS	Maximum Linear Standardization
Nadam	Nesterov Accelerated Adaptive Moment
PCA	Principal Component Analysis
PCs	Principal Components
Pdc	Port de charge
PP	Pression Plantaire
R	Coefficient de corrélation
RBF	Radial Basis Function
RF	Random Forest
RMSProp	Root Mean Square Propagation
RMSE	Root Mean Square Error
RNN	Recurrent Neural Network
RS	Robust Scaler
SGD	Stochastic Gradient Descent
SML	Supervised Machine Learning
SVR	Support Vector Regression
VS	Vector Standardization
WLS	Weighted Least Squares
WNN	Wavelet Neural Network
ZS	Z-Score

Introduction générale

Cette thèse s'inscrit dans le cadre du projet de recherche TEEMPO (Technologie pour l'Evaluation EMbarquée de la Pénibilité et de la mOtricité). Son objectif est la conception et la réalisation d'un système embarqué pour l'estimation des contraintes articulaires qui s'expriment en condition écologique d'activité. Le consortium regroupe 4 partenaires : Emka-Electronique (ETI), Ergocentre (TPE), l'université d'Orléans avec le laboratoire PRISME (Sciences de l'ingénieur, UR4229) et TEA (PME). Emka-Electronique contribue à la fabrication de composants électroniques et le développement de capteur-logiciel, Ergocentre apporte son expertise en ergonomie, PRISME apporte son expertise dans le traitement des données et l'automatisme, TEA est l'intégrateur final du dispositif, il est fabricant et distributeur de matériel pour la mesure et l'analyse du comportement humain. Je suis rattachée au laboratoire PRISME et mon travail industriel se réalise au sein de l'entreprise Emka avec un contrat CIFRE. Il porte sur le développement de méthodes d'estimations des contraintes (Force) de réaction au sol à partir des données fournies par des semelles de pression. Le premier segment visé par l'industriel, pour la commercialisation du dispositif final, est le monde du travail, notamment dans une aide à l'identification de facteurs physiques impliqués dans l'émergence de troubles musculo-squelettiques (TMS).

Les TMS représentent la principale cause de morbidité liée au travail et sont la première cause de maladies professionnelles indemnisées, représentant 88 % des maladies professionnelles reconnues par le régime général : 44 492 cas en 2019 [1]. Les causes des TMS sont multifactorielles mais dans des activités de manutention et de port de charge, la composante physique n'est pas à sous-estimer. C'est pourquoi, il semble pertinent de proposer des dispositifs de terrain, portables et non encombrants, permettant l'estimation de la charge portée journalière et celle de contraintes articulaires des segments sollicités au cours du travail.

Les atteintes des TMS se localisent principalement au niveau des membres supérieurs (complexe articulaire de l'épaule, coude, carpes, métacarpes et phalanges), ainsi que celui du rachis et plus particulièrement sur l'étage lombaire.

L'estimation des contraintes articulaires porte sur la détermination des torseurs d'effort intersegmentaire. Pour cela, il est nécessaire d'accéder à la mesure cinématique des déplacements segmentaires, de mobiliser une modélisation des segments corporels (chaînon) en y intégrant des paramètres anthropométriques et inertiels, ceci afin de définir les cinétiques segmentaires, et d'opérer une démarche de dynamique inverse. Cette dernière procède chaînon par chaînon, de manière récursive. Deux stratégies sont possibles, une descendante en partant du segment libre le plus distal pour aller vers les appuis, une montante en partant des appuis pour aller vers le segment qui nous intéresse. L'estimation sera d'autant moins entachée d'erreur si des indéterminations sont levées. C'est pourquoi, en condition de laboratoire, il est classiquement réalisé la mesure des forces de réactions aux sol (*Ground Reaction Force*, GRF) au moyen de plateforme de force. Cette estimation en condition écologique peut se réaliser au moyen de semelles instrumentées munies de capteurs de pression.

L'estimation de la GRF, à partir de semelles instrumentées de mesure de pression, se construit au moyen de méthodes d'apprentissage automatique (*Machine Learning*, ML) qui intègrent des étapes de normalisation et de réduction de dimension, sachant que les semelles sont équipées d'un réseau d'une à plusieurs dizaines de capteurs. Il s'avère, dans la littérature, que les différentes méthodes déployées dans ces stratégies d'apprentissage n'ont pas été évaluées que ce soit par une légitimation théorique ou encore dans une démarche comparative entre méthodes. La présente thèse a donc pour objectif de définir les méthodes optimales d'estimation de la GRF au regard de notre cadre applicatif qui concerne le port et la manutention de charge. Pour cela, notre travail comprend 4 études comparatives : une première sur différentes méthodes de normalisation ; une seconde sur la réduction de dimension et la sélection optimale de capteurs ; une troisième sur différentes méthodes d'apprentissage et une quatrième sur la combinaison optimale de l'ensemble des approches (réduction de dimension et méthodes d'apprentissage) pour l'estimation de la GRF.

Le premier chapitre de ce mémoire présente la définition et l'intérêt de la détermination de la GRF, les technologies de semelles de pression, l'état de l'art concernant l'estimation de la GRF à partir de mesures de pression et nous précisons notre travail de recherche par rapport à la littérature, ce qui nous permet de positionner notre innovation.

Le deuxième chapitre détaille le protocole expérimental des différentes études. Nous présentons également une section dédiée aux méthodes de Réduction de Dimension (RD), qui revêtent une importance capitale, notamment pour réduire la dimension des données des capteurs de pression. Nous présentons une section dédiée aux méthodes de ML permettant l'estimation des composantes de la GRF, couvrant deux familles principales : l'apprentissage supervisé, connu en anglais sous le nom de *Supervised Machine Learning* (SML) et l'apprentissage profond, connu en anglais sous le nom de *Deep Learning* (DL).

Pour les chapitres 3 à 6, nous présenterons notre travail de recherche à travers quatre études différentes, ainsi que nos contributions visant à estimer les trois composantes de la GRF à partir des données de pression d'une semelle instrumentée.

Pour le troisième chapitre, nous présentons notre première étude portant sur l'impact de 12 méthodes de normalisation sur l'analyse en composantes principales (*Principal Component Analysis*, PCA) sur la précision de l'estimation des composantes de la GRF en utilisant la semelle Moticon pour les activités de marche. Cette analyse est réalisée en utilisant trois méthodes de ML en conjonction avec PCA : moindres carrés (*Least Squares*, LS), un réseau de neurones artificiels (*Artificial Neural Network*, ANN) et la régression à vecteurs de support (*Support Vector Regression*, SVR). La méthode PCA est utilisée dans la littérature afin de réduire la dimension des données des capteurs de pression pour estimer les composantes de la GRF. En effet, la méthode de normalisation est une étape cruciale dans la PCA et elle a un impact sur la précision de l'estimation des composantes de la GRF.

Pour le quatrième chapitre, nous présentons notre deuxième étude concernant la sélection des capteurs de pression de la semelle pour l'estimation des composantes de la GRF par la méthode ANN à travers l'étude de la PCA. L'objectif de cette étude est d'obtenir un dispositif à faible coût en sélectionnant les capteurs les plus importants pour estimer les composantes de la GRF, sans compromettre la précision de cette estimation en utilisant les données de pression de tous les capteurs.

Pour le cinquième chapitre, nous présentons notre troisième étude concernant la comparaison de la précision de l'estimation de la GRF entre les méthodes de SML et DL. L'objectif de cette étude de chercher à savoir si les méthodes de SML peuvent donner de meilleurs résultats que les méthodes DL, qui sont les plus utilisées dans la littérature.

Pour le sixième et dernier chapitre, nous présentons notre quatrième étude concernant la comparaison de la précision de l'estimation des composantes de la GRF entre 13 méthodes de ML, avec ou sans méthode de RD. L'objectif est d'identifier la meilleure méthode de réduction de dimension en termes de précision d'estimation et d'efficacité de réduction, ainsi que de déterminer la méthode de ML la plus performante.

Chapitre 1 Estimation de la force de réaction au sol au moyen de semelles de pression

1.1 La force de réaction au sol (Ground Reaction Force, GRF)

Les approches de la biomécanique, en particulier celles des composantes de la force de réaction au sol, appelée en anglais *Ground Reaction Force* (GRF), sont utilisées dans des études d'analyse du mouvement et de la posture [2]. Outre l'intérêt pour le développement de connaissances fondamentales sur la motricité, ces paramètres sont mobilisés dans les champs applicatifs du médical, de l'ergonomie ou encore du sport [3].

La GRF est la force que le sol applique à un corps (dans notre cas, le pied) en contact avec lui.

La Figure 1.1 présente un exemple de décomposition de la GRF en fonction de ses trois composantes de force au regard du référentiel corporel (la composante verticale (F_z), antéro-postérieure (F_y) et médio-latérale (F_x)) [4].




Figure 1.1. Exemple de décomposition de la GRF en fonction de ses trois composantes de force au regard du référentiel corporel : verticale, antéro-postérieure et médio-latérale (F_z , F_y , F_x , respectivement). Le point de contact pied-sol est défini ici ponctuel au barycentre des appuis et symbolisé par le rond plein.

1.2 Intérêt de la détermination de la GRF

Les travaux en biomécanique de l'analyse du mouvement visent à développer des connaissances fondamentales sur la motricité humaine. Cette préoccupation d'intégrer la dynamique dans l'étude du mouvement se trouve déjà dans les travaux de J-E Marey [5] datant de 1894.

Dans le domaine médical, la GRF est utilisée pour évaluer les conditions de marche. Par exemple, elle est utilisée pour prévenir les blessures [6], faciliter la rééducation [7-9] et évaluer les dysfonctionnements moteurs pour la scoliose idiopathique de l'adolescent [10], dans le cas de la maladie de Parkinson [11, 12] et de l'asymétrie de marche [13].

La détermination de la GRF peut également présenter un intérêt dans le domaine de l'ergonomie. Elle permet d'identifier les conditions de travail propices à l'apparition de troubles musculo-squelettiques (TMS). Ces troubles périarticulaires affectent les muscles, les nerfs, les tendons, les ligaments et les articulations. Les lésions dorsales représentent 39 % de l'ensemble de ces troubles [14]. Elles peuvent être causées par des activités telles que le maintien de la posture, la manutention ou le Port de charge (Pdc) [15].

La méthode de la dynamique inverse est utilisée pour calculer les contraintes sur les articulations comme dans le cas de manutention de charge [16]. L'estimation sera améliorée par la prise en compte des données

de la GRF. Les valeurs de la GRF jouent un rôle crucial dans l'estimation de la force exercée au niveau de la région lombaire [16-21].

Aussi, nous pouvons citer les objectifs des activités statiques, qu'elles soient effectuées avec et sans Pdc. En ergonomie, les activités statiques désignent les situations où une personne maintient une posture ou une position fixe. Leur objectif est de déterminer si, en situation statique, il est possible de trouver le poids du sujet. Dans la situation statique, la somme des forces verticales F_z des deux pieds est égale au poids du sujet. Si nous prenons en compte le poids de la charge, la somme des forces verticales F_z des deux pieds est égal au poids du sujet, additionné au poids de la charge.

1.3 Principe de la détermination de la GRF

Le mesure des composantes de la GRF (F_z , F_y , F_x) est effectuée au moyen de plateformes de force, disponible en laboratoire. En condition écologique, une mesure directe au moyen des capteurs de forces n'est pour l'instant pas encore proposée par les industriels. Cependant, une estimation de la composante verticale (F_z) est maintenant possible à partir de semelles équipées d'un réseau de capteur de pression. La force F_z est égale à la somme de chaque valeur de capteur de pression multipliée par la surface de chaque capteur, dont l'équation est la suivante :

$$F_z = \sum_{i=1}^N P_i S_i, \quad (1.1)$$

avec P_i et S_i représentant respectivement les valeurs de pression et de la surface de chaque capteur et N est le nombre des capteurs de la semelle.

Néanmoins, les deux composantes F_y et F_x doivent être aussi évaluées. Les études [2, 10, 22-26], ont mis l'accent sur l'estimation des composantes de la GRF à partir d'une semelle équipée de capteurs de pression. Le principe repose sur des méthodes d'apprentissage automatique (*Machine Learning*, ML), dont l'objectif est d'identifier le lien entre les données de Pression Plantaire (PP) de la semelle et les composantes de la GRF en 3D (F_x , F_y et F_z). Le défi était principalement dans l'estimation de la composante F_y , suivie de la composante F_x , plutôt que la composante F_z . Cela est dû au fait que l'estimation de la composante verticale est plus simple en raison de la relation linéaire (équation 1.1) entre les capteurs de pression et la force verticale.

1.3.1 Technologies des semelles de pression

Etienne Jules Marey était le premier à mesurer les pressions du pied à la fin du 19ème siècle [27]. Marey a développé une chaussure de pression pneumatique munie d'un tambour qui mesure la pression exercée par le pied.

La Figure 1.2 présente les chaussures de mesure de pression pneumatique proposées par E-J Marey.



Marey , Comptes rendus académie des sciences

Figure 1.2. Les chaussures de mesure de pression pneumatique proposées par E-J Marey.

Actuellement les industriels ont développé des semelles de pression conçues à l'aide de composants électroniques. Deux technologies de semelle sont utilisées, basées sur des capteurs capacitifs ou résistifs (Tableau 1.1). Les travaux sur l'estimation de la GRF ont été majoritairement effectués pour des semelles à capteurs capacitifs [2, 10, 22, 23, 25, 26]. Ceux-ci disposent d'une sensibilité et d'une précision plus grandes que leurs homologues résistifs (Tableau 1.1), ces derniers ayant par contre un temps de réponse plus rapide et un coût de construction plus faible. Aucune étude n'a comparé la performance de ces deux technologies dans l'estimation de la GRF.

Le Tableau 1.1 présente le fonctionnement, les avantages et les inconvénients des capteurs de pression résistifs et capacitifs [28, 29].

Tableau 1.1. Fonctionnement, avantages et inconvénients des capteurs de pression résistifs et capacitifs.

Type de capteur	Fonctionnement	Avantages	Inconvénients
Capacitif	Un capteur de pression capacitif est un dispositif dont la capacité varie en fonction de la pression appliquée, grâce à une modification de l'épaisseur entre les conducteurs du condensateur.	Haute sensibilité Haute précision Faible consommation d'énergie	Temps de réponse lent Coûteux à fabriquer et à intégrer Sensible aux conditions environnementales telles que la température, l'humidité, etc.
Résistif	Un capteur de pression résistif est un dispositif dont la résistance varie en fonction de la pression appliquée.	Faible coût Petite taille Temps de réponse rapide	Une précision inférieure par rapport à d'autres types de capteurs Consommation d'énergie élevée Sensible à la température

1.4 Estimation de la GRF à partir des mesures de pression

En 1999, Savelberg et de Lange [23] ont été les premiers à utiliser les réseaux de neurones (*Artificial Neural Network*, ANN) pour estimer la composante F_y de la GRF. Fung et al. [26] ont estimé les composantes de la GRF avec la méthode des moindres carrés (*Least Squares*, LS), tout en réduisant les données de PP avec le facteur d'inflation de la variance, appelé en anglais *variance inflation factor*. Cette réduction vise à éliminer les variables d'entrée (PP) contribuant à la redondance [30]. Ce facteur d'inflation évalue la multicollinéarité entre les variables indépendantes dans un modèle de régression multiple [30]. D'autres chercheurs [2, 10, 22] ont employé ANN en conjonction avec deux méthodes de

RD, analyse en composantes principales et information mutuelle (*Principal Component Analysis - Mutual Information*, PCA-MI), pour réduire la dimensionnalité des données sur le PP. Rouhani et al. [2] ont comparé les méthodes ANN, neuro-flou localement linéaire (*Locally Linear Neuro Fuzzy*, LLNF) et LS pour estimer les composantes de la GRF. Sim et al. [10] ont comparé les trois méthodes présentées par Rouhani et al. [2] et ont également inclus la méthode de réseau neuronal à ondelettes (*Wavelet Neural Network*, WNN) dans leur comparaison.

Les méthodes de ML sont alimentées par des données qui sont transformées avec l'objectif d'améliorer leur qualité (extraction de caractéristiques) et leur nombre (sélection de caractéristiques). Les études [2, 10, 22, 26] montrent en effet un besoin d'extraction de caractéristiques qui réalise une transformation des données linéaire ou non, visant à limiter la redondance des données d'entrée (PP). Parmi les méthodes les plus utilisées mentionnées, la méthode PCA transforme les variables d'entrée vers une autre base de dimension plus petite que l'originale. Ces nouvelles caractéristiques, appelées composantes principales (*Principal Components*, PCs), sont décorrélatées et contiennent la plupart des variances cumulatives présentes dans toutes les variables originales [31]. La normalisation est la première étape de PCA, qui permet d'attribuer une importance égale à toutes les variables d'entrées. En effet, si les variables ont des valeurs dans des plages hétérogènes, les variables de petites valeurs seront moins importantes que les variables de valeurs plus élevées dans la procédure d'estimation. Les études [2, 10, 22] ont utilisé la PCA en conjonction avec une méthode de ML (PCA-ML) et une méthode de normalisation spécifique. Ces méthodes de normalisation peuvent avoir un impact sur la qualité de l'estimation des composantes de la GRF. Alors que certaines études ont normalisé les données de PP en fonction de la longueur de la semelle (*Length of the Insole*, LI) [2] ou du poids corporel (*Body Weight*, BW) [10] (méthodes physiques), d'autres, comme [22], ont proposé une normalisation dans l'intervalle [-1, 1] (méthodes statistiques). Cependant, aucun de ces auteurs n'a justifié son choix de méthode de normalisation. En outre, seules quelques méthodes de normalisation ont été étudiées, alors qu'il en existe de nombreuses dans la littérature. En contexte applicatif, les données brutes doivent être normalisées et il est nécessaire de considérer une normalisation adhoc des données d'entrée avant calcul PCA. Dans d'autres domaines, les auteurs de [32, 33] ont utilisé la méthode de normalisation Min-Max avec PCA-ML, tandis que les auteurs de [34] ont utilisé la méthode ZS. De plus, la normalisation ZS est la méthode la plus fréquemment suggérée lors de l'utilisation de la méthode PCA [35-37] (**étude n°1**).

Dans l'étude [25], les auteurs ont utilisé la réduction dimensionnelle des données de PP par une procédure empirique en ajustant le modèle linéaire. Ils ont testé plusieurs combinaisons de capteurs pour trouver le meilleur modèle linéaire, sans expliquer leur choix ni le nombre de combinaisons testées. Cependant, les méthodes empiriques de réduction de dimension peuvent être chronophages et nécessitent un temps important pour trouver le meilleur modèle. De plus, elles peuvent manquer de précision et de rigueur par rapport aux méthodes statistiques, conduisant à des résultats peu fiables en raison d'interprétations subjectives. En outre, ce type de procédure ne permet aucune possibilité de généralisation. En effet, pour obtenir un dispositif à faible coût, il est nécessaire de minimiser le coût de calcul, le temps et l'utilisation de la mémoire, tout en garantissant un niveau élevé de précision dans l'estimation des composantes de la GRF. Dans cette optique, il est souhaitable d'optimiser à la fois l'emplacement et le nombre de capteurs. À notre connaissance, aucune étude n'a évalué les avantages de la méthode de PCA pour identifier le nombre optimal de capteurs de pression nécessaires à l'estimation des composantes de la GRF et leur emplacement spatial optimal sur la surface de la semelle (**étude n°2**).

Pour répondre à l'objectif de performance, des méthodes de ML doivent bien entendu être considérées, au sein des familles d'apprentissage automatique supervisé (*Supervised Machine Learning*, SML) ou d'apprentissage profond (*Deep Learning*, DL). Les études [2, 10, 22-25] suggèrent l'utilisation des méthodes de DL telles que ANN et la mémoire à long terme bidirectionnelle (*Bidirectional Long Short-Term Memory*, BLSTM) pour l'estimation des composantes de la GRF à partir des données de PP. Cependant, cette recommandation est faite sans avoir testé les différentes méthodes de SML. Les méthodes DL présentent certains inconvénients par rapport aux méthodes SML. Elles nécessitent une puissance de calcul élevée et un temps d'apprentissage considérable [38]. De ce fait, l'apprentissage des modèles DL requiert souvent des serveurs GPU coûteux [38]. En outre, pour trouver le modèle DL optimal, plusieurs hyperparamètres doivent être ajustés et testés, tels que l'optimiseur, le taux d'apprentissage et le nombre de couches cachées. Pour trouver le meilleur modèle, ces hyperparamètres

sont testés dans différentes combinaisons, chacune nécessitant le calcul et l'évaluation d'un modèle complet. Plus le nombre d'hyperparamètres est élevé, plus le nombre de combinaisons à tester est important. Par ailleurs, les modèles de SML sont plus faciles à déployer que les méthodes DL. De plus, dans d'autres domaines, les méthodes de DL ne procurent pas nécessairement une meilleure précision d'estimation que les méthodes de SML [39-41]. On peut donc s'interroger, au regard de notre cadre expérimental, du type de méthode de ML à privilégier (**étude n°3**).

Les études [2, 10, 22-26] ont utilisé les méthodes ANN, LS, LLNF et BLSTM pour estimer les composantes de la GRF. Les méthodes LLNF et WNN appartiennent à la famille des ANN. La principale différence réside dans la fonction d'activation utilisée dans la couche cachée. LLNF n'utilise pas une fonction d'activation mais elle combine un modèle localement linéaire et une fonction floue [42]. WNN utilise une fonction d'activation basée sur des ondelettes. Autrement dit, seules trois méthodes de ML, à savoir ANN, LS et BLSTM, ont été testées. Pourtant, il existe de nombreuses autres méthodes de ML telles que la régression à vecteurs de support (*Support Vector Regression*, SVR), k plus proches voisins (*K-Nearest Neighbors*, KNN), etc. (**étude n°4**).

Les auteurs des références [2, 10, 22] ont utilisé la méthode PCA-MI pour réduire la dimension des données de PP. Cependant, ces études n'ont pas clairement expliqué la procédure de RD des PP avec PCA-MI. Ils ont présenté les résultats de la réduction avec PCA-MI sans détailler leur approche. De plus, ils ont combiné les deux méthodes de RD, PCA et MI, sans justifier pourquoi cette combinaison était nécessaire. Il n'est pas clair pourquoi les auteurs ont choisi cette combinaison et pourquoi ils n'ont pas utilisé seulement PCA ou seulement MI pour réduire la dimension des PP. De plus, en termes de résultats d'estimation des composantes de la GRF, les auteurs n'ont pas cherché à évaluer la meilleure méthode entre PCA-MI, PCA et MI. Notons que des objectifs de réduction du coût de calcul et du coût matériel ne sont pas toujours incompatibles avec des meilleures performances en estimation. En effet, dans certains cas, les techniques de RD permettent de répondre aux objectifs de réduction de coût matériel et logiciel tout en accroissant les performances d'estimation [43]. Il existe plusieurs méthodes pour réduire la dimension des données de PP : le clustering, des méthodes de ML, les méthodes de sélection de caractéristiques (méthode de filtrage telles que la méthode MI, méthode embarquée, méthode de wrapper) et les méthodes d'extraction de caractéristiques linéaires telles que la PCA ou non linéaire telles que l'analyse des composantes principales du noyau (*Kernel Principal Component Analysis*, KPCA). En plus, toutes les études [2, 10, 22-26] ont utilisé uniquement les données de PP d'une semelle pour estimer les composantes de la GRF. Aucune étude n'a cherché à intégrer d'autres données, telles que celles provenant d'une centrale inertielle (connue en anglais sous le nom d'*Inertial Measurement Unit* (IMU)), avec les données de PP afin de vérifier si l'ajout des données de l'IMU améliore la précision de l'estimation des composantes de la GRF (**étude n°4**).

1.5 Positionnement et innovation

Dans ce qui suit, nous précisons notre travail de recherche pour les quatre études mentionnées ci-dessus, vis-à-vis de la littérature, ce qui permet de positionner l'innovation apportée par chacune d'entre elles.

- Étude numéro 1

À notre connaissance, aucune étude n'a évalué l'impact des méthodes de normalisation sur la PCA dans l'estimation des composantes de la GRF. C'est pourquoi le chapitre 3 évalue l'impact de 12 méthodes de normalisation différentes issues de la littérature sur la précision de l'estimation des composantes de la GRF en utilisant PCA-ANN, PCA-LS et PCA-SVR. Aussi, dans cette étude, nous évaluerons également les performances de la méthode SVR pour l'estimation des composantes de la GRF, en tant qu'autre méthode comparative qui, à notre connaissance, n'a jamais été testée auparavant dans la littérature. Dans cette étude nous utilisons la semelle Moticon pour des activités de marche.

- Étude numéro 2

Aussi, dans le même contexte, nous souhaitons évaluer les avantages de la méthode de PCA pour sélectionner les capteurs de pression importants afin d'obtenir un dispositif à faible coût.

Le chapitre 4 présente une procédure complète de sélection de capteurs. Après la transformation PCA, nous proposons trois stratégies de sélection des caractéristiques, à savoir : *Backward* (appelée en amont en français), *Block* (appelée par blocs en français) et *Forward* (appelée vers l'avant en français).

Nous avons validé la procédure de sélection des capteurs importants à l'aide de la modélisation ANN pour évaluer l'estimation des composantes de la GRF avant et après sélection. Un point important de la procédure de sélection proposée est l'identification du nombre de capteurs et l'évaluation de leur pertinence sans avoir à recourir à un environnement de laboratoire avec des plateformes de force coûteuse. En outre, l'avantage de l'utilisation de la PCA pour la sélection des capteurs de pression est que la procédure proposée ne nécessite pas l'utilisation d'une méthode de ML pour estimer les composantes de la GRF, ce qui peut être très chronophage. Cette étude de sélection de capteurs sera réalisée expérimentalement pour les deux semelles Moticon et Fscan pour des activités de marche. Nous allons comparer ces deux semelles en termes de précision de l'estimation des composantes de la GRF avec PCA-ANN. À notre connaissance, cette comparaison entre ces deux semelles n'a pas été étudiée dans la littérature.

- Étude numéro 3

Le chapitre 5 évalue la précision de trois méthodes de DL (ANN, réseau neuronal convolutif (*Convolutional Neural Network*, CNN) et LSTM) et de trois méthodes de SML (forêt d'arbres décisionnels (*Random Forest*, RF), SVR et LS) dans l'estimation des composantes de la GRF pendant la marche, la situation statique et les activités de Pdc en utilisant la semelle Moticon. À notre connaissance, la comparaison de la précision d'estimation des trois composantes de la GRF de ces six méthodes de DL et SML n'a pas encore été explorée dans la littérature. Notre objectif est de déterminer si les méthodes DL, telles qu'utilisées dans des études antérieures [2, 10, 22-25], fournissent de meilleurs résultats que les méthodes SML. Ceci constitue notre première contribution dans ce chapitre. De plus, aucune étude n'a, à notre connaissance, évalué l'estimation des composantes de la GRF à partir des données de PP d'une semelle de pression pour des activités en situation statique et des tâches de Pdc. Cette évaluation est d'une importance considérable dans le domaine de l'ergonomie. Ceci représente notre deuxième contribution du chapitre.

- Étude numéro 4

Dans le chapitre 6, notre première contribution est de comparer la performance d'estimation des 13 méthodes de ML, avec ou sans méthode de RD (PCA, MI, PCA-MI et la méthode de sélection des capteurs importants (PCA-Block) que nous proposerons dans l'étude 2 du chapitre 4) pour l'estimation des composantes de la GRF. Nous allons estimer les composantes de la GRF pour les activités de marche, statique et Pdc en utilisant les semelles Fscan et Moticon. Les 13 méthodes comprendront SVR, KNN, RF, LS, ANN, PCA-ANN, PCA-MI-ANN, MI-ANN, PCA-Block-ANN, CNN, LSTM et les unités récurrentes fermées (*Gated Recurrent Unit*, GRU), pour estimer les composantes de la GRF à partir des données de PP, ainsi qu'ANN en prenant comme entrées à la fois les données de PP et les données d'accélération selon les trois axes d'une IMU (uniquement pour la semelle Moticon). Nous voulons vérifier si l'ajout des données de l'IMU améliore ou non la précision de l'estimation des composantes de la GRF.

Notre deuxième contribution est de comparer la performance d'estimation des quatre méthodes de ML-RD (PCA-ANN, PCA-MI-ANN, MI-ANN et PCA-Block-ANN) afin de déterminer laquelle offre la meilleure précision dans l'estimation des composantes de la GRF et réduit le plus efficacement le nombre de données de PP. Nous décrirons également la procédure de sélection des capteurs de pression.

À notre connaissance, aucune étude n'a comparé ces deux semelles. Notre troisième contribution est donc de comparer les résultats d'estimation des composants de la GRF entre les semelles Fscan et Moticon.

De plus, à notre connaissance, aucune étude n'a comparé les résultats d'estimation de F_z avec ceux déterminés par la semelle (somme des capteurs de pression multipliée par les surfaces des capteurs, équation 1.1). Cette quatrième contribution intègre donc aussi une comparaison entre ces estimateurs donnés par le fabricant de la semelle avec nos résultats d'estimation.

Enfin, notre cinquième contribution est d'évaluer la performance de chaque activité afin de déterminer laquelle offre les meilleurs résultats en termes d'estimation des composantes de la GRF.

Chapitre 2 Matériels et méthodes

2.1. Introduction

Dans ce chapitre, nous allons, en premier lieu, présenter le protocole, les technologies et les matériels utilisés pour estimer les composantes de la GRF à partir des données de PP des semelles de pressions pour six activités. Les matériels comprennent deux types de semelles de pression, deux plateformes de force, huit caméras infrarouges et un système Vicon. Nous allons exposer les six activités réalisées par les sujets, à savoir la marche lente et normale, la situation statique sans et avec une charge de 5 kg, le port d'une charge de 5 kg de gauche à droite et inversement, ainsi que le port d'une charge de 5 kg de bas en haut et inversement. Nous présenterons dans la section 2.4 le diagramme de la démarche de travail qui illustre les étapes nécessaires pour récupérer et traiter les données des semelles de pression et des deux plateformes de force.

En deuxième lieu, nous présenterons les méthodes de ML pour estimer les composantes de la GRF et les méthodes de RD afin de réduire la dimension de PP. Nous présenterons également dans la section 2.7 le diagramme de la démarche de travail qui illustre les étapes pour estimer les composantes de la GRF.

2.2 Matériels

Nous avons utilisé deux plateformes de force (AMTI, modèle : BMS600900, USA, dimensions : 600 mm x 900 mm), un système d'analyse de mouvement (Vicon, UK), huit caméras infrarouges et deux semelles de pression Moticon (ReGo AG, Munich) et Fscan (Tekscan, USA).

La Figure 2.1 montre l'emplacement des caméras infrarouges qui entouraient les deux plateformes de force.




Figure 2.1. Emplacement des caméras infrarouges (quatre caméras sont visibles) et les deux plateformes de force (AMTI, modèle : BMS600900, USA, dimensions : 600 mm x 900 mm).

L'objectif des deux plateformes de force est d'obtenir les données des composantes de la GRF en 3D pour les deux pieds.

Pour notre étude, nous nous concentrons sur le modèle du bas du corps, également appelé « *lower body* » en anglais. Pendant les tests expérimentaux, nous allons équiper les sujets avec 16 marqueurs situés sur la partie inférieure du corps. Les caméras infrarouges émettent un rayonnement réfléchi par les marqueurs. Nous récupérons une vidéo du mouvement du bas du corps du sujet en 3D enregistrée par le système Vicon.

La Figure 2.2 illustre l'emplacement des 16 marqueurs du modèle du bas du corps, ainsi que le modèle du bas du corps du sujet en 3D, construit à l'aide du logiciel « Nexus version 2.13 » du système de Vicon [44].

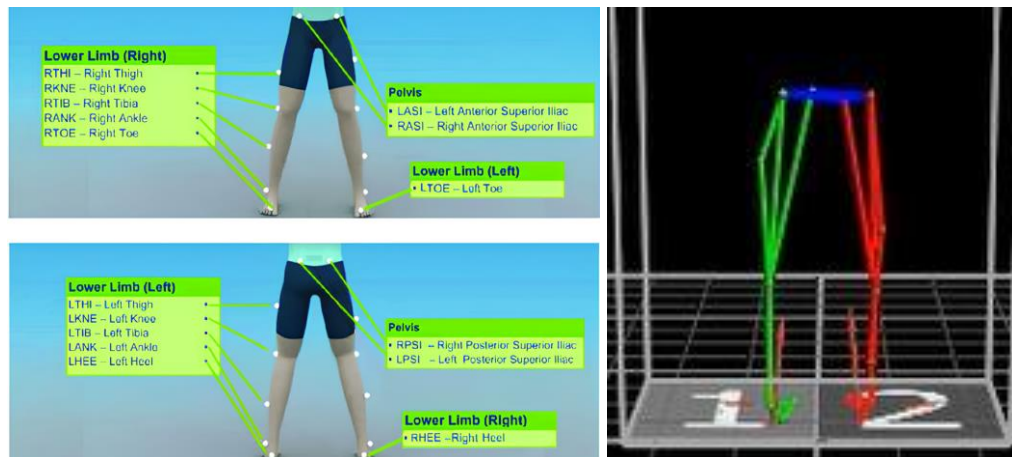


Figure 2.2. L'emplacement des 16 marqueurs du modèle du bas du corps (image gauche) et le modèle du bas du corps du sujet en 3D, construit à l'aide du logiciel « Nexus version 2.13 » du système de Vicon (image droite).

Nous allons utiliser deux semelles de pression instrumentées, avec les pointures présentées entre parenthèses :

- 1) une semelle Moticon équipée de 16 capteurs de pressions capacitifs qui intègre également une centrale inertielle (pointure : 42 EU) ;
- 2) une semelle Fscan équipée de 64 capteurs de pressions résistifs (pointure : 37-45 EU).

La Figure 2.3 présente deux images des deux semelles.



Figure 2.3. La semelle Fscan (Tekscan, USA) (image gauche), la semelle Moticon (ReGo AG, Munich) (image droite).

Le Tableau 2.1 présente des données relatives à ces deux semelles, tout en indiquant ses différents éléments.

Tableau 2.1. Deux semelles instrumentées équipées de capteurs de pression.

Types de semelles	Intervalle de pression (KPa)	Nombre de capteurs de pression	Poids (g)	Type de capteur	Autre capteurs
Fscan	0 – 862	64	322	Résistif	-----
Moticon	0 – 500	16	-----	Capacitif	Centrale inertielle

2.3 Protocole

Neuf sujets valides de sexe masculin (taille : $178 \pm 4,2$ cm, poids : $77 \pm 11,1$ kg, âge : 47 ± 15 ans) ont participé à notre étude en utilisant la semelle Moticon, tandis que quatorze sujets valides (7 hommes et 7 femmes : taille : $172 \pm 7,2$ cm, poids : $71 \pm 9,6$ kg, âge : 34 ± 11 ans) ont utilisé la semelle Fscan. Avant de commencer les expériences, tous les sujets ont reçu des informations détaillées sur l'objectif et la procédure de l'étude. Ils ont signé un consentement, conformément aux normes éthiques de la déclaration d'Helsinki (2013). Les sujets portaient leurs propres chaussures avec les semelles Moticon ou Fscan. Ensuite, nous avons équipé les sujets avec 16 marqueurs réfléchissants pour construire le modèle du bas du corps. Au cours de l'expérience, les sujets sont entourés de huit caméras et le système Vicon est utilisé pour obtenir la localisation tridimensionnelle des 16 marqueurs nécessaires à la construction de leur modèle en 3D (Figure 2.2). Les données des deux plateformes de force et les données du système des semelles Moticon et Fscan sont échantillonnées à 100 Hz.

Avant de participer à l'expérience, nous avons demandé à chaque sujet de faire des exercices pour calibrer la semelle Moticon ou Fscan et le système Vicon. Les exercices de calibrage pour la semelle Moticon comprenaient : une marche lente, rester immobile et des déplacements du poids du corps (appelés *shifts of body weight* en anglais). Pour la semelle Fscan, les exercices de calibrage consistaient à rester immobile sur un seul pied et à marcher. Pour le système Vicon, les exercices de calibrage consistaient à marcher et à rester immobile. De plus, cela leur avait permis de mieux s'adapter à l'environnement expérimental.

Après la calibration, les sujets ont effectué six activités différentes sur les deux plateformes de force pour obtenir les données des composantes de la GRF en 3D pour les deux pieds. Les six tâches contenaient des pas (pour les deux activités de marche), des essais (pour les deux activités de port de charge) et des durées (pour les deux activités en situation statique sans et avec port de charge) effectués sur les plateformes de force (le nombre indiqué présente le nombre minimal et maximal de pas, des essais et des durées parmi tous les sujets pour les deux semelles pour les deux pieds) :

- la marche normale de 6 à 10 essais : Moticon (7-20 pas sur les plateformes), Fscan : (6-15 pas sur les plateformes) (Figure 2.4) ;
- la marche lente de 6 à 10 essais : Moticon (8-22 pas sur les plateformes), Fscan : (8-26 pas sur les plateformes) (Figure 2.4) ;
- situation statique (rester debout immobile) : Moticon (20-50 s), Fscan : (20-50 s) (Figure 2.5) ;
- situation statique avec Port de charge (Pdc) de 5 kg (Pdc statique) : Moticon (20-50 s), Fscan : (20-50 s) (Figure 2.5) ;
- porter une charge de 5 kg de bas vers le haut et inversement (Pdc bas-haut) : Moticon (7-18 essais), Fscan : (7-13) (Figure 2.6).
- porter une charge de 5 kg de gauche à droite et inversement (Pdc gauche-droite) : Moticon (5-11 essais), Fscan : (5-12) (Figure 2.7) ;

Les sujets devaient marcher de manière continue et libre sur les plateformes de force pendant 6 à 10 tours (essais) dans la direction indiquée par la flèche sur la Figure 2.4. Un tour comprend une série de pas sur les plateformes de force. Les plateformes de force étaient intégrées dans une plateforme de bois (Figure 2.4) qui permettait d'initier et d'arrêter la marche en dehors des plateformes de force, ainsi aucune attention n'était portée par le sujet pour ajuster sa marche sur les plateformes de force.

Dans la Figure 2.5, le sujet devait rester debout immobile dans une situation statique sans et avec Pdc de 5 kg.

En utilisant la semelle Fscan, dans la Figure 2.6, le sujet débutait en situation statique (étape 1). Il portait une charge de 5 kg de la chaise et il la posait à la table (étape 2). Ensuite, le sujet déposait la charge de 5 kg sur la table et revenait en situation statique (étape 3). Le sujet prenait la charge de 5 kg de la table et il la ramenait à sa position initiale (chaise) (étape 4). Enfin, le sujet revenait en situation statique (étape 5). Pour la semelle Moticon, il n'y avait pas d'étape 3, c'est-à-dire le sujet effectuait de manière continue le Pdc de la chaise vers la table et inversement. Les deux activités du Pdc, du gauche vers la droite et de bas en haut, sont inspirées de l'article [45].

En utilisant la semelle Fscan, dans la Figure 2.7, le sujet débutait en situation statique (étape 1). Il portait une charge de 5 kg de l'extrême gauche de la table et il la ramenait à l'extrême droite de la table (étape 2). Ensuite, le sujet déposait la charge de 5 kg sur l'extrême droite de la table et revenait en situation statique (étape 3). Enfin, le sujet prenait la charge de 5 kg de l'extrême droite de la table et il la ramenait à sa position initiale (l'extrême gauche de la table) (étape 4). Le sujet revenait en situation statique (étape 5). Pour la semelle Moticon, il n'y avait pas d'étape 3, c'est-à-dire le sujet effectuait de manière continue le Pdc de l'extrême gauche de la table et il la ramenait à l'extrême droite de la table, et inversement.




Figure 2.4. Trajectoire du sujet pour la marche normale et lente.




Figure 2.5. Situation statique (image gauche), situation statique avec Pdc de 5 kg (image droite).




Figure 2.6. Les cinq étapes effectuées par le sujet pour porter une charge de 5 kg du bas (chaise) vers le haut (table) et inversement. Les flèches rouges indiquent le passage d'une étape à l'autre.




Figure 2.7. Les cinq étapes effectuées par le sujet pour porter une charge de 5 kg de gauche à droite et inversement. Les flèches rouges indiquent le passage d'une étape à l'autre.

2.4 Démarche de travail pour le traitement des données

Nous allons présenter la démarche de travail effectuée pour récupérer et traiter les données des deux plateformes de force et les données des semelles Moticon et Fscan.

La Figure 2.8 illustre le diagramme de la démarche de travail pour récupérer et traiter les données des deux plateformes de force et les données des semelles Moticon et Fscan.

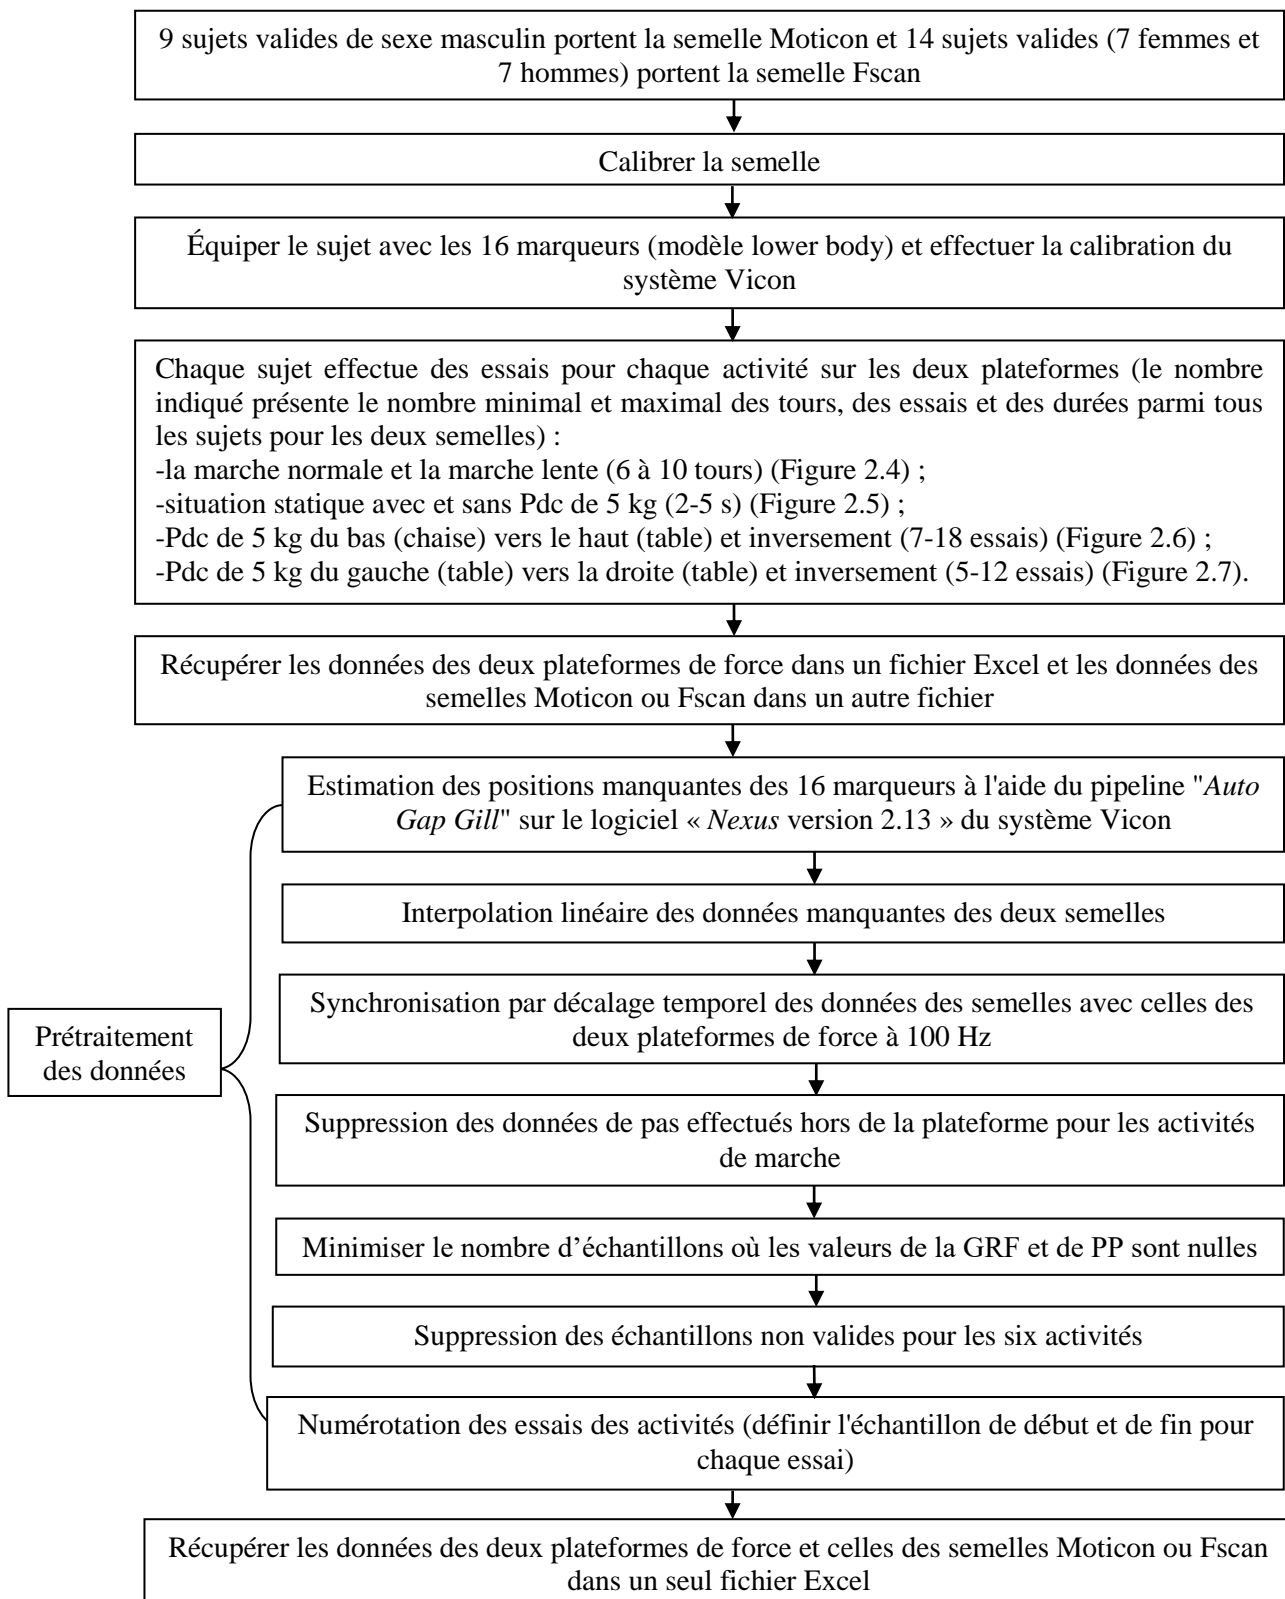


Figure 2.8. Diagramme de démarche de travail pour récupérer et traiter les données des deux plateformes de force et les données des semelles.

2.4.1 Prétraitement des données

Nous allons expliquer les différents blocs de prétraitement des données du diagramme présenté à la Figure 2.8.

- **Estimation des positions manquantes des 16 marqueurs**

Dans les vidéos des mouvements enregistrés par le Vicon, certaines trames peuvent présenter des ruptures de trajectoires dues à des marqueurs manquants. Pour extrapoler la trajectoire manquante, nous avons comblé ces lacunes à l'aide du pipeline "Auto Gap Gill" sur le logiciel « Nexus version 2.13 » du système Vicon. En conséquence, nous avons estimé les positions manquantes des 16 marqueurs.

- **Interpolation linéaire des données manquantes des deux semelles**

Certaines valeurs manquent dans les données des deux semelles. Nous avons procédé à remplir ces lacunes par interpolation linéaire.

- **Synchronisation par décalage temporel**

En l'absence d'une méthode directe pour synchroniser numériquement ou analogiquement les données de la plateforme de force avec les données des semelles, nous avons choisi une approche de synchronisation par décalage temporel pour les deux pieds, droit et gauche. Nous utilisons la composante F_z fournie par le système de semelles (la composante F_z équivaut à la somme de PP multipliée par les surfaces des capteurs). Au début de chaque activité, nous enregistrons d'abord les données de la plateforme, puis celles de la semelle. À la fin, nous arrêtons d'abord l'enregistrement des données de la plateforme, puis celui des données de la semelle. Par conséquent, les données de la semelle sont généralement plus courtes que celles de la plateforme. Nous prenons la courbe F_z de la semelle et la décalons par rapport à la courbe F_z de la plateforme de force sur une plage de temps donnée. Ensuite, pour chaque décalage temporel, nous calculons la valeur de l'écart quadratique moyen (*Root Mean Square Error*, RMSE) et le coefficient de corrélation (R) comme deux fonctions du décalage temporel. La valeur de décalage temporel avec le plus faible RMSE correspond au décalage optimal pour synchroniser les données des semelles avec celles des plateformes de force. Une valeur R élevée garantit une corrélation suffisante entre les deux courbes et valide la valeur de décalage temporel.

La Figure 2.9 présente un exemple de synchronisation pour un extrait de l'activité de marche avec la semelle Moticon pour le pied droit pour trois pas consécutifs.

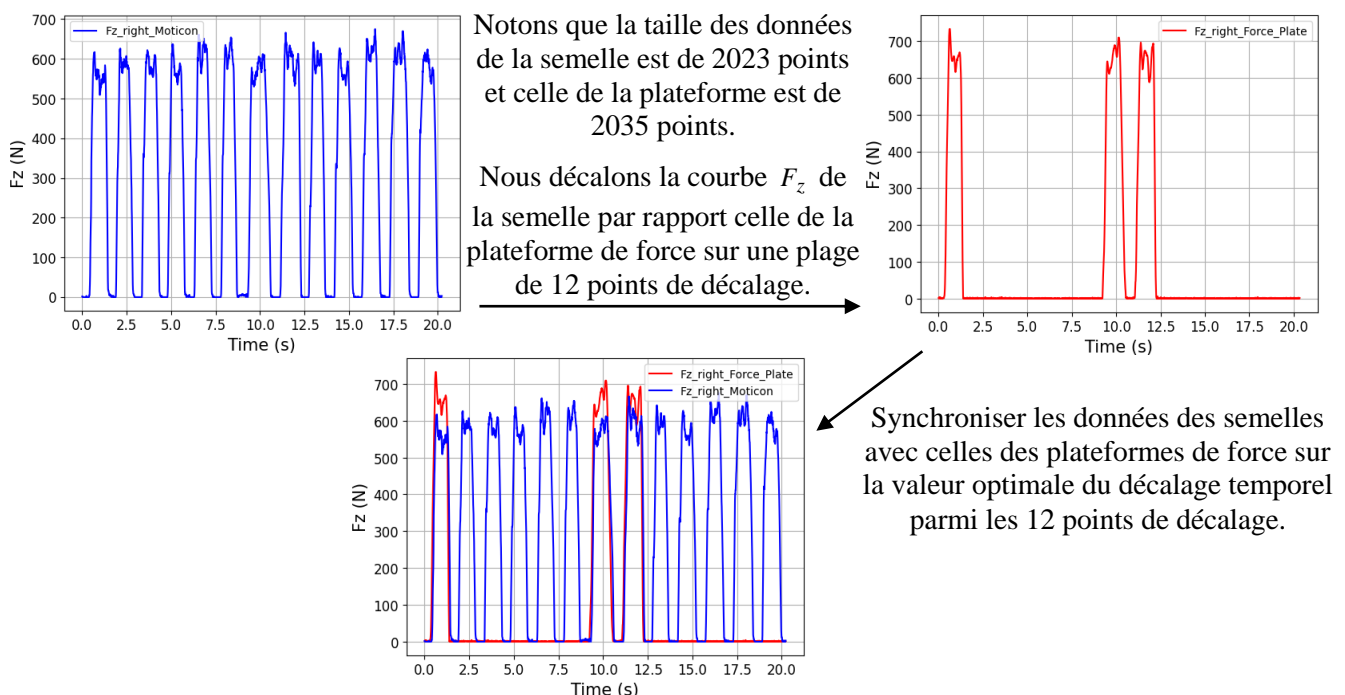


Figure 2.9. Exemple de synchronisation pour un extrait de l'activité de marche avec la semelle Moticon pour le pied droit pour trois pas consécutifs.

- **Suppression des données de pas effectués hors de la plateforme pour les activités de marche**

Pour les deux tâches de marche, le sujet doit effectuer des tours (essais) sur les plateformes de force. Nous aurons des échantillons des pas de la semelle effectuée en dehors des plateformes. Nous éliminons ces échantillons et ne considérons que ceux effectués sur les plateformes.

La Figure 2.10 présente un exemple d'un extrait de l'activité de marche du pied droit avec la semelle Moticon pour trois pas consécutifs.

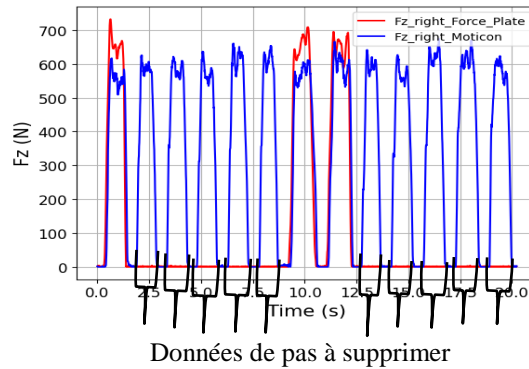


Figure 2.10. Exemple d'un extrait de l'activité de marche du pied droit avec la semelle Moticon pour trois pas consécutifs.

- **Minimiser le nombre d'échantillons où les valeurs de la GRF et de PP sont nulles**

Après la suppression des échantillons de pas en dehors de la plateforme, nous minimisons le nombre d'échantillons où les valeurs de la GRF et de PP sont nulles, c'est-à-dire lorsque le pied est levé. Afin de minimiser ce nombre d'échantillons, présenté dans des rectangles noirs dans la Figure 2.11, nous conservons de 5 à 10 échantillons dont les valeurs de F_z mesurées par la plateforme sont inférieures à 1-0.2 N. En effet, les valeurs de F_z mesurées peuvent inclure des erreurs de mesure de l'ordre de 7-5 N, ce qui peut conduire à des valeurs non nulles allant jusqu'à 7-5 N lorsque le pied est levé.

La Figure 2.11 présente un extrait de l'activité de marche pour trois pas consécutifs avec la semelle Moticon après suppression des échantillons de pas effectués en dehors de la plateforme.

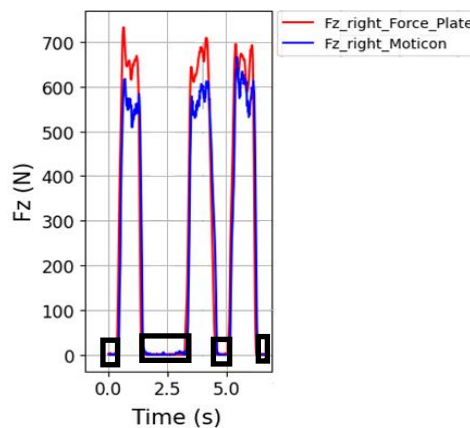


Figure 2.11. Extrait de l'activité de marche pour trois pas consécutifs avec la semelle Moticon après suppression des échantillons de pas effectués en dehors de la plateforme. Les rectangles en noir représentent les échantillons dont les valeurs F_z et PP sont nulles.

- **Suppression des données non valides pour les six activités**

En utilisant les vidéos de mouvement enregistrées par le système Vicon pour chaque sujet et chaque tâche, ainsi que les courbes de F_z déterminées par la plateforme de force, nous vérifions s'il y a des données non valides à supprimer. Par exemple, dans l'activité de Pdc de gauche à droite et inversement, un sujet a lâché la charge et est resté immobile pendant environ 3 secondes sans rien faire. Ces données de 3 secondes sont considérées comme non valides et doivent être supprimées.

- **Numérotation des essais des activités**

Après la suppression des données hors de la plateforme et des données non valides, nous allons numéroter les essais des activités. Pour chaque activité, il est nécessaire de définir les deux points de début et de fin de chaque essai.

La Figure 2.12 présente un exemple des essais de marche pour le pied gauche avec la semelle Moticon.

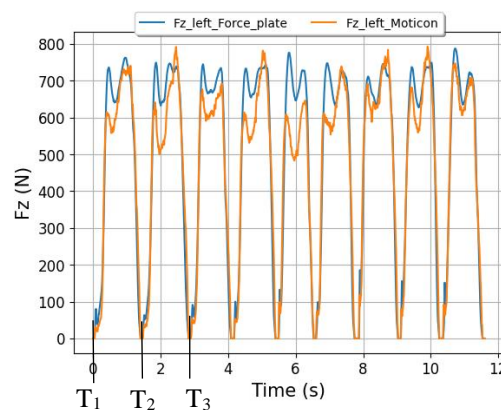


Figure 2.12. Exemple des essais de marche pour le pied gauche avec la semelle Moticon.

Pour les activités de marche : un essai comprend tous les échantillons d'un pas, depuis le contact initial du talon jusqu'au décollage du pied. Par exemple, dans la Figure 2.12, l'essai numéro 1 comprend toutes les données de l'échantillon de T_1 (contact initial du talon) jusqu'à T_2 (décollage du pied). L'essai numéro 2 comprend toutes les données de l'échantillon de T_2 jusqu'à T_3 , et ainsi de suite.

Pour les cas statiques et statique avec Pdc de 5 kg, un essai correspondant à 5% de tous les échantillons.

Pour le Pdc gauche-droite et le Pdc bas-haut, nous utilisons les vidéos de mouvement enregistrées par le système Vicon pour définir les deux points de début du Pdc (où le sujet est en situation statique, correspondant à l'étape 1 dans les deux Figures 2.6 et 2.7) et de fin (où le sujet est en situation statique, correspondant à l'étape 5 dans les deux Figures 2.6 et 2.7).

La numérotation des essais est utile pour la phase d'apprentissage, afin de construire un modèle d'estimation des composantes de la GRF. En effet, lors de la phase d'apprentissage du modèle, au lieu d'apprendre à partir d'échantillons aléatoires (ce qui pourrait entraîner le risque que le modèle ne couvre pas complètement la dynamique des amplitudes de la GRF), le modèle apprendra à partir des essais aléatoires. Notons qu'un essai correspond à une séquence d'échantillons.

2.4.2 Autres traitements

Les notions de marche lente et rapide étant subjectives, il est nécessaire d'évaluer les vitesses d'avancement correspondantes, ceci pour positionner nos résultats par rapport aux études de la littérature. Nous présentons ainsi la méthode d'estimation de la vitesse de la marche normale et lente, ainsi que le calcul du nombre d'échantillons pour les six activités.

2.4.2.1 Estimation de la vitesse de la marche normale et lente

Tout d'abord, nous calculons la vitesse entre deux pas successifs des deux pieds aux deux moments initiaux où les deux composantes verticales de la GRF des plateformes de force sont au maximum (les deux points gris illustrés dans la Figure 2.13).

La Figure 2.13 illustre les deux composantes verticales de la GRF pour deux pas successifs des deux pieds, mesurées avec les plateformes de force.

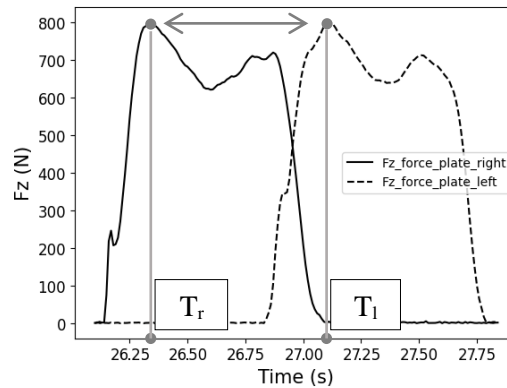


Figure 2.13. Les deux composantes verticales de la GRF pour deux pas successifs des deux pieds, mesurées avec les plateformes de force. Les deux points gris indiquent les moments initiaux où les deux composantes verticales sont au maximum.

La formule de la vitesse entre les deux pas successifs des deux pieds s'écrit :

$$V = \frac{\sqrt{(CoPx_l - CoPx_r)^2 + (CoPy_l - CoPy_r)^2}}{abs(T_l - T_r)}, \text{ (m/s)} \quad (2.1)$$

avec $CoPx_l$, $CoPy_l$, $CoPx_r$, $CoPy_r$, T_l et T_r sont les coordonnées en 2D du centre de pression, appelé en anglais *Center of Pressure* (CoP), et les temps d'échantillonnage du pied gauche et du pied droit, respectivement.

Ensuite, pour chaque sujet, nous calculons la vitesse moyenne en moyennant les vitesses calculées entre deux pas successifs à l'aide de l'équation 2.1 pour l'ensemble de ses essais de marche. En effet, la vitesse de la marche correspond à la vitesse d'une foulée de marche. Nous avons supposé qu'une foulée correspond à deux pas successifs des deux pieds, multipliés par deux [46]. En d'autres termes, nous avons supposé que la vitesse de marche correspondait à la vitesse entre deux pas successifs des deux pieds. Enfin, nous avons calculé la vitesse moyenne et l'écart type de la vitesse de la marche pour tous les sujets pour les deux semelles (Tableau 2.2).

Tableau 2.2. Moyenne \pm l'écart type de la vitesse de la marche pour l'ensemble des sujets (Moticon : 9 sujets, Fscan : 14 sujets).

Semelle	Marche normale (m/s)	Marche lente (m/s)
Moticon	0,6 \pm 0,14	0,40 \pm 0,05
Fscan	0,7 \pm 0,07	0,44 \pm 0,15

2.4.2.2 Calcul du nombre d'échantillons pour les six activités

Les Tableaux 2.3 et 2.4 présentent le nombre d'échantillons pour les six activités pour les deux semelles Moticon et Fscan. Entre parenthèses, le nombre de pas pour la marche lente et normale, le nombre

d'essais pour le Pdc gauche-droite et le Pdc bas-haut et le nombre d'essais pour les cas statiques et statique avec Pdc de 5 kg, où un essai correspondant à 5% de tous les échantillons.

Tableau 2.3. Nombre d'échantillons des deux pieds pour les 9 sujets (nombre de pas pour la marche ou nombre d'essais pour le Pdc ou nombre d'essais pour les cas statiques, où un essai correspondant à 5% de tous les échantillons) pour la semelle Moticon.

Activité	Pied droit	Pied gauche
	Dataset total : 160183	Dataset total : 164526
Marche normale	11100 (101)	12719 (111)
Marche lente	15008 (112)	17732 (128)
Statique	27032 (180)	27032 (180)
Pdc statique	24197 (180)	24197 (180)
Pdc bas-haut	41777 (86)	41777 (86)
Pdc gauche-droite	41069 (72)	41069 (72)

Tableau 2.4. Nombre d'échantillons des deux pieds pour les 14 sujets (nombre de pas pour la marche ou nombre d'essais pour le Pdc ou nombre d'essais pour les cas statiques, où un essai correspondant à 5% de tous les échantillons) pour la semelle Fscan.

Activité	Pied droit	Pied gauche
	Dataset total : 282356	Dataset total : 278578
Marche normale	14579 (142)	14468 (142)
Marche lente	31917 (244)	28250 (223)
Statique	38950 (280)	38950 (280)
Pdc statique	39272 (280)	39272 (280)
Pdc bas-haut	87528 (123)	87528 (123)
Pdc gauche-droite	87282 (100)	87282 (100)

2.5 Méthodes de Réduction de Dimension (RD)

Les techniques de ML traitent une quantité massive de données pour résoudre des problèmes de prédiction ou de classification. Pour améliorer potentiellement la précision des méthodes d'apprentissage et réduire leur temps d'apprentissage, il est recommandé de réduire la dimension des caractéristiques (les variables d'entrée). La Réduction de Dimension (RD) est une procédure très répandue dans divers domaines scientifiques. Elle correspond à une étape de prétraitement, qui peut être appliquée pour toute analyse de données [43]. En outre, nous pouvons citer les avantages suivants de la RD [43] :

1. éliminer les variables entrées redondantes et bruitées ;
2. implémenter des méthodes d'apprentissage avec un nombre limité d'entrées permettra de réduire à la fois le temps d'apprentissage et les coûts de calcul ;
3. éviter le surapprentissage, appelé en anglais : *overfitting* ;
4. parfois, l'utilisation de toutes les variables d'entrées comme entrées du modèle d'estimation peut dégrader la précision de l'algorithme mis en jeu, en augmentant toutefois le coût de calcul. Il est donc nécessaire de réduire la dimension des données afin d'améliorer la précision de l'estimation en éliminant les variables entrées redondantes.

Il existe deux méthodes de RD. La première méthode est fondée sur des méthodes de sélection de caractéristiques qui permettent de sélectionner les caractéristiques essentielles parmi tout l'ensemble de données d'entrées. Quant à la deuxième méthode, elle repose sur l'extraction de caractéristiques, tout en créant des nouvelles caractéristiques à partir de celles existantes dans tout l'ensemble de données d'entrées. Par ailleurs, il est possible de combiner les méthodes d'extraction de caractéristiques et de sélection.

En utilisant l'une de ces deux méthodes de RD, il est possible de pouvoir générer un sous-ensemble à partir de tous les ensembles de données d'entrées disponibles. Ce sous-ensemble doit contenir l'information la plus importante pour estimer la sortie.

2.5.1 Méthodes de sélection de caractéristiques

La sélection de caractéristiques (ou fonctionnalités) est une procédure qui est utilisée pour sélectionner les variables d'entrées les plus pertinentes pour la phase d'apprentissage. Lorsque nous avons l'accès à un grand ensemble de données, il faut choisir quelles sont les meilleures variables d'entrées (ou prédicteurs) pour le modèle d'estimation.

Il existe principalement trois méthodes de sélection de caractéristiques à savoir : méthode de filtrage, méthode de *Wrapper* et méthode embarquée [43].

La méthode embarquée [47] repose sur la mise en œuvre des algorithmes appropriés pour garantir une meilleure sélection des caractéristiques. En d'autres termes, la procédure de sélection est intégrée dans le processus d'apprentissage automatique. À titre d'exemple, nous pouvons citer la méthode de RF.

Les méthodes *Wrapper* sélectionnent les caractéristiques en les considérant comme des sous-ensembles de variables d'entrée, évaluant chaque sous-ensemble à l'aide d'un algorithme d'estimation spécifique. La sélection des caractéristiques est ainsi basée sur les performances du modèle lors de l'utilisation de ces différents sous-ensembles de variables. Cette approche est fiable mais nécessite un temps de calcul important [48], car elle implique l'entraînement et l'évaluation de plusieurs modèles.

Dans notre étude, nous nous intéressons aux méthodes de filtrage.

2.5.1.1 Méthode de filtrage

La méthode de filtrage, qui permet de sélectionner des caractéristiques, consiste à classer les variables d'entrées selon un critère de classement approprié, et ce, par ordre croissant ou décroissant [49]. Lorsque nous choisissons une valeur du seuil, nous supprimons les variables en dessous du seuil, ce qui correspond à l'élimination des variables les moins pertinentes. Notons toutefois que cette méthode est simple et efficace. Il est à indiquer qu'une caractéristique pertinente doit être indépendante des autres variables d'entrées et dépendante des sorties [49].

La Figure 2.14 représente le principe de la méthode de filtrage.




Figure 2.14. Principe de la méthode de filtrage.

Il existe trois méthodes de filtrage : les tests statistiques univariés, la matrice de corrélation et l'information mutuelle.

Les tests statistiques univariés sont utilisés pour sélectionner les caractéristiques qui dépendent fortement de la sortie. Nous pouvons envisager deux types de situations : si les entrées sont catégoriques (nous utilisons le test du khi carré) ou quantitatives (nous utilisons la fonction ANOVA) [49].

La matrice de corrélation [49], est une matrice carrée dont ces éléments correspondent à des coefficients de corrélation entre les différentes variables. À partir des valeurs de cette matrice, nous pouvons envisager deux situations : éliminer l'entrée faiblement corrélée avec la sortie ou éliminer l'une des deux entrées fortement corrélées.

Nous présenterons l'information mutuelle dans la sous-section suivante.

2.5.1.1.1 Mutual Information (MI)

L'Information Mutuelle, qui correspond à l'appellation anglo-saxonne *Mutual Information (MI)*, permet de mesurer la dépendance statistique entre les variables aléatoires. En outre, l'information mutuelle, qui est utilisée dans la sélection des variables d'entrées pour les modèles de prédiction, peut être utilisée pour calculer soit la dépendance entre un ensemble de variables d'entrées et une variable de sortie, soit la dépendance entre les variables d'entrées. Le meilleur jeu de données d'entrées est celui qui maximise ce type d'information dans le cas où on calcule la dépendance entre les variables d'entrées et une variable de sortie. Pour le 2ème cas, lorsque nous calculons la dépendance entre les variables d'entrée, le meilleur jeu de données d'entrée lorsque l'information mutuelle tend vers zéro. L'avantage essentiel de l'information mutuelle réside dans l'élimination des entrées redondantes. Par ailleurs, elle permet de calculer la dépendance soit entre les variables d'entrées, soit la dépendance entre les variables d'entrées et une variable de sortie, tout en se différenciant du coefficient de corrélation, qui est un cas particulier de dépendance et se limite à calculer les dépendances linéaires entre ces variables.

Shannon [50], qui fut l'un des pionniers du domaine de la théorie de l'information et de la communication, a introduit la notion de l'entropie, en vue de pouvoir calculer la quantité d'information d'une variable aléatoire discrète. En outre, il a publié des résultats importants dans ce domaine, notamment les techniques de discrétisation des signaux, en énonçant toutefois son célèbre théorème d'échantillonnage.

Ainsi, pour calculer la quantité d'information d'une variable aléatoire discrète X dont ces valeurs possibles à l'issue de plusieurs essais sont : $[x_1, x_2, \dots, x_n]$, nous pouvons définir l'entropie $H(X)$ de cette variable aléatoire comme suit [50] :

$$H(X) = -\sum_{i=1}^n p(X = x_i) \log(p(X = x_i)), \quad (2.2)$$

où le symbole \log désigne le logarithme népérien.

Pour chaque variable x_i , nous pouvons introduire une probabilité $p(x_i)$.

Soit une deuxième variable aléatoire discrète Y , dont ses valeurs possibles sont : $[y_1, y_2, \dots, y_n]$, qui sont issues de plusieurs essais.

La densité de probabilité jointe de la variable aléatoire discrète X et de celle Y est notée par $p(x_i, y_j)$.

Dans ce cas, l'entropie conjointe $H(X; Y)$ est définie comme suit :

$$H(X; Y) = -\sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log(p(x_i, y_j)). \quad (2.3)$$

En théorie de l'information, il est possible de pouvoir définir une entropie conditionnelle entre deux variables aléatoires, et ce, pour décrire une certaine quantité d'information qui est nécessaire pour connaître l'une de ces deux variables aléatoires à partir de la connaissance exacte de l'autre variable aléatoire.

Ainsi, et en notant l'entropie conditionnelle d'une variable aléatoire discrète X sachant la variable aléatoire discrète Y par : $H(X \setminus Y)$, nous pouvons définir cette entropie par l'expression suivante :

$$H(X \setminus Y) = \sum_{j=1}^m p(y_j) H(X \setminus Y = y_j), \quad (2.4)$$

En s'appuyant sur la théorie des probabilités et la théorie de l'information, nous pouvons calculer l'information mutuelle (MI) de deux variables aléatoires qui peut correspondre à une quantité permettant de mesurer la dépendance statistique de ces deux variables aléatoires. Par exemple, nous pouvons envisager la situation où ces deux variables aléatoires sont indépendantes.

Nous noterons par $I(X;Y)$ l'information mutuelle du couple (X,Y) de deux variables aléatoires discrètes X et Y , dont leur densité de probabilité jointe est notée par $p(x_i, y_j)$. Cette information mutuelle peut être définie par l'expression suivante :

$$I(X;Y) = -\sum_{i=1}^n \sum_{j=1}^m p(x_i, y_j) \log\left(\frac{p(x_i, y_j)}{p(x_i)p(y_j)}\right), \quad (2.5)$$

où les deux quantités $p(x_i)$ et $p(y_j)$ désignent les distributions marginales des deux variables aléatoires X et Y , respectivement.

La Figure 2.15 présente les relations entre l'entropie individuelle ($H(X), H(Y)$), l'entropie conjointe $H(X;Y)$, les entropies conditionnelles ($H(X \setminus Y), H(Y \setminus X)$) et l'information mutuelle $I(X;Y)$.




Figure 2.15. Relation entre l'entropie individuelle ($H(X), H(Y)$), l'entropie conjointe $H(X;Y)$, les entropies conditionnelles ($H(X \setminus Y), H(Y \setminus X)$) et l'information mutuelle $I(X;Y)$.

Il est à indiquer que l'information mutuelle est utilisée pour pouvoir mesurer la dépendance statistique entre les deux variables discrètes X et Y , ceci va nous permettre de mieux sélectionner les variables d'entrées, en vue d'élaborer des modèles de prédiction.

Estimation de l'information mutuelle par la méthode d'histogramme

Nous pouvons estimer l'information mutuelle par la méthode d'histogramme. Dans ce cas, nous divisons l'axe en des intervalles constants dx , dont le nombre total de cet intervalle correspond à un certain canal, appelé *bin* en anglais.

La densité de probabilité de la variable x_i dans l'intervalle dx contenu dans le canal i est définie par :

$$p(x_i) = \frac{k_i}{Ndx}, \quad (2.6)$$

où N représente le nombre d'effectif ou le nombre d'échantillons, k_i est le nombre d'échantillons contenu dans le canal i parmi le nombre total d'effectif N .

La densité de probabilité du couple (x_i, x_j) des deux variables x_i et x_j dans l'intervalle (dx, dy) contenu dans le canal (i, j) peut être décrite par l'expression suivante :

$$p(x_i, x_j) = \frac{k_{ij}}{Ndx dy}, \quad (2.7)$$

avec k_{ij} désigne le nombre d'échantillons contenu dans le canal (i, j) parmi le nombre total de N effectifs.

Nous pouvons diviser l'histogramme en un intervalle (R_x, R_y) de taille $dx * dy$ et de coordonnées (i, j) .

Nous pouvons opter pour l'approximation suivante de l'information mutuelle par la méthode d'histogramme entre deux variables aléatoires discrètes X et Y :

$$I(X, Y) = \sum_{i=1}^{R_x} \sum_{j=1}^{R_y} \frac{k_{ij}}{N dx dy} \log\left(\frac{k_{ij} N dx dy}{N dx dy k_i k_j}\right), \quad (2.8)$$

qui peut s'écrire comme suit :

$$I(X, Y) = \sum_{i=1}^{R_x} \sum_{j=1}^{R_y} \frac{k_{ij}}{N dx dy} \log\left(\frac{k_{ij} N}{k_i k_j}\right). \quad (2.9)$$

avec k_i et k_j étant le nombre d'échantillons contenus dans les canaux i et j respectivement, et R_x et R_y étant des intervalles de l'histogramme de tailles dx et dy respectivement.

Différentes méthodes ont été proposées dans la littérature, en vue de calculer le nombre de canaux. Nous citons ci-après plus particulièrement les trois méthodes suivantes :

1. méthode développée par l'université Rice de Houston [51], qui donne l'expression suivante :

$$K = 2N^{1/3}. \quad (2.10)$$

2. méthode de la racine carrée [51], soit :

$$K = \sqrt{N} \quad (2.11)$$

3. méthode de Sturges [51], qui permet de donner :

$$K = 1 + \log_2(N). \quad (2.12)$$

2.5.2 Méthodes d'extraction de caractéristiques

La méthode d'extraction de caractéristiques consiste à extraire des nouvelles données d'entrées, et ce, à partir d'un certain jeu de données [43]. Cette méthode permet d'expliquer correctement une représentation des données, en minimisant toutefois le nombre des données d'entrées redondantes. Elle transforme les variables mises en jeu dans un autre espace de données, tout en gardant les données les plus pertinentes. Il convient de souligner que les méthodes d'extraction de caractéristiques comprennent à la fois des techniques de réduction de dimension linéaires et non linéaires.

Nous pouvons citer les méthodes de réduction de dimension linéaires telles que la méthode de PCA [47, 52], une méthode non supervisée pour réduire la dimension des données numériques, la méthode de décomposition en valeurs singulières [52, 53], également non supervisée et utilisée pour la compression des images, ainsi que la méthode d'analyse discriminante linéaire [54], une technique supervisée, employée pour des données catégorisées (ou des classes spécifiques).

Pour les méthodes de réduction de dimension non linéaires, nous pouvons citer l'analyse en composantes principales à noyau (*Kernel Principal Component Analysis*, KPCA), qui correspond à une extension de la méthode PCA basée sur une approche à noyau [55]. La méthode KPCA permet de transformer les données d'entrée non linéaires en une dimension plus élevée à travers une fonction noyau, afin d'assurer une séparation linéaire des données. Cependant, cette méthode nécessite un temps de calcul très important.

Dans notre étude, nous nous intéressons à la méthode de PCA, que nous présentons dans la sous-section suivante.

2.5.2.1 Méthode de Principal Component Analysis (PCA)

La méthode d'analyse en composantes principales, qui est connue dans la littérature anglo-saxonne sous l'appellation *Principal Component Analysis* (PCA), est largement utilisée dans l'analyse de données multivariées [52]. Ainsi, elle permet d'étudier des ensembles de données multidimensionnelles, tout en se basant sur des variables quantitatives. La PCA est une méthode non supervisée.

La méthode PCA permet la réduction de la dimension d'un ensemble de données d'entrée (PP), qui peuvent être corrélés, en les transformant dans une autre base de dimension plus petite que l'originale.

Ces nouvelles caractéristiques, appelées *Principal Components* (PCs), sont décorrélatées et contiennent la plupart des variances cumulatives présentes dans toutes les variables originales [47]. En outre, la méthode PCA permet de réduire la dimension des variables d'entrées sans trop perdre d'information, tout en supprimant la redondance des variables d'entrées. L'implémentation de la méthode PCA peut se faire en se basant sur les étapes suivantes :

1. normaliser les données d'entrée ;
2. calculer la matrice de variance-covariance avec les données normalisées ;
3. calculer les valeurs propres et les vecteurs propres de la matrice de variance-covariance ;
4. trier les vecteurs propres par ordre croissant selon leur valeur propre ;
5. calculer la variance cumulée des valeurs propres dans l'ordre croissant ;
6. choisir la valeur du nombre k PCs qui permet d'expliquer la variance cumulative dans les données (généralement, la variance cumulative choisie est de 98 %) ;
7. créer la matrice de projection, appelée W , en utilisant les k PCs ;
8. utiliser la matrice W pour projeter les données dans un nouvel ensemble.

2.6 Méthodes de Machine Learning (ML) pour estimer les composantes de la GRF

L'apprentissage automatique, connu en anglais sous le terme de *Machine Learning* (ML), est une approche fondée sur l'intelligence artificielle, les mathématiques et la statistique, qui met l'accent sur la capacité d'un ordinateur ou d'une machine à acquérir et apprendre à partir de données.

Dans le cadre de notre étude, nous présentons les deux familles de méthodes de ML, à savoir l'apprentissage automatique supervisé (*Supervised Machine Learning*, SML) et l'apprentissage profond (*Deep Learning*, DL), pour l'estimation des composantes de la GRF.

2.6.1 Méthodes de Supervised Machine Learning (SML)

Dans le cas de l'apprentissage supervisé, celui-ci est composé de variables d'entrée (X) et de variables de sortie (Y). À travers les données d'entrée, nous développons un algorithme pour estimer la sortie (Y) à partir d'une fonction de mapping ou de prédiction, notée f telle que : $Y = f(X)$. Pour de nouvelles données d'entrée, nous estimons la sortie à partir de cette fonction de mapping. Nous appelons cet apprentissage "supervisé" car nous guidons l'algorithme dans son apprentissage de la fonction de prédiction en lui fournissant des exemples annotés.

Dans ce qui suit, nous allons présenter quatre méthodes de SML qui sont : KNN, SVR, LS et RF.

2.6.1.1 K-Nearest Neighbors (KNN)

La méthode des K plus proches voisins, connue dans la littérature anglo-saxonne sous l'appellation *K-Nearest Neighbors* (KNN), est une méthode d'apprentissage supervisée non paramétrique introduite en 1951 par Evelyn et Hodges [54]. Elle est largement utilisée pour les problèmes de régression et de classification en raison de sa simplicité et de son efficacité. Dans le cas de problèmes de régression, cette méthode calcule la distance entre chaque nouvelle observation et les données d'entrée de l'ensemble d'entraînement. Ensuite, elle estime la sortie en prenant la moyenne des K valeurs de sortie de l'ensemble d'entraînement qui ont la plus petite distance par rapport à la donnée d'observation. La performance de cette méthode dépend de la fonction choisie pour calculer la distance ainsi que du paramètre K [56]. Lorsque K est trop petit, le résultat peut être sensible aux échantillons bruités. En revanche, une valeur de K trop grand peut entraîner des distances élevées, susceptibles de générer des erreurs dans la sortie estimée.

Il existe plusieurs façons de calculer la distance entre deux points : la distance euclidienne, la distance de Minkowski, la distance de Manhattan, la distance de Chebyshev, la distance de Canberra et la distance de Bray Curtis. En effet, la méthode de distance euclidienne est la plus couramment utilisée pour la méthode KNN. L'avantage de KNN réside dans sa simplicité et sa facilité d'interprétation. Il peut être appliqué à

des ensembles de données linéaires et non linéaires. Cependant, cette méthode présente des limites, car elle nécessite de stocker toutes les données d'entraînement en mémoire pour effectuer les estimations. Pour de grands ensembles de données, cela peut entraîner des temps de calcul considérablement plus longs. De plus, le choix de la valeur de K n'est pas évident et nécessite souvent l'expérimentation de plusieurs combinaisons pour obtenir des résultats satisfaisants.

Il est recommandé de normaliser les données d'entrée et les nouvelles observations lors de l'utilisation de KNN. Cette normalisation est importante car la méthode KNN repose sur le calcul des distances entre les données d'entrée de la phase d'apprentissage et les observations pour effectuer des estimations [56]. Si les données d'entrée ne sont pas normalisées, les entrées ayant des valeurs plus élevées auront un impact plus important sur le calcul de la distance, ce qui pourrait entraîner des résultats d'estimation incorrects.

2.6.1.2 Support Vector Regression (SVR)

La régression à vecteurs de support, appelée en anglais *Support Vector Regression* (SVR), est une méthode d'apprentissage statistique supervisé utilisée pour les problèmes de régressions. Pour les problèmes de classification, nous pouvons utiliser l'algorithme analogue aux machines à vecteurs de support, appelé en anglais *Support Vector Machine*. Dans la Figure 2.16 ci-dessous, considérons ces deux lignes noires comme la limite de décision et la ligne rouge comme l'hyperplan. La distance entre ces deux lignes rouge et noir est notée ζ , qui est un paramètre choisi, tandis que les variables ζ' et ζ indiquent les erreurs entre les deux limites de décision et les données mesurées [57].




Figure 2.16. Exemple d'une fonction hyperplan qui maximiser le nombre de données de sortie mesurées à l'intérieur de la limite de décision.

Le but de cette méthode est de trouver la fonction de l'hyperplan, qui peut être une fonction ou non linéaire, maximisant le nombre de données mesurées à l'intérieur de la limite de décision [57].

Par conséquent, pour obtenir le meilleur modèle SVR, il faut que l'écart entre les données mesurées qui se situent à l'intérieur des limites de décision et l'hyperplan, soit minimisée et reste inférieure à une la valeur prédéfinie ζ . Les études [58, 59] présentent plus en détail la procédure mathématique de la méthode SVR. Il existe un paramètre dans la méthode SVR noté C [58], qui est une constante strictement positive. Il s'agit d'un paramètre régularisable qui détermine la tolérance aux écarts entre la fonction du noyau et les données de sortie mesurées.

Nous pouvons également utiliser la fonction noyau, qui permet de transformer l'ensemble de données mesurées non linéaires de l'espace d'entrée de faible dimension dans un espace de caractéristiques de haute dimension, afin de les séparer linéairement, comme montrée dans la Figure 2.17.

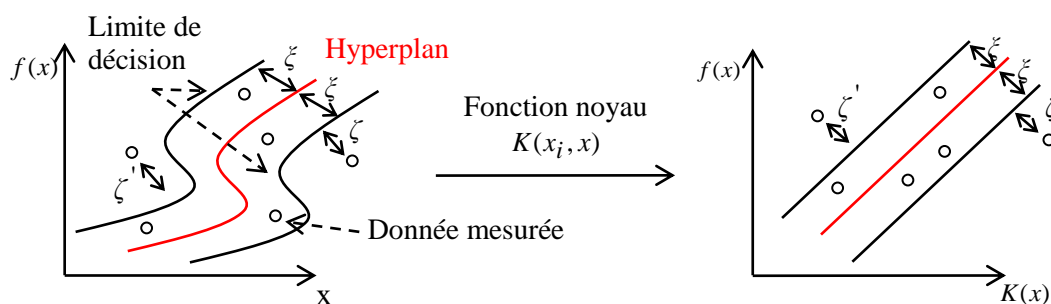


Figure 2.17. Transformation des données mesurées non linéaires de l'espace d'entrée de faible dimension dans un espace de caractéristiques linéaire de haute dimension.

La fonction noyau la plus populaire est la fonction noyau à base radiale, appelée en anglais *Radial Basis Function* (RBF). L'hyperparamètre gamma γ est un paramètre ajusté pendant la phase d'entraînement. Il agit comme une régularisation pour éviter le *overfitting* et contrôle la propagation de la fonction dans l'espace de dimension supérieure [58]. Pour les deux variables d'entrée x_i et x_j , le noyau RBF, noté K évaluant leur non-linéarité, est décrit dans l'équation suivante :

$$K = \exp(-\gamma(x_i - x_j)^2) \quad (2.13)$$

Tout comme pour la méthode de KNN, il est recommandé de normaliser les données d'entrée afin d'éviter que les entrées ayant des valeurs plus grandes ne dominent celles ayant des valeurs plus petites [60]. Étant donné que la fonction de noyau ou l'hyperplan dépend généralement des produits scalaires, les entrées de grande valeur peuvent dominer et entraîner de mauvaises estimations.

2.6.1.3 Least Squares (LS)

La méthode des moindres carrés ordinaire, connue dans la littérature anglo-saxonne sous l'appellation *Least Squares* (LS), est très répandue dans diverses applications industrielles pour résoudre des problèmes d'estimation paramétrique. En effet, cette méthode permet d'obtenir une estimation optimale en se basant sur la connaissance de plusieurs données expérimentales. L'idée de base de la méthode LS repose sur la minimisation d'un critère quadratique entre les grandeurs mesurées et des grandeurs estimées, qui sont relatives au modèle mathématique choisi. Cette méthode consiste à minimiser un critère quadratique tout en ajoutant des pondérations (ou des poids) aux valeurs mesurées (ou observées). Si nous considérons un nuage de points de données (x_j, y_j) , nous cherchons à les ajuster par une expression mathématique linéaire comme suit :

$$y_i = ax_i + b + e_i, i = 1, \dots, n, \dots \quad (2.14)$$

où e_i est un bruit, a et b sont deux paramètres de l'équation linéaire que nous cherchons à estimer.

La Figure 2.18 présente un exemple de l'allure d'une droite de régression estimée avec la méthode LS.




Figure 2.18. L'allure d'une droite de régression estimée avec la méthode LS (ξ est l'erreur entre la variable estimée \hat{y}_i et la variable mesurée y_i).

Le principe de la méthode LS consiste à minimiser la somme des carrés des résidus (ξ dans la Figure 2.18) pour trouver les paramètres a et b du modèle linéaire :

$$J = \frac{\sum_{i=1}^n (y_i - (ax_i + b))^2}{n}, \quad (2.15)$$

L'étude [61] fournit plus de détails sur la procédure de recherche des paramètres a et b avec la méthode LS. Le vecteur estimé optimal $\hat{\theta}$ peut être défini par l'équation suivante :

$$\hat{\theta} = (\Phi^T \Phi)^{-1} \Phi^T Y. \quad (2.16)$$

$$\text{avec } \Phi = \begin{bmatrix} x_1 & \cdots & 1 \\ \vdots & \cdots & \vdots \\ x_n & \cdots & 1 \end{bmatrix}, Y = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} \text{ et } \hat{\theta} = \begin{bmatrix} a \\ b \end{bmatrix}. \quad (2.17)$$

La méthode LS peut être utilisée pour modéliser des relations non linéaires, mais il est nécessaire de connaître l'équation non linéaire qui relie les sorties aux entrées [62]. Il existe également la régression des moindres carrés partiels, appelée en anglais *partial least squares*, qui emprunte la démarche de LS avec PCA. Elle vise à identifier les variables d'entrée qui maximisent la corrélation avec la variable de sortie. Les variables d'entrée sélectionnées sont appelées variables latentes. Nous pouvons également situer l'algorithme d'estimation paramétrique en utilisant la méthode des moindres carrés pondérés, appelée en anglais *Weighted Least Squares* (WLS). La méthode WLS est une technique permettant de gérer l'hétéroscédasticité. Ce phénomène se manifeste lorsque la variance des erreurs dans un modèle de régression n'est pas constante, mais varie selon les valeurs des variables indépendantes. WLS remédie à ce problème en attribuant des poids différents à chaque observation en fonction de leur degré d'incertitude.

2.6.1.4 Random Forest (RF)

Leo Breiman [63] a introduit une méthode d'apprentissage automatique supervisée appelée forêt d'arbres décisionnels (ou forêts aléatoires), connue en anglais sous le nom de *Random Forest* (RF). Cette méthode est utilisée pour résoudre les problèmes de classification et de régression. La méthode RF est constituée de plusieurs arbres de décision. Chacun de ces arbres est constitué de trois éléments : les nœuds de décision (appelés "*decision nodes*" en anglais), les nœuds feuilles (appelés "*leaf nodes*" en anglais) et un nœud racine (appelé "*root node*" en anglais). Dans un arbre de décision, le nœud racine est le point de départ du processus de prise de décision qui représente un ensemble de données de variables

sélectionnées à partir des données d'apprentissage. Ensuite, l'ensemble de données est divisé aléatoirement en sous-ensemble de même taille appelés le sac (appelés "bag" en anglais), tandis que les échantillons non utilisés sont désignés comme des échantillons hors sac (appelés "out of bag" en anglais). Chaque arbre possède son propre sous-ensemble de données et divise ces données en branches, qui se subdivisent ensuite en d'autres branches. Cette séquence se poursuit jusqu'à ce qu'un nœud feuille soit atteint, où une décision dans le cas de la classification ou une estimation est faite pour cette branche spécifique. Pour les problèmes de régression, la valeur moyenne de toutes les sorties estimées issues des nœuds feuilles des différents arbres sera la sortie estimée finale.

La méthode RF utilise l'approche de l'agrégation de bootstrap, appelée en anglais "bagging". Cela signifie qu'au lieu de s'entraîner sur l'ensemble complet des observations, chaque arbre de décision est entraîné sur des sous-ensembles d'observations. Plusieurs arbres sont ainsi entraînés sur différents échantillons, puis leurs résultats sont agrégés. Cette méthode permet de réduire le surapprentissage et d'améliorer la précision de l'estimation.

La Figure 2.19 présente un diagramme illustrant un exemple d'une forêt d'arbres décisionnels composée de deux arbres, avec deux variables d'entrée X ($X[0]$, $X[1]$) et deux variables de sortie (y_1 , y_2). La taille des données est égale à 5.

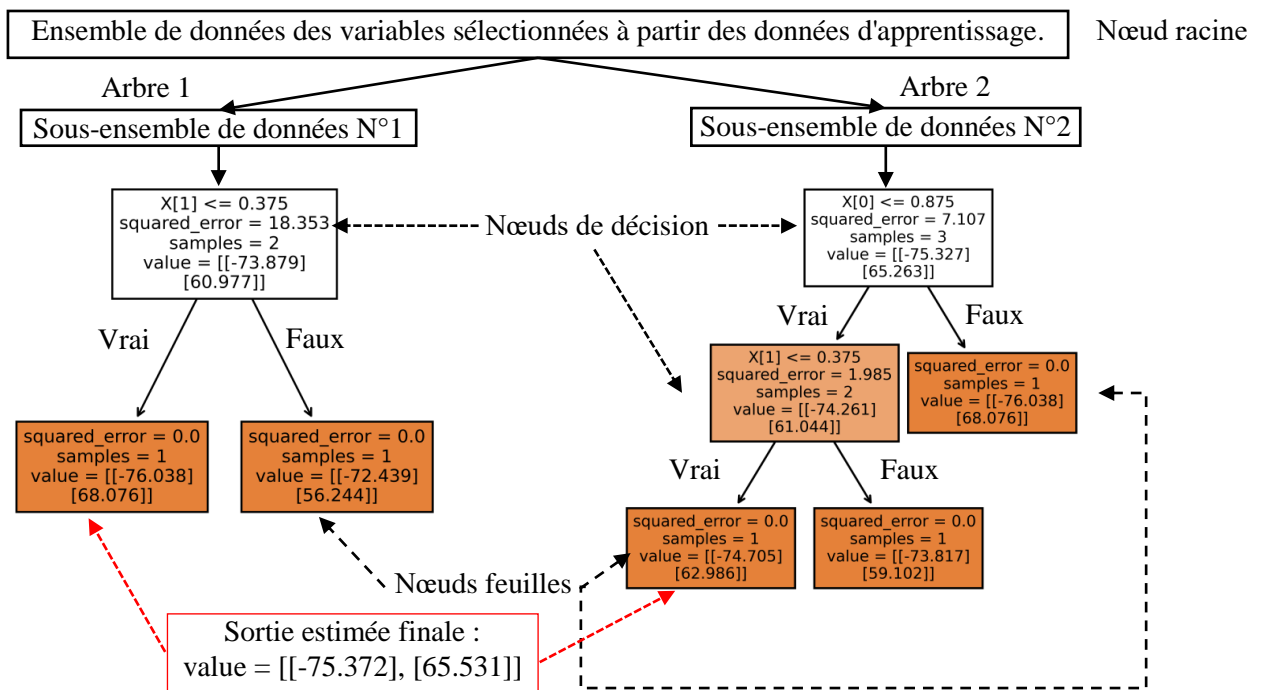


Figure 2.19. Exemple d'une forêt d'arbres décisionnels composée de deux arbres, avec deux variables d'entrée X et deux variables de sortie. La taille des données est égale à 5. La sortie estimée finale est la valeur moyenne des deux sorties estimées des nœuds feuilles des deux arbres. Les valeurs de *squared_error* correspondent à l'erreur quadratique moyenne entre les valeurs de Y estimées et mesurées dans chaque nœud.

Nous allons expliquer uniquement comment calculer les valeurs de sortie estimées dans l'arbre numéro 2 de la Figure 2.19, puisque les valeurs de sortie estimées dans les deux arbres se calculent de la même manière. Les cinq valeurs de ($X[0]$, $X[1]$) et de (y_1 , y_2) mesurées sont présentées dans le Tableau 2.5.

Tableau 2.5. Les cinq valeurs de ($X[0]$, $X[1]$) ainsi que celles de (y_1 , y_2) mesurées.

Indice	($X[0]$, $X[1]$)	(y_1 , y_2)
0	(1, 0,25)	(-70,707, 53,833)
1	(1, 0,50)	(-72,439, 56,244)

2	(0,75, 0,50)	(-73,817, 59,102)
3	(0,75, 0,25)	(-74,705, 62,986)
4	(1, 0,25)	(-76,038, 68,076)

Le Tableau 2.6 présente les indices des données des variables X et Y mesurées dans le sous-ensemble de données N°2 pour chaque nœud de décision du 2ème arbre, ainsi que les valeurs de Y estimées. Par exemple, dans le premier nœud de décision, pour estimer $[y_1, y_2]$, il faut calculer la moyenne des données mesurées de $[y_1, y_2]$ pour les indices suivants : 4, 3, 2, 4, 4 du Tableau 2.5

Tableau 2.6. Les indices des données des variables X et Y mesurées dans le sous-ensemble de données N°2 pour chaque nœud de décision du 2ème arbre, ainsi que les valeurs de $[y_1, y_2]$ estimées.

Numéro du noeud de décision du 2ème arbre	Les indices des données des variables X et Y mesurées dans le sous-ensemble de données N°2	$[y_1, y_2]$ estimées
1ère noeud de décision	4, 3, 2, 4, 4	$[(-76,038*3-74,705-73,817) / 5, (68,076*3+62,986+59,102) / 5] = [-75,327, 65,263]$
2ème noeud de décision (si $X[0] \leq 0.875$)	Si la condition est vraie : 3, 2	$[(-74,705-73,817) / 2, (59,102+62,986) / 2] = [-74,261, 61,044]$
	Si la condition est fausse : 4	$[-76,038, 68,076]$
3ème noeud de décision (si $X[1] \leq 0.375$)	Si la condition est vraie : 3	$[-74,705, 62,986]$
	Si la condition est fausse : 2	$[-73,817, 59,102]$

Les étapes de sélection des données des variables pendant la phase d'apprentissage dans le nœud racine sont les suivantes :

1. sélectionner une ou plusieurs variables d'entrée en fonction de leur capacité à séparer les données en groupes homogènes ;
2. calculer la mesure d'impureté. Pour les problèmes de régression, la mesure d'impureté peut être soit l'erreur quadratique moyenne soit l'erreur absolue moyenne, calculée entre chaque valeur de sortie estimée et mesurée. Cette mesure est utilisée pour évaluer la qualité d'estimation de chaque division. Pour les problèmes de classifications, nous pouvons utiliser l'impureté de Gini ou l'entropie ;
3. trouver la meilleure division des variables d'entrée ou les meilleurs sous-ensembles qui minimisent l'erreur d'estimation ;
4. répéter les étapes 1 à 3 pour chaque sous-ensemble de données jusqu'à ce que toutes les feuilles de l'arbre soient atteintes.

2.6.2 Méthodes de Deep Learning (DL)

Les réseaux de neurones semblent être un développement récent, alors qu'ils ont été développés avant l'invention des ordinateurs et ont traversé plusieurs époques. Le premier neurone artificiel a été introduit en 1943 par le neurophysiologiste Warren McCulloch et le logicien Walter Pitts [64]. Cependant, la technologie disponible à l'époque ne permettait pas de réaliser de grandes choses. Dans cette section, nous allons présenter les différentes méthodes de DL, qui reposent sur les réseaux de neurones.

2.6.2.1 Artificial Neural Network (ANN)

Un réseau de neurones artificiels, appelé en anglais *Artificial Neural Network* (ANN), est un modèle de traitement de données inspiré du fonctionnement du cerveau humain. Un modèle ANN est constituée de plusieurs perceptrons ou neurones qui sont interconnectés pour former des couches. Connue aussi sous le nom de réseau de neurones à propagation avant, appelé en anglais *feedforward neural network*. Son nom

le plus courant est le perceptron multicouche, également appelé en anglais Multilayer Perceptron. Le perceptron a été inventé en 1957 par Frank Rosenblatt [65].

Un modèle ANN se compose principalement de trois couches : une couche d'entrée, des couches cachées et une couche de sortie. La couche d'entrée correspond au nombre de variables d'entrée, la ou les couches cachées traitent les données entrées, et la couche de sortie produit un résultat prédit. Un modèle est le premier à avoir été inventé et constitue le type le plus simple de réseau de neurones artificiels. Dans ce réseau, l'information se propage dans une seule direction, vers l'avant, à partir des nœuds d'entrée, en passant par les couches cachées et se déplace vers les nœuds de sortie. En effet, un ANN est principalement utilisé pour résoudre des problèmes liés aux données tabulaires (comme dans notre étude).

La Figure 2.20 présente l'architecture d'un modèle ANN.

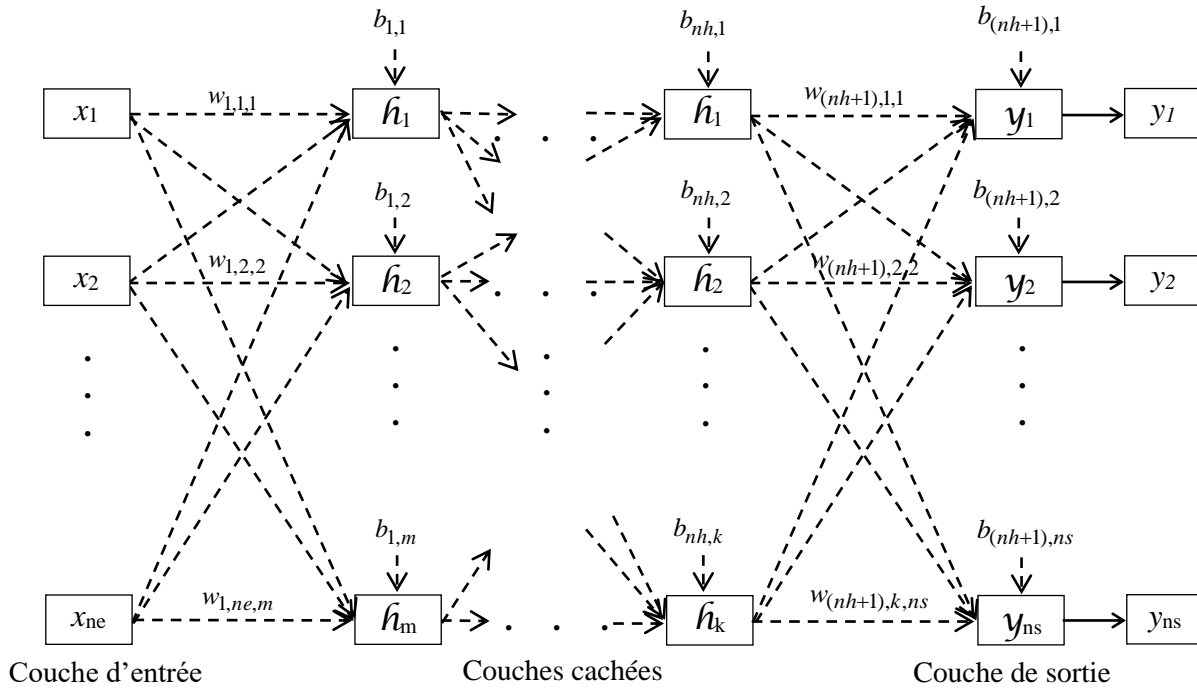


Figure 2.20. Architecture d'un modèle ANN.

Dans la Figure 2.20, $X = [x_1, \dots, x_{ne}]$ représente le vecteur d'entrée, $Y = [y_1, \dots, y_{ns}]$ représente le vecteur de sortie. Les variables ne , ns , m , k et nh représentent respectivement le nombre de variables d'entrée, le nombre de variables de sortie à estimer, le nombre de neurones dans la première couche cachée, le nombre de neurones dans la dernière couche cachée et le nombre totale de couches cachées.

Dans la Figure 2.20, la sortie du neurone j dans la première et la dernière couche cachée est notée respectivement $\hat{h}_1(j)$ et $\hat{h}_{nh}(j)$ est :

$$\hat{h}_1(j) = \hat{h}_j \left(\sum_{i=1}^{ne} w_{1,i,j} x_i + b_{1,j} \right), j = 1, \dots, m, \quad (2.18)$$

et

$$\hat{h}_{nh}(j) = \hat{h}_j \left(\sum_{i=1}^{np} w_{nh,i,j} \hat{h}_{(nh-1)}^{(i)} + b_{nh,j} \right), j = 1, \dots, k. \quad (2.19)$$

avec $w_{1,i,j}$ et $w_{nh,i,j}$ sont les poids entre la couche cachée et la couche précédente, $b_{1,j}$ et $b_{nh,j}$ sont les biais du neurone j , \hat{h}_j est la fonction d'activation du neurone j dans la couche cachée et \hat{h}_{nh-1} est la sortie du neurone j dans la couche cachée de l'avant dernier.

L'équation de sortie estimée issue de la fonction d'activation de la couche de sortie est :

$$y_j = \mathcal{Y}_j \left(\sum_{i=1}^k w_{(nh+1),i,j} \hat{h}_{nh}(i) + b_{(nh+1),j} \right), j = 1, \dots, ns, \quad (2.20)$$

avec $w_{(nh+1),i,j}$ est le poids entre la dernière couche cachée et la couche de sortie, $b_{(nh+1),j}$ est le biais du neurone de sortie j et \mathcal{Y}_j est la fonction d'activation de la couche de sortie j .

Généralement, pour les problèmes de régression la fonction d'activation de la couche de sortie \mathcal{Y}_j est la fonction identité.

Afin d'améliorer la précision de l'estimation, le réseau de neurone est généralement accompagné de la méthode de la rétropropagation. Cette méthode permet d'ajuster et mettre à jour les poids des connexions réseau, les biais et les paramètres de la fonction d'activation afin de minimiser la fonction de perte, qui représente l'écart entre les sorties mesurées et les sorties estimées du réseau. Cette méthode est toujours accompagnée d'optimiseurs tels que *Stochastic Gradient Descent* (SGD), *Adaptive Moment* (Adam), Adamax etc. Ces optimiseurs cherchent à minimiser une fonction de perte. Pour notre étude, la fonction de perte utilisée pour résoudre le problème de régression est l'erreur quadratique.

2.6.2.1.1 Wavelet Neural Network (WNN)

La transformée en ondelettes est couramment utilisée en traitement de signal. Elle est connue pour offrir à la fois une localisation dans le domaine temporel et fréquentiel, et elle peut extraire les petits détails d'un signal.

La méthode ANN est une approche robuste basée sur le fonctionnement du cerveau humain pour reconnaître des données spécifiques parmi une grande quantité de données, par exemple. Cette méthode peut également gérer de nombreuses tâches simultanément. Le réseau de neurones à ondelettes, connu en anglais sous le nom de *Wavelet Neural Network* (WNN), fusionne la puissance de la transformée en ondelettes avec celle des réseaux de neurones.

En 1992, Q. Zhang et A. Benveniste [66] ont introduit la méthode WNN, en utilisant la fonction d'ondelette comme fonction d'activation plutôt que la fonction d'activation classique telle que tanh. Le modèle WNN utilise la méthode de rétropropagation pour mettre à jour les poids entre les couches, les biais et les paramètres de la fonction mère d'ondelette afin de rapprocher la sortie estimée à la sortie mesurée. Avec la méthode WNN, l'équation de sortie $\hat{h}(j)$ du neurone j de la couche cachée de la Figure 2.20 s'écrit comme suit [67] :

$$\hat{h}(j) = \hat{h}_j \left(\frac{\sum_{i=1}^{ne} w_{ij} x_i - b_j}{a_j} \right), j = 1, \dots, m, \quad (2.21)$$

où m est le nombre de neurones dans une couche cachée, \hat{h}_j est la fonction mère d'ondelette; w_{ij} est le poids reliant deux couches successives, b_j et a_j sont respectivement les paramètres de décalage et d'échelle pour \hat{h}_j .

G. Wang et al. [67] ont proposé plusieurs fonctions mères d'ondelettes pour mettre en œuvre le modèle WNN, comme l'ondelette Morlet (connue en anglais sous le nom *Morlet wavelet function*), qui a été utilisée dans les références [10, 22] pour estimer les composantes de la GRF dont l'équation est :

$$\hat{h}(x) = \cos(1.75x) \exp\left(-\frac{x^2}{2}\right) \quad (2.22)$$

2.6.2.2 Recurrent Neural Network (RNN)

La méthode ANN suppose que les données sont indépendantes, ce qui signifie que chaque entrée est traitée de manière isolée, sans tenir compte des entrées précédentes ou suivantes. Par conséquent, l'état interne des données précédentes s'efface et ne peut pas être utilisé pour le traitement des données suivantes [68]. Pour les données séquentielles, cette approche n'est pas performante car les données sont dépendantes. Le réseau de neurones récurrent, connus sous le nom de *Recurrent Neural Network* (RNN) en anglais, sont adaptés pour résoudre ce problème avec des données séquentielles telles que les séries chronologiques, le texte, le traitement de la parole, l'audio et le traitement vidéo. Autrement dit, ils sont utilisés pour des données d'entrée de taille variable, telles que les textes.

La méthode RNN se distingue des méthodes ANN en ce qu'elle possède un état caché souvent noté h , appelé en anglais *hidden state*. Cet état caché représente une mémoire, ce qui permet aux RNN de stocker les dépendances temporelles dans les données séquentielles. Son calcul est basé sur utilisant de l'entrée courante et de la variable d'état caché de l'étape précédente [68]. L'étude [68] détaille l'algorithme RNN.

Le problème avec les méthodes RNN est qu'elles doivent remonter très loin dans le temps pour récupérer des informations antérieures (elles doivent être capables d'apprendre les dépendances temporelles), mais cela entraîne une propagation longue. Lorsque la séquence à traiter est trop longue, la rétropropagation du gradient d'erreur peut soit devenir trop grande et entraîner une explosion, soit au contraire devenir trop petite et disparaître, ce phénomène est appelé *vanishing gradient* en anglais. Autrement dit, les deux problèmes qui peuvent survenir avec les méthodes RNN en raison de la propagation longue sont l'explosion ou la disparition du gradient.

Pour résoudre les problèmes de disparition ou d'explosion de gradient, nous allons introduire deux architectures appelées en anglais *Long Short-Term Memory* (LSTM) et *Gated Recurrent Unit* (GRU).

2.6.2.2.1 Long Short-Term Memory (LSTM)

La méthode *Long Short-Term Memory* (LSTM) améliore les méthodes RNN grâce aux cellules de mémoire, notées c , qui permettent de stocker et récupérer des informations. Cela facilite l'apprentissage des relations temporelles sur de longues périodes [69]. La méthode LSTM met à jour son état de cellule de mémoire en fonction de l'activation des portes (notées "*gates*" en anglais), qui contrôlent les opérations réalisées sur cette cellule de mémoire. Ces opérations sont : l'écriture grâce à la porte d'entrée, la lecture grâce à la porte de sortie ou la réinitialisation grâce à la porte d'oubli [69]. Une cellule d'un réseau LSTM possède 3 portes et 2 états (état de la cellule de mémoire c et l'état caché h).

Nous pouvons constater que les réseaux LSTM possèdent deux états principaux : l'état caché et l'état de cellule de mémoire. L'état caché présente la sortie du réseau à un instant donné et contient les données qui ont été traitées par les portes d'entrée, de sortie et d'oubli. Ensuite, cet état caché est utilisé pour calculer la sortie du réseau à l'instant suivant. Quant à la mémoire de la cellule, elle permet de stocker les informations sur longues périodes, supprimer les informations inutiles et de prendre en compte les dépendances temporelles dans les données d'entrée. La mémoire de la cellule est mise à jour à chaque instant en fonction des informations d'entrée ainsi que des portes d'entrée, de sortie et d'oubli.

2.6.2.2.2 Gated Recurrent Unit (GRU)

Une variante de l'architecture des LSTM s'appelle en anglais *Gated Recurrent Unit* (GRU), développée en 2014 par Cho et al. [70]. Le réseau GRU présente des avantages par rapport aux réseaux LSTM en termes de simplicité, de coût de calcul et de coût de mémoire, car il dispose de moins de paramètres. Le nombre de portes est égal à 2, à savoir la porte de réinitialisation (noté "*reset gate*" en anglais) et la porte de mise à jour (noté "*update gate*" en anglais). Quant aux nombres d'états, il est égal à 1 (l'état caché h).

En termes de performance, il est difficile de déterminer quelle méthode est la meilleure entre GRU et LSTM. Parfois, les résultats de précision peuvent être comparables, tandis que dans d'autres cas, l'une de ces deux méthodes se révèle supérieure [71]. Cela dépend du domaine d'application et de la taille des données [71].

2.6.2.2.3 Bidirectional Recurrent Neural Network (BRNN)

Les réseaux de neurones récurrents bidirectionnels, appelés en anglais *Bidirectional Recurrent Neural Network* (BRNN), ont été introduits en 1999 par Schuster et Paliwal [70]. L'architecture de la méthode BRNN contient deux couches cachées de directions opposées appelées "*backward*" (vers l'arrière) et "*forward*" (vers l'avant). Les sorties obtenues correspondent aux concaténations des sorties des deux directions, contenant simultanément des informations sur les états passés (vers l'arrière) et futurs (vers l'avant).

Les réseaux GRU et LSTM peuvent également avoir une architecture bidirectionnelle, notée *Bidirectional Gated Recurrent Unit* (BGRU) et BLSTM respectivement.

Les avantages d'un réseau neuronal récurrent bidirectionnel par rapport à un réseau neuronal récurrent classique sont les suivants :

1) prise en compte des données passées et futures : un réseau de neurones récurrents classique prend en considération uniquement les données du passé alors qu'un réseau bidirectionnel prend en compte à la fois les données du passé et du futur. Par conséquent, le réseau comprend la séquence d'entrée globale et la qualité de l'estimation s'améliore. Il est surtout utilisé dans des problèmes de reconnaissance vocale, la reconnaissance d'écriture manuscrite, la traduction automatique ou l'estimation de séquences temporelles ;

2) réduction de l'effet de dépendance temporelle : ce type de réseau permet de réduire l'effet de dépendance temporelle en tenant en compte à la fois les données du passé et du futur. En effet, cela permet au réseau de mieux gérer les séquences de données longues et de résoudre les problèmes de disparition de gradient.

Par contre, un réseau neuronal récurrent bidirectionnel présente un inconvénient, car il doit connaître la séquence complète des données avant de faire la prédiction. Par exemple, il est nécessaire que la personne cesse de parler afin de permettre la récupération de la séquence audio complète, ce qui est essentiel pour résoudre les problèmes de prédiction.

Dans certains cas, les réseaux neuronaux récurrents, qu'ils soient bidirectionnels ou non, sont accompagnés d'une ou plusieurs couches de ANN.

La Figure 2.21 présente une architecture comprenant deux couches BLSTM composées respectivement de N et N_1 cellules, avec une séquence d'entrée de taille $(p+1)$. X_t est un vecteur de n variables d'entrée à l'instant t et X_{t-p} est un vecteur de n variables d'entrée à l'instant $t-p$. Par exemple, pour estimer les sorties y_1, \dots, y_m à l'instant t , il faut utiliser les données d'entrée courantes X_t ainsi que des échantillons précédents (X_{t-1}, \dots, X_{t-p}).

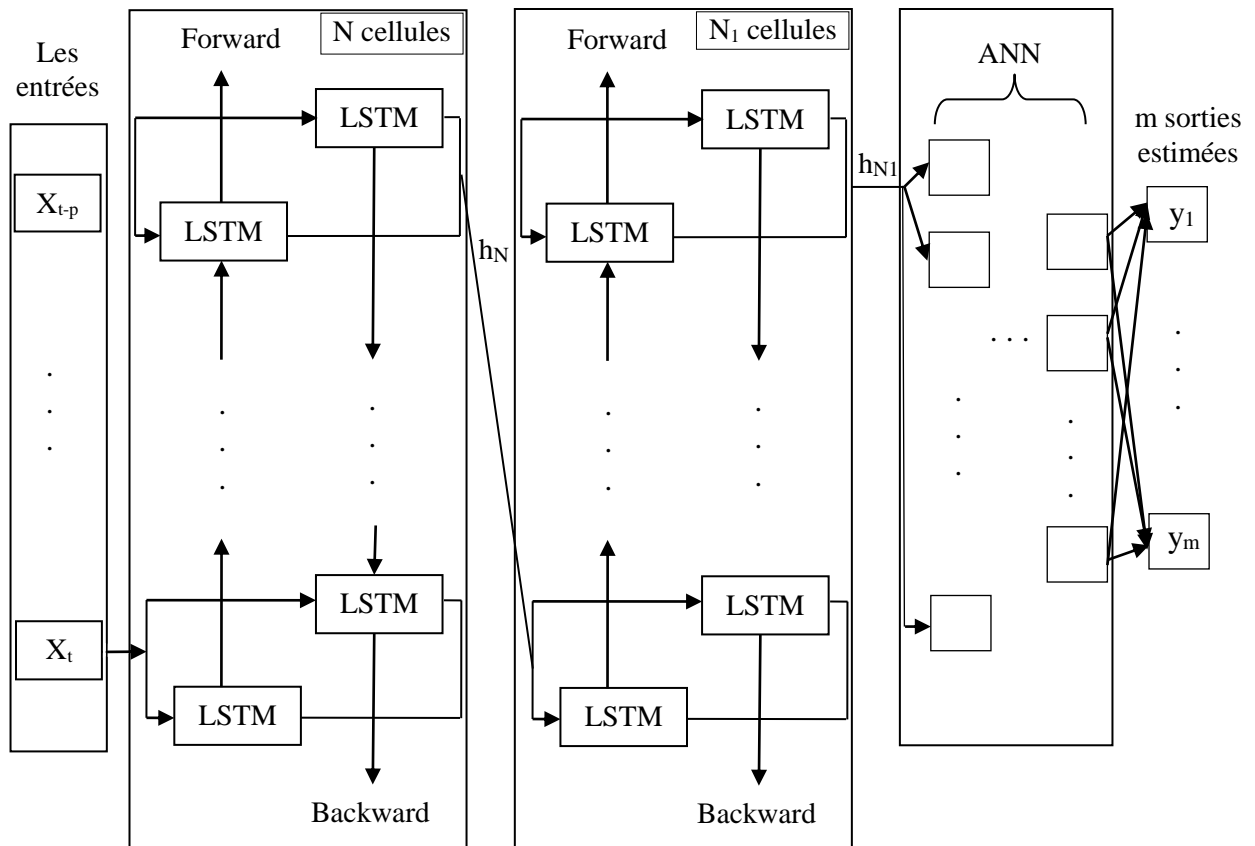


Figure 2.21. Architecture comprenant deux couches BLSTM de cellules N et N_1 respectivement, avec une séquence d'entrée de taille $(p+1)$. h_N et h_{N_1} sont les deux états cachés et les sorties des deux couches BLSTM.

2.6.2.3 Convolutional Neural Network (CNN)

Le réseau de neurones convolutif, appelé *Convolutional Neural Network* (CNN) en anglais, est spécialement conçu pour traiter des images. La méthode ANN ne peut pas traiter les images en raison du nombre énorme de pixels. Par exemple, le nombre de pixels pour une image en couleur de taille $224 \times 224 \times 3$ est égal à 150 millions de pixels. En utilisant la méthode ANN, il faudrait 150 millions de neurones, ce qui n'est pas réaliste. De plus, la méthode CNN peut être utilisée pour traiter des signaux unidimensionnels.

L'architecture des CNN est alors plus spécifique. Elle comporte deux blocs principaux [72]. Le premier bloc contient les opérations de filtrage par convolution. La particularité de ce bloc est qu'il fonctionne comme un extracteur de caractéristiques. Quant au second bloc, les valeurs du vecteur d'entrée sont transformées à l'aide des fonctions d'activation et des combinaisons linéaires afin de produire un nouveau vecteur en sortie. La méthode CNN comporte quatre types de couches : la couche de convolution, la couche de *pooling*, la couche de correction relu et la couche ANN [73]. Ces quatre types de couches sont expliqués ci-dessous :

- 1) la couche de convolution permet d'appliquer un filtre mathématique à une image en 2D ou à un signal en 1D (connue sous le nom de couche Conv1D). Cette couche permet d'extraire les zones intéressantes de l'image ou du signal. La couche Conv1D contient les paramètres suivants [73] : canaux de sortie (*out_channels*) ou nombre de filtres, taille du noyau (*kernel size*) ;
- 2) la couche de correction relu est appliquée après la couche de convolution. La fonction *relu* doit être appliquée à chaque pixel d'une image ou le signal 1D. Chaque valeur négative sera remplacée par un 0. La fonction *relu* surmonte le problème de *vanishing gradient*, qui permet aux modèles CNN d'apprendre plus rapidement et d'augmenter son performance [72] ;
- 3) la couche de *pooling* est souvent placée après la couche de convolution. L'opération de *pooling* permet de réduire la taille des images ou du signal 1D, tout en préservant leurs caractéristiques importantes. Ainsi, le signal ou l'image est découpé en cellules régulières, puis la valeur maximale

- avec l'opération MaxPool1d ou la moyenne avec l'opération AvgPool1d de chaque cellule est calculée. Le paramètre des opérations MaxPool1d et AvgPool1d est : taille du noyau ;
- 4) la couche ANN, qui est la dernière couche de la méthode CNN.

La Figure 2.22 présente un exemple de l'architecture de la méthode CNN pour un signal 1D, comprenant une seule couche de convolution et une couche de pooling.

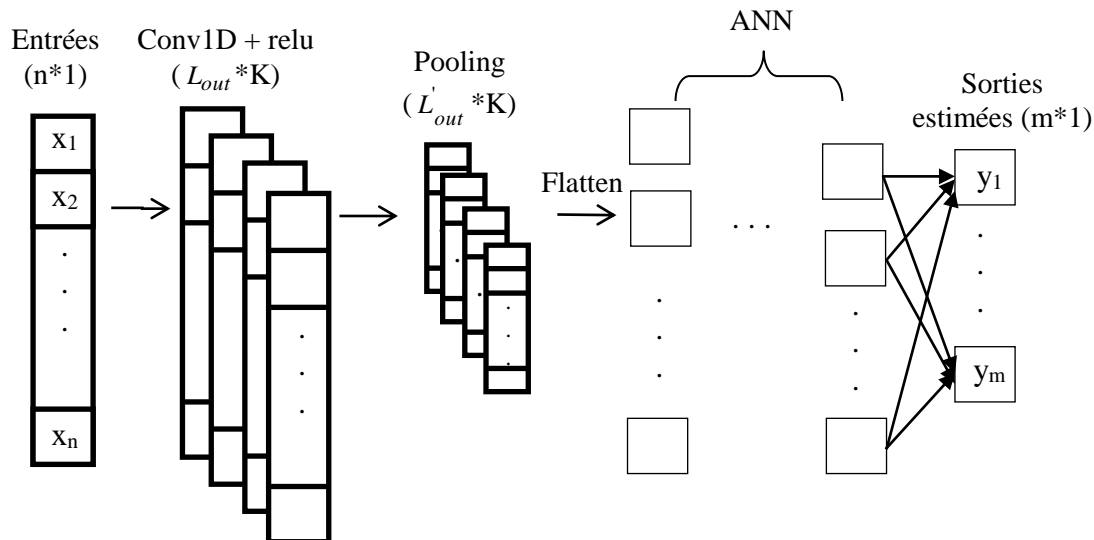


Figure 2.22. Exemple de l'architecture de la méthode CNN pour un signal 1D. L_{out} et L'_{out} sont respectivement les sorties de la couche Conv1D et de pooling et K est la taille du filtre de la couche Conv1D.

Dans la Figure 2.22, le mot "*Flatten*" signifie "aplatir". C'est une opération qui transforme une matrice multidimensionnelle en un vecteur unidimensionnel.

2.7 Diagramme de démarche de travail pour estimer les composantes de la GRF

La Figure 2.23 présente la démarche de travail pour estimer les composantes de la GRF.

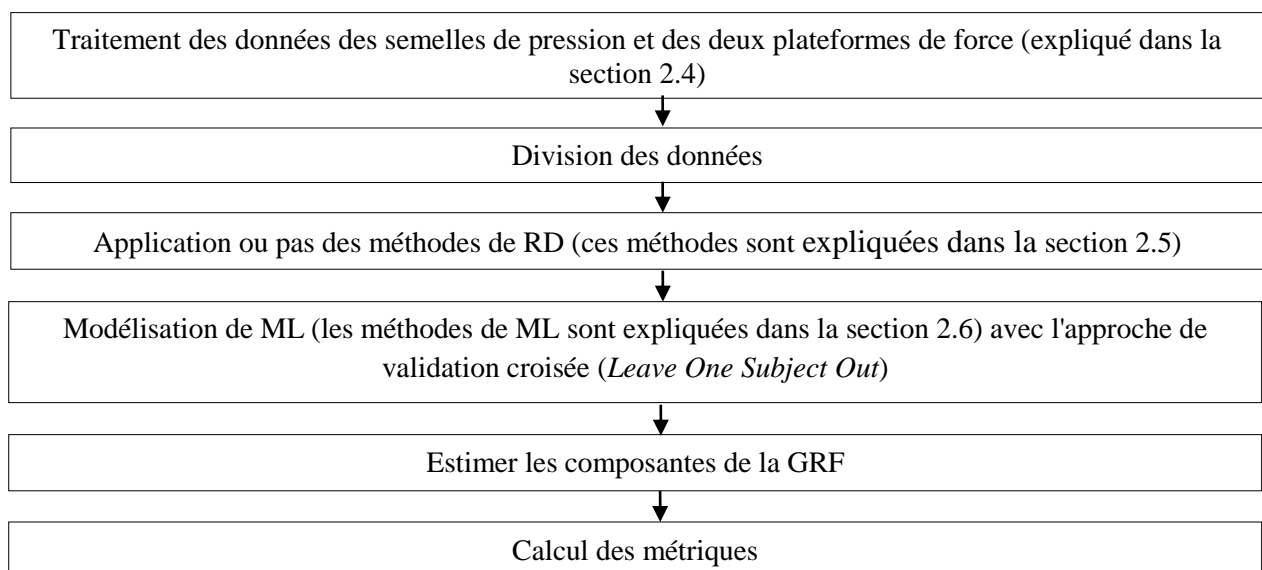


Figure 2.23. Diagramme de démarche de travail pour estimer les composantes de la GRF.

2.7.1 Division des données

Nous allons étudier deux stratégies d'apprentissage, à savoir : intrasujet, intersujet pour apprendre le modèle ML. Les définitions de l'intrasujet et l'intersujet sont :

1. intrasujet (intras) où le modèle est appris à partir des données des différents sujets et le test est effectué sur les données des mêmes sujets. Cependant, ces données de test n'étaient pas utilisées lors de l'apprentissage ;
2. intersujet (inters) où le modèle est appris par les données des différents sujets et le test est effectué sur les données d'un autre sujet.

Pour chaque activité de chaque sujet, 70 % des essais ont été utilisés pour la phase d'entraînement. Les 10 % des essais ont été réservés uniquement pour la phase de validation des méthodes neuronales telles que l'ANN, le CNN, le LSTM, etc. Les données des 20 % restants ont été utilisées pour évaluer la stratégie intras. Les données du 9^e sujet (semelle Moticon) et du 14^e sujet (semelle Fscan) ont été utilisées pour tester la stratégie inters afin d'évaluer la capacité de généralisation du modèle construit.

Pour prévenir le surapprentissage pour les méthodes neuronales, nous avons divisé le taux d'apprentissage par 10 si la fonction de perte de l'ensemble de validation ne diminuait pas après 10 époques consécutives alors que la fonction de perte d'entraînement diminue. L'entraînement s'arrête si la fonction de perte de validation continue à diminuer après 45 époques consécutives ou si le modèle atteint 1000 époques.

2.7.2 Modélisation de ML avec l'approche de validation croisée Leave One Subject Out (LOSO)

Nous allons chercher à trouver les meilleurs paramètres et l'architecture optimale de la méthode de ML pour l'estimation des composantes de la GRF.

Pour obtenir des résultats robustes, nous avons utilisé l'approche de validation croisée *Leave One Subject Out* (LOSO), c'est-à-dire que les stratégies intras et inters ont impliqué une rotation de l'ensemble de données d'entraînement, de validation et de test.

La Figure 2.24 explique le principe de l'approche de validation croisée LOSO. Cette approche consiste à entraîner le modèle sur les données des (n-1) sujets. Pour la stratégie inters, le test est effectué sur les échantillons du sujet qui a été exclu de l'entraînement (présentée en rouge dans la Figure 2.24). Pour la stratégie intras, le test est effectué sur les échantillons des (n-1) sujets, dont les échantillons n'ont pas été utilisés pour entraîner le modèle (présentée en noir dans la Figure 2.24).

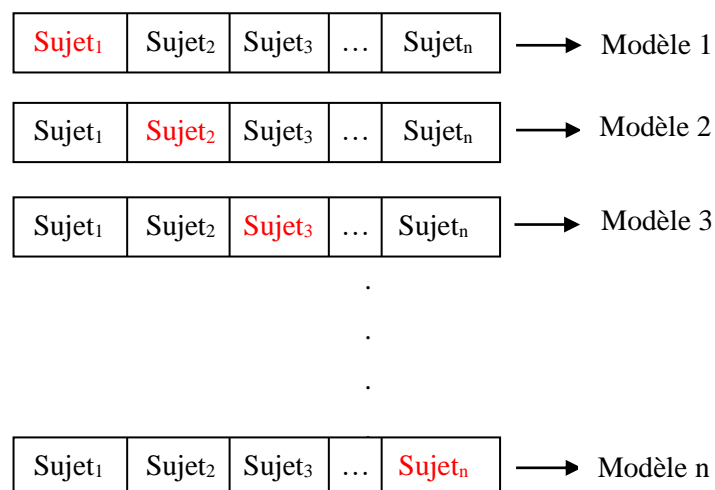


Figure 2.24. Principe de l'approche de validation croisée LOSO. Les échantillons du sujet exclus de l'entraînement sont marqués en rouge, tandis que ceux des sujets ayant participé à l'entraînement sont en noir. Par exemple, le modèle 1 a été entraîné avec les données des sujets numéro 2 (Sujet₂) jusqu'au sujet numéro n (Sujet_n). Le test inters sera réalisé sur le sujet numéro 1, qui a été exclu de l'entraînement.

Pour implémenter les modèles neuronaux, nous avons utilisé la bibliothèque Pytorch (v3.10.7) et le GPU NVIDIA RTX A4500. Les autres méthodes de SML (LS, RF, SVR et KNN) ont été implémentées en utilisant Python (v3.10.7) et un processeur Intel Xeon Gold 5218R @ 2,10 GHz.

2.7.3 Métriques

Nous avons calculé les valeurs de RMSE et le coefficient R pour évaluer la précision de la méthode de ML dans l'estimation des composantes de la GRF :

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (\text{N}) \quad (2.23)$$

et

$$R = \frac{\sum_{i=1}^n (\hat{y}_i - \mu(\hat{Y}))(y_i - \mu(Y))}{\sqrt{\sum_{i=1}^n (\hat{y}_i - \mu(\hat{Y}))^2 \sum_{i=1}^n (y_i - \mu(Y))^2}} \quad (2.24)$$

avec n est le nombre de points de données des composantes de la GRF, y_i est la composante de la GRF mesurée par la plateforme de force (F_x , F_y ou F_z) à l'instant i , \hat{y}_i est la composante de la GRF estimée à partir des données de PP de la semelle à l'instant i , $\mu(\hat{Y})$ est la moyenne des données estimées d'une composante de la GRF, $\hat{Y} = \hat{y}_1, \dots, \hat{y}_n$ est le vecteur des données estimées d'une composante de la GRF, $\mu(Y)$ est la moyenne des données mesurées d'une composante de la GRF et $Y = y_1, \dots, y_n$ est le vecteur des données mesurées d'une composante de la GRF.

Ces deux métriques sont les plus utilisées dans les études [2, 10, 22-26].

Les résultats d'estimation optimaux, qui représentent les meilleurs résultats, présentent la valeur de RMSE la plus faible tout en maintenant une valeur de R importante.

2.8 Conclusion

Dans ce chapitre, nous avons présenté le protocole, les technologies et les matériels utilisés pour estimer les composantes de la GRF à partir des deux semelles de pressions Moticon et Fscan pour six scénarios. Pour la semelle Fscan, 14 sujets de pointures 37 à 45 ont participé à l'expérience et pour la semelle Moticon, 9 sujets de pointure 42 ont participé. Les six activités réalisées par les sujets pour les deux semelles comprennent la marche lente et normale, la situation statique sans et avec une charge de 5 kg, le port d'une charge de 5 kg de gauche à droite et inversement, ainsi que le port d'une charge de 5 kg de bas en haut et inversement. Nous avons présenté le diagramme de démarche de travail qui illustre les étapes nécessaires pour récupérer et traiter les données des semelles de pression et des deux plateformes de force.

Nous avons également présenté les méthodes de ML pour estimer les composantes de la GRF, ainsi que les méthodes de RD afin de réduire la dimension de PP. Aussi, nous avons présenté le diagramme de la démarche de travail illustrant les étapes nécessaires pour estimer les composantes de la GRF à partir des données de pression de la semelle.

Chapitre 3 Impact des méthodes de normalisation sur la PCA sur la précision de l'estimation des composantes de la GRF

3.1 Introduction

La normalisation est la première étape de PCA, qui attribue une importance égale à toutes les variables d'entrée. Les études [2, 10, 22] ont utilisé la PCA-ML et une méthode de normalisation spécifique pour estimer les composantes de la GRF. Ces méthodes de normalisation peuvent avoir un impact sur la qualité de l'estimation des composantes de la GRF.

À notre connaissance, aucune étude n'a évalué les avantages de méthode de PCA en combinaison avec des approches de normalisation. Dans la présente étude, nous proposons donc d'évaluer l'impact de 12 méthodes de normalisation différentes issues de la littérature sur la précision de l'estimation des composantes de la GRF en utilisant la semelle Moticon pour les activités de marche. Les trois composantes seront estimées à l'aide d'ANN et de LS. Il s'agit de la première contribution. Nous évaluerons également les performances de la méthode SVR pour l'estimation des composantes de la GRF, en tant qu'autre méthode comparative qui, à notre connaissance, n'a jamais été testée auparavant dans la littérature. Il s'agit de la deuxième contribution. Cette étude a donné lieu à une publication [74].

La Figure 3.1 présente le diagramme de flux pour estimer les composantes de la GRF à partir des données de PP, où PP représente les données d'entrée, PP_{norm} représente les données d'entrée normalisées et W est la matrice de projection déterminée par PCA. La précision de l'estimation est calculée après la modélisation des méthodes ML. Dans une première étape, l'apprentissage est effectué en utilisant un ensemble de données d'entraînement (en rouge) pour la modélisation. Dans une deuxième étape, la performance du modèle est évaluée en calculant les métriques de performance en utilisant l'ensemble de données de test (en bleu).

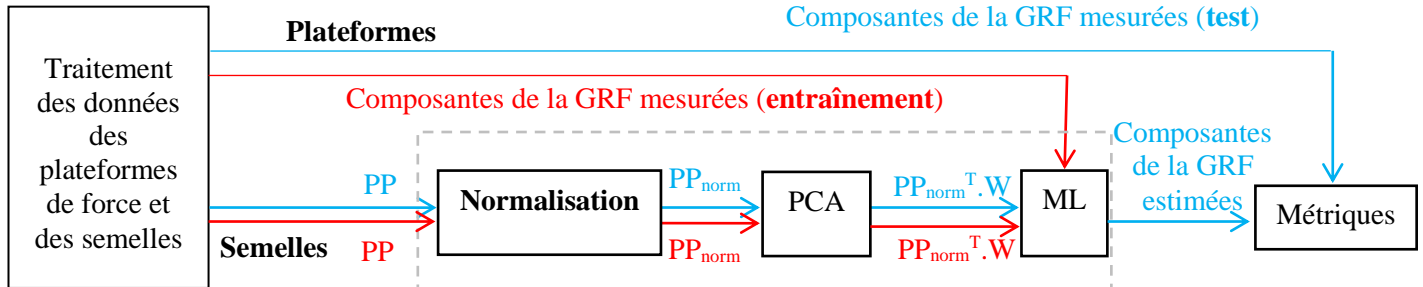


Figure 3.1. Le diagramme de flux pour estimer les composantes de la GRF à partir des données de PP. L'ensemble des données de PP d'entraînement est utilisé pour la modélisation des méthodes de ML en utilisant les données de la GRF mesurées correspondantes (en rouge). L'ensemble des données de PP de test est utilisé pour évaluer la performance d'estimation des composantes de la GRF en utilisant les données de la GRF mesurées correspondantes (en bleu). Le rectangle gris indique le pipeline classique de PCA-ML pré-normalisation. Le bloc de traitement des données est expliqué dans la section 2.4.

3.2 Les méthodes de normalisation

La normalisation garantit que toutes les variables ont la même importance et se situent sur la même échelle, la normalisation peut contribuer à accélérer la phase d'apprentissage. Dans notre étude, nous présentons et appliquons 12 méthodes de normalisation : Min-Max dans la plage [0, 1] et [-1, 1], Moyenne, Z-Score, Robust Scaler, Vector Standardization, Maximum Linear Standardization, Decimal Scaling, Médiane, Tanh (méthodes statistiques); Body Weight et Length of the Insole (méthodes anthropométriques/physiques).

Min-Max (MM) est l'une des méthodes de normalisation les plus courantes. Cette méthode est un bon choix pour le cas où les bornes (les valeurs minimales et maximales) des données sont connues [75]. Pour

un vecteur de données, $X = [x_1, x_2, \dots, x_n]$, les données normalisées à l'aide de la méthode Min-Max dans la plage $[0, 1]$ ($MM_{[0,1]}$) sont données par l'équation suivante :

$$x_{\text{norm}_i} = \frac{x_i - \min(X)}{\max(X) - \min(X)}, i = 1, \dots, n, \quad (3.1)$$

avec n est la taille des données.

Cependant, cette méthode peut ne pas être robuste car elle est très sensible aux valeurs aberrantes [75]. Cette méthode peut être généralisée pour ajuster les données dans l'intervalle $[a, b]$ [76] ($MM_{[a,b]}$), en utilisant l'équation ci-dessous :

$$x_{\text{norm}_i} = a + \frac{x_i - \min(X)}{\max(X) - \min(X)}(b - a). \quad (3.2)$$

La méthode de normalisation Moyenne [77] est une technique très connue, qui consiste à transformer la moyenne des données à zéro. Ceci est obtenu en appliquant l'équation ci-dessous :

$$x_{\text{norm}_i} = \frac{x_i - \mu(X)}{\max(X) - \min(X)}, \quad (3.3)$$

avec $\mu(X)$ représente la moyenne des données. Un inconvénient potentiel de cette méthode est sa sensibilité aux valeurs aberrantes.

Une autre méthode qui transforme la moyenne en zéro est appelée la technique *Z-Score* (ZS). Les données sont normalisées en utilisant la moyenne $\mu(X)$ et l'écart type $\sigma(X)$ des données, où l'écart type des données normalisées devient égal à un [75]. La formule pour normaliser les données à l'aide de la méthode ZS est donnée ci-dessous :

$$x_{\text{norm}_i} = \frac{x_i - \mu(X)}{\sigma(X)}. \quad (3.4)$$

La méthode ZS est plus robuste que la méthode moyenne via à vis les valeurs aberrantes.

La méthode *Robust Scaler* (RS) est une technique fiable utilisée pour les données contenant des valeurs aberrantes [75]. Une fois normalisées, les données présenteront une médiane de zéro :

$$x_{\text{norm}_i} = \frac{x_i - \text{median}(X)}{x_{75} - x_{25}}, \quad (3.5)$$

avec x_{75} est le troisième quartile et x_{25} est le premier quartile.

Anysza et Ibadova [78] définissent la méthode de standardisation vectorielle, connu en anglais sous le nom *Vector Standardization* (VS), qui peut être exprimée à l'aide de l'équation ci-dessous :

$$x_{\text{norm}_i} = \frac{x_i}{\sqrt{\sum_{i=1}^n x_i^2}}. \quad (3.6)$$

Ils ont proposé [77] également une autre technique de normalisation appelée *Maximum Linear Standardization* (MLS). Cette méthode consiste à diviser chaque échantillon par la valeur maximale de toutes les données pouvant être représentées à l'aide de l'équation suivante :

$$x_{\text{norm}_i} = \frac{x_i}{\max(X)}. \quad (3.7)$$

La méthode *Decimal Scaling* (DS) est particulièrement utilisée lorsque toutes les différentes données sont distribuées sur une échelle logarithmique. Par exemple, si nos données contiennent deux variables, la première est dans la plage $[0, 1]$ et l'autre dans la plage $[0, 1000]$, cette méthode peut être une option appropriée [75]. Les données normalisées peuvent être exprimées sous la forme de l'équation suivante :

$$x_{\text{norm}_i} = \frac{x_i}{10^d}, \quad (3.8)$$

avec d est le nombre de chiffres de la valeur absolue maximale des données [75], $d = \log_{10}(\max(\text{abs}(X)))$.

La normalisation médiane (Med) consiste à diviser chaque échantillon par la médiane de toutes les valeurs de données. Cette méthode n'est pas influencée par des variations extrêmes [79]. Les données normalisées sont données par l'équation suivante :

$$x_{\text{norm}_i} = \frac{x_i}{\text{median}(X)}. \quad (3.9)$$

La méthode de normalisation Tanh, proposée par Hampel et al. [76], peut être utilisée pour mettre à l'échelle les données dans l'intervalle [0, 1] en utilisant l'équation fournie ci-dessous :

$$x_{\text{norm}_i} = 0.5 \left(\tanh \left(0.01 \left(\frac{x_i - \mu(X)}{\sigma(X)} \right) \right) + 1 \right). \quad (3.10)$$

La méthode de normalisation du poids corporel, connu en anglais sous le nom *Body Weight* (BW), consiste à diviser chaque échantillon par le poids corporel (BW) du sujet [24]. Les données normalisées peuvent être exprimées à l'aide de l'équation suivante :

$$x_{\text{norm}_i} = \frac{x_i}{\text{BW}}. \quad (3.11)$$

La méthode de normalisation de la longueur de la semelle, connue en anglais sous le nom *Length of the Insole* (LI), proposée par Rouhani et al. [10], qui consiste à diviser les données de pression par la longueur de la semelle (LI). Les données normalisées peuvent être calculées à l'aide de l'équation ci-dessous :

$$x_{\text{norm}_i} = \frac{x_i}{\text{LI}}. \quad (3.12)$$

Les données d'entrée (PP) doivent être normalisées pour chaque capteur de pression lors de l'utilisation de PCA avant SVR, LS et ANN. Dans le cas de PCA-ANN, les sorties estimées de l'ANN sont des valeurs normalisées qui nécessitent un post-traitement de dénormalisation pour récupérer les grandeurs appropriées des composantes de la GRF. La méthode de dénormalisation appliquée à la sortie estimée est la procédure inverse de la méthode de normalisation appliquée à l'entrée. Les auteurs de [10] proposent une utilisation spécifique de la méthode LI en dénormalisant la sortie estimée avec la méthode BW.

3.3 Architectures et paramètres optimaux des modèles PCA-ANN et PCA-SVR

Nous voulons trouver les architectures et les paramètres optimaux des méthodes de PCA-ANN et PCA-SVR qui produisant la meilleure précision pour estimer les composantes de la GRF.

Nous avons utilisé la méthode PCA pour réduire la dimension des données d'entrée de 16 à k PCs, en supposant que k est la plus petite valeur pour laquelle la variance cumulative est supérieure à 98 %.

- **PCA-ANN**

Afin de trouver le meilleur modèle PCA-ANN produisant la plus haute précision pour estimer les composantes de la GRF, nous avons réalisé des tests avec différents paramètres et architectures en utilisant les données du pied droit dans l'ordre suivant :

- 1) initialisation : 1 couche d'entrée avec k neurones, 1 couche de sortie avec 3 neurones, 2 couches cachées avec (128, 256) neurones, batch size : 32, optimiseur : Adamax, taux d'apprentissage : 0.01, fonction d'activation : leaky relu, méthode de normalisation : Moyenne ;
- 2) modifier le nombre de couches cachées et leurs neurones respectifs, qui sont indiqués entre parenthèses : 1 couche cachée : (150) ; 2 couches cachées : (256, 128), (200, 400), (400, 200) ; 3 couches cachées : (600, 400, 200) ; 4 couches cachées : (800, 600, 400, 200) ;
- 3) modifier l'optimiseur : Adam, SGD avec des valeurs de momentum égales à 0.5 et 0.9, Adamax ;
- 4) modifier le taux d'apprentissage : 0.001, 0.01, 0.05 et 0.1 ;
- 5) modifier la valeur de batch size : 1, 16, 32, 64 et 128 ;
- 6) modifier la fonction d'activation : sigmoïde, relu, tanh, leaky relu et l'ondelette Morlet.

Les paramètres optimaux identifiés à partir de ces simulations pour la modélisation du ANN, qui produisent la plus haute précision pour l'estimation des composantes de la GRF pour le pied droit, sont les suivants : taux d'apprentissage : 0.01, batch size : 32 et optimiseur : Adamax. Le modèle ANN est composée de couches cachées, chacune composée de 400 et 200 neurones, respectivement. La fonction d'activation choisie pour les deux couches cachées est relu.

- **PCA-SVR**

Nous avons réalisé des tests avec des noyaux linéaires et RBF en faisant varier les paramètres (ξ , C et γ) pour le pied droit. Plus précisément, pour les noyaux linéaires et RBF, nous avons effectué ces tests suivants : $\xi = 15$ et 20 avec différentes valeurs de C , incluant 0.1, 1, 10, 50 and 100. De plus, le paramètre supplémentaire γ avec des valeurs de 0.1, 1, 10, 50 et 100 a été testé pour le noyau RBF.

À partir de ces simulations, il a été constaté que le modèle PCA-SVR avec le noyau RBF avec $\xi = 20$, $C = 50$ et $\gamma = 10$ présentait la précision la plus élevée dans l'estimation des composantes de la GRF pour le pied droit.

Par souci de simplification, nous supposons que les paramètres et l'architecture du modèle PCA-SVR et du PCA-ANN pour le pied gauche sont identiques à ceux du pied droit.

3.4. Résultats

Pour les 3 méthodes ML, nous avons utilisé l'approche de validation croisée LOSO. Cela implique la création d'un total de 108 modèles (9 modèles pour chacune des 12 méthodes de normalisation) pour chaque pied et chaque méthode ML.

- **Impact des méthodes de normalisation sur PCA pour ANN, LS et SVR pour l'estimation des composantes de la GRF**

Les 9 modèles issus des méthodes PCA-ANN, PCA-LS et PCA-SVR sont évalués au moyen des métriques RMSE et R pour les deux pieds et les deux stratégies. Les Tableaux I.1 à I.4 dans l'annexe I présentent les valeurs moyennes et les écarts-types de ces métriques. Ces valeurs sont rapportées pour toutes les méthodes de normalisation. Les meilleurs résultats d'estimation, en considérant les valeurs de RMSE et de R, sont en **gras**, pour les stratégies **intras** et **inters**. Le nombre optimal de PCs expliquant plus de 98 % de la variance cumulative des données de PP est également présenté dans ces tableaux.

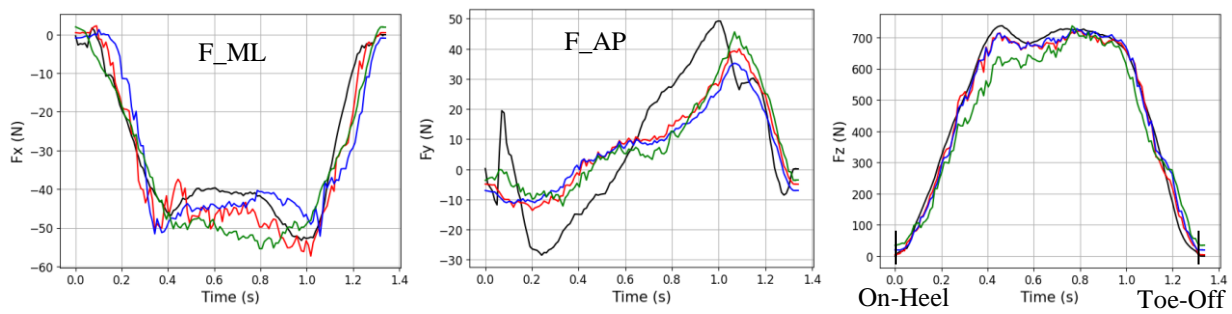
Nous avons réalisé une analyse afin de déterminer la meilleure méthode de ML et la méthode de normalisation correspondante pour estimer les composantes de la GRF pour les deux pieds, en utilisant les deux stratégies. Pour le pied gauche, en analysant les Tableaux I.1 et I.2, nous avons constaté que, pour la stratégie intras, la méthode PCA-SVR est la meilleure méthode pour estimer F_x , F_y et F_z en utilisant les méthodes de normalisation Moyenne, $MM_{[-1,1]}$ et Moyenne, respectivement. Pour inters stratégie, PCA-LS est la meilleure méthode pour estimer F_x et F_y en utilisant les méthodes de normalisation LI et Moyenne, respectivement. Pour l'estimation de la composante F_z , PCA-ANN est la meilleure méthode en utilisant la méthode Tanh. Pour le pied droit, en analysant les Tableaux I.3 et I.4, nous avons constaté que, pour la stratégie intras, PCA-ANN est la meilleure méthode pour estimer F_x , F_y et F_z en utilisant les méthodes de normalisation ZS, Tanh and Med and $MM_{[0,1]}$, respectivement. Pour inters stratégie, PCA-ANN est la meilleure méthode pour estimer F_x , F_y et F_z en utilisant les méthodes de normalisation VS and MLS, Tanh and VS, respectivement. Nous pouvons conclure que, pour estimer les composantes de la GRF, PCA-ANN est la meilleure méthode, suivie de PCA-SVR, puis de PCA-LS dans un ordre décroissant d'efficacité.

- **Un exemple d'illustration d'un pas pour la marche lente et normale**

La Figure 3.2 présente une illustration des composantes de la GRF estimées d'un seul pas de l'ensemble de données de test du pied droit selon les stratégies intras. La technique de normalisation qui produit l'estimation la plus précise pour chaque méthode de ML dans les Tableaux I.3 et I.4 est utilisée pour estimer chaque composante de la GRF (par exemple, pour le pied droit et en utilisant la méthode PCA-SVR, $MM_{[0,1]}$ est utilisé pour estimer F_z pour la stratégie intras).

Pied droit — Plateforme de force — PCA-ANN — PCA-LS — PCA-SVR

a) Un pas pour l'activité de marche lente pour la stratégie intras



b) Un pas pour l'activité de marche normale pour la stratégie intras




Figure 3.2. Composantes de la GRF estimées et mesurées pour un pas des activités de marche lente et marche normale du pied droit en utilisant la stratégie intras. Les composantes estimées sont représentées en rouge pour PCA-ANN, en bleu pour PCA-SVR et en vert pour PCA-LS. Les composantes mesurées par la plateforme de force sont représentées en noir.

Le Tableau 3.1 affiche les valeurs de RMSE et de R, correspondant à la Figure 3.2, entre les composantes estimées et mesurées de la GRF. Les valeurs de RMSE et de R sont calculées entre l'instant du contact initial au talon (appelé en anglais *on-heel*) et l'instant du décollage du pied (appelé en anglais *toe-off*).

Tableau 3.1. RMSE (R) entre les composantes de la GRF estimées (par les données de PP de la semelle) et mesurées (par la plateforme de force) pour la marche lente et normale selon les stratégies intras pour le pied droit, correspondant à la Figure 3.2. La méthode de normalisation la plus précise pour chaque méthode de ML dans les Tableaux I.3 et I.4 est utilisée pour estimer chaque composante de la GRF.

Activité	Méthode	F_x (N)	F_y (N)	F_z (N)
Marche lente	PCA-ANN	5,15 (0,975)	11,17 (0,709)	26,60 (0,996)
	PCA-SVR	7,40 (0,912)	12,43 (0,681)	29,03 (0,995)
	PCA-LS	6,92 (0,948)	12,63 (0,669)	68,49 (0,980)
Marche normale	PCA-ANN	6,88 (0,946)	24,84 (0,425)	48,95 (0,988)
	PCA-SVR	10,53 (0,941)	21,12 (0,577)	45,33 (0,989)
	PCA-LS	8,91 (0,911)	23,61 (0,484)	75,18 (0,973)

Selon le Tableau 3.1, les résultats pour l'estimation des composantes de la GRF par les stratégies intras lors de la marche lente sont plus précis que ceux de la marche normale.

Les Tableaux I.1 à I.4 et 3.1, indiquent que les résultats de l'estimation de F_x et F_y pour les trois méthodes PCA-ANN, PCA-SVR et PCA-LS, en utilisant la méthode de normalisation optimale, sont proche. Cependant, il y a une différence dans l'estimation de la composante F_z , où la méthode PCA-ANN offre les meilleurs résultats, sauf dans un cas. De plus, comme montre la Figure 3.2, dans les cas où

les valeurs de la GRF mesurées par la plateforme de force sont égales à 0, en particulier pour la composante F_z , PCA-LS et PCA-SVR peuvent fournir une estimation qui diffère de 0 en raison du biais constant, qui est défini par le paramètre b . Dans de tels cas, PCA-ANN est la meilleure option.

3.5 Discussion

Nous pouvons constater que les résultats optimaux sont obtenus avec PCA-ANN, suivis de PCA-SVR, puis de PCA-LS, avec respectivement 7, 3 et 2 configurations optimales parmi les 12 configurations. Les 12 configurations comprennent trois composantes, deux pieds et deux stratégies. PCA-LS et PCA-SVR recherchent toutes deux le meilleur hyperplan pour réaliser une régression. Cette dernière est linéaire pour LS et non linéaire pour SVR (choix du noyau RBF), ce qui explique les résultats plus précis obtenus avec PCA-SVR que PCA-LS. Même si PCA-SVR offre les meilleurs résultats pour certaines configurations spécifiques (3 parmi les 12 optimales), nous recommandons l'utilisation de PCA-ANN qui montre les meilleurs résultats dans la majorité des configurations (7 parmi les 12 optimales).

À partir des Tableaux I.1 à I.4 et 3.1, nous pouvons déduire que l'efficacité de chaque méthode de normalisation utilisant PCA varie en fonction des méthodes de ML (ANN, SVR et LS) et de la stratégie (intras ou inters) utilisée, pour estimer les composantes de la GRF des deux pieds. Contrairement aux suggestions d'études antérieures [35-37], nos résultats suggèrent que la normalisation ZS n'est pas toujours l'approche optimale pour estimer les composantes de la GRF lors de l'utilisation de PCA. Par exemple, l'utilisation de la méthode ZS pour estimer les composantes de la GRF pour les deux pieds avec PCA-SVR pour les deux stratégies n'est pas recommandée car la précision de l'estimation est faible (les valeurs de RMSE sont de 1,2 à 2,7 fois supérieures aux résultats optimaux).

De plus, les auteurs [2, 10] ont recommandé l'utilisation des méthodes BW et LI pour estimer les composantes de la GRF lors de l'utilisation de PCA. Cependant, pour les méthodes PCA-SVR et PCA-LS, dans le cas de l'estimation de F_z pour les deux pieds et les deux stratégies, ces deux méthodes ont montré des performances médiocres, avec des valeurs de RMSE allant de 1,1 à 4,1 fois supérieures aux résultats optimaux.

En conclusion, pour estimer les composantes de la GRF pour les deux stratégies et les deux pieds, nous recommandons d'utiliser la méthode VS pour PCA-ANN (valeurs de RMSE allant de 1 à 1,2 fois supérieures aux résultats optimaux) et PCA-LS (valeurs de RMSE allant de 1 à 1,4 fois supérieures aux résultats optimaux). Pour PCA-SVR, nous recommandons d'utiliser la méthode Moyenne (les valeurs de RMSE allant de 1 à 1,2 fois supérieures aux résultats optimaux). De plus, une même méthode de normalisation peut produire soit des précisions faibles, soit d'excellentes précisions, en fonction de la méthode de ML utilisée. Il est recommandé de ne pas définir une méthode de normalisation a priori indépendamment de la méthode ML. Par exemple, la méthode de normalisation BW peut être la moins performante pour PCA-SVR. Dans l'estimation de la composante F_z avec la stratégie intras pour du pied gauche, cette méthode produit des valeurs de RMSE (271,29 N) qui sont plus de trois fois supérieures aux résultats optimaux (59,35 N). Cependant, pour PCA-ANN, l'utilisation de la même méthode de normalisation BW pour estimer les composantes des deux stratégies pour les deux pieds donne de bons résultats, avec des valeurs de RMSE allant de 1,03 à 1,06 fois supérieures aux résultats optimaux.

Dans le cas où nous souhaitons comparer ou tester les performances des trois méthodes de ML en utilisant les mêmes données de PCs, nous recommandons d'utiliser les méthodes Moyenne et VS de manière consensuelle pour estimer les composantes de la GRF pour les deux stratégies et les deux pieds. Ces deux méthodes ont montré des résultats favorables pour les trois méthodes de ML par rapport aux résultats optimaux.

PCA peut réduire le temps de calcul en réduisant la dimension de l'entrée. Cependant, il nécessite 16 capteurs pour réduire la dimension d'entrée à 10-6 PC (Tableaux I.1 - I.4), en fonction de la méthode de normalisation. Cela suggère un choix prudent de la méthode de normalisation pour minimiser le nombre de PCs.

3.6 Conclusion

Nous avons mené une étude approfondie sur les méthodes de normalisation avec PCA-ML pour l'estimation des composantes de la GRF, explorant 12 méthodes de normalisation statistiques et physiques au lieu des 3 proposées par les auteurs dans [2, 10, 22]. De plus, nous avons étudié la méthode de

normalisation ZS, largement utilisée et recommandée avec PCA [35-37], dans d'autres domaines d'application. Cependant, la justification de choix de ces méthodes n'a pas été expliquée. Nous avons testé PCA-SVR, une méthode qui, à notre connaissance, n'avait jamais été examinée dans la littérature pour l'estimation de la GRF. La méthode PCA-SVR a atteint la deuxième précision la plus élevée pour l'estimation des composantes de la GRF, suivant PCA-ANN. Nous recommandons finalement l'utilisation de certaines méthodes de normalisation en fonction de la méthode de ML employée. Pour PCA-ANN et PCA-LS, la méthode de normalisation VS est recommandée. Pour PCA-SVR, la méthode Moyenne est recommandée.

Chapitre 4 Sélection des capteurs de pression de la semelle pour l'estimation des composantes de la GRF par la méthode ANN à travers l'étude de la PCA

4.1 Introduction

Dans le contexte d'un dispositif portable et économique permettant d'estimer les composantes de la GRF à partir de mesures de pression d'une semelle, la sélection des capteurs importants est abordée. En effet, pour obtenir un dispositif à faible coût, il est nécessaire de minimiser le coût de calcul, le temps et l'utilisation de la mémoire, tout en garantissant un niveau élevé de précision dans l'estimation des composantes de la GRF. Dans cette optique, il est souhaitable d'optimiser à la fois l'emplacement et le nombre de capteurs. C'est pourquoi un prétraitement factoriel est souvent utilisé. Dans le cas d'utilisation des semelles, la PCA est la méthode la plus couramment utilisée dans la littérature [2, 10, 22].

Cette procédure répond à trois questions importantes. La première est de déterminer le nombre de capteurs importants parmi le nombre total de capteurs. La deuxième consiste à déterminer les emplacements spatiaux optimaux des capteurs sur la surface de la semelle. La troisième concerne la capacité de la méthode proposée à identifier le nombre de capteurs et à évaluer leur importance sans utiliser un environnement de laboratoire coûteux avec une plateforme de force. Cette étude sera réalisée expérimentalement pour les deux semelles lors d'activités de marche en utilisant deux semelles : Moticon et Fscan. Cette étude a donné lieu à une publication [80].

Un point important de la procédure de sélection proposée est l'identification du nombre de capteurs et l'évaluation de leur pertinence sans avoir recours à un environnement de laboratoire à plateformes de force très coûteux. En outre, l'avantage de l'utilisation de PCA pour la sélection des capteurs de pression est que la procédure proposée ne nécessite pas l'utilisation d'une méthode de ML pour estimer les composantes de la GRF, ce qui prend beaucoup de temps.

Dans cette étude, en premier lieu, nous allons comparer la précision de l'estimation des composantes de la GRF entre les deux semelles de pression. L'estimation est réalisée en utilisant la méthode ANN combiné à la PCA. En deuxième lieu, identifier le nombre optimal et les emplacements des capteurs de pression par une procédure de classement des capteurs pour les deux semelles, en utilisant la PCA et les trois stratégies de sélection. Dans ce contexte, nous avons utilisé trois stratégies de sélection : **Backward** (appelée en amont en français), **Block** (appelée par blocs en français) et **Forward** (appelée vers l'avant en français). Nous avons validé la procédure de sélection des capteurs importants à l'aide de la modélisation ANN.

La Figure 4.1 présente le diagramme de flux pour la sélection des capteurs importants.

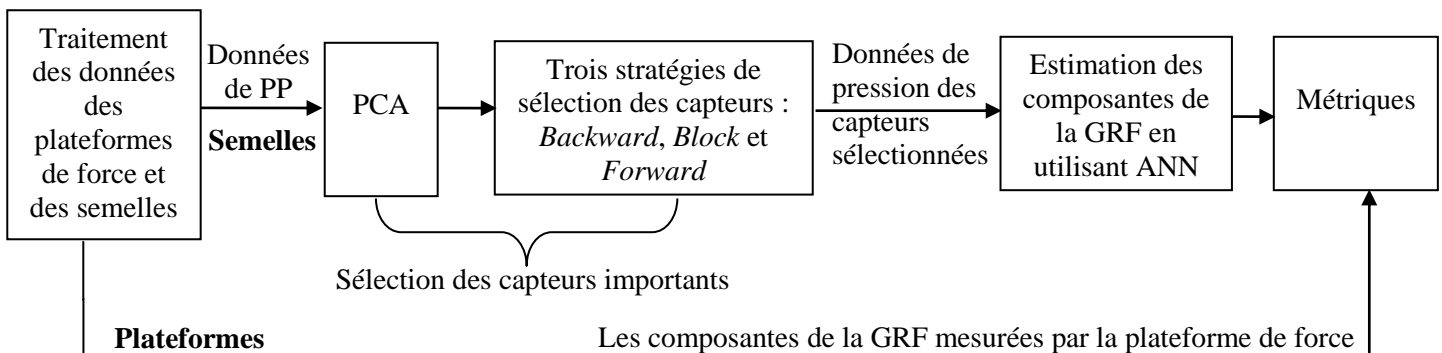


Figure 4.1. Diagramme de flux pour la sélection des capteurs importants. Le bloc de traitement des données est expliqué dans la section 2.4.

Nous avons utilisé la PCA pour réduire la dimension des données d'entrée provenant des N capteurs de pression (N égal à 16 pour la semelle Moticon et 64 pour la semelle Fscan) en k PCs, en supposant que k est la plus petite valeur pour laquelle la variance cumulative est supérieure à 98 % [2, 10].

4.2 Les trois stratégies pour sélectionner les capteurs importants après PCA pour l'estimation des composantes de la GRF

Dans le cadre de cette étude, nous nous concentrons sur la sélection des capteurs de pression les plus et les moins importants parmi l'ensemble des capteurs pour les deux pieds et les deux semelles, en utilisant trois stratégies : *Backward*, *Block* et *Forward*. Ces stratégies impliquent une procédure de sélection des capteurs en trois étapes. Tout d'abord, l'objectif est de classer les capteurs en fonction de leur importance pour les trois stratégies. Une fonction de perte appropriée (appelée en anglais *loss*) est définie pour ce classement. Deuxièmement, nous évaluons la puissance des PCs en retirant de manière itérative les capteurs les moins importants en fonction de leur classement. Une fonction de masse appropriée (appelée en anglais *mass*) permet d'effectuer cette évaluation. Troisièmement, nous déterminons combien de capteurs peuvent être retirés sans dégrader les informations transmises par l'ensemble des capteurs. En fonction des valeurs de la fonction de masse, nous sélectionnons la meilleure stratégie parmi les trois qui garantit la diminution la plus lente de la fonction de masse. Deux critères de sélection sont définis pour déterminer le nombre et l'emplacement spatial des capteurs les moins importants pouvant être retirés pour la stratégie sélectionnée.

1) Classer les capteurs en fonction de leur importance

La stratégie *Backward* est une approche itérative conçue pour éliminer le capteur de pression le moins important à chaque itération. Pour évaluer l'importance d'un capteur, nous utilisons une fonction de perte qui quantifie l'impact de l'élimination d'un capteur sur la puissance des PCs (totale des valeurs propres pondérées) conservées par la PCA. La fonction de perte compare le vecteur des valeurs propres $\lambda_j = \lambda_{j,1}, \dots, \lambda_{j,k_j}$ obtenu par la PCA en utilisant le nombre total de capteurs N_d (N_0 contient les numéros des 16 capteurs pour la semelle Moticon et 64 pour la semelle Fscan) avec le vecteur des valeurs propres $\tilde{\lambda}_j = \tilde{\lambda}_{j,1}, \dots, \tilde{\lambda}_{j,\tilde{k}_j}$ obtenu après avoir retiré chaque capteur parmi l'ensemble des capteurs N_d pour chaque itération j ($j=1, \dots, \text{len}(N_d)$) :

$$\text{loss}_j = \sum_{i=1}^{\tilde{k}_j} ((\lambda_{j,i} - \tilde{\lambda}_{j,i}) \cdot \sigma_{j,i}), \quad (4.1)$$

$$N_d = \begin{cases} N_0, & \text{si } d = 0 \\ N_{d-1} \setminus \{\text{le numéro du capteur ayant la plus petite valeur de } \text{loss}_j\}, & \\ \text{si } d = 1, \dots, N_{\text{deleted_sensors}} \end{cases} \quad (4.2)$$

où $\lambda_{j,i}$, $\tilde{\lambda}_{j,i}$ et $\sigma_{j,i}$ sont les éléments des vecteurs λ_j , $\tilde{\lambda}_j$ et σ_j , respectivement, $\sigma_j = \sigma_{j,1}, \dots, \sigma_{j,k_j}$ est le vecteur des variances obtenu par la PCA en utilisant le nombre total de capteurs N_d , k_j et \tilde{k}_j sont le nombre de PCs en utilisant le nombre total de capteurs N_d et après avoir retiré chaque capteur parmi N_d , respectivement et $N_{\text{deleted_sensors}}$ est le nombre de capteurs supprimés qui est égal à 8 pour Moticon et 48 pour Fscan. Nous avons utilisé le vecteur des variances σ_j dans l'équation 4.1 pour attribuer de l'importance aux valeurs propres les plus élevées.

Les valeurs de perte les plus élevées indiquent les capteurs les plus importants.

En résumé, la stratégie *Backward* élimine de manière itérative chaque capteur ayant la plus faible valeur de perte.

La stratégie *Block* est similaire à la stratégie *Backward*, visant à supprimer les capteurs de pression les moins importants. La différence est que cette stratégie n'est pas itérative (il n'y a pas l'itération d). Elle est

réalisée par une fonction de perte (équation 4.1) qui compare le vecteur des valeurs propres λ_j obtenu par la PCA en utilisant l'ensemble des capteurs N_0 et le vecteur des valeurs propres $\tilde{\lambda}_j$ obtenu après avoir retiré chaque capteur parmi N_0 pour chaque itération j ($j=1, \dots, \text{len}(N_0)$).

La stratégie **Forward** est une stratégie itérative inverse à la stratégie **Backward** qui vise à ajouter le capteur le plus important. Nous définissons un ensemble M_d , qui contient les capteurs les plus importants (avons initialisé M_0 avec les numéros de 8 capteurs pour Moticon et 16 pour Fscan, qui ont les valeurs de perte les plus élevées déterminées par la stratégie **Block**). La fonction de perte est calculée entre le vecteur des valeurs propres λ_j obtenu par la PCA en utilisant l'ensemble des capteurs restants ($N_0 \setminus \{M_d\}$) (N_0 contient les numéros des 16 capteurs pour la semelle Moticon et 64 pour la semelle Fscan) et le vecteur des valeurs propres $\tilde{\lambda}_j$ obtenu à partir des capteurs restants ($N_0 \setminus \{M_d\}$) après avoir retiré chaque capteur pour chaque itération j ($j = 1, \dots, \text{len}(N_0 \setminus \{M_d\})$). Selon les valeurs de perte, le numéro de capteur le plus important sera ajouté à l'ensemble M_d . L'ensemble M_d est exprimé comme suit :

$$M_d = \begin{cases} M_0, & \text{si } d = 0 \\ M_{d-1} \cup \{ \text{le numéro du capteur ayant la plus forte valeur de } \text{loss}_j \}, & \\ \text{si } d = 1, \dots, N_{\text{deleted_sensors}} \end{cases} \quad (4.3)$$

2) Évaluation de la fonction de masse

L'objectif est d'évaluer la masse d'information résultante à chaque fois qu'un capteur est retiré (le capteur avec la plus petite valeur de perte dans les stratégies **Backward** et **Block**) ou ajouté (le capteur avec la plus grande valeur de perte dans la stratégie **Forward**). La fonction de masse nécessite le classement des capteurs obtenu par la fonction de perte. Cette fonction évalue la masse d'information, définie comme la puissance des PCs (total des valeurs propres pondérées), ceci chaque fois qu'un capteur est supprimé (le capteur ayant la plus faible valeur de perte dans les stratégies **Backward** et **Block**) ou ajouté (le capteur ayant la plus grande valeur de perte dans la stratégie **Forward**). À chaque itération d , nous calculons le vecteur des valeurs propres $\lambda_d^* = \lambda_{d,1}^*, \dots, \lambda_{d,k_d}^*$ après avoir retiré de N_d (stratégie **Backward**) et de N_0 (stratégie **Block**) ou ajouté à M_d (stratégie **Forward**) d capteur(s), à partir duquel nous évaluons la fonction de masse exprimée comme suit :

$$\text{mass}_d = \sum_{i=1}^{k_d^*} (\lambda_{d,i}^* \cdot \sigma_{0,i}) \quad (4.4)$$

où $\lambda_{d,i}^*$ et $\sigma_{0,i}$ sont les éléments des vecteurs λ_d^* et σ_0 , respectivement, $\sigma_0 = \sigma_{0,1}, \dots, \sigma_{0,k_0}$ est le vecteur des variances obtenu par la PCA en utilisant le nombre total de capteurs N_0 , k_0 est le nombre de PCs en utilisant N_0 et k_d^* est le nombre de PCs calculé après avoir retiré d capteur(s) (stratégies **Backward** et **Block**) ou ajouté d capteur(s) (stratégie **Forward**).

Nous avons utilisé le vecteur des variances σ_0 dans l'équation 4.4 pour attribuer de l'importance aux valeurs propres les plus élevées.

La fonction de masse calcule la puissance des PCs en utilisant les capteurs classés par chaque stratégie.

3) Critères de sélection pour déterminer le nombre et l'emplacement spatial des capteurs importants

La détermination des capteurs importants se fait en trois étapes en utilisant deux critères.

Premièrement, nous sélectionnons parmi les trois stratégies celle qui garantit la décroissance la plus lente de la fonction de masse moyennée pour toutes les modèles (configurations) LOSO.

Deuxièmement, nous supprimons les capteurs les moins importants, ceux qui dépassant 90 % de la valeur maximale de la fonction de masse moyennée (la valeur maximale est la masse moyennée calculée en utilisant tous les capteurs). Les capteurs supprimés sont identifiés spatialement dans la semelle par leur numéro. Ceci constitue le premier critère de sélection.

Troisièmement, nous calculons la fréquence de suppression pour chaque capteur parmi tous les modèles LOSO. Nous sélectionnons les capteurs supprimés dont les nombres d'occurrence sont supérieurs ou égaux à (nombre total de modèles LOSO - 1). Dans notre étude, pour la semelle Moticon, nous sélectionnons les capteurs dont les occurrences sont supérieures ou égales à 8 et pour la semelle Fscan, supérieures ou égales à 13. Ceci constitue le deuxième critère de sélection.

4.2.1 Exemple de la procédure de sélection des capteurs pour le pied droit avec la semelle Moticon pour les 3 stratégies

Pour les 3 stratégies, nous allons calculer les valeurs de perte (loss) et de masse (mass), d'un seul modèle parmi les 9 LOSO modèles pour le pied droit avec la semelle Moticon. L'ensemble N_0 contient les numéros des 16 capteurs de Moticon telle que, $N_0 = \{1, 2, 3, \dots, 16\}$.

La stratégie **Backward** :

1) itération $d = 0$, calculer la valeur de masse à partir des données des 16 capteurs de N_0 : $mass_0 = 14,956$. Ensuite, calculer les valeurs de perte pour chaque capteur parmi l'ensemble N_0 selon l'équation 4.1 pour les itérations $j = 1, \dots, 16$. Les numéros de capteur (leurs valeurs de perte) sont les suivants selon l'ordre croissant : 14 (0,310), 16 (0,317), 9 (0,355), 7 (0,475), 13 (0,48), 12 (0,588), 10 (0,644), 15 (0,745), 8 (0,765), 11 (0,794), 5 (0,905), 2 (1,205), 4 (1,392), 6 (1,415), 1 (1,449), 3 (1,638) ;

2) itération $d = 1$, retirer le capteur numéro 14 du N_0 car il a la plus faible valeur de perte : $N_1 = N_0 \setminus \{14\}$ et calculer la valeur de masse à partir des données des capteurs de N_1 selon l'équation 4.4 : $mass_1 = 14,632$. Ensuite, calculer les valeurs de perte pour chaque capteur parmi N_1 pour les itérations $j = 1, \dots, 15$: 16(0,332), 9(0,406), 7(0,499), 13(0,552), 10(0,631), 12(0,633), 15(0,756), 8(0,811), 11(0,843), 5(0,994), 2(1,232), 6(1,467), 4(1,489), 1(1,522), 3(1,767) ;

.

.

.

3) itération $d = 7$, retirer le capteur numéro 11 du N_6 car il a la plus faible valeur de perte : $N_7 = N_6 \setminus \{11\}$ et calculer la valeur de masse à partir des données des capteurs de N_7 selon l'équation 4.4 : $mass_7 = 11,777$. Ensuite, calculer les valeurs de perte pour chaque capteur parmi N_7 capteurs pour les itérations $j = 1, \dots, 9$: 15 (0,399), 7 (0,609), 8 (0,806), 5 (1,377), 2 (1,592), 4 (1,976), 6 (1,994), 1 (1,998), 3 (2,340) ;

4) dernière itération $d = 8$, retirer le capteur numéro 15 du N_7 car il a la plus faible valeur de perte : $N_8 = N_7 \setminus \{15\}$ et calculer la valeur de masse à partir des données des capteurs de N_8 : $mass_8 = 11,283$.

Le vecteur de masse contenant les 9 valeurs de $mass_0, \dots, mass_8$ est [14,956; 14,632; 14,307; 13,935; 13,392; 12,822; 12,257; 11,777; 11,283].

La stratégie **Block** :

1) calculer les valeurs de perte pour chaque capteur parmi N_0 selon l'équation 4.1 : 14 (0,310), 16 (0,317), 9 (0,355), 7 (0,475), 13 (0,48), 12 (0,588), 10 (0,644), 15 (0,745), 8 (0,765), 11 (0,794), 5 (0,905), 2 (1,205), 4 (1,392), 6 (1,415), 1 (1,449), 3 (1,638). Ces valeurs correspondant à l'itération $d = 0$ pour la stratégie **Backward** ;

2) calculer les valeurs de masse selon l'équation 4.4 en retirant itérativement de 0 à $N_{deleted_sensors}$ capteurs les moins importants de l'ensemble N_0 ($N_{deleted_sensors}$ est égale à 8). Le vecteur de masse est [14,956; 14,645; 14,316; 13,952; 13,441; 12,893; 12,288; 11,735; 11,129].

La stratégie **Forward** :

1) itération $d = 0$, initialisation de M_0 avec les numéros des 8 capteurs les plus importants, déterminés par la stratégie **Block** : $M_0 = \{8, 11, 5, 2, 4, 6, 1, 3\}$ et calculer la valeur de masse à partir des données de ces 8 capteurs : $mass_0 = 11,129$. Ensuite, calculer les valeurs de perte pour chaque capteur parmi $N_0 \setminus M_0$ selon l'équation 4.4 pour les itérations $j = 1, \dots, 8$: 13 (0,535), 12 (0,546), 11 (0,642), 6 (0,765), 15 (0,878), 8 (1,133), 14 (1,635), 9 (1,914) ;

2) itération $d = 1$, ajouter le capteur numéro 9, qui est le plus important, à M_0 : $M_1 = M_0 \cup \{9\}$ et calculer la valeur de masse à partir des données des capteurs de M_1 : $mass_1 = 11,657$. Ensuite, calculer les valeurs de perte pour chaque capteur parmi $N_0 \setminus M_1$ pour les itérations $j = 1, \dots, 7$: 6 (0,961), 13 (1,231), 12 (1,366), 11 (1,397), 8 (1,606), 15 (1,745), 14 (2,51) ;

.

.

.

3) itération $d = 5$, ajouter le capteur numéro 14, qui est le plus important, à M_4 : $M_5 = M_4 \cup \{14\}$ et calculer la valeur de masse à partir des données des capteurs de M_5 : $mass_5 = 13,605$. Ensuite, calculer les valeurs de perte pour chaque capteur parmi $N_0 \setminus M_5$ pour les itérations $j = 1, \dots, 3$: 6 (1,528), 13 (1,571), 12 (1,575) ;

4) itération $d = 6$, ajouter le capteur numéro 12, qui est le plus important, à M_5 : $M_6 = M_5 \cup \{12\}$ et calculer la valeur de masse à partir des données des capteurs de M_6 : $mass_6 = 14,158$. L'ensemble $N_0 \setminus M_6$ contient deux capteurs, numérotés 6 et 13, avec des valeurs de perte de 1,528 et 1,571, respectivement. Par conséquent, nous ne pouvons pas calculer les valeurs de perte après PCA. Lorsque nous retirons un des deux capteurs, il est nécessaire de calculer la matrice de covariance dans la PCA qui doit avoir une dimension supérieure ou égale à 2 ;

5) itération $d = 7$, ajouter le capteur numéro 13, qui est le plus important, à M_6 : $M_7 = M_6 \cup \{13\}$ et calculer la valeur de masse à partir des données des capteurs de M_7 : $mass_7 = 14,505$;

6) dernière itération $d = 8$, ajouter le capteur numéro 6 à M_7 : $M_8 = M_7 \cup \{6\}$ ($M_8 = N_0$) et calculer la valeur de masse à partir des données des capteurs de M_8 : $mass_8 = 14,956$.

Le vecteur de masse est [11,129; 11,657; 12,301; 12,696; 13,008; 13,605; 14,158; 14,505; 14,956].

Nous allons expliquer les deux critères de sélection. Après avoir calculé les valeurs de masse et les valeurs de perte moyennée pour les 9 LOSO modèles du pied droit, comme expliqué dans le paragraphe ci-dessous, il faut suivre les étapes suivantes :

1) calculer les valeurs de masse moyennée pour les 9 LOSO modèles pour les 3 stratégies, telle que :

la masse moyennée pour la stratégie **Block** : [14,799; 14,480; 14,146; 13,795; 13,358; 12,799; 12,233; 11,626; 10,993] ;

la masse moyennée pour la stratégie **Backward** : [14,799; 14,479; 14,148; 13,805; 13,365; 12,836; 12,254; 11,697; 11,087] ;

la masse moyennée pour la stratégie **Forward** : [10,993; 11,545; 12,089; 12,639; 13,109; 13,675; 14,116; 14,469; 14,799].

Nous allons sélectionner parmi ces trois stratégies celle qui garantit la décroissance la plus lente de la fonction de masse moyennée pour toutes les LOSO modèles. Par conséquent, en regardant les valeurs de masse moyennée, nous choisissons la stratégie **Block** par rapport à la stratégie **Forward**. De plus, la

stratégie *Block* est plus simple que la stratégie *Backward* (les deux stratégies *Backward* et *Block* fournissent des valeurs de masse moyennée similaires). Le Tableau 4.1 présente les numéros des 8 capteurs les moins importants déterminés par la stratégie *Block* ;

2) multiplier la valeur maximale de la masse moyennée par 0,9 : $14,799 \times 0,9 = 13,319$ (la valeur maximale de la masse moyennée est calculée en utilisant tous les capteurs) ;

3) le critère de sélection numéro 1 : selon le vecteur de masse moyennée, il faut éliminer les n premiers capteurs les moins importants, ceux qui dépassent 90% de la valeur maximale de masse moyennée. Autrement dit, n est égal à 4 ;

4) le critère de sélection numéro 2 : chercher les numéros de ces 4 capteurs et calculer leur fréquence d'occurrence pour tous les 9 LOSO modèles. D'après le Tableau 4.1, les numéros de ces 4 capteurs les moins importants pour tous les 9 LOSO modèles (leurs fréquences d'occurrence) sont les suivants : 14 (9), 9 (9), 16 (8) et 7 (6). Dans la procédure de sélection, nous retirons uniquement les 3 capteurs dont la fréquence d'occurrence est supérieure ou égale à 8, à savoir : 14, 9 et 16.

Tableau 4.1. Les numéros des 8 capteurs les moins importants déterminés par la stratégie *Block* pour les 9 LOSO modèles, notés M_1, M_2, \dots, M_9 . Les 4 capteurs les moins importants selon le critère de sélection numéro 1 sont en **gras souligné**.

Modèle	M_1	M_2	M_3	M_4	M_5	M_6	M_7	M_8	M_9
Numéro du 1ère capteur le moins important	<u>14</u>	<u>16</u>	<u>14</u>	<u>14</u>	<u>14</u>	<u>14</u>	<u>14</u>	<u>14</u>	<u>9</u>
Numéro du 2ème capteur le moins important	<u>16</u>	<u>9</u>	<u>16</u>	<u>16</u>	<u>7</u>	<u>16</u>	<u>16</u>	<u>16</u>	<u>14</u>
Numéro du 3ème capteur le moins important	<u>9</u>	<u>14</u>	<u>9</u>	<u>9</u>	<u>16</u>	<u>9</u>	<u>9</u>	<u>9</u>	<u>7</u>
Numéro du 4ème capteur le moins important	<u>7</u>	<u>10</u>	<u>10</u>	<u>7</u>	<u>9</u>	<u>10</u>	<u>7</u>	<u>7</u>	<u>10</u>
Numéro du 5ème capteur le moins important	13	13	7	5	13	7	12	10	12
Numéro du 6ème capteur le moins important	12	12	13	10	10	13	10	12	13
Numéro du 7ème capteur le moins important	10	7	12	13	12	12	13	13	11
Numéro du 8ème capteur le moins important	15	15	11	12	15	11	15	11	8

4.3 Modélisation de PCA-ANN et validation de la modélisation ANN avec la sélection des capteurs les plus importants

Pour trouver les paramètres et architectures optimaux du PCA-ANN pour les deux semelles, nous avons varié les paramètres et les architectures pour le pied droit comme expliqué dans la sous-section 3.3. Le Tableau 4.2 présente les paramètres et l'architecture optimale du PCA-ANN pour les deux semelles pour le pied droit.

Tableau 4.2. Paramètres et architecture optimale de PCA-ANN pour les deux semelles.

Semelle	Paramètres	Architecture
Moticon	taux d'apprentissage = 0,01, fonction d'activation : relu batch size = 32, optimiseur : Adamax, méthode de normalisation de PP et des composantes de la GRF : Moyenne	1 couche d'entrée avec k neurones, 1 couche de sortie avec 3 neurones, 2 couches cachées, chacune composée de 400 et 200 neurones, respectivement
Fscan	taux d'apprentissage = 0,05, fonction d'activation : leaky relu, batch size = 32, optimiseur : SGD avec momentum = 0,9, méthode de normalisation de PP et des composantes de la GRF : Moyenne	

Dans un souci de simplification, nous avons considéré que le pied gauche possède les mêmes architectures et paramètres de PCA-ANN que le pied droit lors de l'utilisation de la semelle Moticon ou Fscan.

Afin de valider la performance de la procédure de sélection, nous avons utilisé d'une part les modèles PCA-ANN précédemment créés, dont les paramètres et architectures sont définis dans le Tableau 4.2 en utilisant les 16 capteurs et les 64 capteurs de chaque semelle. D'autre part, nous avons créé des modèles ANN en utilisant les mêmes paramètres et architectures que dans le Tableau 4.2, en limitant le nombre de capteurs d'entrée aux capteurs les plus importants. La comparaison est réalisée en utilisant l'ensemble de données de test et en évaluant la qualité des résultats d'estimation à l'aide des métriques. Pour obtenir des résultats robustes, les stratégies intras et inters incluent la rotation des ensembles de données d'entraînement et de test, ce qui signifie que nous avons créé 9 LOSO modèles (Moticon) et 14 modèles (Fscan) pour PCA-ANN et ANN pour les deux pieds (approche de validation croisée LOSO).

4.4 Résultats

Le Tableau 4.3 présente la moyenne et l'écart type des métriques des 9 LOSO modèles (Moticon) et 14 LOSO modèles (Fscan) issus des PCA-ANN et ANN en supprimant les capteurs les moins importants selon la stratégie *Block*. Ces métriques sont calculées pour l'ensemble de test. Les meilleurs résultats d'estimation sont mis en **gras** pour estimer les composantes de la GRF pour les stratégies **intras** et **inters**. De plus, ce tableau présente les valeurs minimales et maximales du nombre optimal de PCs expliquant plus de 98 % de la variance cumulative des données de PP.

- **Comparaison entre les semelles Fscan et Moticon en utilisant PCA-ANN**

Selon le Tableau 4.3, pour l'estimation de F_z et F_x par les stratégies intras et inters pour les deux pieds, l'utilisation des données de la semelle Moticon donne des résultats plus précis par rapport à la semelle Fscan (les résultats optimaux de F_z estimés par les données Fscan sont plus de deux fois supérieurs aux résultats optimaux estimés par les données Moticon). Pour l'estimation de F_y par les deux stratégies pour les deux pieds, l'utilisation des données de la semelle Fscan donne des résultats plus précis par rapport à la semelle Moticon, à l'exception du pied gauche pour la stratégie inters.

- **Sélection des capteurs importants en utilisant les trois stratégies**

Les Figures 4.2 et 4.3 présentent le nombre de capteurs supprimés en utilisant les semelles Moticon et Fscan pour les trois stratégies de sélection en fonction des valeurs de la masse moyenne pour tous les LOSO modèles, pour les deux pieds. De plus, le nombre de capteurs supprimés, ainsi que leurs numéros, dépassant 90 % de la valeur maximale de la masse moyennée pour tous les LOSO modèles et leurs fréquences d'occurrences correspondantes, sont indiqués en utilisant la stratégie de *Block*. Nous choisissons la stratégie *Block* pour la sélection des capteurs car elle garantit la diminution la plus lente de la fonction de masse moyennée pour tous les LOSO modèles par rapport à la stratégie *Forward* (Figures 4.2 et 4.3). De plus, la méthode de la stratégie *Block* est plus simple que la stratégie *Backward* (les deux stratégies *Backward* et *Block* fournissent des valeurs de masse moyennée similaires pour tous les LOSO modèles, pour les deux pieds et les deux semelles).

Les Figures 4.4 et 4.5 représentent la puissance des capteurs et identifient les capteurs les moins et les plus importants en fonction des valeurs de perte moyennée pour les LOSO modèles en utilisant la stratégie *Block*. Nous calculons la puissance des capteurs pour déterminer si une valeur élevée de puissance indique qu'il s'agit d'un capteur important pour l'estimation des composantes de la GRF. La formule de calcul de puissance pour chaque capteur de pression est :

$$Puissance = \frac{1}{N} \sum_{i=1}^N P_i^2 \quad (4.5)$$

avec N est le nombre d'échantillons et P est la valeur de pression du capteur.

Dans les Figures 4.4 et 4.5, les valeurs de perte moyennée les plus élevées indiquent les capteurs les plus importants. Les numéros des capteurs supprimés qui satisfont l'ensemble de la procédure de sélection sont reportés dans un rectangle gris. En analysant la perte moyenne totale pour les semelles Moticon et Fscan

présentées dans les Figures 4.4 et 4.5, il a été découvert que les capteurs de pression situés au niveau du pied arrière étaient les plus importants pour l'estimation des composantes de la GRF pour les deux pieds.

Comme le montrent les Figures 4.4 et 4.5, une valeur élevée de puissance d'un capteur ne le rend pas nécessairement très important pour l'estimation des composantes de la GRF. Par exemple, pour les deux pieds, les capteurs de pression numéro 4 de la semelle Moticon ou 51 de la semelle Fscan sont des capteurs cruciaux car ils présentent des valeurs de perte moyennée importantes, malgré des valeurs de puissance de pression plus faibles. En revanche, les capteurs de pression numéro 14 de Moticon ou 56 pour le pied droit et 48 pour le pied gauche de Fscan présentent des valeurs élevées de puissance de pression et des valeurs faibles de perte moyennée.

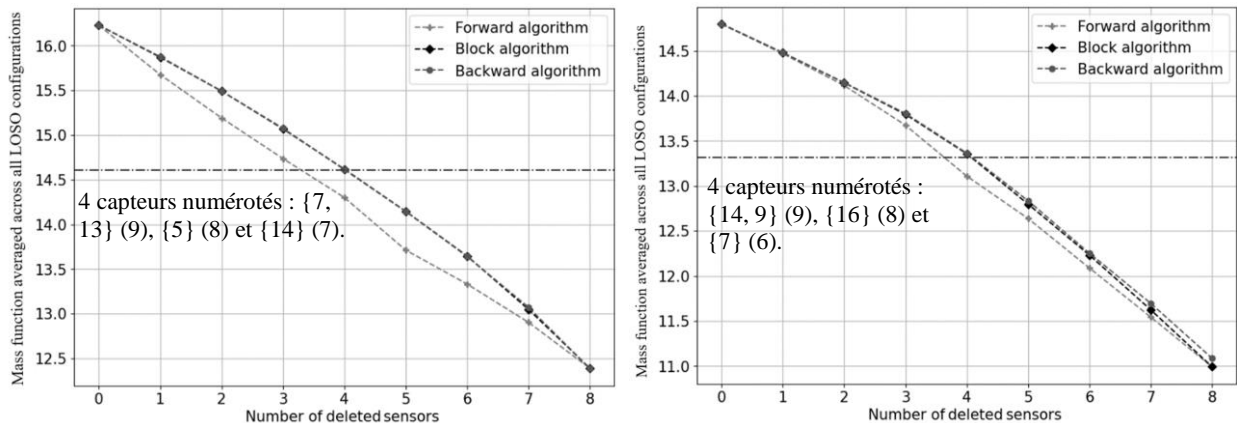


Figure 4.2. Nombre de capteurs supprimés en utilisant la semelle Moticon avec les trois stratégies de sélection pour le pied gauche (image de gauche) et le pied droit (image de droite) basées sur la valeur de masse moyennée pour toutes les configurations (modèles) LOSO. La ligne horizontale représente 90 % de la valeur maximale de la fonction de masse. En dessous de cette ligne, les numéros de capteurs (avec leur fréquence d'occurrence) dépassant ce seuil pour les 9 modèles LOSO sont indiqués en utilisant la stratégie de *Block*.

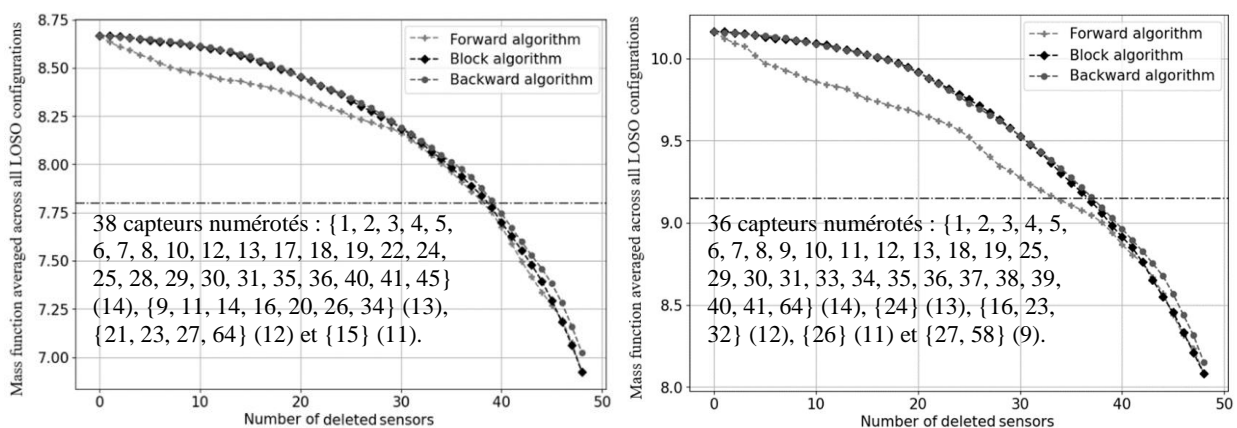


Figure 4.3. Nombre de capteurs supprimés en utilisant la semelle Fscan avec les trois stratégies de sélection pour le pied gauche (image de gauche) et le pied droit (image de droite) basées sur la valeur de masse moyennée pour toutes les configurations (modèles) LOSO. La ligne horizontale représente 90 % de la valeur maximale de la fonction de masse. En dessous de cette ligne, les numéros de capteurs (avec leur fréquence d'occurrence) dépassant ce seuil pour les 14 modèles LOSO sont indiqués en utilisant la stratégie de *Block*.


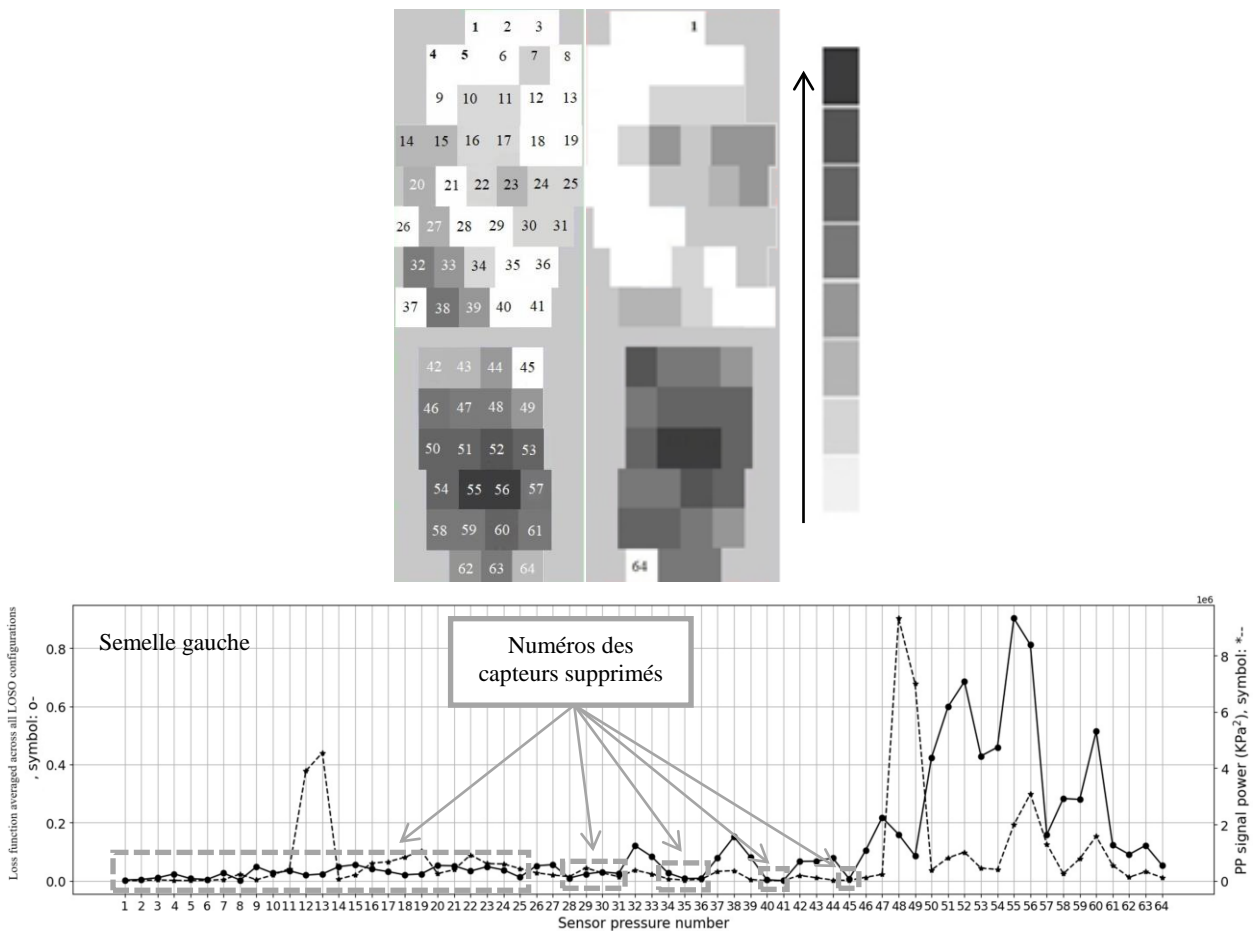


Figure 4.4. La semelle de Moticon pour le pied gauche (graphique de gauche) et pour le pied droit (graphique de droite). Pour chaque graphique, pour chacun des 16 capteurs de pression : fonction de perte moyennée avec la stratégie *Block* (ligne droite, étiquette à gauche) ; puissance du signal PP moyennée (ligne en pointillés, étiquette à droite). Les numéros des capteurs supprimés qui satisfont l'ensemble de la procédure de sélection sont mis en évidence dans des rectangles gris. Le niveau d'importance de chaque capteur est représenté par des niveaux de gris (image du milieu), où le blanc indique le capteur le moins important et le noir indique le capteur le plus important en fonction du classement de la valeur de perte moyennée.






Figure 4.5. La semelle Fscan pour le pied gauche (image du milieu) et pour le pied droit (image du bas). Pour chaque graphique, pour chacun des 16 capteurs de pression : fonction de perte moyennée avec la stratégie *Block* (ligne droite, étiquette à gauche) ; puissance du signal PP moyennée (ligne en pointillés, étiquette à droite). Les numéros des capteurs supprimés qui satisfont l'ensemble de la procédure de sélection sont mis en évidence dans des rectangles gris. Le niveau d'importance de chaque capteur est représenté par des niveaux de gris (image ci-dessus), où le blanc indique le capteur le moins important et le noir indique le capteur le plus important en fonction du classement de la valeur de perte moyennée.

Tableau 4.3. Moyenne \pm écart-type de RMSE (R) entre les composantes de la GRF estimées (par les données de PP de la semelle) et mesurées (par la plateforme de force) des deux pieds pour les deux méthodes en utilisant les données de test : la méthode de référence PCA-ANN (valeurs min-max des PCs) utilise les 16 ou 64 capteurs (en italique), l'autre méthode utilise ANN en supprimant les capteurs les moins importants. Les numéros des capteurs supprimés (la fréquence d'occurrence) sont rapportés.

Semelle	Pied	Stratégie	Méthode	Nombre de capteurs nécessaires	F_x (N)	F_y (N)	F_z (N)
			<i>PCA-ANN (9-10 PCs)</i>	16	<i>11,40 (0,885) \pm 0,58 (0,009)</i>	<i>33,34 (0,621) \pm 1,51 (0,031)</i>	<i>66,37 (0,976) \pm 3,60 (0,003)</i>
		Intras	ANN avec 3 capteurs supprimés numérotés : {9, 14} (9); et {16} (8).	13	11,93 (0,873) \pm 0,37 (0,010)	33,22 (0,620) \pm 1,44 (0,049)	66,73 (0,974) \pm 2,22 (0,002)
	droit		<i>PCA-ANN (9-10 PCs)</i>	16	<i>17,62 (0,776) \pm 8,06 (0,078)</i>	<u>41,33 (0,486) \pm 14,35 (0,147)</u>	<i>93,88 (0,949) \pm 22,20 (0,03)</i>
		Inters	ANN avec 3 capteurs supprimés	13	<u>16,59 (0,724) \pm 3,05 (0,088)</u>	45,07 (0,388) \pm 15,40 (0,205)	<u>92,67 (0,949) \pm 15,15 (0,019)</u>
			<i>PCA-ANN (9-10 PCs)</i>	16	<i>14,09 (0,712) \pm 1,01 (0,025)</i>	<i>30,93 (0,643) \pm 2,17 (0,038)</i>	<i>62,84 (0,978) \pm 3,95 (0,002)</i>
		Intras	ANN avec 3 capteurs supprimés numérotés : {7, 13} (9) et {5} (8).	13	13,86 (0,722) \pm 0,69 (0,023)	32,12 (0,623) \pm 1,87 (0,036)	60,39 (0,979) \pm 2,97 (0,001)
	gauche		<i>PCA-ANN (9-10 PCs)</i>	16	<i>18,85 (0,525) \pm 4,64 (0,191)</i>	<i>38,95 (0,529) \pm 13,58 (0,201)</i>	<i>102,51 (0,942) \pm 17,42 (0,025)</i>
		Inters	ANN avec 3 capteurs supprimés	13	17,95 (0,495) \pm 4,76 (0,176)	45,01 (0,519) \pm 10,17 (0,102)	<u>95,50 (0,947) \pm 15,92 (0,021)</u>
			<i>PCA-ANN (38-41 PCs)</i>	64	<i>15,97 (0,692) \pm 0,57 (0,012)</i>	<i>22,78 (0,611) \pm 0,57 (0,012)</i>	<i>150,29 (0,822) \pm 5,00 (0,010)</i>
		Intras	ANN avec 30 capteurs supprimés numérotés : {1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 18, 19, 25, 29, 30, 31, 33, 34, 35, 36, 37, 38, 39, 40, 41, 64} (14) et {24} (13).	34	15,78 (0,698) \pm 0,42 (0,014)	23,58 (0,585) \pm 0,70 (0,012)	151,75 (0,818) \pm 4,78 (0,010)
	droit						

Fscan	Inters	PCA-ANN (38-41 PCs)	64	19,61 (0,606) ± 2,87 (0,143)	29,21 (0,526) ± 5,43 (0,097)	180,60 (0,768) ± 61,43 (0,135)
		ANN avec 30 capteurs supprimés	34	18,89 (0,628) ± 2,99 (0,149)	29,82 (0,489) ± 6,81 (0,133)	182,86 (0,782) ± 54,99 (0,139)
	Intras	PCA-ANN (35-37 PCs)	64	15,50 (0,662) ± 0,52 (0,023)	24,90 (0,581) ± 0,51 (0,016)	160,63 (0,802) ± 5,35 (0,011)
		ANN avec 33 capteurs supprimés numérotés : {1, 2, 3, 4, 5, 6, 7, 8, 10, 12, 13, 17, 18, 19, 22, 24, 25, 28, 29, 30, 31, 35, 36, 40, 41, 45} (14) et {9, 11, 14, 16, 20, 26, 34} (13)	31	15,13 (0,671) ± 0,40 (0,013)	25,24 (0,551) ± 0,45 (0,013)	161,76 (0,798) ± 4,80 (0,010)
	gauche	PCA-ANN (35-37 PCs)	64	28,36(0,425) ± 13,94(0,210)	42,35(0,308) ± 36,01(0,210)	274,91 (0,671) ± 24,08 (0,203)
		ANN avec 33 capteurs supprimés	31	24,47 (0,446) ± 11,84 (0,274)	40,71 (0,310) ± 29,89 (0,227)	267,86 (0,679) ± 243,62 (0,223)

- **Comparaison de performances sans sélection (PCA-ANN) et avec sélection (ANN)**

Le Tableau 4.3 a été conçu pour comparer l'estimation des composantes de la GRF en utilisant les semelles Moticon et Fscan avec le PCA-ANN avec 16 et 64 capteurs (méthode de référence), respectivement, et l'ANN en supprimant les capteurs les moins importants. Les numéros de capteurs supprimés sont présentés dans le Tableau 4.3.

Le Tableau 4.3 montre que les résultats de l'estimation des composantes de la GRF entre les deux méthodes sont assez similaires. Afin d'évaluer l'impact de la sélection des capteurs sur la précision de l'estimation des composantes de la GRF, nous avons calculé le rapport entre les valeurs de RMSE des composantes de la GRF estimées obtenues avec les deux méthodes, les deux semelles, les deux pieds et les deux stratégies (Tableau 4.4). Une valeur de ratio inférieure à 1 indique que la sélection des capteurs améliore l'estimation des composantes de la GRF (en gras dans le Tableau 4.4). C'est toujours le cas pour l'estimation de la composante F_z , comme indiqué dans le Tableau 4.4. En moyenne, ce ratio oscille légèrement autour de 1 pour les trois composantes de la GRF, ce qui indique que la réduction des capteurs maintient toujours des performances similaires.

Tableau 4.4. Les valeurs minimales et maximales du ratio de RMSE entre PCA-ANN et ANN en supprimant les capteurs les moins importants dans les configurations inters, intras, pied gauche et pied droit du Tableau 4.3. Les valeurs en gras indiquent des estimations améliorées avec moins de capteurs.

Semelle	F_x	F_y	F_z
Moticon	0,91 – 1,05	1 – 1,09	0,87 - 1
Fscan	0,86 – 0,99	0,96 – 1,03	0,97 - 1

4.5 Discussion

À partir le Tableau 4.3, les valeurs R indiquent que la composante verticale (F_z) (Moticon : R_Fz = 0,949 – 0,979, Fscan : R_Fz = 0,697 – 0,822) a montré de meilleurs résultats de corrélation que la composante antéro-postérieure (F_y) (Moticon : R_Fy = 0,486 – 0,643, Fscan : R_Fy = 0,310 – 0,581) et la composante médio-latérale (F_x) (Moticon : R_Fx = 0,495 – 0,885, Fscan : R_Fx = 0,446 – 0,692). En fait, la composante verticale est une conséquence directe de ce que mesurent les capteurs de pression, ce qui explique les valeurs de corrélation les plus élevées. Pour la stratégie inters, nous avons obtenu des erreurs significatives par rapport à la stratégie intras, principalement en raison des différences de poids

des sujets. Dans l'étude [14], ils ont modélisé et testé la stratégie inters sur des sujets de poids égal, présentant ainsi de meilleurs résultats que les nôtres.

Dans la littérature, les études [2, 10, 22-26] ont trouvé $R_{Fz} = 0,650 - 0,992$, $R_{Fy} = 0,621 - 0,984$ et $R_{Fx} = 0,719 - 0,930$, mettant en évidence une large plage de valeurs R parmi toutes les études. Cela rend la comparaison avec nos résultats non évidents, car les conditions expérimentales et les technologies différaient entre ces études et la nôtre. Par exemple, certaines études portaient sur des exercices de course [25], des exercices de golf [22], des élévations de mollet [24], des activités de marche [10, 23, 24] pour des valeurs de vitesses très variables, allant de 0,77 à 2,3 m/s et des sujets souffrant de pathologies [10, 2]. Les études [23, 26] sont similaires à notre étude car elles explorent l'activité de la marche pour des sujets en bonne santé. Cependant, les résultats diffèrent des nôtres, avec une différence essentielle reposant sur la technologie de la semelle. Cela est corroboré par nos résultats où nous avons montré que l'utilisation de différentes technologies de semelles avec le même protocole de collecte de données et le même traitement des données conduit à des estimations différentes de la GRF. La technologie des semelles variait, avec Micro-EMED utilisé dans [23], Pedar dans [2, 10, 22, 25, 26] et une semelle fabriquée en laboratoire dans [24]. Certaines études utilisaient une plateforme de force (modèle AMTI ou Kistler) [2, 10, 22, 23, 26] ou un tapis roulant [24, 25]. De plus, la plupart des références [2, 23-26] n'ont pas mentionné le nombre d'échantillons de test utilisés pour le calcul des métriques. Certains articles se sont uniquement concentrés sur la stratégie intras sans tester la stratégie inters [10, 22, 24, 25].

Selon le Tableau 4.3, l'utilisation des données de la semelle Moticon donne des résultats plus précis par rapport aux données de la semelle Fscan pour l'estimation des composantes de la GRF en utilisant PCA-ANN, notamment pour les composantes de F_z et F_x . Pour la composante F_y , Fscan a donné les meilleurs résultats avec une valeur de RMSE allant de 22,78 à 42,35 N. Cependant, cette erreur n'est pas très élevée par rapport aux résultats obtenus avec la semelle Moticon, qui a fourni des valeurs de RMSE allant de 30,93 à 45,07 N.

Nous pouvons conclure qu'une semelle équipée d'un plus grand nombre de capteurs n'implique pas nécessairement qu'elle fournira les meilleurs résultats d'estimation. Dans notre cas, la semelle Moticon a ¼ du nombre de capteurs par rapport à la semelle Fscan et elle présente les meilleurs résultats. Cela peut également s'expliquer par la sensibilité plus faible des capteurs Fscan [81] par rapport à Moticon, ce qui peut entraîner des erreurs dans l'estimation des composantes de la GRF. De plus, la surface des capteurs Fscan est plus petite par rapport à Moticon, ce qui nécessite l'application d'une pression plus importante pour détecter des informations. Notons que la comparaison des semelles est basée sur les mêmes coûts de dispositif (16 capteurs pour Moticon et 64 pour Fscan).

De plus, notre objectif était d'identifier les capteurs de pression les plus et les moins efficaces pour les deux semelles. Après avoir analysé les Figures 4.4 et 4.5, il a été découvert que les capteurs situés au milieu du pied (voûte plantaire) étaient les moins efficaces en raison de la pression plus faible dans cette région, car elle a le moins de contact avec le sol. En revanche, les capteurs situés à l'arrière du pied se sont avérés les plus efficaces. Cela peut s'expliquer par le fait que, lors de l'activité de marche, les sujets initient généralement leur pas par une frappe du talon [82]. De plus, le capteur numéro 15 pour Moticon s'est avéré efficace car il correspond aux phalanges qui ont un temps de contact prolongé lors de la frappe de l'avant-pied et sont les dernières à quitter le sol, principalement dans la phase de *loading response* (0 - 12% du cycle de marche) et la phase de *pre-swing* (50 - 62% du cycle de marche) [82]. De plus, ces sujets ont une morphologie normale du pied et ne souffrent d'aucune pathologie particulière du pied telle que le *valgus* ou le *varus*. Ce n'est pas le cas pour Fscan, car les capteurs de Fscan nécessitent des pressions plus élevées pour avoir des données par rapport à Moticon (la puissance de pression dans les zones des phalanges est nulle (Figure 4.5)).

De plus, nous avons conclu que se confier uniquement aux valeurs de pression ne permet pas de déterminer les capteurs les plus pertinents, car une valeur élevée ne garantit pas leur qualité (Figures 4.4 et 4.5). Par conséquent, nous avons montré que la PCA était utile pour déterminer les meilleurs capteurs de pression pour l'estimation des composantes de la GRF. Notre étude a montré qu'il était possible de réduire le nombre de capteurs sans dégrader significativement les performances de l'estimation des composantes de la GRF en utilisant un réseau ANN (Tableaux 4.3 et 4.4). Dans certains cas, l'ANN en

supprimant les capteurs les moins importants a donné des résultats supérieurs par rapport à la PCA-ANN en utilisant tous les capteurs, en particulier pour la composante F_z .

4.6 Conclusion

L'objectif principal de cette étude était de minimiser le temps de calcul et les ressources matérielles des capteurs pour l'estimation des composantes de la GRF. Cette tâche a été réalisée en sélectionnant les capteurs importants à l'aide de deux semelles : Moticon et Fscan. Nous avons utilisé les valeurs de la perte moyennée calculées avec la PCA pour sélectionner un ensemble limité de capteurs sans compromettre les performances d'estimation par rapport à l'utilisation de l'ensemble complet des capteurs (Tableaux 4.3 et 4.4). Dans certains cas, l'utilisation de la moitié des capteurs a amélioré les résultats. En effet, en supprimant 3 parmi les 16 capteurs pour la semelle Moticon (les deux pieds) et 33 (pied gauche) ou 30 (pied droit) parmi les 64 capteurs pour la semelle Fscan, la qualité de l'estimation des composantes de la GRF a été minimalement impactée par rapport à l'utilisation de tous les capteurs. Remarquablement, les deux semelles avec moins de capteurs ont conduit à de meilleures estimations de la composante verticale. Aussi, dans le contexte de notre travail, la semelle Moticon a présenté des performances supérieures pour estimer les composantes de la GRF par rapport à la semelle Fscan.

Chapitre 5 Comparaison de la précision de l'estimation des composantes de la GRF entre les méthodes d'apprentissage automatique supervisé et d'apprentissage profond à l'aide d'une semelle de pression

5.1 Introduction

Les méthodes de DL et de SML, visent à déterminer la relation entre les données de PP de la semelle et les trois composantes de la GRF. Dans cette étude, nous avons cherché à évaluer la précision de trois méthodes DL (ANN, CNN et LSTM) et de trois méthodes de SML (RF, SVR et LS) dans l'estimation des composantes de la GRF pendant les six activités de marche, statiques et Pdc en utilisant la semelle Moticon. À notre connaissance, la comparaison de la précision d'estimation de ces six méthodes n'a pas encore été étudiée dans la littérature. Notre objectif est de déterminer si les méthodes DL, telles qu'elles ont été utilisées dans des études antérieures [2, 10, 22-25], donnent de meilleurs résultats que les méthodes SML. Il s'agit là de notre première contribution. De plus, aucune étude n'a, à notre connaissance, évalué l'estimation des composantes de la GRF à partir des données de PP d'une semelle de pression pour des activités en situation statique et des tâches de Pdc. Cette évaluation est d'une importance considérable dans le domaine de l'ergonomie. Il s'agit de notre deuxième contribution. Cette étude a donné lieu à une publication à [83].

La Figure 5.1 illustre Le diagramme de flux pour l'estimation des composantes de la GRF à partir des données PP, où le PP présente les données d'entrée. La précision de l'estimation est évaluée après la modélisation DL / SML. Le processus se compose de deux étapes. La première étape consiste à entraîner le modèle à l'aide de l'ensemble de données d'entraînement (représenté en rouge). Lors de la deuxième étape, les performances du modèle sont évaluées à l'aide des métriques en utilisant l'ensemble de données de test (représenté en bleu).

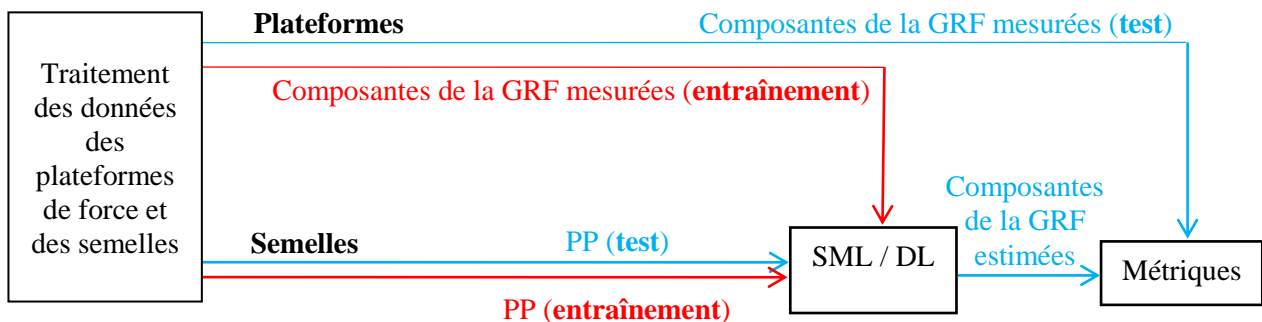


Figure 5.1. Le diagramme de flux pour l'estimation des composantes de la GRF à partir des données PP. L'ensemble de données d'entraînement PP est utilisé pour la modélisation DL / SML, en incorporant les données correspondantes de la GRF mesurées par la plateforme de force (en rouge). L'ensemble de données de test PP est ensuite utilisé pour évaluer la performance des composants GRF, en utilisant les données correspondantes de la GRF mesurées par la plateforme de force (en bleu). Le bloc de traitement des données est expliqué dans la section 2.4.

5.2 Détermination de l'architecture et les paramètres optimaux des méthodes de SML et DL

Afin de déterminer l'architecture et les paramètres optimaux des méthodes de SML et DL pour l'estimation de la composante GRF, nous avons effectué des tests avec différents paramètres et architectures pour ANN, LSTM, CNN, RF et SVR pour le pied droit.

- **SVR**

Nous avons normalisé les entrées (données de PP) avec la méthode ZS. Nous avons testé les noyaux linéaires (SVR linéaire) et RBF (SVR non-linéaire) pour estimer les composantes de la GRF. Plus

précisément, pour ces deux noyaux, nous avons testé $\zeta = 15$ et 20 avec différentes valeurs de C , incluant $0,01; 0,1; 1; 10; 50; 100; 300; 600$ et 900 . De plus, le paramètre supplémentaire γ avec des valeurs de $0,01; 0,1; 1; 10; 50; 100; 300; 600$ et 900 a été testé pour le noyau RBF.

- **RF**

Nous avons testé la méthode RF composées de T arbres, où T varie selon les valeurs suivantes : $T = [10, 50, 100, 500, 1000, 5000, 10000]$, pour estimer chaque composante de la GRF.

- **LS**

Nous cherchons à déterminer les équations linéaires qui relient les composantes de la GRF aux données de PP des deux pieds.

- **ANN**

- 1) initialisation : 1 couche d'entrée de 16 neurones, 2 couches cachées de (256, 128) neurones, 1 couche de sortie de 5 neurones, fonction d'activation : sigmoïde, méthode de normalisation : Moyenne, batch size : 32, taux d'apprentissage : 0,01, optimiseur : Adamax ;
- 2) modifier l'optimiseur : Adadelta, *Adaptive Gradient* (AdaGrad), Adam, AdamW, Adamax, *Nesterov Accelerated Adaptive Moment* (Nadam), *Root Mean Square Propagation* (RMSProp), SGD avec différentes valeurs de momentum : 0; 0,5 et 0,9 ;
- 3) modifier le taux d'apprentissage : 0,04; 0,08; 0,01; 0,005 et 0,008 ;
- 4) modifier les valeurs de batch size : 1, 4, 16, 32, 64, 128 et 256 ;
- 5) modifier le nombre de couches cachées et leurs neurones (indiqués entre parenthèses) : 1 couche : (33), (150) ; 2 couches : (50, 50), (125, 125), (256, 128), (128, 256) ; 3 couches : (256, 256, 128) ; 4 couches : (100, 100, 100, 100) ;
- 6) modifier la fonction d'activation : leaky relu pour $\alpha = 0,1$ et $\alpha = 0,01$, relu, tanh, sigmoïde, softSign, Morlet wavelet, softPlus, elu ($\alpha = 1$) ;
- 7) modifier la méthode de normalisation : $MM_{[0,1]}$, $MM_{[-1,1]}$, Moyenne, ZS, RS, VS, MLS, DS, Med, Tanh, BW et LI.

- **CNN**

- 1) initialisation : 1 couche d'entrée de 16 neurones, 3 couches de convolution : Conv1D (nombre de filtres = 14, taille du noyau = 4), Conv1D (taille du filtre = 10, taille du noyau = 4), Conv1D (nombre de filtres = 8, taille du noyau = 4), 3 couches de pooling : AvgPool1d (taille du noyau = 2), un ANN avec une 1 couche cachée de 32 neurones ;
- 2) utiliser MaxPool1d au lieu de AvgPool1d ;
- 3) modifier la taille du noyau des couches de convolution : 2, 3, 4 et 5 ;
- 4) modifier le nombre de couches de convolution : 1, 2 et 3 ;
- 5) modifier le nombre de filtres des couches de convolution : 4, 8, 14 et 20 ;
- 6) modifier le nombre de couches cachées de ANN et leurs neurones (indiqués entre parenthèses) : 1 couche (96) ; 2 couches (96, 50) ; 3 couches : (96, 60, 25), (96, 100, 50).

- **LSTM**

- 1) initialisation: 1 couche d'entrée de 16 neurones, 1 couche LSTM de 128 cellules, un ANN avec 2 couches cachées de (128, 50) neurones, la taille de la séquence d'entrées est égale à 20 (LSTM utilise les données de PP à l'instant actuel t ainsi que des échantillons précédents aux instants : $t-19, \dots, t-1$ pour estimer les composantes de la GRF à l'instant t).
- 2) modifier le nombre de couches de LSTM et leurs cellules (indiquées entre parenthèses) : 1 couche LSTM (128), 2 couches LSTM : (400, 200), (400, 100) et (800, 400) ;

- 3) modifier le nombre de couches cachées de ANN et leurs neurones (indiqués entre parenthèses) : 1 couche (400); 2 couches (256, 128); 3 couches : (400, 100, 50), (400, 300, 150) ;
- 4) tester le BLSTM au lieu du LSTM avec la meilleure architecture et paramètres obtenus à partir de ces 3 étapes ;
- 5) modifier le nombre de couches de BLSTM et leurs cellules (indiquées entre parenthèses) : 1 couche (400), 2 couches : (400, 200), (600, 200) ;
- 6) modifier la taille de la séquence d'entrées : 20, 40, 60, 80 et 100.

Les paramètres et l'architectures optimaux pour les méthodes ANN, CNN, BLSTM, SVR et RF obtenus à partir des simulations, qui ont montré la plus grande précision dans l'estimation des composantes de la GRF pour le pied droit, sont présentés dans le Tableau 5.1. Les méthodes CNN et BLSTM ont utilisé les paramètres optimaux (batch size, optimiseur, taux d'apprentissage, etc.) que l'ANN.

Tableau 5.1. Paramètres et architectures optimaux pour les méthodes de SML et DL. Les paramètres optimaux (batch size, optimiseur, taux d'apprentissage, etc.) de l'ANN sont appliqués au CNN et à la BLSTM.

ANN	CNN	BLSTM	SVR	RF
2 couches cachées de (256, 128) neurones, fonction d'activation: leaky relu, méthode de normalisation: BW, batch size : 4, optimiseur: Adamax, taux d'apprentissage : 0,01	1 couche de convolution : Conv1D (nombre de filtres = 8, taille du noyau = 4), 1 couche MaxPool1d (taille du noyau = 2), un ANN avec 3 couches cachées de (96, 60, 25) neurones	2 couches BLSTM avec (400, 200) cellules, un ANN avec 3 couches cachées de (400, 300, 150) neurones, une taille de séquence d'entrée égale à 20	SVR à noyau RBF avec $\zeta = 20$, $C = 100$ et $\gamma = 0,1$	T = 1000

Par souci de simplicité, lors de la modélisation des méthodes de SML et DL pour le pied gauche, nous avons utilisé les mêmes paramètres optimaux et architectures que ceux utilisés pour estimer les composantes de la GRF pour le pied droit.

5.3 Résultats

La performance des 9 LOSO modèles (ANN, BLSTM, CNN, SVR, LS et RF) est évaluée à l'aide des métriques RMSE et R. Les Figures 5.2 et 5.3 affichent la moyenne de ces métriques pour le jeu de données de test pour chaque estimation de composante GRF et chaque activité, pour les deux pieds et les deux stratégies, pour chaque méthode DL et SML. Plutôt que de présenter des tableaux volumineux reprenant les métriques de toutes les activités pour chaque composante de la GRF pour les deux pieds en fonction de la stratégie, nous avons opté pour une représentation graphique afin de faciliter la lecture et l'analyse. Pour plus de détails, les Tableaux II.1 et II.2 de l'annexe II présentent la moyenne et l'écart-type des métriques RMSE et R.

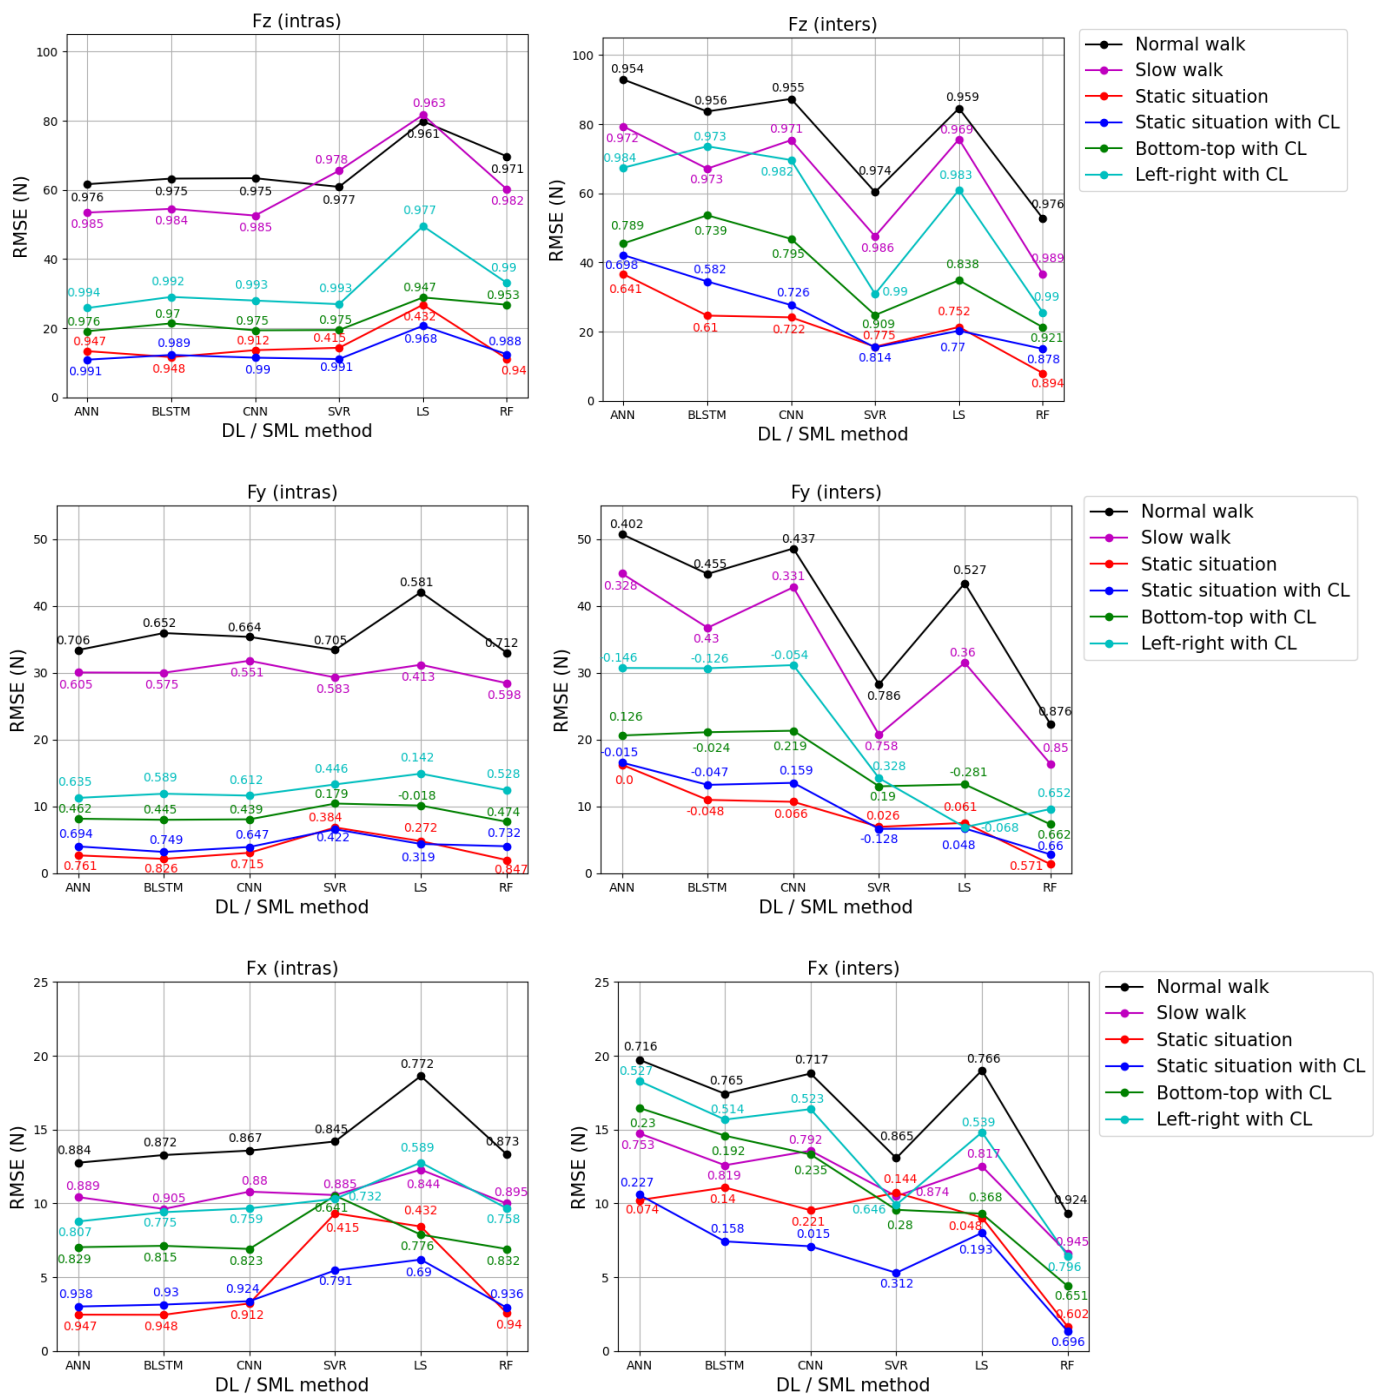


Figure 5.2. Les allures de RMSE moyenne entre les composantes de la GRF estimées (par les données de PP de la semelle) et mesurées (par la plateforme de force) pour le pied droit, pour chaque méthode de DL et SML, pour le jeu de données de test, couvrant les deux stratégies et chaque activité. La courbe noire représente la "Marche normale", la courbe magenta représente la "Marche lente", la courbe rouge représente la "Situation statique", la courbe bleue représente le "Pdc statique", la courbe verte représente le "Pdc bas-haut" et la courbe cyan représente le "Pdc gauche-droite". Les valeurs moyennes de R sont indiquées au-dessus des valeurs de RMSE pour chaque méthode de DL et SML.

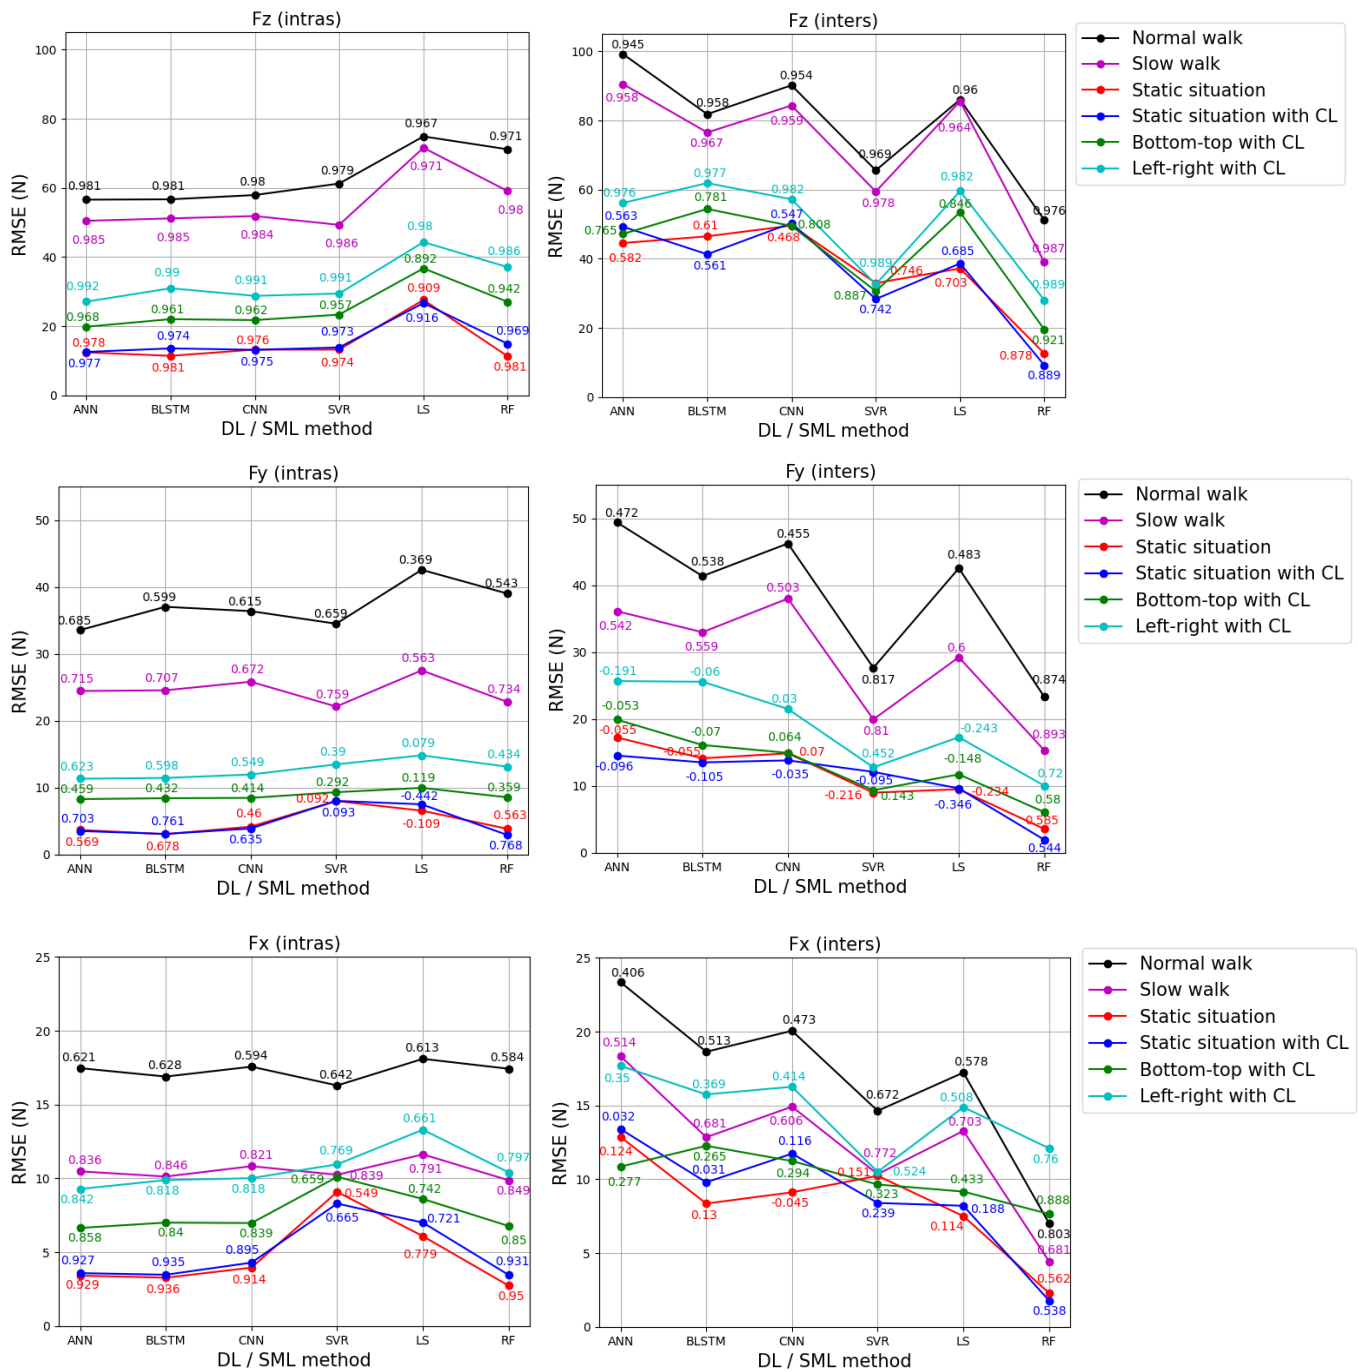


Figure 5.3. Les allures de RMSE moyenne entre les composantes de la GRF estimées (par les données de PP de la semelle) et mesurées (par la plateforme de force) pour le pied gauche, pour chaque méthode de DL et SML, pour le jeu de données de test, couvrant les deux stratégies et chaque activité. La courbe noire représente la "Marche normale", la courbe magenta représente la "Marche lente", la courbe rouge représente la "Situation statique", la courbe bleue représente le "Pdc statique", la courbe verte représente le "Pdc bas-haut" et la courbe cyan représente le "Pdc gauche-droite". Les valeurs moyennes de R sont indiquées au-dessus des valeurs de RMSE pour chaque méthode de DL et SML.

La Figure 5.4 présente un exemple des allures des courbes de sommes des forces verticales F_z mesurées par la plateforme et le poids du sujet (masse du sujet multipliée par la gravité g) pour les cas statiques avec et sans Pdc. L'objectif de cette Figure est de fournir un exemple démontrant que le poids du sujet dans la "situation statique" ainsi que le poids du sujet plus 5 kg supplémentaires dans la "situation statique avec Pdc" sont égaux à la somme des deux forces F_z des deux pieds mesurées par la plateforme.




Figure 5.4. Un exemple des allures des courbes de sommes des forces verticales mesurées par la plateforme et le poids du sujet pour les cas statique (image gauche) et statique avec Pdc (image droite). Les allures des courbes des forces verticales mesurées par la plateforme des deux pieds sont également représentées. Dans les deux images, g est la gravité, qui est égale à 10 m/s^2 .

Nous avons mené une analyse afin d'identifier la méthode d'estimation la plus efficace (SML et DL) pour chaque activité parmi les six, pour estimer chaque composante de la GRF pour les deux pieds en utilisant les deux stratégies.

Pour le pied droit, en analysant la Figure 5.2, nous avons constaté que pour la stratégie intras et pour l'estimation de F_z , ANN était la méthode la plus efficace pour les activités "Pdc statique", "Pdc bas-haut" et "Pdc gauche-droite". La méthode SVR s'est révélée la plus efficace pour la "marche normale", CNN pour la "marche lente" et RF pour la "situation statique". En ce qui concerne l'estimation de F_y , RF était la méthode la plus efficace pour la "marche normale", la "marche lente", la "situation statique" et le "Pdc bas-haut", tandis que la BLSTM s'est avérée optimale pour le "Pdc statique" et ANN pour le "Pdc gauche-droite". Pour l'estimation de F_x , ANN était la méthode la plus efficace pour la "marche normale" et le "Pdc gauche-droite", BLSTM pour la "marche lente" et la "situation statique", CNN pour le "Pdc bas-haut" et RF était la méthode la plus efficace pour le "Pdc statique".

Pour la stratégie inters, la méthode RF s'est révélée être la plus efficace pour toutes les activités pour l'estimation des trois composantes de la GRF.

Pour le pied gauche, en analysant la Figure 5.3, nous avons constaté que pour la stratégie intras et pour l'estimation de F_z , ANN était la méthode la plus efficace pour la "marche normale", le "Pdc statique", le "Pdc bas-haut" et le "Pdc gauche-droite". La méthode RF s'est révélée la plus efficace pour la "situation statique" et SVR pour la "marche lente". En ce qui concerne l'estimation de F_y , ANN s'est avérée être la méthode la plus efficace pour la "marche normale", le "Pdc bas-haut" et le "Pdc gauche-droite", SVR pour la "marche lente", BLSTM pour la "situation statique" et RF pour le "Pdc statique". Pour l'estimation de F_x , ANN était la méthode la plus efficace pour le "Pdc bas-haut" et le "Pdc gauche-droite", BLSTM pour la "Pdc statique", SVR pour la "marche normale" et RF pour la "situation statique" et la "marche lente".

Pour la stratégie inters, la méthode RF s'est révélée être la plus efficace pour toutes les activités concernant l'estimation des trois composantes de la GRF. Pour l'estimation de F_x , la méthode SVR s'est également avérée être la deuxième méthode la plus efficace pour l'activité "Pdc gauche-droite".

D'après la Figure 5.4, dans le cas statique, la différence entre les deux allures des courbes de sommes des forces verticales mesurées par la plateforme et le poids du sujet est d'environ 0,05 à 5 N. De même, dans le cas statique avec Pdc, la différence entre ces deux allures varie de 5 à 14 N. Cette variation dans le cas statique avec Pdc implique que des forces externes s'ajoutent à la force F_z . Ces forces externes sont dues

à ses mouvements peuvent inclure des ajustements de la posture et des mouvements de balancement pour maintenir l'équilibre (le sujet en portant la charge n'est pas totalement immobile).

5.4 Discussion

D'après les valeurs optimales moyenne de R des Figures 5.2 et 5.3, notre étude a indiqué que, pour les deux stratégies, les deux pieds et les six activités, la composante verticale (F_z) de la GRF ($R_{Fz} = 0,878 - 0,994$) pouvait être estimée avec plus de précision que la composante antéro-postérieure (F_y) ($R_{Fy} = 0,459 - 0,876$) et la composante médio-latérale (F_x) ($R_{Fx} = 0,538 - 0,950$). Cette fourchette plus élevée de valeurs de R pour l'estimation de la composante F_z pourrait être attribuée au fait que les méthodes de DL et SML ont construit des modèles qui décrivent mieux la relation entre la composante F_z et les capteurs de pression. Cela peut s'expliquer par la relation physique linéaire entre la composante F_z et les capteurs de pression (F_z est égal à la somme des capteurs de pression multipliée par la surface du capteur), qui rend la modélisation beaucoup plus simple que pour les autres composantes. Dans la littérature, les auteurs des références [2, 10, 22, 23, 25] ont trouvé des valeurs de $R_{Fz} = 0,650 - 0,992$, $R_{Fy} = 0,606 - 0,984$ et $R_{Fx} = 0,634 - 0,930$. Cela confirme la conclusion selon laquelle les valeurs R de la composante F_z sont plus élevées que les autres composantes, indépendamment de la méthode d'estimation et de la technologie de la semelle et de la plaque de force.

Nous avons conclu que, pour estimer les composantes de la GRF pour les deux pieds et les deux stratégies, la méthode RF était la plus efficace, suivie de ANN, SVR, BLSTM et enfin CNN, dans l'ordre décroissant d'efficacité (Figures 5.2 et 5.3). Ces classements d'efficacité étaient basés sur 46, 15, 5, 5 et 2 configurations optimales parmi les 72 configurations totales. Ces configurations comprenaient les trois composantes, six activités, deux pieds et deux stratégies. La méthode RF a montré des résultats supérieurs par rapport aux méthodes de DL, notamment pour la stratégie inters pour les deux pieds. Contrairement aux suggestions des recherches précédentes [2, 10, 22-25], nos résultats indiquent que les méthodes DL ne sont pas toujours la méthode optimale pour estimer les composantes de la GRF par rapport aux méthodes SML. En outre, BLSTM (une méthode très complexe à mettre en œuvre) et SVR (une méthode plus simple) ont donné des résultats similaires.

Non seulement les méthodes de SML sont plus performantes que les méthodes DL, mais elles présentent également d'autres avantages. Elles nécessitent souvent moins de temps d'apprentissage pour trouver le modèle optimal (voir section 5.2) et sont plus robustes aux variations des hyperparamètres en raison de leur nombre réduit. L'ajustement des hyperparamètres dans les méthodes DL peut s'avérer difficile et exigeant sur le plan informatique. Dans notre étude, l'apprentissage des méthodes DL a nécessité l'utilisation d'un GPU, tandis que pour les méthodes SML, un CPU était suffisant.

Les Figures 5.2 et 5.3 suggèrent que la précision de chaque activité dépend des méthodes de SML et DL (RF, SVR, LS, ANN, BLSTM et CNN), ainsi que de la stratégie (intras ou inters) utilisée pour estimer les composantes de la GRF pour les deux pieds. En général, pour estimer les composantes de la GRF pour les six activités, les deux stratégies et les deux pieds, nous recommandons d'utiliser la méthode RF, qui a montré des valeurs moyennes de RMSE allant de 1 à 1,4 fois supérieures aux résultats optimaux (la valeur maximale de 1,4 est le rapport entre la RMSE moyenne de RF (26,78 N) et celui de ANN (19,14 N) pour "Pdc bas-haut" pour F_z dans la stratégie intras pour le pied droit). L'annexe III présente les allures des composantes de la GRF estimées par la méthode RF et mesurées par la plateforme pour un essai des six activités pour la stratégie intras en utilisant la semelle Moticon.

Dans la plupart des cas, quelle que soit la méthode DL et SML, quel que soit le pied et quelle que soit la stratégie, la "Pdc statique" et la "situation statique" ont donné les meilleurs résultats par rapport à la "Pdc bas-haut" et à la "Pdc gauche-droite", qui à leur tour ont donné de meilleurs résultats que la "marche normale" et la "marche lente". En d'autres termes, les deux situations statiques ont montré une plus grande précision que les situations dynamiques (Pdc et la marche), ce qui est cohérent car l'estimation des composantes de la GRF dans les situations statiques est beaucoup moins difficile (les variations de PP et des composantes de la GRF mesurées par la plateforme de force sont faibles) que dans les situations dynamiques.

Il convient de noter que la précision des composantes de la GRF peut dépendre fortement de la stratégie employée. Par exemple, ANN a produit de bons résultats d'estimation pour la stratégie intras pour les trois composantes et les six activités pour les deux pieds, avec des valeurs de RMSE moyennes allant de 1 à 1,26 fois plus élevées que les résultats optimaux (la valeur maximale de 1,26 est le rapport entre la RMSE moyenne de ANN (4 N) et celle de BLSTM (3,18 N) pour la "Pdc statique" pour F_y dans la stratégie intras pour le pied droit). Inversement, la méthode ANN a produit les pires résultats pour la stratégie inters, avec des valeurs de RMSE moyennes allant de 1,42 à 12,02 fois supérieures aux résultats optimaux (la valeur minimale de 1,42 est le rapport entre la RMSE moyenne de ANN (10,85 N) et celle de RF (7,64 N) pour "Pdc bas-haut" pour le pied droit pour F_x dans la stratégie inters pour le pied gauche, la valeur maximale de 12,02 est le rapport entre la RMSE moyenne de ANN (16,23 N) et celui de RF (1,35 N) pour "situation statique" pour F_y dans la stratégie inters pour le pied droit). Ceci a montré un manque de robustesse et de capacités de généralisation de la modélisation ANN. Ce problème pourrait être partiellement résolu en ajoutant des sujets supplémentaires et en augmentant le nombre d'essais par sujet [2].

5.5 Conclusion

Nous avons comparé la précision de trois méthodes de DL et de trois méthodes de SML pour l'estimation des composantes de la GRF pour les deux pieds dans le cadre de six activités. De nombreuses études [2, 10, 22-25] recommandent d'utiliser les méthodes de DL pour l'estimation des composantes de la GRF sans tester les méthodes de SML. Notre étude a montré que les méthodes de DL ne sont pas toujours le meilleur choix pour l'estimation des composantes de la GRF. La méthode RF a donné de meilleurs résultats que les trois méthodes de DL. En outre, la méthode RF nécessite moins de réglage des hyperparamètres que les modèles de DL. Il est plus rapide et plus facile de trouver le meilleur modèle RF, car il n'y a pas plusieurs combinaisons d'hyperparamètres à tester. Aussi, la mise en œuvre d'un modèle RF est plus simple que la méthode de DL.

Chapitre 6 Comparaison de la précision de l'estimation des composantes de la GRF entre 13 méthodes de Machine Learning avec ou sans méthode de réduction de dimension à l'aide d'une semelle de pression

6.1 Introduction

Cette étude sera réalisée pendant les six activités de marche, statique et Pdc, en utilisant les deux semelles : Moticon et Fscan.

Dans cette étude, la première contribution est de comparer la performance d'estimation des 13 méthodes de ML, avec ou sans méthode de RD (PCA, MI, PCA-MI et la méthode de sélection des capteurs importants (PCA-Block) que nous avons proposée dans l'étude 2 du chapitre 4) pour l'estimation des composantes de la GRF. Les 13 méthodes incluront SVR, KNN, RF, LS, ANN, PCA-ANN, MI-ANN, PCA-MI-ANN, PCA-Block-ANN, CNN, LSTM et GRU pour estimer les composantes de la GRF à partir des données de PP, ainsi qu'ANN en prenant comme entrées à la fois les données de PP et les données d'accélération selon les trois axes de l'IMU (uniquement pour la semelle Moticon).

Notre deuxième contribution est de comparer la performance d'estimation des quatre méthodes de ML-RD (PCA-ANN, PCA-MI-ANN, MI-ANN et PCA-Block-ANN) afin de déterminer laquelle offre la meilleure précision dans l'estimation des composantes de la GRF et réduit le plus efficacement le nombre de données de PP. En effet, des études [2, 10, 22] ont utilisé la méthode PCA-MI pour réduire la dimension des données de PP. Cependant, ces études ont combiné les deux méthodes de RD, PCA et MI, sans justifier pourquoi cette combinaison était nécessaire et pourquoi ils n'ont pas utilisé uniquement PCA ou MI. Il est important de noter que PCA-MI et PCA nécessitent la récupération de tous les capteurs pour réduire la dimension des données de PP (ces deux méthodes de RD appartiennent à la famille de l'extraction de caractéristiques), tandis que PCA-Block et MI permettent de sélectionner des capteurs sans avoir à récupérer tous les capteurs (ces deux méthodes de RD appartiennent à la famille de la sélection de caractéristiques).

À notre connaissance, aucune étude n'a comparé les deux semelles de technologies différentes (résistive ou capacitive), afin de déterminer si une semelle dotée d'un réseau plus dense de capteurs résistifs (Fscan) produit des performances d'estimation comparables à celles d'une semelle moins dense de capteurs capacitifs (Moticon). La troisième contribution est donc de comparer les résultats d'estimation des composants de la GRF entre les deux semelles Fscan et Moticon.

De plus, à notre connaissance, aucune étude n'a comparé les résultats d'estimation de F_z avec ceux déterminés par la semelle (somme des capteurs de pression multipliée par les surfaces des capteurs). La quatrième contribution consiste à réaliser cette comparaison.

Enfin, la cinquième contribution est d'évaluer la performance des six activités afin de déterminer laquelle offre les meilleurs résultats en termes d'estimation des composantes de la GRF.

La Figure 6.1 illustre Le diagramme de flux pour l'estimation des composantes de la GRF à partir des données PP, avec et sans les données de l'IMU, où le PP et IMU représentent les données d'entrée. La précision de l'estimation est évaluée après la modélisation de la méthode de ML ou RD-ML. Le processus se compose de deux étapes. La première étape consiste à entraîner le modèle à l'aide de l'ensemble de données d'entraînement (**représenté en rouge**). Lors de la deuxième étape, les performances du modèle sont évaluées à l'aide des métriques en utilisant l'ensemble de données de test (**représenté en bleu**).

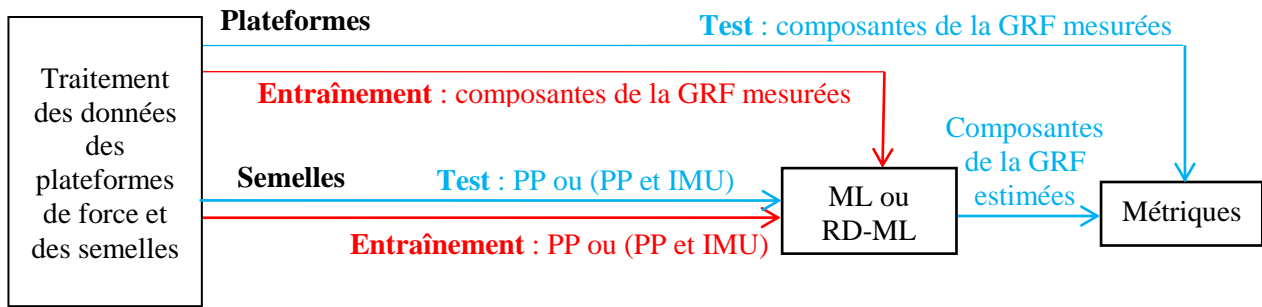


Figure 6.1. Le diagramme de flux pour l'estimation des composantes de la GRF à partir des données PP, avec et sans les données de l'IMU. L'ensemble de données d'entraînement PP ou PP+IMU est utilisé pour la modélisation de la méthode de ML ou RD-ML, en incorporant les données correspondantes de la GRF mesurées par la plateforme de force (en rouge). L'ensemble de données de test PP ou PP+IMU est ensuite utilisé pour évaluer la performance des composants GRF, en utilisant les données correspondantes de la GRF mesurées par la plateforme de force (en bleu). Le bloc de traitement des données est expliqué dans la section 2.4.

6.2 Détermination de l'architecture et des paramètres optimaux des méthodes de ML et RD-ML

Nous avons testé plusieurs configurations des 13 méthodes de ML et RD-ML afin de déterminer l'architecture et les paramètres optimaux offrant la meilleure précision dans l'estimation des trois composantes de la GRF pour les deux semelles.

- **SVR**

Nous avons normalisé les données de PP avec la méthode ZS. Nous avons testé les noyaux linéaires (SVR linéaire) et RBF (SVR non-linéaire) pour estimer les composantes de la GRF. Plus précisément, pour ces deux noyaux, nous avons testé $\zeta = 15$ et 20 (pour la semelle Moticon), $\zeta = 30$ et 35 (pour la semelle Fscan) avec différentes valeurs de C , incluant $0,01; 0,1; 1; 10; 50; 100; 300; 600$ et 900 pour les pieds gauche et droit des deux semelles. Pour la semelle Fscan, nous ne pouvons pas tester ζ en dessous de 30 , et pour la semelle Moticon, en dessous de 15 , car nous n'avons pas réussi à trouver le modèle SVR. De plus, le paramètre supplémentaire γ avec des valeurs de $0,01; 0,1; 1; 10; 50; 100; 300; 600$ et 900 a été testé pour le noyau RBF.

- **KNN**

Nous avons normalisé les données de PP avec la méthode de normalisation ZS. Nous avons varié le paramètre K de 1 jusqu'à la taille du jeu de données d'entraînement. Nous sélectionnons la valeur de K qui donne les valeurs de RMSE les plus faibles tout en maintenant une valeur élevée de R pour estimer chaque composante de la GRF pour les deux pieds et les deux semelles.

- **RF**

Nous avons testé la méthode RF composée de T arbres, où T varie selon les valeurs suivantes : $T = [10, 50, 100, 500, 1000, 5000, 10000]$, pour les deux pieds et les deux semelles.

- **LS**

Nous cherchons à déterminer les équations linéaires qui relient les composantes de la GRF aux données de PP des deux pieds pour les deux semelles.

- **ANN**

Pour les deux semelles et les deux pieds, nous avons suivi les étapes de l'ANN décrites dans la section 5.2.

- **PCA-ANN**

Pour la semelle Moticon et les deux pieds, nous avons suivi les étapes de l'ANN dans la section 5.2. La seule différence réside dans l'initialisation, où nous avons utilisé 1 couche d'entrée avec k neurones, où k

est le nombre de PCs correspondant à la plus petite valeur pour laquelle la variance cumulative était supérieure à 98 %.

- **MI-ANN**

Nous avons utilisé la méthode MI pour réduire le nombre de capteur de pression tout en conservant les capteurs les plus pertinents. Premièrement, nous calculons les valeurs de MI par la méthode d'histogramme entre chaque capteur de pression et chaque composante de la GRF pour les deux pieds et les deux semelles. Deuxièmement, nous cherchons à identifier les numéros de capteurs dont la valeur de MI est inférieure à 70% de la valeur maximum du MI pour la semelle Moticon et à 40% pour la semelle Fscan. Troisièmement, pour les 3 composantes de la GRF, nous calculons la fréquence d'occurrence de chaque capteur, c'est-à-dire le nombre de fois où chaque capteur avait une valeur de MI inférieur à 70% de la valeur maximum du MI pour la semelle Moticon et à 40% pour la semelle Fscan. Finalement, nous supprimons parmi les 16 capteurs (pour la semelle Moticon) et les 64 capteurs (pour la semelle Fscan) ceux dont la fréquence d'occurrence est égale à 3 (la valeur 3 correspondant aux 3 composantes).

Nous avons testé la méthode MI en utilisant trois méthodes de détermination du nombre de canaux : la méthode de Rice de Houston, la méthode de la racine carrée et la méthode de Sturges. Les équations correspondantes sont présentées dans la sous-section 2.5.1.1. Ces trois méthodes ont abouti aux mêmes capteurs à supprimer pour les données du pied droit avec la semelle Moticon. C'est pourquoi nous avons choisi l'une de ces méthodes, à savoir celle de Rice de Houston, pour caluler les histogrammes des MI pour les deux semelles et les deux pieds.

Pour estimer les composantes de la GRF en réduisant le nombre de capteurs de pression avec la méthode MI, nous utilisons un ANN dont l'architecture et les paramètres optimaux sont ceux décrits dans le paragraphe sur l'ANN. La seule différence réside dans l'initialisation, où nous avons utilisé une couche d'entrée avec N_1 neurones. N_1 correspond au nombre de capteurs les plus pertinents sélectionnés avec la méthode MI.

Les Figures 6.2 à 6.5 montrent les histogrammes des MI des 3 composantes de la GRF en fonction du numéro des capteurs de la semelle (Moticon et Fscan) pour les deux pieds.




Figure 6.2. Les histogrammes de MI des 3 composantes de la GRF en fonction du numéro des capteurs de la semelle **Moticon** pour le pied **droit**. Le trait rouge représente 70% de la valeur maximum du MI. Pour chaque composante de la GRF, un rectangle noir contient les numéros des capteurs dont les valeurs de MI sont en dessous du trait rouge. Les numéros des capteurs supprimés (leur fréquence d'occurrence) sont : {7} (3).





Figure 6.3. Les histogrammes de MI des 3 composantes de la GRF en fonction du numéro des capteurs de la semelle **Moticon** pour le pied **gauche**. Le trait rouge représente 70% de la valeur maximum du MI. Pour chaque composante de la GRF, un rectangle noir contient les numéros des capteurs dont les valeurs de MI sont en dessous du trait rouge. Les numéros des capteurs supprimés (leur fréquence d'occurrence) sont : {5, 7, 9, 15} (3).








Figure 6.4. Les histogrammes de MI des 3 composantes de la GRF en fonction du numéro des capteurs de la semelle **Fscan** pour le pied **droit**. Le trait rouge représente 40% de la valeur maximum du MI. Pour chaque composante de la GRF, un rectangle noir contient les numéros des capteurs dont les valeurs de MI sont en dessous du trait rouge. Les numéros des capteurs supprimés (leur fréquence d'occurrence) sont : {1, 2, 4, 5, 6, 7, 8, 9, 12, 13, 14, 19, 25, 29, 30, 31, 33, 34, 35, 36, 37, 39, 40, 41, 43, 44, 45, 47, 48, 49, 64} (3).



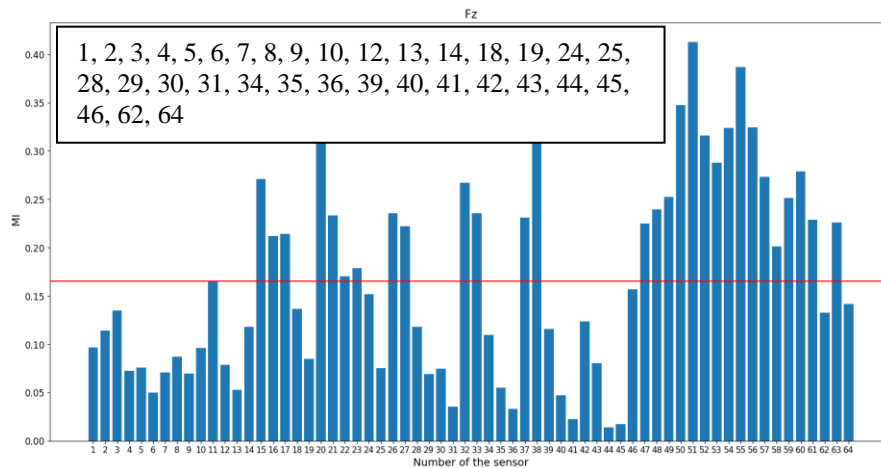


Figure 6.5. Les histogrammes de MI des 3 composantes de la GRF en fonction du numéro des capteurs de la semelle **Fscan** pour le pied **gauche**. Le trait rouge représente 40% de la valeur maximum du MI. Pour chaque composante de la GRF un rectangle noir contient les numéros des capteurs dont les valeurs de MI sont en dessous du trait rouge. Les numéros des capteurs supprimés (leur fréquence d'occurrence) sont : {1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 12, 13, 14, 18, 19, 24, 25, 28, 29, 30, 31, 34, 35, 36, 39, 40, 41, 42, 43, 44, 45, 46, 62} (3).

- **PCA-MI-ANN**

Nous avons utilisé PCA-MI pour conserver les PCs les plus pertinentes sélectionnées avec la méthode MI. Premièrement, nous calculons les valeurs de MI par la méthode d'histogramme entre chaque PC et chaque composante de la GRF pour les deux pieds et les deux semelles. Deuxièmement, nous cherchons à identifier les numéros de PCs dont la valeur de MI est inférieure à 70% de la valeur maximum du MI pour les deux semelles. Troisièmement, pour les 3 composantes, nous calculons la fréquence d'occurrence de chaque PC, c'est-à-dire le nombre de fois où chaque PC avait une valeur de MI inférieur à 70% de la valeur maximum du MI pour les deux semelles. Finalement, nous supprimons les PCs parmi les k PCs dont la fréquence d'occurrence est égale 3.

Pour estimer les composantes de la GRF en réduisant le nombre de PCs avec la méthode PCA-MI, nous utilisons un ANN dont son architecture et les paramètres optimaux sont celle trouvés dans le paragraphe ANN. La seule différence réside dans l'initialisation, où nous avons utilisé une couche d'entrée avec N_2 neurones. N_2 correspond au nombre de PCs les plus pertinents sélectionnés avec la méthode PCA-MI.

Les Figures 6.5 à 6.8 montrent les histogrammes des MI des 3 composantes de la GRF en fonction du numéro de PCs déterminées par PCA de la semelle (Moticon et Fscan) pour les deux pieds.




Figure 6.5. Les histogrammes de MI des 3 composantes de la GRF en fonction du numéro de PCs déterminées par PCA de la semelle **Moticon** pour le pied **droit**. Le trait rouge représente 70% de la valeur maximum du MI. Pour chaque composante de la GRF, un rectangle noir contient les numéros des PCs dont les valeurs de MI sont en dessous du trait rouge. Les numéros de PCs supprimés (leur fréquence d'occurrence) sont : {7} (3).


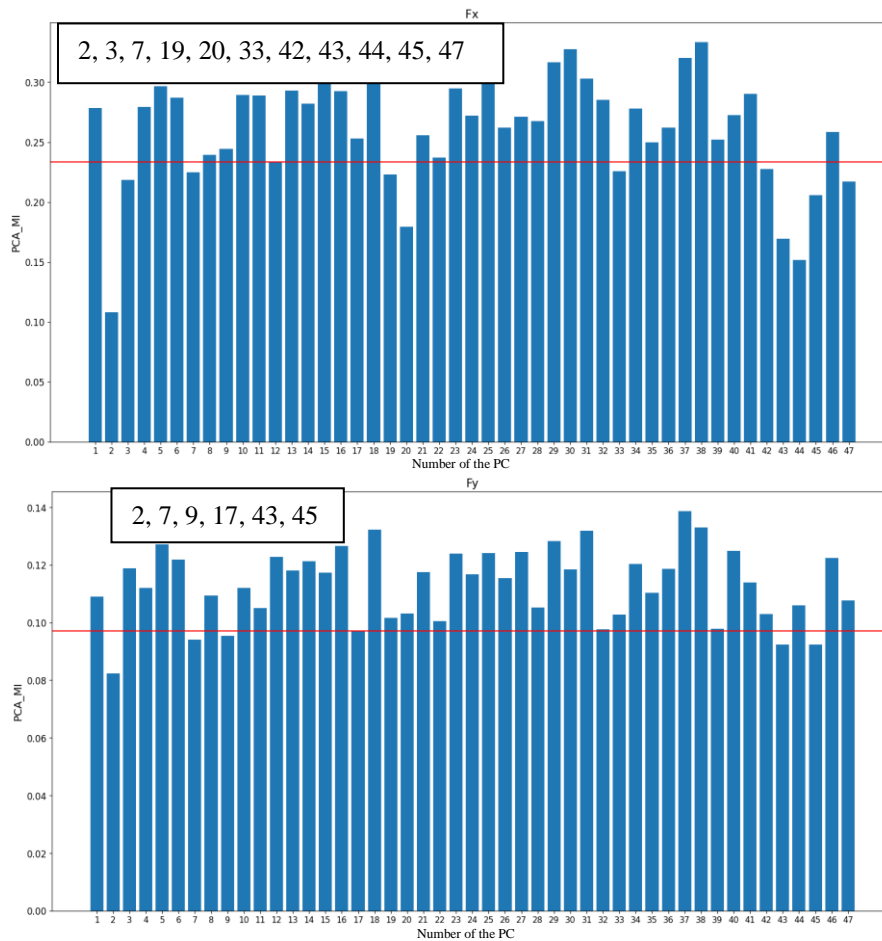


Figure 6.6. Les histogrammes de MI des 3 composantes de la GRF en fonction du numéro de PCs déterminées par PCA de la semelle **Moticon** pour le pied **gauche**. Le trait rouge représente 70% de la valeur maximum du MI. Pour chaque composante de la GRF, un rectangle noir contient les numéros des PCs dont les valeurs de MI sont en dessous du trait rouge. Les numéros de PCs supprimés (leur fréquence d'occurrence) sont : {8} (3).




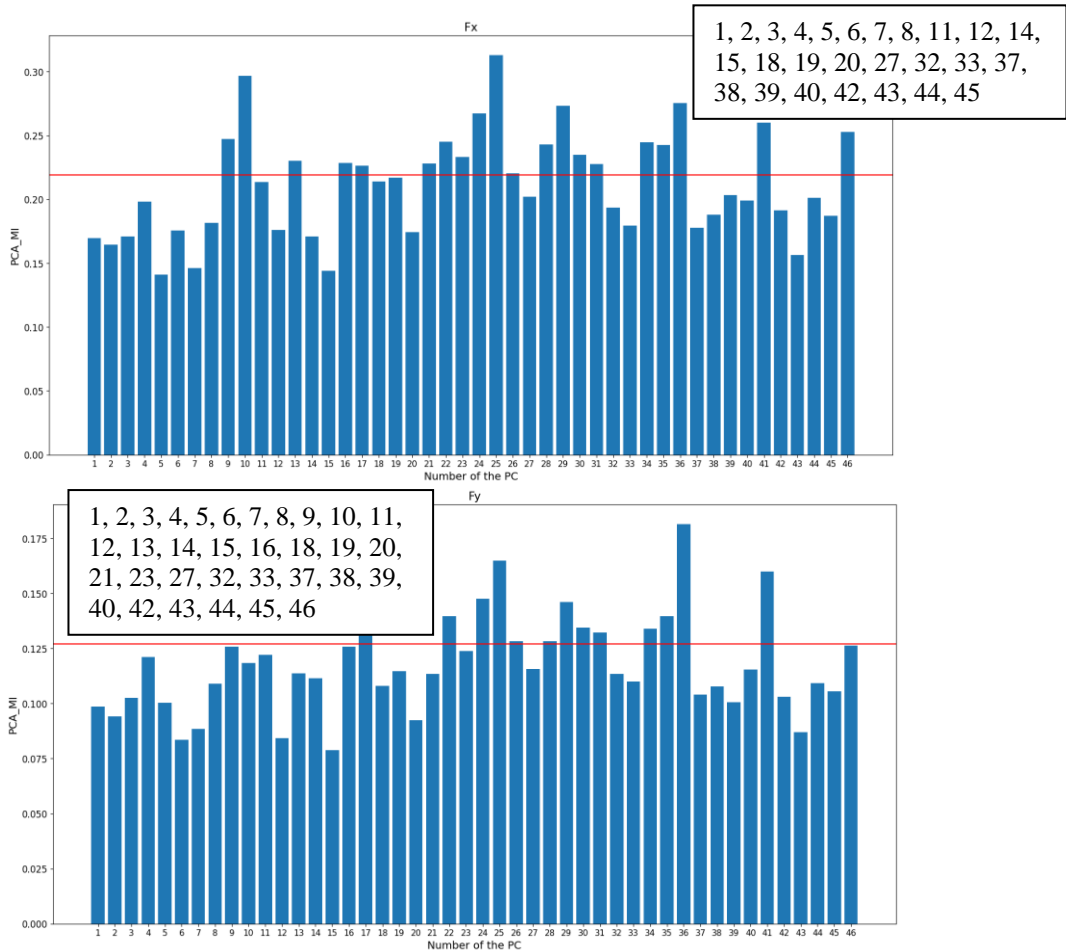


Figure 6.7. Les histogrammes de MI des 3 composantes de la GRF en fonction du numéro de PCs déterminées par PCA de la semelle **Fscan** pour le pied **droit**. Le trait rouge représente 70% de la valeur maximum du MI. Pour chaque composante de la GRF, un rectangle noir contient les numéros des PCs dont les valeurs de MI sont en dessous du trait rouge. Les numéros de PCs supprimés (leur fréquence d'occurrence) sont : {2, 43, 45} (3).






Figure 6.8. Les histogrammes de MI des 3 composantes de la GRF en fonction du numéro de PCs déterminées par PCA de la semelle **Fscan** pour le pied **gauche**. Le trait rouge représente 70% de la valeur maximum du MI. Pour chaque composante de la GRF, un rectangle noir contient les numéros des PCs dont les valeurs de MI sont en dessous du trait rouge. Les numéros de PCs supprimés (leur fréquence d'occurrence) sont : {1, 2, 3, 5, 6, 7, 8, 12, 15, 20, 32, 43} (3).

- **PCA-Block-ANN**

Nous allons utiliser notre méthode proposée dans l'étude numéro 2 du chapitre 4 en combinant PCA avec les trois stratégies (*Block*, *Backward* et *Forward*) pour sélectionner les capteurs importants pour l'estimation des composantes de la GRF des deux pieds et des deux semelles.

Les Figures 6.9 et 6.10 présentent le nombre de capteurs supprimés en utilisant les semelles Moticon et Fscan pour les trois stratégies de sélection en fonction des valeurs de la masse, pour les deux pieds. De plus, le nombre de capteurs supprimés, ainsi que leurs numéros, dépassant 90 % de la valeur maximale de la masse, sont indiqués en utilisant la stratégie de *Block*. Nous choisissons la stratégie *Block* pour la sélection des capteurs car elle garantit la diminution la plus lente de la fonction de masse par rapport à la stratégie *Forward* (Figures 6.9 et 6.10) pour les deux semelles et les deux pieds. De plus, la méthode de la stratégie *Block* est plus simple que la stratégie *Backward* (les deux stratégies *Backward* et *Block* fournissent des valeurs de masse similaires pour les deux pieds).

Pour estimer les composantes de la GRF en utilisant la stratégie *Block*, nous utilisons un ANN dont l'architecture et les paramètres optimaux sont ceux trouvés dans le paragraphe ANN. La seule différence réside dans l'initialisation, où nous avons utilisé une couche d'entrée avec N_3 neurones. N_3 correspond au nombre de capteurs les plus importants sélectionnés avec la stratégie PCA-Block.

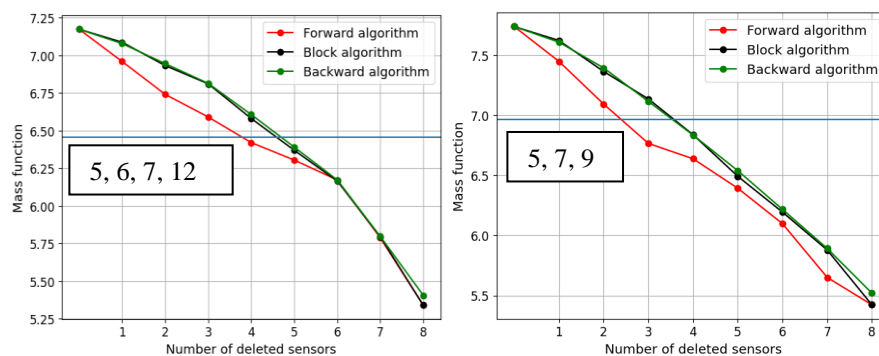


Figure 6.9. Nombre de capteurs supprimés en utilisant la semelle Moticon avec les trois stratégies de sélection pour le pied gauche (image de gauche) et le pied droit (image de droite) en fonction de la valeur de la masse. La ligne horizontale représente 90 % de la valeur maximale de la fonction de masse. En dessous de cette ligne, les numéros de capteurs qui dépassent ce seuil pour la stratégie de *Block* sont supprimés.




Figure 6.10. Nombre de capteurs supprimés en utilisant la semelle Fscan avec les trois stratégies de sélection pour le pied gauche (image du bas) et le pied droit (image du haut) en fonction de la valeur de la masse. La ligne horizontale représente 90 % de la valeur maximale de la fonction de masse. En dessous de cette ligne, les numéros de capteurs qui dépassent ce seuil pour la stratégie de *Block* sont supprimés.

Pour la semelle Moticon, pour des raisons de simplification et étant donné que les architectures et les paramètres optimaux de l'ANN et du PCA-ANN des deux pieds sont les mêmes, nous allons effectuer les tests des configurations uniquement pour le pied droit afin de trouver les meilleures architectures et paramètres pour CNN, LSTM et GRU. Pour le pied gauche, nous utilisons les mêmes paramètres et architectures optimaux que ceux trouvés pour le pied droit.

- **CNN**

Pour la semelle Moticon et le pied droit, nous avons suivi les étapes de la CNN décrites dans la section 5.2

- **LSTM**

Pour la semelle Moticon et le pied droit, nous avons suivi les étapes de l'LSTM décrites dans la section 5.2

- **GRU**

Pour la semelle Moticon et le pied droit, nous avons suivi les étapes de l'LSTM décrites dans la section 5.2. Au lieu d'utiliser des couches LSTM, nous utilisons des couches GRU.

- **ANN en ajoutant les données des accélérations de l'IMU aux données du PP (uniquement pour la semelle Moticon)**

Nous allons utiliser la méthode ANN en prenant comme données d'entrées les 3 variables d'accélération selon les trois axes de l'IMU de la semelle Moticon et les 16 capteurs de pressions (ANN (PP+IMU)). Nous utilisons l'architecture et les paramètres optimaux du ANN.

Pour les deux semelles et les deux pieds, les paramètres optimaux pour les méthodes SVR, KNN et RF, obtenus à partir des simulations, sont présentés dans le Tableau 6.1.

Tableau 6.1. Paramètres optimaux des méthodes SVR, KNN et RF pour les deux pieds et les deux semelles.

Méthode ML	Paramètres optimaux
SVR	SVR avec le noyau RBF pour : $\zeta = 35$ (pour la semelle Fscan) et $\zeta = 20$ (pour la semelle Moticon), $\gamma = 0,1$. Les valeurs de C varient en fonction de l'estimation de chaque composante de la GRF pour (chaque semelle, pied et stratégie) :
	(Moticon, pied droit, intras) : F_z, F_y et $F_x = 50, 10$ et 600
	(Moticon, pied droit, inters) : F_z, F_y et $F_x = 600, 10$ et 100
	(Moticon, pied gauche, intras) : F_z, F_y et $F_x = 100, 100$ et 50
	(Moticon, pied gauche, inters) : F_z, F_y et $F_x = 50, 1$ et 1
	(Fscan, pied droit, intras) : F_z, F_y et $F_x = 100, 600$ et 1
	(Fscan, pied droit, inters) : F_z, F_y et $F_x = 1, 1$ et 1
	(Fscan, pied gauche, intras) : F_z, F_y et $F_x = 50, 10$ et 600
	(Fscan, pied gauche, inters) : F_z, F_y et $F_x = 1, 1$ et 600
KNN	Les valeurs de K varient en fonction de l'estimation de chaque composante de la GRF pour (chaque semelle, pied et stratégie) :
	(Moticon, pied droit, intras) : F_z, F_y et $F_x = 27, 74$ et 62
	(Moticon, pied droit, inters) : F_z, F_y et $F_x = 1881, 19801$ et 461
	(Moticon, pied gauche, intras) : F_z, F_y et $F_x = 27, 111$ et 38
	(Moticon, pied gauche, inters) : F_z, F_y et $F_x = 41, 101$ et 161
	(Fscan, pied droit, intras) : F_z, F_y et $F_x = 3, 73$ et 3
	(Fscan, pied droit, inters) : F_z, F_y et $F_x = 9500, 33000$ et 9990
(Fscan, pied gauche, intras) : F_z, F_y et $F_x = 45, 35$ et 99	
	(Fscan, pied gauche, inters) : F_z, F_y et $F_x = 45500, 31500$ et 29050
RF	$T = 1000$ pour l'estimation des composantes de la GRF pour chaque semelle, pied et stratégie

En utilisant la semelle Moticon, pour les deux pieds, les paramètres et l'architectures optimaux pour les méthodes ANN, MI-ANN, ANN (PP+IMU), PCA-ANN, PCA-MI-ANN, PCA-Block-ANN, CNN, BLSTM et BGRU obtenus à partir des simulations, sont présentés dans le Tableau 6.2. Les méthodes CNN, BLSTM et BGRU ont utilisé les mêmes paramètres optimaux (batch size, optimiseur, taux d'apprentissage, etc.) que l'ANN.

Tableau 6.2. Paramètres et architectures optimaux pour les méthodes ANN, MI-ANN, ANN (PP+IMU), PCA-ANN, PCA-MI-ANN, PCA-Block-ANN, CNN, BLSTM et BGRU en utilisant la semelle Moticon pour les deux pieds. Les paramètres optimaux (batch size, optimiseur, taux d'apprentissage, etc.) de l'ANN sont appliqués au CNN, BLSTM et BGRU.

ANN, MI-ANN, ANN (PP+IMU),	PCA-ANN, PCA-MI-ANN, PCA-Block-ANN	CNN	BLSTM	BGRU
2 couches cachées de (256, 128) neurones, fonction d'activation : leaky relu, méthode de normalisation : BW, batch size : 4, optimiseur : Adamax, taux d'apprentissage : 0,01	2 couches cachées de (256, 128) neurones, fonction d'activation : leaky relu, méthode de normalisation : Moyenne, batch size : 4, optimiseur : Adamax, taux d'apprentissage : 0,01	1 couche de convolution : Conv1D (nombre de filtres = 8, taille du noyau = 4), 1 couche MaxPool1d (taille du noyau = 2), un ANN avec 3 couches cachées de (96, 60, 25) neurones	2 couches BLSTM avec (400, 200) cellules, un ANN avec 3 couches cachées de (400, 300, 150) neurones, une taille de séquence d'entrée égale à 20	2 couches BGRU avec (400, 200) cellules, un ANN avec 3 couches cachées de (400, 300, 150) neurones, une taille de séquence d'entrée égale à 20

En utilisant la semelle Fscan, nous avons conclu que les paramètres et l'architecture optimaux d'ANN avec la semelle Fscan sont les mêmes que ceux d'ANN avec la semelle Moticon, à l'exception de la valeur de batch size, qui est égale à 32. Par souci de simplification, pour estimer les composantes de la GRF des deux pieds, nous avons adopté les mêmes architectures et paramètres optimaux que ceux trouvés en utilisant la semelle Moticon pour les méthodes MI-ANN, PCA-ANN, PCA-MI-ANN, PCA-Block-ANN, CNN, BLSTM et BGRU, à l'exception de la valeur de batch size qui est égale à 32.

6.3 Résultats de l'estimation des composantes de la GRF pour les méthodes de ML et ML-RD

Les Tableaux IV.1 - IV.4 dans l'annexe IV présentent les résultats d'estimation des valeurs de RMSE et R entre les composantes de la GRF estimées (à partir de PP de la semelle) et mesurées (par la plateforme de force) pour les 13 méthodes de ML et RD-ML pour la stratégie intras (8 sujets pour Moticon et 13 sujets pour Fscan) et la stratégie inters (1 seul sujet) des deux pieds en utilisant les deux. Aussi, ces tableaux incluent les valeurs de RMSE et R entre la composante F_z déterminée par la semelle et mesurée par la plateforme de force, notée F_z Mot pour la semelle Moticon et F_z Fsc pour la semelle Fscan.

6.3.1 Discussion

Nous allons discuter et analyser les résultats d'estimation des différentes méthodes de ML et ML-RD, présentés dans les Tableaux IV.1 - IV.4, pour les deux semelles, les deux stratégies et les deux pieds. Pour la stratégie intras, les résultats optimaux dans les Tableaux IV.1 à IV.4 sont présentés en gras, et pour la stratégie inters, ils sont présentés en gras souligné.

À partir des résultats des Tableaux IV.1 - IV.4, nous pouvons conclure que l'estimation de chaque composant de la GRF pour chaque pied dépend de la semelle utilisée, de la méthode de ML et de la stratégie. Aussi, la stratégie inters présente des mauvais résultats par rapport à la stratégie intras, en raison des poids différents des sujets impliqués.

- **La méthode recommandée pour chaque semelle pour estimer les composantes de la GRF**

Les résultats d'estimation avec la méthode ANN en utilisant la semelle Moticon pour les deux pieds, dans le cadre de la stratégie intras, indiquent les meilleurs résultats (les valeurs de RMSE sont égales à 1 par rapport aux résultats optimaux). Pour la stratégie inters, RF présente les meilleurs résultats (les valeurs de RMSE sont égales à 1 par rapport aux résultats optimaux).

Les résultats d'estimation avec la méthode PCA-ANN en utilisant la semelle Fscan pour les deux pieds, pour la stratégie intras, indiquent les meilleurs résultats (les valeurs de RMSE sont de 1 à 1,05 fois plus élevées que les résultats optimaux). Pour la stratégie inters, KNN présente les meilleurs résultats (les valeurs RMSE sont de 1 à 1,13 fois plus élevées que les résultats optimaux).

- **Comparaison des performances d'ANN (IMU+PP) par rapport aux résultats optimaux en utilisant la semelle Moticon**

Dans le cadre de la stratégie intras et pour les deux pieds, la méthode ANN (IMU+PP : 19 entrées) donne des résultats avec des valeurs de RMSE allant de 1 à 1,07 fois supérieures aux résultats optimaux. Pour la stratégie inters, les valeurs de RMSE sont de 1,67 à 3 fois plus élevées que les résultats optimaux.

=>L'ajout des données d'accélération de l'IMU aux données de PP a présenté de bons résultats pour la stratégie intras. Cependant, pour la stratégie inters, les résultats s'écartent fortement de la valeur optimale. De plus, cette méthode, étant donné qu'elle nécessite l'ajout de 3 entrées, augmente légèrement le temps de calcul et le nombre des entrées.

- **Comparaison des performances de PCA-MI-ANN, MI-ANN, PCA-ANN et PCA-Block-ANN par rapport aux résultats optimaux des Tableaux IV.1 - IV.4**

Nous souhaitons comparer les performances des résultats d'estimation des composantes de la GRF entre les méthodes PCA-MI-ANN, MI-ANN, PCA-ANN et PCA-Block-ANN. De plus, nous voulons déterminer quelle méthode de RD permet d'obtenir les meilleurs résultats de réduction de dimension des données de PP.

En utilisant la semelle Moticon, pour les deux pieds et les deux stratégies, la méthode de sélection des capteurs MI-ANN (avec des valeurs de RMSE allant de 1,04 à 3,23 fois plus élevées que les résultats optimaux) est légèrement meilleure que la méthode de sélection des capteurs PCA-Block-ANN (avec des valeurs de RMSE allant de 1,03 à 3,39 fois plus élevées que les résultats optimaux), qui est elle-même meilleure que la méthode de réduction de dimension PCA-ANN (avec des valeurs de RMSE allant de 1 à 4,37 fois plus élevées que les résultats optimaux). Enfin, la méthode de fusion de la réduction avec la sélection, PCA-MI-ANN, présente les performances les moins bonnes (avec des valeurs de RMSE allant de 1 à 4,86 fois plus élevées que les résultats optimaux).

=>Les méthodes MI-ANN et PCA-Block-ANN offrent de meilleures estimations en utilisant la semelle Moticon pour les deux pieds et les deux stratégies. De plus, ces deux méthodes ont permis de réduire le nombre d'entrées de 16 capteurs de pression à 12 capteurs pour le pied gauche et à 15 capteurs (MI) et 13 capteurs (Block) pour le pied droit, réduisant ainsi le temps d'apprentissage de l'ANN. Les méthodes PCA-MI et PCA permettent de réduire la dimension des entrées à 9-10 PCs pour les deux pieds. Toutefois, ces deux méthodes nécessitent de récupérer toutes les données des 16 capteurs de pression pour effectuer la réduction.

En utilisant la semelle Fscan, pour les deux pieds et la stratégie intras, la méthode PCA-ANN (les valeurs de RMSE sont de 1 à 1,05 fois plus élevées que les résultats optimaux), la méthode PCA-MI-ANN (les valeurs de RMSE sont de 1 à 1,07 fois plus élevées que les résultats optimaux) et la méthode PCA-Block-ANN (les valeurs de RMSE sont de 1 à 1,11 fois plus élevées que les résultats optimaux) sont meilleures que la méthode MI-ANN (les valeurs de RMSE sont de 1,09 à 1,31 fois plus élevées que les résultats optimaux). Pour la stratégie inters, la méthode PCA-ANN (avec des valeurs de RMSE allant de 1,18 à 2,06 fois plus élevées que les résultats optimaux) est meilleure que la méthode PCA-MI-ANN (avec des valeurs de RMSE allant 1,03 à 3,06 fois plus élevées que les résultats optimaux), qui est elle-même meilleure que la méthode PCA-Block-ANN (avec des valeurs de RMSE allant de 1,32 à 3,85 fois plus élevées que les résultats optimaux). Enfin, la méthode MI-ANN est la moins performante (avec des valeurs de RMSE allant de 1,69 à 29,69 fois plus élevées que les résultats optimaux).

=>La méthode PCA-ANN a présenté les meilleurs résultats d'estimation pour les deux stratégies, en utilisant la semelle Fscan pour les deux pieds. La méthode PCA permet de réduire la dimension des entrées à 46-47 PCs pour les deux pieds.

- **Comparaison des résultats d'estimation pour les trois composantes de la GRF entre les semelles Fscan et Moticon**

L'estimation de F_z et F_x en utilisant la semelle Moticon est meilleure à celle obtenue avec la semelle Fscan pour les deux stratégies et les deux pieds. En effet, en utilisant la méthode optimale, les valeurs de RMSE pour l'estimation de F_z avec la semelle Moticon vont de 18,69 à 29,23 N et pour l'estimation de F_x de 5,58 à 8,66 N. Ces valeurs sont jusqu'à 5,64 fois inférieures à celles obtenues avec les semelles Fscan (les valeurs de RMSE pour l'estimation de F_z avec la semelle Fscan vont de 94,49 à 164,73 N et les valeurs de RMSE pour l'estimation de F_x vont de 8,86 à 10,43 N).

Les résultats d'estimation de la composante F_y en utilisant les deux semelles pour les deux pieds dépendent de la stratégie. Pour la stratégie intras, pour les deux pieds, en utilisant la méthode optimale, l'utilisation de la semelle Fscan (les valeurs de RMSE varient entre 11,42 et 11,50 N) donne de meilleurs résultats que que la semelle Moticon (les valeurs de RMSE varient entre 14,52 et 14,77 N). Pour la stratégie inters, c'est l'inverse, la semelle Moticon (les valeurs de RMSE varient entre 8,16 et 8,70 N) donne de meilleurs résultats que la semelle Fscan (les valeurs de RMSE varient entre 10,40 et 10,68 N).

=>En effet, nous recommandons l'utilisation de la semelle Moticon pour estimer les composantes de la GRF. Nous pouvons conclure que le nombre plus élevé de capteurs dans une semelle n'entraîne pas nécessairement une meilleure précision dans les résultats d'estimation. Dans notre étude, la semelle Moticon, qui possède seulement un quart du nombre de capteurs de la semelle Fscan, présente les meilleurs résultats. Cela peut être attribué à la sensibilité des capteurs Fscan, comme mentionné dans une étude antérieure [81], par rapport à ceux de Moticon, ce qui peut introduire des erreurs dans l'estimation des composantes de la GRF. De plus, la taille des capteurs de la semelle Fscan est plus petite que celle des capteurs Moticon, nécessitant ainsi une pression plus élevée pour détecter les informations. Notons que la comparaison des semelles est basée sur les mêmes prix de dispositif (16 capteurs pour Moticon et 64 pour Fscan).

- **Comparaison des résultats optimaux de F_z estimé par rapport aux résultats F_z Mot et F_z Fsc**

Les valeurs de RMSE de la composante F_z estimée avec la meilleure méthode de ML ou RD-ML, dans le cadre de la stratégie intras, en utilisant les deux semelles pour les deux pieds, sont de 2,25 à 2,73 fois inférieures à celle déterminées par les semelles (F_z Fsc et F_z Mot). Pour la stratégie inters, les valeurs de RMSE sont de 1,53 à 3,07 fois inférieures à celles déterminées par les deux semelles, sauf pour le pied gauche avec la semelle Fscan, où nous n'avons pas de réduction.

=>En utilisant les deux semelles, l'estimation de F_z avec la méthode de ML ou RD-ML a été améliorée par rapport à celle déterminée avec la semelle, sauf pour le pied gauche avec la semelle Fscan pour la stratégie inters.

6.3.2 Performance des six activités en utilisant la méthode de ML ou ML-RD recommandée

Les Tableaux IV.5 - IV.8 dans annexe IV présentent les valeurs de RMSE et de R entre les composantes de la GRF estimées avec les méthodes recommandées pour les deux semelles et les deux stratégies et les composantes mesurées (par la plateforme) des deux pieds, pour les six activités. Aussi, ces tableaux incluent les valeurs de RMSE et de R entre la composante F_z déterminée par la semelle et mesurée par la plateforme de force.

Le classement de l'estimation des trois composantes de la GRF pour les deux stratégies, en utilisant les deux semelles pour les deux pieds lors des six activités, est le suivant (les valeurs min-max des RMSE sont présentées entre parenthèses) :

-Avec la semelle Moticon, pour les deux stratégies et les deux pieds : statique et Pdc statique (0,70 – 13,29 N) > Pdc bas-haut et Pdc gauche-droite (4,74 – 27,61 N) > la marche lente (5,08 – 52,36 N) > la marche normale (5,21 – 64,08 N) ;

-Avec la semelle Fscan, pour les deux stratégies et les deux pieds : Pdc statique (1,52 – 80,39 N) > statique (2,01 – 95,96 N) > Pdc bas-haut (4,51 – 112,3 N) > Pdc gauche-droite (7,16 – 230,7 N) > la marche lente (9,39 – 225,5 N) > la marche normale (16,96 – 243,7 N).

=>Pour l'estimation des trois composantes de la GRF en utilisant les deux semelles, pour les deux stratégies et les deux pieds, la situation statique et Pdc statique montrent de meilleurs résultats que les deux activités de Pdc et les deux activités de marche (situation dynamique). En d'autres termes, les deux situations statiques ont montré une plus grande précision que les situations dynamiques, ce qui est cohérent car l'estimation des composantes de la GRF dans les cas statiques est beaucoup moins difficile (les variations de PP et des composantes de la GRF mesurées par la plateforme de force sont faibles) que dans les cas dynamiques.

=>Dans l'estimation de la composante F_z pour les deux pieds en utilisant les deux semelles et les deux stratégies, pour les six activités, F_z estimée avec la méthode optimale est meilleure que F_z déterminée par les deux semelles (les valeurs de RMSE de F_z déterminées par les semelles peuvent être jusqu'à 6,5 fois plus élevées que celles estimées), sauf dans le cas de l'estimation pour le pied gauche en utilisant la semelle Fscan et la stratégie inters.

6.4 Conclusion

Nous avons comparé 13 méthodes de ML, avec ou sans méthode de RD (PCA, MI, PCA-MI et PCA-Block). Pour la semelle Moticon et les deux pieds, nous avons montré que ANN a présenté de meilleurs résultats d'estimation des composantes de la GRF pour la stratégie intras, tandis que RF a été plus efficace pour la stratégie inters. Pour la semelle Fscan et les deux pieds, PCA-ANN a été plus efficace pour la stratégie intras, tandis que KNN a présenté de meilleurs résultats pour la stratégie inters. En utilisant la semelle Moticon, l'ajout des données d'accélération de l'IMU aux données de PP a donné de bons résultats pour la stratégie intras, mais de mauvais résultats pour la stratégie inters. Par conséquent, l'ajout de l'IMU n'est pas recommandé, d'autant plus que cela augmente légèrement le temps d'apprentissage.

Aussi, nous avons montré qu'il n'est pas nécessaire de combiner les deux méthodes de RD, PCA et MI, pour améliorer la précision et réduire la dimension des PP, contrairement à ce qui est recommandé dans d'autres études [2, 10, 22] pour les deux semelles.

En utilisant la semelle Moticon, pour les deux pieds et les deux stratégies, MI-ANN présente les meilleurs résultats d'estimation. De plus, la méthode MI permet de réduire le nombre d'entrées de 16 capteurs de pression à 12 capteurs pour le pied gauche et 15 capteurs pour le pied droit, sans nécessiter la récupération de toutes les données des 16 capteurs de pression pour effectuer cette réduction, contrairement à PCA-MI et PCA. Aussi, la méthode PCA-Block-ANN a donné des valeurs de RMSE similaires à celles de la méthode MI-ANN, mais elle a également réduit le nombre de capteurs à 12 pour le pied gauche et 13 pour le pied droit. La réduction du nombre de capteurs avec la méthode PCA-Block est plus importante que celle obtenue avec la méthode MI.

En utilisant la semelle Fscan, pour les deux pieds et les deux stratégies, PCA-ANN a présenté les meilleurs résultats d'estimation. La méthode PCA a permis de réduire la dimension des entrées à 46-47 PCs pour les deux pieds.

Nous avons démontré que la semelle Moticon (avec des capteurs capacitifs) a fourni de meilleurs résultats d'estimation des composantes de la GRF que la semelle Fscan (avec des capteurs résistifs). Il est important de noter que la comparaison des semelles est basée sur des dispositifs de prix équivalents (16 capteurs pour Moticon et 64 pour Fscan).

Nous avons comparé les résultats d'estimation de la composante F_z obtenus avec la méthode de ML ou RD-ML optimale à ceux déterminés par les deux semelles Fscan et Moticon. Dans la plupart des cas (deux pieds, deux semelles et deux stratégies), nous avons réussi à améliorer l'estimation de la composante F_z (les valeurs de RMSE pour les estimations de F_z sont de 1,53 à 3,07 fois inférieures à celle déterminées par les semelles).

Pour l'estimation des trois composantes de la GRF en utilisant les deux semelles, pour les deux stratégies et les deux pieds, nous avons démontré que les situations statiques (la situation statique et Pdc statique) offrent une précision supérieure à celle des situations dynamiques (les deux activités de Pdc et les deux activités de marche). Cela est cohérent, car l'estimation des composantes de la GRF dans les cas statiques est beaucoup moins difficile (les variations de PP et des composantes de la GRF mesurées par la plateforme de force sont faibles) que dans les cas dynamiques.

Chapitre 7 Conclusion et perspective

La détermination des trois composantes de la force de réaction au sol (*Ground Reaction Force*, GRF) (médio-latérale F_x , antéro-postérieure F_y et verticale F_z) est importante pour le calcul de contraintes mécaniques que peut subir un individu. Pour des études de terrain, cette estimation se réalise à partir de mesures de capteurs de pression, intégrés dans un réseau de semelles instrumentées, au moyen de méthodes d'apprentissages, en référence à des mesures directes sur la plateforme de force. Ces méthodes, dans un contexte d'application qui se veut ambulatoire, nécessitent des réductions de coût de calcul, tout en conservant une estimation acceptable de ces grandeurs. La réduction du coût de calcul est classiquement réalisée par une réduction de dimension des variables d'entrée au moyen d'analyse en composantes principale (*Principal Component Analysis*, PCA). Cette dernière nécessite une étape de normalisation. Il s'est avéré qu'aucune légitimation (théorique ou comparative) sur le type de normalisation n'a été réalisée dans la littérature, au regard de la précision d'estimation des composantes de la GRF. De plus, toujours dans le but de réduire à la fois les coûts de calcul et matériel, il n'a pas été exploité, au moyen de la PCA, la possibilité de sélectionner le nombre optimal de capteurs au regard de leur localisation dans les semelles instrumentées. C'est pourquoi nous avons réalisé les **études 1 et 2** sur l'incidence des types de normalisation et sur les capacités de sélection de capteurs dans la méthode PCA, combinées à différentes méthodes d'apprentissages pour l'activité de marche.

Douze types de normalisation ont été évalués dans l'**étude 1** du chapitre 3, combinés à trois méthodes d'apprentissage automatique (*Machine Learning*, ML) : moindres carrés (*Least Squares*, LS) ; réseau de neurones artificiels (*Artificial Neural Network*, ANN) ; régression à vecteurs de support (*Support Vector Regression*, SVR). Cette étude a été réalisée pour les activités de marche avec la semelle Moticon. Cette étude a montré que la performance des types de normalisation dépend de la méthode de ML. Pour la LS et l'ANN, la normalisation « Standardisation Vectorielle » est la plus performante, tandis que pour la SVR, le type « Moyenne » donne de meilleurs résultats.

La **seconde étude** du chapitre 4 a exploré la performance de l'estimation des trois composantes de la GRF, avec ou sans sélection de capteurs, dans le cadre de la méthode ANN. Trois stratégies de sélection de capteurs ont été proposées après la transformation de PCA : *Forward* (vers l'avant) ; *Backward* (en amont) ; *Block* (par blocs). Dans cette étude, nous nous sommes intéressés aux activités de marche. Deux semelles différentes ont été utilisées : Moticon (technologie capacitive) et Fscan (technologie résistive) comportant 16 et 64 capteurs, respectivement. La diminution de 19 % et de 50 % de capteurs pour les semelles Moticon et les Fscan, respectivement, a peu impacté la précision de l'estimation des composantes de la GRF par rapport à l'utilisation de tous les capteurs. Un résultat remarquable est que la diminution du nombre de capteurs a conduit à de meilleures estimations pour la composante verticale. De plus, il apparaît que la performance de la semelle Moticon, malgré un réseau de capteur plus restreint, est supérieure à celle de la semelle Fscan (16 contre 64 capteurs). Ceci peut s'expliquer par la technologie capacitive utilisée dans la semelle Moticon, ainsi que par la plus grande surface unitaire de ses capteurs, ce qui leur confère une sensibilité supérieure à celle des capteurs résistifs de la semelles Fscan, qui ont une surface unitaire plus petite.

Les méthodes de ML n'ont pas non plus été comparées de manière approfondie et seules un nombre restreint de méthodes a été exploité, avec un accent principalement mis sur l'apprentissage profond (*Deep Learning*, DL). C'est pourquoi, il est recommandé dans la littérature [2, 22, 23-25] l'utilisation des méthodes ANN et de la mémoire à long terme bidirectionnelle (*Bidirectional Long Short-Term Memory*, BLSTM). Cependant, les modèles DL nécessitent une puissance de calcul élevée et un temps d'apprentissage plus long [38]. De plus, pour obtenir le modèle DL optimal, il est nécessaire d'ajuster plusieurs hyperparamètres tels que l'optimiseur, le taux d'apprentissage et le nombre de couches cachées. En revanche, les modèles automatiques supervisés (*Supervised Machine Learning*, SML) sont plus simples à déployer. Aussi, dans d'autres domaines [39-41], les méthodes DL n'ont pas toujours montré une supériorité de performance comparativement à celle de méthodes SML. Nous avons donc réalisé une étude comparative des méthodes de ML (**étude 3** du chapitre 5), regroupant trois méthodes DL (ANN, LSTM et un réseau neuronal convolutif / *Convolutional Neural Network*, CNN) et trois méthodes SML (SVR, LS et forêt d'arbres décisionnels / *Random Forest*, RF). Cette étude a été réalisée pour les activités

de marche, statique et Port de charge (Pdc) avec la semelle Moticon. Les méthodes DL ne sont pas toujours le choix optimal. En particulier, la méthode RF a montré des performances supérieures comparativement aux trois méthodes de DL. De plus, la méthode RF nécessite moins de réglages d'hyperparamètres que les modèles DL, ce qui rend la recherche du meilleur modèle plus rapide et plus simple.

Seules trois méthodes de ML, à savoir ANN, LS et BLSTM, ont été testées dans les études [2, 10, 22-26]. De plus, des études [2, 10, 22] ont combiné deux méthodes de Réduction de Dimension (RD) des données de pression, PCA et l'information mutuelle (*Mutual Information*, MI), sans préciser pourquoi elles ont opté pour cette combinaison plutôt qu'une seule méthode. **La quatrième étude** du chapitre 6 s'est donc concentrée sur la comparaison de la précision de l'estimation des composantes de la GRF entre 13 méthodes de ML, avec ou sans méthode de RD (PCA, MI, PCA-MI et la méthode de sélection des capteurs (PCA-Block) proposée dans l'étude 2 du chapitre 4, en utilisant les semelles Moticon et Fscan. Les 13 méthodes de ML incluent : SVR, k plus proches voisins (*K-Nearest Neighbors*, KNN), RF, LS, ANN, PCA-ANN, PCA-MI-ANN, MI-ANN, PCA-Block-ANN, CNN, LSTM et les unités récurrentes fermées (*Gated Recurrent Unit*, GRU). De plus, nous avons testé ANN en utilisant à la fois les données de pression et les données d'accélération selon les trois axes de la centrale inertielle (*Inertial Measurement Unit*, IMU) uniquement pour la semelle Moticon, afin d'examiner si l'ajout des données IMU améliore la précision de l'estimation, un aspect qui n'a pas encore été étudié dans la littérature. Cette étude a été réalisée pour les activités de marche, statique et Pdc avec les semelles Moticon et Fscan.

Pour la semelle Moticon, nous avons montré que les méthodes ANN et RF ont donné de meilleurs résultats d'estimation, tandis que PCA-ANN et KNN ont donné de meilleurs résultats pour la semelle Fscan. De plus, en utilisant la semelle Moticon, l'ajout de l'IMU n'est pas recommandé, car il n'améliore pas les résultats d'estimation et augmente légèrement le temps d'apprentissage. Nous avons également montré qu'il n'est pas nécessaire de combiner PCA et MI pour améliorer la précision et réduire la dimension des données de pression. Avec la semelle Moticon, MI-ANN a donné les meilleurs résultats d'estimation. De plus, la méthode MI permet une réduction de 16 % du nombre de capteurs sans nécessiter les données complètes des 16 capteurs, contrairement à PCA-MI et PCA. La méthode PCA-Block-ANN a produit des résultats d'estimation similaires à ceux de MI-ANN tout en permettant une réduction de 22 % du nombre de capteurs, ce qui est plus important que la réduction obtenue avec MI. Pour la semelle Fscan, PCA-ANN a présenté les meilleurs résultats d'estimation.

Par ailleurs, la stratégie d'apprentissage peut être menée de deux manières différentes : soit dans une stratégie intrasujet ; soit dans une stratégie intersujet. Dans la grande majorité de nos travaux, la première stratégie s'est avérée plus performante que la seconde. Ceci est dû à la variation importante de poids parmi les groupes de sujets de nos études. La stratégie intersujet nécessite, pour obtenir des résultats plus performants, un nombre élevé de sujets dont les poids sont proches les uns des autres.

De plus, nos résultats sont fondés sur des méthodes de ML qui dépendent du contexte d'apprentissage, y compris le profil des sujets et les types d'activités. Étant donné que nos travaux ont été menés sur des sujets adultes valides, nos résultats ne sont applicables qu'à ce type de population et doivent être réévalués pour d'autres groupes spécifiques, tels que les enfants, les personnes âgées, les sportifs de haut niveau, et les personnes ayant des dysfonctionnements moteurs etc. Nos travaux concernaient des activités de marche lente et normale, de posture statique avec et sans Pdc, de manutention de charge horizontalement de gauche à droite et inversement, verticalement de bas en haut et inversement. Dans ces études, la masse de la charge portée et manutentionnée était de 5 kg. Nous avons privilégié ces types d'activité au regard du cadre applicatif de cette thèse qui concerne en premier lieu le monde du travail de la manutention et du Pdc. Nos résultats sont donc valides pour ces conditions d'activité. Il est donc nécessaire de réévaluer les performances des méthodes proposées lorsque nous nous écartons de ces conditions.

Annexe I : Moyenne \pm écart type de RMSE (R) entre les composantes estimées et mesurées avec la semelle Moticon pour PCA-ANN, PCA-LS et PCA-SVR pour l'ensemble de données de test pour les activités de marche

Tableau I.1. Moyenne \pm écart type de RMSE (R) entre les composantes F_x et F_y estimées (par les données de PP de la semelle) et mesurées (par la plateforme de force) pour les 9 modèles, en considérant les stratégies intras et inters, en utilisant les données de test du pied gauche. Les meilleurs résultats pour la stratégie **intras** sont en gras et pour **l'inters** sont en gras souligné.

Stratégie	Méthode de normalisation	Nombre de PCs	F_x (N)			F_y (N)			
			PCA-ANN	PCA-LS	PCA-SVR	PCA-ANN	PCA-LS	PCA-SVR	
Intras	MM _[0,1]	10-9	13,89 (0,712) $\pm 0,56$ (0,016)	14,97 (0,641) \pm 0,67 (0,028)	13,83 (0,710) \pm 0,51 (0,009)	30,92 (0,647) \pm 2,13 (0,032)	33,05 (0,546) \pm 1,04 (0,025)	29,85 (0,666) $\pm 1,80$ (0,029)	
	MM _[-1,1]	10-9	14,12 (0,707) $\pm 0,87$ (0,023)	14,99 (0,639) \pm 0,68 (0,028)	14,30 (0,681) \pm 0,46 (0,018)	31,48 (0,632) \pm 2,51 (0,051)	33,03 (0,547) \pm 1,03 (0,024)	29,04 (0,675) $\pm 1,13$ (0,020)	
	Mean	10-9	14,09 (0,712) $\pm 1,01$ (0,025)	15,12 (0,633) \pm 0,78 (0,028)	13,78 (0,712) \pm 0,56 (0,010)	30,93 (0,643) \pm 2,17 (0,038)	33,09 (0,544) \pm 1,11 (0,031)	29,24 (0,679) $\pm 1,70$ (0,028)	
	ZS	10	13,88 (0,720) $\pm 1,05$ (0,029)	15,11 (0,633) \pm 0,77 (0,027)	16,78 (0,549) \pm 0,43 (0,020)	30,21 (0,663) \pm 1,55 (0,023)	32,60 (0,562) \pm 1,07 (0,031)	36,11 (0,452) $\pm 0,96$ (0,027)	
	RS	10-9	14,11 (0,706) $\pm 0,50$ (0,015)	15,20 (0,626) \pm 0,88 (0,037)	15,36 (0,644) 0,22 (0,019)	30,28 (0,656) \pm 1,74 (0,027)	33,10 (0,545) \pm 1,32 (0,020)	31,79 (0,607) $\pm 0,87$ (0,024)	
	VS	10	14,23 (0,697) $\pm 0,60$ (0,019)	14,92 (0,646) \pm 0,69 (0,019)	14,78 (0,656) \pm 0,672 (0,021)	31,33 (0,620) \pm 1,22 (0,039)	32,85 (0,555) \pm 0,84 (0,030)	32,85 (0,551) $\pm 0,84$ (0,026)	
	MLS	10-9	14,11 (0,709) $\pm 0,70$ (0,027)	14,97 (0,641) \pm 0,67 (0,028)	13,83 (0,710) \pm 0,51 (0,009)	30,95 (0,644) \pm 2,50 (0,042)	33,05 (0,546) \pm 1,04 (0,025)	29,85 (0,666) $\pm 1,80$ (0,029)	
	DS	6	14,82 (0,658) $\pm 0,83$ (0,031)	16,03 (0,559) \pm 0,66 (0,072)	15,18 (0,624) \pm 0,63 (0,047)	31,92 (0,599) \pm 1,68 (0,041)	33,04 (0,547) \pm 1,00 (0,023)	31,30 (0,607) $\pm 1,28$ (0,024)	
	Med	9-8	15,40 (0,655) $\pm 0,99$ (0,033)	14,94 (0,640) \pm 0,73 (0,029)	17,57 (0,494) \pm 0,49 (0,009)	31,94 (0,613) \pm 1,04 (0,035)	33,16 (0,545) \pm 1,33 (0,031)	37,44 (0,362) $\pm 0,89$ (0,035)	
	Tanh	10	15,20 (0,621) $\pm 0,72$ (0,030)	15,17 (0,630) \pm 0,69 (0,021)	15,19 (0,633) \pm 0,77 (0,026)	32,85 (0,550) \pm 0,80 (0,049)	33,10 (0,542) \pm 1,09 (0,049)	33,19 (0,535) $\pm 0,93$ (0,048)	
	BW	9	14,80 (0,699) $\pm 1,01$ (0,018)	15,35 (0,648) \pm 0,45 (0,024)	19,29 (0,257) \pm 0,63 (0,014)	31,55 (0,627) \pm 1,59 (0,044)	33,66 (0,534) \pm 1,25 (0,030)	39,30 (0,006) $\pm 1,15$ (0,001)	
	LI	9-8	14,47 (0,686) $\pm 0,54$ (0,016)	15,26 (0,621) \pm 0,76 (0,029)	19,13 (0,282) \pm 0,61 (0,024)	30,88 (0,647) \pm 1,44 (0,035)	33,52 (0,530) \pm 0,86 (0,023)	39,30 (0,013) $\pm 1,15$ (0,008)	
	Inters	MM _[0,1]	10-9	17,48 (0,528) $\pm 3,92$ (0,191)	15,10 (0,610) \pm 3,42 (0,138)	17,68 (0,473) \pm 2,97 (0,139)	38,09 (0,538) \pm 8,74 (0,123)	32,62 (0,638) \pm 6,62 (0,088)	37,94 (0,527) $\pm 7,06$ (0,097)
		MM _[-1,1]	10-9	17,96 (0,528) $\pm 4,58$ (0,203)	15,16 (0,613) \pm 3,38 (0,140)	16,33 (0,546) \pm 4,40 (0,117)	38,53 (0,574) \pm 9,56 (0,091)	32,61 (0,639) \pm 6,63 (0,088)	35,34 (0,513) $\pm 9,77$ (0,114)
Mean		10-9	18,85 (0,525) $\pm 4,64$ (0,191)	14,87 (0,623) \pm 3,86 (0,143)	17,14 (0,502) \pm 3,50 (0,159)	38,95 (0,529) \pm 13,6 (0,201)	31,43 (0,652) \pm 6,29 (0,086)	37,75 (0,528) $\pm 7,83$ (0,084)	
ZS		10	17,32 (0,526) $\pm 4,89$ (0,205)	15,12 (0,587) \pm 2,96 (0,139)	17,52 (0,514) \pm 4,23 (0,087)	41,60 (0,528) \pm 12,2 (0,134)	32,32 (0,619) \pm 6,93 (0,091)	39,58 (0,175) $\pm 11,1$ (0,071)	
RS		10-9	18,01 (0,532) $\pm 4,93$ (0,227)	14,88 (0,593) \pm 3,64 (0,195)	16,94 (0,547) \pm 4,46 (0,102)	36,43 (0,585) \pm 9,60 (0,077)	32,28 (0,634) \pm 7,27 (0,082)	37,70 (0,370) $\pm 11,3$ (0,085)	
VS		10	14,66 (0,602) $\pm 3,32$ (0,155)	14,56 (0,620) \pm 2,83 (0,136)	14,94 (0,623) \pm 3,60 (0,149)	32,62 (0,649) \pm 6,72 (0,053)	32,07 (0,637) \pm 6,71 (0,085)	31,60 (0,636) $\pm 6,77$ (0,085)	
MLS		10-9	18,49 (0,525) $\pm 5,60$ (0,201)	15,10 (0,610) \pm 3,42 (0,138)	17,68 (0,473) \pm 2,97 (0,139)	38,89 (0,528) \pm 11,7 (0,183)	32,62 (0,638) \pm 6,62 (0,088)	37,94 (0,527) $\pm 7,06$ (0,097)	
DS		6	18,23 (0,521) $\pm 5,52$ (0,198)	17,26 (0,524) \pm 4,54 (0,150)	16,88 (0,532) \pm 4,62 (0,159)	33,89 (0,615) \pm 7,11 (0,071)	32,62 (0,625) \pm 6,48 (0,094)	32,52 (0,631) $\pm 6,69$ (0,065)	
Med		9-8	16,51 (0,567) $\pm 4,88$ (0,152)	14,68 (0,601) \pm 3,14 (0,148)	17,93 (0,486) \pm 4,24 (0,113)	35,35 (0,606) \pm 7,85 (0,060)	31,99 (0,634) \pm 7,07 (0,094)	39,68 (0,131) $\pm 11,3$ (0,087)	
Tanh		10	15,07 (0,616) $\pm 3,58$ (0,138)	14,78 (0,595) \pm 2,88 (0,136)	15,14 (0,605) \pm 3,26 (0,140)	31,81 (0,638) \pm 6,99 (0,071)	32,29 (0,620) \pm 6,92 (0,092)	31,50 (0,638) $\pm 7,09$ (0,080)	
BW		9	17,52 (0,567) $\pm 4,15$ (0,106)	16,00 (0,598) \pm 3,85 (0,139)	19,14 (0,286) \pm 3,73 (0,081)	41,60 (0,513) \pm 10,0 (0,138)	32,97 (0,624) \pm 7,14 (0,074)	40,06 (0,006) $\pm 11,0$ (0,003)	
LI		9-8	17,26 (0,530) $\pm 3,43$ (0,150)	14,49 (0,634) \pm 3,11 (0,109)	19,04 (0,310) \pm 3,77 (0,082)	42,90 (0,463) \pm 12,3 (0,233)	33,03 (0,610) \pm 8,52 (0,097)	40,06 (0,018) $\pm 11,0$ (0,017)	

Tableau I.2. Moyenne \pm écart type de RMSE (R) entre la composante F_z estimée (par les données de PP de la semelle) et mesurée (par la plateforme de force) pour les 9 modèles, en considérant les stratégies intras et inters, en utilisant les données de test du pied gauche. Les meilleurs résultats pour la stratégie **intras** sont en gras et pour **l'inters** sont en gras souligné.

Stratégie	Méthode de normalisation	Nombre de PCs	F_z (N)		
			PCA-ANN	PCA-LS	PCA-SVR
Intras	MM _[0,1]	10-9	63,13 (0,977) \pm 4,15 (0,003)	83,36 (0,957) \pm 12,67 (0,013)	59,99 (0,979) \pm 4,39 (0,003)
	MM _[-1,1]	10-9	64,70 (0,976) \pm 4,63 (0,003)	84,66 (0,956) \pm 12,27 (0,013)	73,40 (0,969) \pm 1,62 (0,002)
	Mean	10-9	62,84 (0,978) \pm 3,95 (0,002)	82,50 (0,959) \pm 8,73 (0,008)	59,35 (0,979) \pm 3,16 (0,002)
	ZS	10	63,38 (0,977) \pm 5,15 (0,004)	77,53 (0,964) \pm 7,22 (0,007)	160,81 (0,837) \pm 6,03 (0,012)
	RS	10-9	71,06 (0,971) \pm 6,78 (0,005)	96,11 (0,941) \pm 22,12 (0,028)	108,83 (0,931) \pm 5,96 (0,009)
	VS	10	72,93 (0,970) \pm 5,55 (0,004)	83,13 (0,958) \pm 6,43 (0,008)	87,15 (0,956) \pm 11,69 (0,012)
	MLS	10-9	66,40 (0,975) \pm 5,77 (0,004)	83,36 (0,957) \pm 12,67 (0,013)	59,99 (0,979) \pm 4,39 (0,003)
	DS	6	108,91 (0,941) \pm 24,48 (0,020)	123,45 (0,886) \pm 42,53 (0,092)	104,16 (0,924) \pm 33,72 (0,059)
	Med	9-8	112,89 (0,928) \pm 13,25 (0,017)	101,34 (0,936) \pm 15,50 (0,022)	185,00 (0,776) \pm 7,14 (0,016)
	Tanh	10	81,53 (0,959) \pm 10,25 (0,010)	79,49 (0,962) \pm 7,37 (0,007)	85,32 (0,96) \pm 14,24 (0,011)
	BW	9	61,84 (0,978) \pm 4,67 (0,003)	109,14 (0,945) \pm 7,68 (0,006)	271,29 (0,442) \pm 6,35 (0,009)
	LI	9-8	72,49 (0,969) \pm 5,71 (0,005)	84,87 (0,956) \pm 12,36 (0,013)	264,95 (0,478) \pm 6,24 (0,010)
Inters	MM _[0,1]	10-9	107,47 (0,944) \pm 25,07 (0,020)	106,96 (0,940) \pm 31,80 (0,030)	112,41 (0,942) \pm 42,21 (0,021)
	MM _[-1,1]	10-9	110,61 (0,936) \pm 25,71 (0,016)	106,95 (0,941) \pm 31,81 (0,030)	118,08 (0,934) \pm 50,36 (0,030)
	Mean	10-9	102,51 (0,942) \pm 17,42 (0,025)	98,15 (0,947) \pm 25,42 (0,025)	106,51 (0,946) \pm 40,92 (0,022)
	ZS	10	106,30 (0,933) \pm 29,23 (0,029)	98,63 (0,949) \pm 24,00 (0,018)	183,11 (0,808) \pm 36,42 (0,046)
	RS	10-9	120,47 (0,912) \pm 38,21 (0,086)	117,99 (0,919) \pm 54,84 (0,085)	146,61 (0,888) \pm 45,29 (0,044)
	VS	10	91,65 (0,949) \pm 24,34 (0,013)	101,65 (0,949) \pm 36,60 (0,027)	98,20 (0,951) \pm 31,74 (0,030)
	MLS	10-9	114,30 (0,938) \pm 32,34 (0,017)	106,96 (0,94) \pm 31,80 (0,030)	112,41 (0,942) \pm 42,21 (0,021)
	DS	6	149,84 (0,904) \pm 54,20 (0,047)	145,49 (0,896) \pm 73,81 (0,090)	120,89 (0,921) \pm 59,96 (0,052)
	Med	9-8	127,73 (0,905) \pm 40,76 (0,035)	95,79 (0,945) \pm 20,06 (0,022)	197,21 (0,766) \pm 3360 (0,073)
	Tanh	10	90,14 (0,952) \pm 19,02 (0,019)	96,70 (0,952) \pm 26,18 (0,020)	97,39 (0,951) \pm 16,28 (0,023)
	BW	9	95,87 (0,949) \pm 27,95 (0,026)	115,54 (0,946) \pm 35,99 (0,024)	269,09 (0,471) \pm 25,96 (0,041)
	LI	9-8	147,79 (0,923) \pm 72,68 (0,032)	108,84 (0,953) \pm 35,87 (0,019)	264,68 (0,497) \pm 25,53 (0,041)

Tableau I.3. Moyenne \pm écart type de RMSE (R) entre les composantes F_x et F_y estimées (par les données de PP de la semelle) et mesurées (par la plateforme de force) pour les 9 modèles, en considérant les stratégies intras et inters, en utilisant les données de test du pied droit. Les meilleurs résultats pour la stratégie **intras** sont en gras et pour **l'inters** sont en gras souligné.

Stratégie	Méthode de normalisation	Nombre de PCs	F_x (N)			F_y (N)		
			PCA-ANN	PCA-LS	PCA-SVR	PCA-ANN	PCA-LS	PCA-SVR
Intras	MM _[0,1]	10-9	11,35 (0,887) \pm 0,56 (0,009)	13,86 (0,823) \pm 0,58 (0,013)	12,51 (0,857) \pm 0,72 (0,011)	33,47 (0,624) \pm 1,75 (0,033)	31,67 (0,624) \pm 1,37 (0,026)	31,64 (0,646) \pm 1,50 (0,025)
	MM _[-1,1]	10-9	11,73 (0,881) \pm 0,50 (0,008)	13,67 (0,829) \pm 0,73 (0,011)	13,82 (0,825) \pm 0,825 (0,010)	32,00 (0,641) \pm 1,20 (0,024)	31,73 (0,622) \pm 1,40 (0,026)	32,66 (0,610) \pm 1,79 (0,033)
	Mean	10-9	11,40 (0,885) \pm 0,58 (0,009)	13,86 (0,823) \pm 0,59 (0,013)	12,49 (0,858) \pm 0,73 (0,012)	33,34 (0,621) \pm 1,51 (0,031)	31,67 (0,624) \pm 1,376 (0,026)	31,55 (0,649) \pm 1,68 (0,028)
	ZS	10	11,28 (0,888) \pm 0,65 (0,013)	13,66 (0,829) \pm 0,75 (0,027)	17,84 (0,699) \pm 0,84 (0,016)	32,38 (0,648) \pm 1,75 (0,048)	31,67 (0,625) \pm 1,50 (0,015)	37,65 (0,425) \pm 1,47 (0,039)
	RS	10-9	11,68 (0,880) \pm 0,60 (0,010)	13,38 (0,837) \pm 0,64 (0,012)	16,34 (0,753) \pm 0,79 (0,019)	33,12 (0,630) \pm 2,06 (0,040)	31,76 (0,621) \pm 1,27 (0,015)	35,93 (0,502) \pm 1,78 (0,046)
	VS	10	11,75 (0,876) \pm 0,55 (0,012)	13,34 (0,838) \pm 0,36 (0,011)	13,50 (0,835) \pm 0,44 (0,011)	31,34 (0,653) \pm 1,44 (0,029)	31,65 (0,624) \pm 1,04 (0,023)	31,26 (0,636) \pm 1,03 (0,021)
	MLS	10-9	11,51 (0,883) \pm 0,48 (0,008)	13,86 (0,823) \pm 0,58 (0,013)	12,50 (0,857) \pm 0,72 (0,011)	32,32 (0,636) \pm 1,33 (0,032)	31,67 (0,624) \pm 1,37 (0,026)	31,64 (0,646) \pm 1,50 (0,025)
	DS	6	12,79 (0,853) \pm 0,55 (0,014)	14,51 (0,804) \pm 1,18 (0,027)	13,66 (0,830) \pm 0,91 (0,014)	32,16 (0,624) \pm 1,90 (0,030)	32,12 (0,612) \pm 1,28 (0,016)	31,26 (0,637) \pm 1,49 (0,013)
	Med	9-8	14,88 (0,811) \pm 1,64 (0,032)	14,33 (0,809) \pm 0,92 (0,028)	19,37 (0,615) \pm 0,75 (0,020)	31,63 (0,665) \pm 2,13 (0,030)	31,56 (0,627) \pm 1,04 (0,021)	39,39 (0,292) \pm 1,86 (0,061)
	Tanh	10	13,36 (0,836) \pm 0,63 (0,020)	13,64 (0,829) \pm 0,82 (0,028)	14,26 (0,818) \pm 0,84 (0,027)	30,80 (0,649) \pm 1,25 (0,014)	31,46 (0,631) \pm 1,32 (0,013)	31,17 (0,644) \pm 1,24 (0,012)
	BW	9	12,55 (0,862) \pm 0,80 (0,018)	14,70 (0,799) \pm 0,97 (0,025)	22,91 (0,390) \pm 0,88 (0,005)	33,33 (0,613) \pm 2,12 (0,057)	31,94 (0,615) \pm 1,35 (0,024)	40,53 (0,002) \pm 1,76 (0,004)

	LI	9-8	11,53 (0,883) ± 0,52 (0,013)	14,03 (0,819) ± 0,72 (0,015)	22,59 (0,431) ± 0,86 (0,009)	32,78 (0,621) ± 1,96 (0,049)	32,01 (0,611) ± 1,23 (0,035)	40,52 (0,032) ± 1,76 (0,011)
Inters	MM _[0,1]	10-9	16,79 (0,777) ± 5,51 (0,064)	14,43 (0,799) ± 2,72 (0,065)	15,19 (0,786) ± 2,53 (0,082)	47,92 (0,434) ± 23,01 (0,180)	34,01 (0,594) ± 8,89 (0,099)	39,48 (0,429) ± 9,67 (0,127)
	MM _[-1,1]	10-9	16,18 (0,770) ± 3,45 (0,071)	14,57 (0,796) ± 2,85 (0,067)	16,75 (0,765) ± 3,34 (0,078)	44,49 (0,450) ± 19,78 (0,161)	34,22 (0,589) ± 8,81 (0,094)	37,96 (0,388) ± 11,41 (0,090)
	Mean	10-9	17,62 (0,776) ± 8,06 (0,078)	14,54 (0,797) ± 2,87 (0,068)	15,15 (0,787) ± 2,48 (0,080)	41,33 (0,486) ± 14,35 (0,147)	34,04 (0,593) ± 8,93 (0,098)	39,12 (0,438) ± 9,08 (0,130)
	ZS	10	15,38 (0,779) ± 3,35 (0,080)	15,29 (0,788) ± 3,18 (0,067)	19,42 (0,654) ± 3,50 (0,073)	42,61 (0,481) ± 12,71 (0,154)	34,30 (0,584) ± 9,75 (0,095)	39,86 (0,140) ± 12,56 (0,053)
	RS	10-9	16,12 (0,739) ± 3,81 (0,110)	15,35 (0,772) ± 3,37 (0,084)	18,56 (0,695) ± 3,37 (0,070)	47,21 (0,482) ± 15,43 (0,124)	33,29 (0,599) ± 10,02 (0,081)	40,00 (0,225) ± 12,17 (0,052)
	VS	10	14,14 (0,798) ± 3,25 (0,089)	14,25 (0,796) ± 2,35 (0,078)	14,21 (0,798) ± 2,26 (0,082)	39,03 (0,515) ± 12,48 (0,169)	33,70 (0,587) ± 9,40 (0,085)	33,21 (0,601) ± 9,35 (0,086)
	MLS	10-9	14,53 (0,810) ± 2,70 (0,067)	14,42 (0,799) ± 2,72 (0,065)	15,19 (0,786) ± 2,53 (0,082)	42,61 (0,520) ± 18,24 (0,138)	34,01 (0,594) ± 8,89 (0,099)	39,48 (0,429) ± 9,67 (0,127)
	DS	6	15,57 (0,744) ± 2,98 (0,122)	15,34 (0,765) ± 2,76 (0,100)	14,72 (0,774) ± 2,91 (0,094)	37,21 (0,523) ± 9,74 (0,122)	33,20 (0,592) ± 9,26 (0,097)	33,14 (0,591) ± 9,35 (0,108)
	Med	9-8	17,82 (0,740) ± 4,69 (0,097)	15,051 (0,79) ± 2,17 (0,076)	20,07 (0,602) ± 3,48 (0,072)	43,86 (0,518) ± 22,05 (0,154)	33,21 (0,610) ± 9,82 (0,081)	39,62 (0,081) ± 12,72 (0,045)
	Tanh	10	14,50 (0,802) ± 2,61 (0,064)	15,19 (0,788) ± 3,17 (0,065)	15,54 (0,792) ± 2,65 (0,061)	33,07 (0,606) ± 9,43 (0,099)	34,38 (0,585) ± 9,40 (0,094)	33,57 (0,597) ± 9,42 (0,093)
	BW	9	16,96 (0,757) ± 4,76 (0,079)	16,00 (0,797) ± 3,19 (0,066)	22,66 (0,401) ± 3,96 (0,043)	44,02 (0,435) ± 15,34 (0,200)	33,73 (0,587) ± 8,64 (0,114)	39,56 (0,010) ± 12,99 (0,015)
	LI	9-8	16,09 (0,770) ± 4,25 (0,099)	14,99 (0,780) ± 2,16 (0,088)	22,46 (0,429) ± 3,96 (0,047)	41,44 (0,469) ± 9,86 (0,079)	33,92 (0,576) ± 10,47 (0,109)	39,55 (0,038) ± 12,99 (0,019)

Tableau I.4. Moyenne ± écart type de RMSE (R) entre la composante F_z estimée (par les données de PP de la semelle) et mesurée (par la plateforme de force) pour les 9 modèles, en considérant les stratégies intras et inters, en utilisant les données de test du pied droit. Les meilleurs résultats pour la stratégie **intras** sont en gras et pour **l'inters** sont en gras souligné.

Stratégie	Méthode de normalisation	Nombre de PCs	F_z (N)		
			PCA-ANN	PCA-LS	PCA-SVR
Intras	MM _[0,1]	10-9	65,68 (0,976) ± 3,36 (0,003)	93,66 (0,948) ± 4,43 (0,006)	67,34 (0,974) ± 2,04 (0,002)
	MM _[-1,1]	10-9	66,15 (0,975) ± 2,39 (0,002)	91,02 (0,951) ± 7,18 (0,007)	76,20 (0,967) ± 3,06 (0,002)
	Mean	10-9	66,37 (0,976) ± 3,60 (0,003)	93,76 (0,948) ± 4,611 (0,006)	67,40 (0,974) ± 1,92 (0,002)
	ZS	10	67,35 (0,974) ± 2,90 (0,003)	102,31 (0,936) ± 18,19 (0,024)	163,65 (0,834) ± 7,49 (0,014)
	RS	10-9	71,24 (0,971) ± 3,38 (0,003)	102,71 (0,935) ± 19,12 (0,024)	127,77 (0,904) ± 6,03 (0,009)
	VS	10	78,23 (0,966) ± 3,67 (0,003)	92,26 (0,949) ± 10,17 (0,012)	99,00 (0,942) ± 13,17 (0,015)
	MLS	10-9	71,57 (0,972) ± 5,05 (0,004)	93,66 (0,948) ± 4,43 (0,006)	67,36 (0,974) ± 2,04 (0,002)
	DS	6	92,22 (0,952) ± 13,58 (0,011)	118,30 (0,912) ± 24,58 (0,037)	99,08 (0,940) ± 17,06 (0,019)
	Med	9-8	116,90 (0,929) ± 11,55 (0,011)	105,90 (0,931) ± 19,61 (0,028)	204,91 (0,725) ± 4,80 (0,011)
	Tanh	10	98,21 (0,942) ± 12,17 (0,015)	102,53 (0,936) ± 15,51 (0,021)	119,46 (0,919) ± 19,15 (0,026)
Inters	BW	9	67,36 (0,974) ± 3,99 (0,003)	114,76 (0,93) ± 16,609 (0,021)	270,02 (0,476) ± 5,38 (0,007)
	LI	9-8	74,35 (0,969) ± 2,65 (0,001)	97,69 (0,943) ± 11,852 (0,013)	262,60 (0,513) ± 5,67 (0,011)
	MM _[0,1]	10-9	93,94 (0,949) ± 24,97 (0,027)	102,28 (0,952) ± 24,87 (0,024)	101,99 (0,948) ± 38,26 (0,019)
	MM _[-1,1]	10-9	92,96 (0,949) ± 24,41 (0,035)	110,95 (0,943) ± 36,74 (0,052)	123,07 (0,928) ± 46,17 (0,029)
	Mean	10-9	93,88 (0,949) ± 22,20 (0,030)	110,01 (0,941) ± 36,95 (0,052)	102,77 (0,946) ± 38,62 (0,022)
	ZS	10	91,65 (0,949) ± 22,68 (0,027)	97,48 (0,944) ± 26,36 (0,020)	185,59 (0,798) ± 38,15 (0,043)
	RS	10-9	104,01 (0,936) ± 30,59 (0,04)	123,92 (0,914) ± 47,41 (0,067)	164,64 (0,852) ± 40,75 (0,034)
	VS	10	89,82 (0,952) ± 30,34 (0,024)	97,09 (0,944) ± 33,64 (0,036)	106,37 (0,932) ± 48,24 (0,059)
	MLS	10-9	<u>95,37 (0,953) ± 25,75 (0,032)</u>	102,28 (0,952) ± 24,87 (0,024)	101,99 (0,948) ± 38,26 (0,019)
	DS	6	134,25 (0,888) ± 50,72 (0,082)	140,46 (0,879) ± 49,44 (0,094)	111,04 (0,912) ± 28,92 (0,060)
Med	9-8	151,27 (0,888) ± 44,57 (0,044)	109,51 (0,925) ± 38,04 (0,069)	209,15 (0,73) ± 33,75 (0,051)	
Tanh	10	103,94 (0,942) ± 38,79 (0,032)	98,25 (0,942) ± 28,44 (0,026)	116,92 (0,931) ± 35,51 (0,039)	
BW	9	93,64 (0,949) ± 20,28 (0,026)	128,14 (0,954) ± 50,48 (0,023)	264,46 (0,501) ± 30,29 (0,038)	
LI	9-8	147,34 (0,922) ± 53,39 (0,053)	101,09 (0,940) ± 28,65 (0,036)	259,22 (0,529) ± 30,39 (0,040)	

Annexe II : Moyenne \pm écart-type du RMSE (R) entre les composantes de la GRF estimées et mesurées des deux pieds avec la semelle Moticon pour les méthodes de DL / SML pour l'ensemble de données de test pour les six activités

Tableau II.1. Moyenne \pm écart-type du RMSE (R) entre les composantes de la GRF estimées (par les données de PP de la semelle) et mesurées (par la plateforme de force) du pied droit sont calculées pour les méthodes de DL / SML pour l'ensemble de données de test pour les six activités. Pour chaque activité, les résultats optimaux pour la stratégie **intras**, sont présentés en gras et pour la stratégie **inters** en gras souligné.

Strategie	Composante	Méthode de DL / SML	Marche normale	Marche lente	Situation statique	Pdc statique	Pdc bas-haut	Pdc gauche-droite
Intras	F_z [N]	ANN	61,66 (0,976) \pm 1,56 (0,001)	53,45 (0,985) \pm 2,49 (0,001)	13,36 (0,969) \pm 0,91 (0,008)	10,90 (0,991) \pm 0,46 (0,002)	19,14 (0,976) \pm 0,47 (0,004)	25,85 (0,994) \pm 0,67 (0,001)
		BLSTM	63,27 (0,975) \pm 2,10 (0,001)	54,52 (0,984) \pm 2,84 (0,002)	11,64 (0,976) \pm 1,10 (0,006)	12,26 (0,989) \pm 0,61 (0,002)	21,39 (0,970) \pm 0,97 (0,004)	29,04 (0,992) \pm 1,14 (0,000)
		CNN	63,38 (0,975) \pm 2,27 (0,002)	52,58 (0,985) \pm 2,61 (0,001)	13,65 (0,968) \pm 1,08 (0,008)	11,47 (0,990) \pm 0,60 (0,001)	19,38 (0,975) \pm 0,68 (0,004)	27,99 (0,993) \pm 0,91 (0,000)
		SVR	60,88 (0,977) \pm 1,26 (0,001)	65,57 (0,978) \pm 2,88 (0,002)	14,33 (0,964) \pm 0,62 (0,008)	11,07 (0,991) \pm 0,24 (0,002)	19,47 (0,975) \pm 0,58 (0,003)	26,95 (0,993) \pm 0,92 (0,000)
		LS	79,84 (0,961) \pm 2,80 (0,002)	81,67 (0,963) \pm 4,31 (0,003)	26,79 (0,877) \pm 2,79 (0,031)	20,70 (0,968) \pm 1,45 (0,007)	28,89 (0,947) \pm 1,32 (0,009)	49,53 (0,977) \pm 2,68 (0,001)
		RF	69,69 (0,971) \pm 3,10 (0,002)	60,15 (0,982) \pm 3,63 (0,002)	11,17 (0,979) \pm 1,13 (0,004)	12,45 (0,988) \pm 1,10 (0,003)	26,78 (0,953) \pm 1,71 (0,006)	33,08 (0,990) \pm 1,21 (0,001)
	F_y [N]	ANN	33,40 (0,706) \pm 1,68 (0,051)	30,04 (0,605) \pm 1,49 (0,029)	2,66 (0,761) \pm 0,21 (0,015)	4,00 (0,694) \pm 0,53 (0,045)	8,15 (0,462) \pm 0,45 (0,043)	11,27 (0,635) \pm 0,47 (0,031)
		BLSTM	35,94 (0,652) \pm 2,19 (0,049)	30,00 (0,575) \pm 1,90 (0,027)	2,14 (0,826) \pm 0,21 (0,039)	3,18 (0,749) \pm 0,74 (0,071)	7,99 (0,445) \pm 0,53 (0,049)	11,89 (0,589) \pm 0,66 (0,048)
		CNN	35,36 (0,664) \pm 1,81 (0,039)	31,79 (0,551) \pm 2,54 (0,016)	3,05 (0,715) \pm 0,43 (0,058)	3,92 (0,647) \pm 0,38 (0,065)	8,06 (0,439) \pm 0,53 (0,052)	11,61 (0,612) \pm 0,77 (0,048)
		SVR	33,41 (0,705) \pm 1,93 (0,051)	29,29 (0,583) \pm 1,36 (0,019)	6,84 (0,384) \pm 0,43 (0,102)	6,57 (0,422) \pm 0,45 (0,098)	10,42 (0,179) \pm 0,38 (0,034)	13,28 (0,446) \pm 0,38 (0,04)
		LS	42,05 (0,581) \pm 1,67 (0,047)	31,19 (0,413) \pm 1,64 (0,054)	4,80 (0,272) \pm 0,50 (0,111)	4,37 (0,319) \pm 0,21 (0,126)	10,12 (-0,018) \pm 0,27 (0,052)	14,89 (0,142) \pm 0,43 (0,057)
		RF	33,01 (0,712) \pm 1,39 (0,038)	28,45 (0,598) \pm 1,75 (0,015)	1,97 (0,847) \pm 0,26 (0,031)	4,03 (0,732) \pm 0,92 (0,053)	7,70 (0,474) \pm 0,37 (0,039)	12,44 (0,528) \pm 0,80 (0,062)
	F_x [N]	ANN	12,75 (0,884) \pm 0,56 (0,012)	10,42 (0,889) \pm 0,55 (0,010)	2,46 (0,947) \pm 0,20 (0,007)	3,01 (0,938) \pm 0,33 (0,014)	7,03 (0,829) \pm 0,53 (0,027)	8,77 (0,807) \pm 0,44 (0,019)
		BLSTM	13,27 (0,872) \pm 0,61 (0,004)	9,62 (0,905) \pm 0,52 (0,009)	2,45 (0,948) \pm 0,31 (0,013)	3,14 (0,930) \pm 0,40 (0,016)	7,12 (0,815) \pm 0,46 (0,038)	9,40 (0,775) \pm 0,30 (0,014)
		CNN	13,57 (0,867) \pm 0,65 (0,010)	10,79 (0,880) \pm 0,94 (0,028)	3,22 (0,912) \pm 0,33 (0,018)	3,37 (0,924) \pm 0,20 (0,011)	6,91 (0,823) \pm 0,53 (0,032)	9,66 (0,759) \pm 0,42 (0,023)
		SVR	14,19 (0,845) \pm 0,67 (0,015)	10,56 (0,885) \pm 0,63 (0,007)	9,32 (0,415) \pm 0,78 (0,165)	5,46 (0,791) \pm 0,53 (0,046)	10,52 (0,641) \pm 0,34 (0,046)	10,30 (0,732) \pm 0,33 (0,017)
		LS	18,62 (0,772) \pm 1,05 (0,024)	12,28 (0,844) \pm 0,51 (0,020)	8,43 (0,432) \pm 0,60 (0,115)	6,19 (0,690) \pm 0,63 (0,074)	7,88 (0,776) \pm 0,38 (0,034)	12,76 (0,589) \pm 0,55 (0,022)
		RF	13,33 (0,873) \pm 0,68 (0,008)	9,99 (0,895) \pm 0,55 (0,008)	2,59 (0,940) \pm 0,14 (0,013)	2,94 (0,936) \pm 0,42 (0,017)	6,91 (0,832) \pm 0,30 (0,032)	9,67 (0,758) \pm 0,39 (0,022)
	F_z [N]	ANN	92,92 (0,954) \pm 20,50 (0,023)	79,36 (0,972) \pm 26,34 (0,011)	36,64 (0,641) \pm 26,40 (0,250)	42,15 (0,698) \pm 30,45 (0,148)	45,50 (0,789) \pm 19,58 (0,125)	67,40 (0,984) \pm 24,57 (0,007)
		BLSTM	83,69 (0,956) \pm 16,85 (0,023)	67,14 (0,973) \pm 13,50 (0,009)	24,63 (0,610) \pm 9,75 (0,286)	34,50 (0,582) \pm 13,20 (0,187)	53,65 (0,739) \pm 21,56 (0,143)	73,60 (0,973) \pm 20,40 (0,015)
		CNN	87,32 (0,955) \pm 18,42 (0,025)	75,38 (0,971) \pm 21,62 (0,015)	24,13 (0,722) \pm 11,54 (0,157)	27,68 (0,726) \pm 12,05 (0,183)	46,82 (0,795) \pm 18,35 (0,104)	69,63 (0,982) \pm 30,27 (0,008)
		SVR	60,35 (0,974) \pm 21,86 (0,024)	47,57 (0,986) \pm 17,26 (0,012)	15,64 (0,775) \pm 6,09 (0,188)	15,44 (0,814) \pm 7,25 (0,091)	24,77 (0,909) \pm 13,29 (0,050)	30,91 (0,990) \pm 14,00 (0,009)
		LS	84,59 (0,959) \pm 25,38 (0,03)	75,66 (0,969) \pm 26,15 (0,021)	21,33 (0,752) \pm 13,07 (0,177)	20,25 (0,770) \pm 8,80 (0,110)	34,84 (0,838) \pm 10,13 (0,102)	60,98 (0,983) \pm 21,00 (0,007)
		RF	52,70 (0,976) \pm 36,57 (0,989) \pm 7,97 (0,894) \pm 15,00 (0,878) \pm 21,25 (0,921) \pm 25,51 (0,990) \pm					

		27,53 (0,033)	21,34 (0,016)	5,75 (0,082)	25,14 (0,116)	18,09 (0,052)	18,41 (0,014)	
Inters	F_y [N]	ANN	50,73 (0,402) ±	44,85 (0,328) ±	16,23 (0,000) ±	16,55 (-0,015) ±	20,61 (0,126) ±	30,71 (-0,146) ±
			15,64 (0,236)	18,58 (0,193)	17,98 (0,141)	18,45 (0,239)	8,20 (0,338)	16,16 (0,291)
		BLSTM	44,79 (0,455) ±	36,73 (0,430) ±	10,97 (-0,048) ±	13,22 (-0,047) ±	21,10 (-0,024) ±	30,67 (-0,126) ±
			17,29 (0,262)	12,02 (0,165)	7,51 (0,223)	9,49 (0,225)	9,58 (0,316)	15,40 (0,278)
		CNN	48,60 (0,437) ±	42,79 (0,331) ±	10,68 (0,066) ±	13,52 (0,159) ±	21,32 (0,219) ±	31,14 (-0,054) ±
			15,63 (0,158)	14,87 (0,188)	6,97 (0,160)	7,91 (0,220)	11,42 (0,388)	13,29 (0,271)
		SVR	28,27 (0,786) ±	20,72 (0,758) ±	6,93 (0,026) ±	6,63 (-0,128) ±	13,00 (0,19) ±	14,22 (0,328) ±
	F_x [N]		14,79 (0,125)	7,41 (0,091)	2,28 (0,220)	1,92 (0,240)	6,90 (0,378)	8,13 (0,338)
		LS	43,39 (0,527) ±	31,49 (0,360) ±	7,53 (0,061) ±	6,70 (0,048) ±	13,29 (-0,281) ±	6,89 (-0,068) ±
			15,35 (0,151)	10,63 (0,172)	5,23 (0,251)	3,15 (0,368)	6,68 (0,293)	4,62 (0,337)
		RF	22,31 (0,876) ±	16,35 (0,850) ±	1,35 (0,571) ±	2,81 (0,660) ±	7,31 (0,662) ±	9,60 (0,652) ±
			14,36 (0,088)	7,49 (0,082)	1,27 (0,465)	4,32 (0,281)	8,11 (0,369)	7,50 (0,395)
		ANN	19,72 (0,716) ±	14,74 (0,753) ±	10,22 (0,074) ±	10,58 (0,227) ±	16,46 (0,230) ±	18,28 (0,527) ±
			5,58 (0,098)	4,64 (0,131)	4,39 (0,380)	7,27 (0,202)	6,58 (0,315)	7,73 (0,236)
BLSTM	17,42 (0,765) ±	12,58 (0,819) ±	11,07 (0,140) ±	7,42 (0,158) ±	14,58 (0,192) ±	15,67 (0,514) ±		
	4,63 (0,094)	2,47 (0,075)	3,82 (0,165)	2,61 (0,201)	4,63 (0,282)	5,83 (0,268)		
CNN	18,79 (0,717) ±	13,56 (0,792) ±	9,53 (0,221) ±	7,09 (0,015) ±	13,31 (0,235) ±	16,38 (0,523) ±		
	5,06 (0,090)	3,43 (0,078)	4,11 (0,241)	2,25 (0,238)	6,06 (0,260)	6,24 (0,261)		
SVR	13,06 (0,865) ±	10,48 (0,874) ±	10,72 (0,144) ±	5,29 (0,312) ±	9,56 (0,280) ±	9,90 (0,646) ±		
	4,06 (0,069)	1,79 (0,043)	5,79 (0,313)	1,88 (0,304)	2,74 (0,218)	2,06 (0,198)		
LS	19,01 (0,766) ±	12,50 (0,817) ±	9,03 (0,048) ±	8,00 (0,193) ±	9,30 (0,368) ±	14,81 (0,539) ±		
	3,74 (0,083)	1,72 (0,064)	5,75 (0,234)	3,67 (0,186)	4,90 (0,136)	6,25 (0,208)		
RF	9,29 (0,924) ±	6,62 (0,945) ±	1,65 (0,602) ±	1,33 (0,696) ±	4,39 (0,651) ±	6,43 (0,796) ±		
	4,88 (0,071)	3,48 (0,041)	1,59 (0,277)	0,99 (0,153)	2,50 (0,184)	4,12 (0,252)		

Tableau II.2. Moyenne ± écart-type du RMSE (R) entre les composantes de la GRF estimées (par les données de PP de la semelle) et mesurées (par la plateforme de force) du pied gauche sont calculées pour les méthodes de DL / SML pour l'ensemble de données de test pour les six activités. Pour chaque activité, les résultats optimaux pour la stratégie **intras**, sont présentés en gras et pour la stratégie **inters** en gras souligné.

Strategie	Composante	Méthode de DL / SML	Marche normale	Marche lente	Situation statique	Pdc statique	Pdc bas-haut	Pdc gauche-droite
Inters	F_z [N]	ANN	56,60 (0,981) ±	50,48 (0,985) ±	12,44 (0,978) ±	12,56 (0,977) ±	19,84 (0,968) ±	27,10 (0,992) ±
			2,63 (0,001)	2,98 (0,001)	0,62 (0,005)	0,65 (0,003)	1,09 (0,003)	0,78 (0,001)
		BLSTM	56,70 (0,981) ±	51,18 (0,985) ±	11,42 (0,981) ±	13,58 (0,974) ±	22,04 (0,961) ±	30,97 (0,99) ±
			3,20 (0,002)	4,16 (0,002)	0,69 (0,005)	1,21 (0,003)	1,44 (0,005)	3,36 (0,002)
		CNN	57,94 (0,98) ±	51,86 (0,984) ±	13,23 (0,976) ±	13,17 (0,975) ±	21,77 (0,962) ±	28,77 (0,991) ±
			3,56 (0,002)	2,81 (0,002)	0,98 (0,004)	0,63 (0,002)	1,83 (0,006)	0,59 (0,001)
		SVR	61,26 (0,979) ±	49,31 (0,986) ±	13,23 (0,974) ±	13,85 (0,973) ±	23,35 (0,957) ±	29,45 (0,991) ±
	F_y [N]		1,41 (0,001)	1,67 (0,001)	0,53 (0,004)	0,52 (0,004)	1,59 (0,005)	0,97 (0,001)
		LS	74,89 (0,967) ±	71,60 (0,971) ±	27,60 (0,909) ±	26,70 (0,916) ±	36,72 (0,892) ±	44,32 (0,980) ±
			2,18 (0,002)	2,12 (0,001)	1,22 (0,026)	1,68 (0,019)	2,24 (0,016)	1,72 (0,002)
		RF	71,16 (0,971) ±	59,08 (0,980) ±	11,29 (0,981) ±	14,89 (0,969) ±	27,04 (0,942) ±	37,09 (0,986) ±
			3,62 (0,002)	2,79 (0,002)	0,73 (0,003)	0,89 (0,004)	2,05 (0,008)	1,13 (0,001)
		ANN	33,55 (0,685) ±	24,45 (0,715) ±	3,67 (0,569) ±	3,51 (0,703) ±	8,28 (0,459) ±	11,33 (0,623) ±
			2,01 (0,040)	1,17 (0,024)	0,42 (0,091)	0,40 (0,116)	0,39 (0,049)	0,57 (0,031)
BLSTM	37,04 (0,599) ±	24,55 (0,707) ±	3,03 (0,678) ±	3,07 (0,761) ±	8,41 (0,432) ±	11,44 (0,598) ±		
	1,95 (0,049)	1,10 (0,025)	0,74 (0,130)	0,51 (0,097)	0,45 (0,039)	0,47 (0,056)		
CNN	36,39 (0,615) ±	25,83 (0,672) ±	4,16 (0,460) ±	3,88 (0,635) ±	8,46 (0,414) ±	11,96 (0,549) ±		
	1,73 (0,044)	2,17 (0,041)	0,60 (0,140)	0,30 (0,086)	0,46 (0,035)	0,73 (0,065)		
SVR	34,51 (0,659) ±	22,12 (0,759) ±	7,99 (0,092) ±	8,01 (0,093) ±	9,31 (0,292) ±	13,47 (0,390) ±		
	1,54 (0,032)	0,47 (0,011)	0,25 (0,132)	0,43 (0,118)	0,37 (0,036)	0,69 (0,058)		
LS	42,57 (0,369) ±	27,53 (0,563) ±	6,55 (-0,109) ±	7,50 (-0,442) ±	9,96 (0,119) ±	14,83 (0,079) ±		
	1,31 (0,047)	1,16 (0,009)	0,59 (0,146)	0,41 (0,054)	0,41 (0,057)	0,55 (0,074)		
RF	39,03 (0,543) ±	22,82 (0,734) ±	3,84 (0,563) ±	2,92 (0,768) ±	8,55 (0,359) ±	13,13 (0,434) ±		
	1,87 (0,046)	0,90 (0,017)	0,59 (0,110)	0,39 (0,085)	0,38 (0,053)	0,75 (0,052)		
Intras	F_z [N]	ANN	17,46 (0,621) ±	10,47 (0,836) ±	3,41 (0,929) ±	3,58 (0,927) ±	6,64 (0,858) ±	9,28 (0,842) ±
			1,26 (0,033)	0,57 (0,018)	0,25 (0,017)	0,53 (0,022)	0,46 (0,022)	0,52 (0,015)
		BLSTM	16,89 (0,628) ±	10,12 (0,846) ±	3,27 (0,936) ±	3,47 (0,935) ±	7,00 (0,840) ±	9,88 (0,818) ±
		1,03 (0,023)	0,36 (0,008)	0,24 (0,010)	0,34 (0,011)	0,37 (0,031)	0,38 (0,016)	
	CNN	17,56 (0,594) ±	10,82 (0,821) ±	3,95 (0,914) ±	4,29 (0,895) ±	6,97 (0,839) ±	10,01 (0,818) ±	
		0,90 (0,025)	0,36 (0,018)	0,53 (0,017)	0,27 (0,015)	0,57 (0,030)	0,54 (0,011)	

	SVR	16,29 (0,642) ± 0,86 (0,017)	10,24 (0,839) ± 0,148 (0,017)	9,08 (0,549) ± 0,47 (0,143)	8,29 (0,665) ± 0,62 (0,046)	10,10 (0,659) ± 0,32 (0,052)	10,95 (0,769) ± 0,34 (0,021)
	LS	18,09 (0,613) ± 0,76 (0,018)	11,62 (0,791) ± 0,20 (0,019)	6,08 (0,779) ± 0,40 (0,051)	7,00 (0,721) ± 0,59 (0,056)	8,60 (0,742) ± 0,42 (0,042)	13,29 (0,661) ± 0,59 (0,029)
	RF	17,42 (0,584) ± 0,94 (0,025)	9,87 (0,849) ± 0,27 (0,017)	2,73 (0,950) ± 0,24 (0,010)	3,46 (0,931) ± 0,35 (0,011)	6,77 (0,850) ± 0,37 (0,027)	10,40 (0,797) ± 0,46 (0,015)
F_z [N]	ANN	99,22 (0,945) ± 33,67 (0,023)	90,54 (0,958) ± 25,95 (0,014)	44,55 (0,582) ± 26,22 (0,203)	49,28 (0,563) ± 23,17 (0,189)	47,17 (0,765) ± 17,17 (0,122)	56,15 (0,976) ± 9,94 (0,012)
	BLSTM	81,82 (0,958) ± 23,63 (0,024)	76,53 (0,967) ± 17,79 (0,015)	46,49 (0,610) ± 26,05 (0,162)	41,30 (0,561) ± 22,93 (0,164)	54,41 (0,781) ± 26,75 (0,114)	61,89 (0,977) ± 20,62 (0,011)
	CNN	90,18 (0,954) ± 26,81 (0,019)	84,33 (0,959) ± 19,68 (0,016)	49,60 (0,468) ± 22,45 (0,270)	50,34 (0,547) ± 25,04 (0,170)	49,48 (0,808) ± 24,70 (0,078)	57,22 (0,982) ± 14,71 (0,008)
	SVR	65,58 (0,969) ± 26,53 (0,027)	59,44 (0,978) ± 30,01 (0,019)	32,96 (0,746) ± 34,13 (0,194)	28,35 (0,742) ± 28,13 (0,147)	30,62 (0,887) ± 23,70 (0,061)	32,60 (0,989) ± 18,06 (0,011)
	LS	86,04 (0,960) ± 23,95 (0,027)	85,54 (0,964) ± 24,22 (0,018)	37,20 (0,703) ± 19,36 (0,202)	38,65 (0,685) ± 23,69 (0,178)	53,48 (0,846) ± 18,00 (0,090)	59,58 (0,982) ± 19,79 (0,009)
	RF	51,17 (0,976) ± 28,68 (0,033)	38,99 (0,987) ± 22,74 (0,017)	12,59 (0,878) ± 18,41 (0,121)	9,20 (0,889) ± 6,74 (0,082)	19,51 (0,921) ± 12,73 (0,051)	28,01 (0,989) ± 21,20 (0,015)
	ANN	49,40 (0,472) ± 18,14 (0,218)	36,12 (0,542) ± 8,42 (0,110)	17,23 (-0,055) ± 12,22 (0,247)	14,53 (-0,096) ± 12,53 (0,341)	19,90 (-0,053) ± 10,55 (0,200)	25,67 (-0,191) ± 9,55 (0,146)
	BLSTM	41,37 (0,538) ± 9,71 (0,107)	32,98 (0,559) ± 8,53 (0,121)	14,12 (-0,055) ± 12,56 (0,209)	13,51 (-0,105) ± 12,73 (0,295)	16,11 (-0,07) ± 8,63 (0,180)	25,57 (-0,060) ± 13,27 (0,204)
	CNN	46,25 (0,455) ± 15,78 (0,254)	38,01 (0,503) ± 12,49 (0,250)	14,86 (0,070) ± 9,48 (0,291)	13,81 (-0,035) ± 10,60 (0,389)	14,93 (0,064) ± 7,54 (0,256)	21,50 (0,030) ± 9,17 (0,275)
	SVR	27,65 (0,817) ± 12,60 (0,075)	19,94 (0,810) ± 7,11 (0,089)	8,98 (-0,216) ± 6,38 (0,309)	12,09 (-0,095) ± 7,97 (0,347)	9,35 (0,143) ± 3,84 (0,263)	12,77 (0,452) ± 6,27 (0,258)
	LS	42,55 (0,483) ± 13,72 (0,183)	29,24 (0,600) ± 8,27 (0,109)	9,50 (-0,234) ± 7,59 (0,143)	9,62 (-0,346) ± 8,83 (0,310)	11,717 (-0,148) ± 4,55 (0,213)	17,27 (-0,243) ± 5,28 (0,224)
	RF	23,32 (0,874) ± 11,10 (0,055)	15,31 (0,893) ± 6,38 (0,053)	3,56 (0,585) ± 5,77 (0,267)	1,94 (0,544) ± 1,48 (0,357)	6,07 (0,580) ± 3,70 (0,345)	10,02 (0,720) ± 8,45 (0,269)
F_x [N]	ANN	23,34 (0,406) ± 8,16 (0,227)	18,33 (0,514) ± 7,78 (0,228)	12,86 (0,124) ± 8,71 (0,143)	13,39 (0,032) ± 7,34 (0,220)	10,85 (0,277) ± 4,73 (0,202)	17,67 (0,350) ± 2,73 (0,267)
	BLSTM	18,63 (0,513) ± 5,38 (0,212)	12,84 (0,681) ± 2,34 (0,098)	8,35 (0,13) ± 4,84 (0,254)	9,79 (0,031) ± 5,15 (0,247)	12,26 (0,265) ± 4,08 (0,122)	15,74 (0,369) ± 4,14 (0,322)
	CNN	20,05 (0,473) ± 5,23 (0,198)	14,91 (0,606) ± 3,25 (0,149)	9,11 (-0,045) ± 5,10 (0,203)	11,73 (0,116) ± 6,29 (0,242)	11,23 (0,294) ± 4,46 (0,109)	16,26 (0,414) ± 4,15 (0,260)
	SVR	14,63 (0,672) ± 4,95 (0,223)	10,34 (0,772) ± 1,57 (0,117)	10,23 (0,151) ± 4,30 (0,235)	8,39 (0,239) ± 4,02 (0,264)	9,64 (0,323) ± 2,791 (0,133)	10,50 (0,524) ± 2,37 (0,262)
	LS	17,22 (0,578) ± 4,85 (0,146)	13,27 (0,703) ± 3,33 (0,097)	7,50 (0,114) ± 3,32 (0,167)	8,20 (0,188) ± 4,22 (0,157)	9,16 (0,433) ± 4,44 (0,136)	14,88 (0,508) ± 4,29 (0,195)
	RF	7,01 (0,803) ± 3,08 (0,149)	4,43 (0,681) ± 3,16 (0,233)	2,29 (0,562) ± 2,41 (0,269)	1,78 (0,538) ± 1,44 (0,340)	7,64 (0,888) ± 4,82 (0,114)	12,09 (0,760) ± 6,90 (0,262)

Annexe III : Les allures des composantes de la GRF estimées par la méthode RF et mesurées par la plateforme pour un essai des six activités pour la stratégie intrasujet en utilisant la semelle Moticon




Figure II.1. Les allures des composantes de la GRF estimées par la méthode RF et mesurées par la plateforme pour la situation **statique**, pour les deux pieds.




Figure II.2. Les allures des composantes de la GRF estimées par la méthode RF et mesurées par la plateforme pour la situation **Pdc statique**, pour les deux pieds.




Figure II.3. Les allures des composantes de la GRF estimées par la méthode RF et mesurées par la plateforme pour un essai de **Pdc bas-haut**, pour les deux pieds.




Figure II.4. Les allures des composantes de la GRF estimées par la méthode RF et mesurées par la plateforme pour un essai de **Pdc gauche-droite**, pour les deux pieds.




Figure II.5. Les allures des composantes de la GRF estimées par la méthode RF et mesurées par la plateforme pour un pas de la **marche lente**, pour le pied droit.




Figure II.6. Les allures des composantes de la GRF estimées par la méthode RF et mesurées par la plateforme pour un pas de la **marche normale**, pour le pied droit.

Annexe IV : Les valeurs de RMSE (R) entre les composantes de la GRF estimées avec 13 méthodes de ML avec ou sans méthode de RD et les composantes mesurées des deux pieds pour les deux semelles

Tableau IV.1. Valeur de RMSE (R) entre les composantes de la GRF estimées et mesurées du pied **droit** en utilisant la semelle **Moticon** pour les stratégies intras (8 sujets) et inters (1 sujet). Les meilleurs résultats d'estimation de chaque composante pour la stratégie **intras** sont présentés en gras et pour la stratégie **inters** en gras souligné.

Stratégie	Méthode ML	Nombre d'entrées	F_x (N)	F_y (N)	F_z (N)	F_z Mot (N)
Intras	SVR	16	12,30 (0,796)	16,85 (0,610)	38,80 (0,979)	68,80 (0,959)
	KNN	16	7,49 (0,866)	14,80 (0,623)	37,10 (0,979)	
	RF	16	8,84 (0,837)	17,85 (0,516)	41,67 (0,975)	
	LS	16	10,08 (0,742)	17,79 (0,342)	46,13 (0,968)	
	ANN	16	7,16 (0,879)	14,52 (0,668)	29,03 (0,987)	
	PCA-ANN	10 PCs	7,47 (0,868)	16,10 (0,590)	36,35 (0,980)	
	MI-ANN	15	7,48 (0,871)	15,60 (0,621)	30,58 (0,986)	
	PCA-MI-ANN	9 PCs	7,94 (0,855)	16,11 (0,595)	39,01 (0,978)	
	PCA-Block-ANN	13	7,43 (0,872)	15,45 (0,625)	34,08 (0,983)	
	CNN	16	7,78 (0,856)	15,37 (0,613)	30,01 (0,987)	
	BLSTM	16	7,59 (0,864)	14,77 (0,647)	31,47 (0,985)	
	BGRU	16	7,79 (0,856)	15,28 (0,615)	31,35 (0,985)	
	ANN (IMU+PP)	19	7,62 (0,864)	14,75 (0,653)	28,98 (0,988)	
Inters	SVR	16	15,63 (0,511)	15,72 (0,315)	46,93 (0,959)	57,34 (0,972)
	KNN	16	17,53 (0,515)	15,60 (0,200)	54,68 (0,941)	
	RF	16	<u>5,58 (0,923)</u>	<u>8,70 (0,833)</u>	<u>18,69 (0,983)</u>	
	LS	16	17,90 (0,630)	18,24 (0,205)	45,84 (0,966)	
	ANN	16	14,93 (0,549)	18,94 (0,279)	38,933 (0,970)	
	PCA-ANN	10 PCs	19,96 (0,091)	19,11 (0,200)	81,70 (0,871)	
	MI-ANN	15	14,84 (0,465)	20,03 (0,236)	52,69 (0,944)	
	PCA-MI-ANN	9 PCs	18,10 (0,092)	21,07 (0,131)	90,88 (0,840)	
	PCA-Block-ANN	13	16,73 (0,471)	19,36 (0,216)	63,30 (0,912)	
	CNN	16	15,02 (0,434)	26,37 (0,244)	45,87 (0,967)	
	BLSTM	16	16,78 (0,411)	18,94 (0,351)	59,77 (0,928)	
	BGRU	16	16,32 (0,523)	18,18 (0,309)	48,63 (0,955)	
	ANN (IMU+PP)	19	12,65 (0,614)	20,74 (0,278)	49,02 (0,957)	

Tableau IV.2. Valeur de RMSE (R) entre les composantes de la GRF estimées et mesurées du pied **gauche** en utilisant la semelle **Moticon** pour les stratégies intras (8 sujets) et inters (1 sujet). Les meilleurs résultats d'estimation de chaque composante pour la stratégie **intras** sont présentés en gras et pour la stratégie **inters** en gras souligné.

Stratégie	Méthode ML	Nombre d'entrées	F_x (N)	F_y (N)	F_z (N)	F_z Mot (N)
Intras	SVR	16	11,26 (0,650)	15,94 (0,584)	42,37 (0,976)	65,85 (0,966)
	KNN	16	8,75 (0,787)	15,77 (0,599)	35,93 (0,982)	
	RF	16	9,49 (0,748)	17,43 (0,537)	42,82 (0,975)	
	LS	16	10,66 (0,653)	18,67 (0,332)	44,39 (0,973)	
	ANN	16	8,71 (0,790)	14,77 (0,682)	29,23 (0,988)	
	PCA-ANN	10 PCs	8,66 (0,795)	16,76 (0,578)	35,25 (0,983)	
	MI-ANN	12	9,23 (0,766)	15,03 (0,662)	33,73 (0,984)	
	PCA-MI-ANN	9 PCs	8,71 (0,791)	16,41 (0,587)	37,27 (0,981)	
	PCA-Block-ANN	12	8,89 (0,777)	17,71 (0,534)	38,06 (0,981)	
	CNN	16	8,76 (0,783)	15,71 (0,625)	30,64 (0,987)	
BLSTM	16	8,78 (0,783)	15,64 (0,638)	30,43 (0,987)		
BGRU	16	8,83 (0,783)	16,60 (0,595)	33,06 (0,985)		
ANN (IMU+PP)	19	9,06 (0,784)	15,34 (0,648)	30,28 (0,988)		
Inters	SVR	16	15,00 (0,525)	14,67 (0,377)	97,07 (0,928)	46,19 (0,969)
	KNN	16	16,05 (0,532)	15,52 (0,240)	79,25 (0,920)	
	RF	16	<u>5,83 (0,933)</u>	<u>8,16 (0,850)</u>	<u>22,26 (0,990)</u>	
	LS	16	14,81 (0,605)	14,86 (0,344)	72,45 (0,967)	
	ANN	16	17,65 (0,564)	16,42 (0,391)	53,62 (0,953)	
	PCA-ANN	10 PCs	17,26 (0,193)	15,82 (0,262)	65,04 (0,931)	
	MI-ANN	12	16,21 (0,558)	16,08 (0,349)	71,98 (0,924)	
	PCA-MI-ANN	9 PCs	16,79 (0,438)	17,16 (0,261)	57,04 (0,942)	
	PCA-Block-ANN	12	14,67 (0,560)	16,22 (0,402)	96,36 (0,904)	
	CNN	16	17,24 (0,512)	15,65 (0,396)	63,60 (0,947)	
BLSTM	16	16,44 (0,475)	15,99 (0,376)	63,27 (0,949)		
BGRU	16	16,20 (0,566)	18,04 (0,282)	61,15 (0,955)		
ANN (IMU+PP)	16	17,41 (0,390)	13,65 (0,518)	58,89 (0,948)		

Tableau IV.3. Valeur de RMSE (R) entre les composantes de la GRF estimées et mesurées du pied **droit** en utilisant la semelle **Fscan** pour les stratégies intras (13 sujets) et inters (1 sujet). Les meilleurs résultats d'estimation de chaque composante pour la stratégie **intras** sont présentés en gras et pour la stratégie **inters** en gras souligné.

Stratégie	Méthode ML	Nombre d'entrées	F_x (N)	F_y (N)	F_z (N)	F_z Fsc (N)
Intras	SVR	64	17,30 (0,357)	18,02 (0,115)	100,49 (0,794)	242,11 (0,577)
	KNN	64	11,34 (0,658)	11,42 (0,515)	127,50 (0,774)	
	RF	64	9,67 (0,696)	12,16 (0,490)	98,08 (0,805)	
	LS	64	11,21 (0,524)	12,56 (0,312)	120,27 (0,684)	
	ANN	64	10,46 (0,651)	12,42 (0,497)	111,33 (0,762)	
	PCA-ANN	47 PCs	9,50 (0,706)	11,42 (0,553)	95,01 (0,817)	
	MI-ANN	33	10,46 (0,646)	12,35 (0,465)	113,92 (0,746)	
	PCA-MI-ANN	44 PCs	9,71 (0,688)	12,21 (0,492)	96,30 (0,811)	
	PCA-Block-ANN	32	9,49 (0,697)	11,88 (0,498)	104,02 (0,777)	
	CNN	64	10,21 (0,648)	11,76 (0,492)	100,49 (0,796)	
	BLSTM	64	10,01 (0,669)	12,42 (0,439)	99,39 (0,799)	
	BGRU	64	9,74 (0,682)	11,94 (0,469)	97,26 (0,809)	
	Inters	SVR	64	15,65 (0,582)	12,32 (-0,112)	
KNN		64	<u>9,93 (0,567)</u>	<u>10,40 (0,085)</u>	142,63 (0,673)	
RF		64	13,92 (0,548)	22,27 (0,020)	171,39 (0,584)	
LS		64	12,85 (0,470)	17,26 (-0,063)	170,70 (0,566)	
ANN		64	28,30 (0,298)	35,84 (0,030)	191,71 (0,677)	
PCA-ANN		47 PCs	15,36 (0,301)	21,38 (0,011)	148,83 (0,652)	
MI-ANN		33	29,20 (0,244)	34,79 (-0,023)	212,82 (0,595)	
PCA-MI-ANN		44 PCs	12,78 (0,438)	22,23 (0,060)	142,45 (0,706)	
PCA-Block-ANN		32	13,43 (0,020)	19,22 (0,405)	165,76 (0,544)	
CNN		64	18,93 (0,278)	25,16 (0,086)	199,44 (0,566)	
BLSTM		64	19,85 (0,497)	26,65 (0,003)	201,10 (0,635)	
BGRU		64	17,25 (0,456)	32,81 (-0,056)	225,19 (0,533)	

Tableau IV.4. Valeur de RMSE (R) entre les composantes de la GRF estimées et mesurées du pied gauche en utilisant la semelle **Fscan** pour les stratégies intras (13 sujets) et inters (1 sujet). Les meilleurs résultats d'estimation de chaque composante pour la stratégie **intras** sont présentés en gras et pour la stratégie **inters** en gras souligné.

Stratégie	Méthode ML	Nombre d'entrées	F_x (N)	F_y (N)	F_z (N)	F_z Fsc (N)
Intras	SVR	64	14,45 (0,434)	16,91 (0,120)	101,73 (0,792)	260,51 (0,547)
	KNN	64	8,86 (0,740)	11,50 (0,540)	108,84 (0,799)	
	RF	64	8,91 (0,729)	11,87 (0,524)	100,03 (0,800)	
	LS	64	11,06 (0,492)	12,87 (0,313)	123,16 (0,673)	
	ANN	64	9,88 (0,680)	13,32 (0,430)	118,43 (0,743)	
	PCA-ANN	46 PCs	8,90 (0,731)	12,12 (0,508)	96,43 (0,816)	
	MI-ANN	31	10,65 (0,631)	14,38 (0,333)	125,30 (0,713)	
	PCA-MI-ANN	34 PCs	8,86 (0,731)	11,98 (0,508)	95,49 (0,820)	
	PCA-Block-ANN	29	9,02 (0,715)	12,81 (0,423)	103,41 (0,785)	
	CNN	64	9,58 (0,685)	12,70 (0,436)	102,56 (0,795)	
	BLSTM	64	9,30 (0,679)	12,63 (0,369)	98,62 (0,805)	
BGRU	64	9,18 (0,697)	12,68 (0,378)	99,96 (0,800)		
Inters	SVR	64	13,60 (0,234)	14,35 (0,138)	224,86 (0,161)	134,48 (0,784)
	KNN	64	<u>10,43 (0,200)</u>	<u>10,68 (0,119)</u>	<u>164,73 (0,669)</u>	
	RF	64	14,35 (0,346)	18,34 (0,075)	183,07 (0,593)	
	LS	64	15,80 (0,361)	34,36 (0,189)	677,41 (0,452)	
	ANN	64	131,7 (0,124)	112,86 (0,158)	1232,6 (0,170)	
	PCA-ANN	46 PCs	16,05 (0,090)	17,04 (0,245)	260,50 (0,480)	
	MI-ANN	31	293,5 (0,178)	188,05 (-0,162)	4890,96 (0,122)	
	PCA-MI-ANN	34 PCs	31,92 (0,265)	23,37 (0,156)	170,30 (0,794)	
	PCA-Block-ANN	29	40,08 (0,302)	39,07 (-0,034)	387,07 (0,396)	
	CNN	64	18,22 (0,066)	23,17 (0,235)	242,21 (0,239)	
	BLSTM	64	14,82 (-0,113)	14,39 (-0,010)	253,99 (0,110)	
BGRU	64	12,57 (0,292)	13,46 (-0,010)	180,98 (0,602)		

Tableau IV.5. Valeur de RMSE (R) entre les composantes de la GRF estimées et mesurées en utilisant la semelle **Moticon** pour le pied **droit** pour les six activités. Pour la stratégie intras, ANN a été utilisée et pour la stratégie inters, RF a été utilisé. Les meilleurs résultats d'estimation de chaque composante parmi les six activités pour la stratégie **intras** sont présentés en gras et pour la stratégie **inters** en gras souligné.

	Stratégie	Marche normale	Marche lente	Statique	Pdc statique	Pdc bas-haut	Pdc gauche-droite
F_x (N)		13,55 (0,881)	9,58 (0,907)	2,55 (0,949)	2,11 (0,968)	8,38 (0,792)	6,37 (0,807)
F_y (N)		32,29 (0,757)	30,01 (0,610)	2,78 (0,775)	4,27 (0,714)	11,83 (0,645)	8,62 (0,459)
F_z (N)	Intras	64,08 (0,975)	52,36 (0,986)	13,29 (0,974)	10,25 (0,993)	26,40 (0,994)	18,98 (0,979)
F_z Mot(N)		94,47 (0,951)	94,82 (0,958)	52,29 (0,864)	44,46 (0,972)	74,70 (0,968)	65,30 (0,940)
F_x (N)		5,21 (0,961)	5,08 (0,948)	0,59 (0,836)	2,98 (0,658)	5,55 (0,618)	7,75 (0,781)
F_y (N)	Inters	23,53 (0,817)	11,91 (0,905)	0,80 (0,862)	0,87 (0,757)	5,20 (0,599)	4,68 (0,735)
F_z (N)		41,60 (0,987)	25,47 (0,995)	5,16 (0,926)	4,16 (0,909)	17,03 (0,909)	14,87 (0,996)
F_z Mot(N)		82,76 (0,968)	78,67 (0,979)	41,33 (0,696)	28,60 (0,744)	60,73 (0,817)	55,64 (0,978)

Tableau IV.6. Valeur de RMSE (R) entre les composantes de la GRF estimées et mesurées en utilisant la semelle **Moticon** pour le pied **gauche** pour les six activités. Pour la stratégie intras, ANN a été utilisée et pour la stratégie inters, RF a été utilisé. Les meilleurs résultats d'estimation de chaque composante parmi les six activités pour la stratégie **intras** sont présentés en gras et pour la stratégie **inters** en gras souligné.

	Stratégie	Marche normale	Marche lente	Statique	Pdc statique	Pdc bas-haut	Pdc gauche-droite
F_x (N)		19,33 (0,572)	10,86 (0,828)	3,13 (0,944)	3,06 (0,947)	6,16 (0,832)	8,93 (0,822)
F_y (N)	Intras	34,84 (0,681)	24,30 (0,734)	3,17 (0,575)	3,07 (0,803)	8,38 (0,483)	11,54 (0,657)
F_z (N)		54,46 (0,983)	49,40 (0,986)	12,52 (0,979)	11,93 (0,981)	20,60 (0,970)	27,61 (0,993)
F_z Mot(N)		76,28 (0,968)	78,56 (0,973)	50,61 (0,914)	58,61 (0,955)	67,73 (0,864)	65,51 (0,972)
F_x (N)		7,91 (0,900)	6,42 (0,889)	0,70 (0,760)	3,18 (0,656)	6,52 (0,582)	6,84 (0,913)
F_y (N)	Inters	20,31 (0,846)	11,91 (0,900)	0,82 (0,905)	1,14 (0,594)	5,28 (0,464)	4,74 (0,743)
F_z (N)		46,72 (0,984)	29,03 (0,994)	4,80 (0,936)	7,64 (0,828)	14,66 (0,902)	21,92 (0,992)
F_z Mot(N)		85,56 (0,952)	64,75 (0,983)	17,36 (0,761)	15,11 (0,533)	21,84 (0,819)	51,54 (0,985)

Tableau IV.7. Valeur de RMSE (R) entre les composantes de la GRF estimées et mesurées en utilisant la semelle **Fscan** pour le pied **droit** pour les six activités. Pour la stratégie intras, PCA-ANN a été utilisée et pour la stratégie inters, KNN a été utilisé. Les meilleurs résultats d'estimation de chaque composante parmi les six activités pour la stratégie **intras** sont présentés en gras et pour la stratégie **inters** en gras souligné.

	Stratégie	Marche normale	Marche lente	Statique	Pdc statique	Pdc bas-haut	Pdc gauche-droite
F_x (N)		20,53 (0,632)	13,71 (0,691)	6,13 (0,707)	3,33 (0,927)	8,69 (0,605)	8,73 (0,692)
F_y (N)	Intras	30,66 (0,673)	17,76 (0,536)	2,73 (0,650)	3,61 (0,699)	8,73 (0,216)	10,06 (0,493)
F_z (N)		177,81 (0,734)	144,8 (0,839)	75,65 (0,195)	37,33 (0,852)	69,77 (0,642)	102,20 (0,878)
F_z Fsc(N)		322,8 (0,038)	316,6 (0,146)	256,5 (-0,161)	243,1 (0,116)	297,1 (-0,035)	242,1 (0,577)
F_x (N)		23,50(0,796)	<u>9,39 (0,864)</u>	4,72 (-0,044)	3,69 (-0,313)	5,94 (-0,056)	12,61 (0,283)
F_y (N)	Inters	34,36 (0,721)	9,41 (-0,474)	<u>2,01 (0,136)</u>	2,74 (-0,511)	7,54 (-0,130)	7,16 (-0,001)
F_z (N)		159,1 (0,928)	165,7 (0,919)	<u>47,21 (0,271)</u>	80,39 (0,041)	112,3 (0,158)	201,4 (0,829)
F_z Fsc(N)		195,4 (0,836)	226,9 (0,864)	85,50 (0,163)	108,7 (0,016)	138,7 (0,747)	277,8 (0,802)

Tableau IV.8. Valeur de RMSE (R) entre les composantes de la GRF estimées et mesurées en utilisant la semelle **Fscan** pour le pied **gauche** pour les six activités. Pour la stratégie intras, PCA-ANN a été utilisée et pour la stratégie inters, KNN a été utilisé. Les meilleurs résultats d'estimation de chaque composante parmi les six activités pour la stratégie **intras** sont présentés en gras et pour la stratégie **inters** en gras souligné.

	Stratégie	Marche normale	Marche lente	Statique	Pdc statique	Pdc bas-haut	Pdc gauche-droite
F_x (N)		22,68 (0,504)	12,37 (0,720)	5,99 (0,839)	2,72 (0,967)	6,98 (0,780)	8,60 (0,702)
F_y (N)	Intras	29,86 (0,687)	22,63 (0,381)	2,64 (0,722)	3,27 (0,766)	7,61 (0,321)	12,00 (0,347)
F_z (N)		184,97 (0,731)	168,1 (0,776)	67,72 (0,806)	38,53 (0,796)	69,76 (0,753)	101,07 (0,877)
F_z Fsc(N)		392,10 (0,052)	325,7 (0,077)	221,2 (0,056)	250,3 (0,047)	332,7 (0,100)	328,6 (0,092)
F_x (N)		16,96 (0,744)	10,72 (0,761)	4,85 (-0,476)	<u>1,52 (-0,292)</u>	<u>7,72 (0,762)</u>	14,89 (0,582)
F_y (N)	Inters	34,40 (-0,053)	13,37 (0,045)	4,24 (-0,175)	<u>1,89 (0,086)</u>	4,51 (-0,107)	9,35 (0,455)
F_z (N)		243,70 (0,797)	225,5 (0,871)	95,96 (0,565)	<u>6,70 (0,141)</u>	97,12 (0,829)	230,7 (0,706)
F_z Fsc(N)		213,40 (0,812)	124,1 (0,882)	32,16 (0,468)	16,86 (0,218)	59,41 (0,840)	217,6 (0,804)

Bibliographie

- [1] C. Ha, and Y. Roquelaure, "Troubles musculo-squelettiques d'origine professionnelle en France. Où en est-on aujourd'hui ?," *Bulletin Épidémiologique Hebdomadaire*, no. 5-6, pp. 35-37, 2010.
- [2] H. Rouhani, J. Favre, X. Crevoisier, and K. Aminian, "Ambulatory assessment of 3D ground reaction force using plantar pressure distribution," *Gait & Posture*, vol. 32, no. 3, pp. 311–316, Jul. 2010.
- [3] N. Hori, R. U. Newton, N. Kawamori, M. R. McGuigan, W. J. Kraemer, and K. Nosaka, "Reliability of performance measurements derived from ground reaction force data during countermovement jump and the influence of sampling frequency," *The Journal of Strength and Conditioning Research*, vol. 23, no. 3, pp. 874–882, May 2009.
- [4] E. M. Ficanha, M. Rastgaar, and K. R. Kaufman, "Ankle mechanics during sidestep cutting implicates need for 2-degrees of freedom powered ankle-foot prostheses," *Journal of Rehabilitation Research and Development*, vol. 52, no. 1, pp. 97–112, Jan. 2015.
- [5] MAREY, Etienne Jules. Le mouvement. 1894., *Eric Zink Livres Anciens*. [Online]. Available: <https://www.livresanciens.com/livres/marey-mouvement-1894-2510>.
- [6] H. M. Ericksen, P. A. Gribble, K. R. Pfile, and B. Pietrosimone, "Different modes of feedback and peak vertical ground reaction force during jump Landing: A Systematic review," *Journal of Athletic Training*, vol. 48, no. 5, pp. 685–695, Oct. 2013.
- [7] B. J. Fregly, J. A. Reinbolt, K. L. Rooney, K. H. Mitchell, and T. L. Chmielewski, "Design of patient-specific gait modifications for knee osteoarthritis rehabilitation," *IEEE Transactions on Biomedical Engineering*, vol. 54, no. 9, pp. 1687–1695, Sep. 2007.
- [8] J. Houck, J. A. Kneiss, S. V. Bukata, and J. E. Puzas, "Analysis of vertical ground reaction force variables during a Sit to Stand task in participants recovering from a hip fracture," *Clinical Biomechanics*, vol. 26, no. 5, pp. 470–476, Jun. 2011.
- [9] K. Y. Shin, Y. H. Rim, Y. S. Kim, H. S. Kim, J. S. Han, C. H. Park, K. S. Lee, and J. H. Mun, "A joint normalcy index to evaluate patients with gait pathologies in the functional aspects of joint mobility," *Journal of Mechanical Science and Technology*, vol. 24, no. 9, pp. 1901–1909, Sep. 2010.
- [10] T. Sim, H. Kwon, S. E. Oh, S. Joo, A. Choi, H. Heo, K.-S. Kim, and J. H. Mun, "Predicting complete ground reaction forces and moments during GAIT with insole plantar pressure information using a Wavelet neural network," *Journal of Biomechanical Engineering*, vol. 137, no. 9, Sep. 2015.
- [11] R. Parry, E. Lalo, J. Roussel, M. Jabloun, J. Riff, M. Welter, and O. Buttelli, "Caractérisation du freezing de la marche en situation réelle," *Neurophysiologie Clinique*, vol. 45, no. 4–5, p. 392, Nov. 2015.
- [12] R. Parry, N. Sellam, E. Lalo, M. Welter, and O. Buttelli, "Pattern électromyographique de la marche parkinsonnienne en condition de vie réelle," *Neurophysiologie Clinique*, vol. 46, no. 4–5, pp. 273–274, Nov. 2016.
- [13] J. Favre, M. Hayoz, J. C. Erhart-Hledik, and T. P. Andriacchi, "A neural network model to predict knee adduction moment during walking based on ground reaction force and anthropometric measurements," *Journal of Biomechanics*, vol. 45, no. 4, pp. 692–698, Feb. 2012.
- [14] D. O. Odebiyi and U. A. C. Okafor, "Musculoskeletal disorders, workplace ergonomics and injury Prevention," in *IntechOpen eBooks*, 2023.
- [15] M. Yazji, M. Raison, C.-É. Aubin, H. Labelle, C. Detrembleur, P. Mahaudens, and M. Mousny, "Are the mediolateral joint forces in the lower limbs different between scoliotic and healthy subjects during gait?," *Scoliosis*, vol. 10, no. S2, Feb. 2015.
- [16] R. Bezzini, L. Crosato, M. T. Losè, C. A. Avizzano, M. Bergamasco, and A. Filippeschi, "Closed-Chain Inverse Dynamics for the Biomechanical Analysis of Manual Material Handling Tasks through a Deep Learning Assisted Wearable Sensor Network," *Sensors*, vol. 23, no. 13, p. 5885, Jun. 2023.
- [17] E. Matijevich, P. Völgyesi, and K. E. Zelik, "A promising wearable solution for the practical and accurate monitoring of low back loading in manual material handling," *Sensors*, vol. 21, no. 2, p. 340, Jan. 2021.
- [18] F. G. Larsen, F. P. Svenningsen, M. S. Andersen, M. De Zee, and S. Skals, "Estimation of spinal loading during manual materials handling using inertial motion capture," *Annals of Biomedical Engineering*, vol. 48, no. 2, pp. 805–821, Nov. 2019.
- [19] A. Muller, C. Pontonnier, X. Robert-Lachaine, G. Dumont, et A. Plamondon, "Motion-based prediction of external forces and moments and back loading during manual material handling tasks," *Applied Ergonomics*, vol. 82, Jan. 2020.
- [20] P. orbeil, A. Plamondon, G. Handrigan, J. Vallee-Marcotte, S. Lau- ´rendeau, J. Ten Have, and N. Manzerolle, "Biomechanical analysis of manual material handling movement in healthy weight and obese workers," *Applied Ergonomics*, vol. 74, pp. 124–133, Jan. 2019.
- [21] A. D. Gagnon, A. Plamondon, and C. Larivière, "A comparison of lumbar spine and muscle loading between male and female workers during box transfers," *Journal of Biomechanics*, vol. 81, pp. 76–85, Nov. 2018.

- [22] S. Joo, S. E. Oh, and J. H. Mun, "Improving the ground reaction force prediction accuracy using one-axis plantar pressure: Expansion of input variable for neural network," *Journal of Biomechanics*, vol. 49, no. 14, pp. 3153–3161, Oct. 2016.
- [23] H. Savelberg and A. Lange, "Assessment of the horizontal, fore-aft component of the ground reaction force from insole pressure patterns by using artificial neural networks," *Clinical Biomechanics*, vol. 14, no. 8, pp. 585–592, Oct. 1999.
- [24] D. A. Jacobs and D. P. Ferris, "Estimation of ground reaction forces and ankle moment with multiple, low-cost sensors," *Journal of Neuroengineering and Rehabilitation*, vol. 12, no. 1, Oct. 2015.
- [25] E. C. Honert, F. Hoitz, S. Blades, S. Nigg, and B. M. Nigg, "Estimating Running Ground Reaction Forces from Plantar Pressure during Graded Running," *Sensors*, vol. 22, no. 9, p. 3338, Apr. 2022.
- [26] D. T.-P. Fong, Y. M. Chan, Y. Hong, P. S. Yung, K. P. Fung, and K. Chan, "Estimating the complete ground reaction forces with pressure insoles in walking," *Journal of Biomechanics*, vol. 41, no. 11, pp. 2597–2601, Aug. 2008.
- [27] M. Saraceno, "La méthode graphique et l'esprit du « capteur d'activité » (1847-1920)," *L Homme Et La Société*, vol. n° 207, no. 2, pp. 51–74, Oct. 2018.
- [28] M. Ghanam, F. Goldschmidtboeing, T. Bilger, A. Bucherer, and P. Woias, "MEMS Shielded Capacitive Pressure and Force Sensors with Excellent Thermal Stability and High Operating Temperature," *Sensors*, vol. 23, no. 9, p. 4248, Apr. 2023.
- [29] S. nor A. Ismail, N. A. Nayan, M. A. S. M. Haniff, R. Jaafar, and Z. May, "Wearable Two-Dimensional Nanomaterial-Based Flexible Sensors for blood pressure Monitoring: a review," *Nanomaterials*, vol. 13, no. 5, p. 852, Feb. 2023.
- [30] R. Salmerón, C. B. García, and J. García, "Variance Inflation Factor and Condition Number in multiple linear regression," *Statistical Computation and Simulation/Journal of Statistical Computation and Simulation*, vol. 88, no. 12, pp. 2365–2384, Apr. 2018.
- [31] S. P. Mishra, U. K. Sarkar, S. Taraphder, S. Datta, D. P. Swain, R. Saikhom, S. Panda, and M. Laishram, "Multivariate statistical data analysis- Principal Component Analysis (PCA)," *International Journal of Livestock Research*, vol. 7, no. 5, pp. 60–78, Jan. 2017.
- [32] C. Liu, "Risk prediction of digital transformation of manufacturing supply chain based on principal component analysis and backpropagation artificial neural network," *Alexandria Engineering Journal*, vol. 61, no. 1, pp. 775–784, Jan. 2022.
- [33] Q. Fang, Z. Yongxiang, C. Xie, H. Zhang, and S. Li, "Research on PCA-LSTM-based Short-term Load Forecasting Method," *IOP Conference Series: Earth and Environmental Science*, vol. 495, no. 1, p. 012015, Apr. 2020.
- [34] T. R. Gadekallu, N. Khare, S. Bhattacharya, S. Singh, P. K. R. Maddikunta, and G. Srivastava, "Deep neural networks to predict diabetic retinopathy," *Journal of Ambient Intelligence and Humanized Computing*, vol. 14, no. 5, pp. 5407–5420, Apr. 2020.
- [35] I. T. Jolliffe and J. Cadima, "Principal component analysis: a review and recent developments," *Philosophical Transactions of the Royal Society A*, vol. 374, no. 2065, p. 20150202, Apr. 2016.
- [36] S. a. M. Stein, A. E. Loccisano, S. M. Firestine, and J. D. Evanseck, "Chapter 13 Principal Components Analysis: A Review of its Application on Molecular Dynamics Data," in *Annual Reports in Computational Chemistry*, 2006, pp. 233–261.
- [37] M. Greenacre, P. J. F. Groenen, T. Hastie, A. I. D'Enza, A. Markos, and E. Tuzhilina, "Principal component analysis," *Nature Reviews Methods Primers*, vol. 2, no. 1, Dec. 2022.
- [38] M. M. Taye, "Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions," *Computers*, vol. 12, no. 5, p. 91, Apr. 2023.
- [39] D. Wu, C. Jennings, J. Terpenney, R. X. Gao, and S. Kumara, "A comparative study on Machine learning Algorithms for smart Manufacturing: tool wear prediction using random forests," *Journal of Manufacturing Science and Engineering*, vol. 139, no. 7, Apr. 2017.
- [40] S. Nawar and A. M. Mouazen, "Comparison between Random Forests, Artificial Neural Networks and Gradient Boosted Machines Methods of On-Line Vis-NIR Spectroscopy Measurements of Soil Total Nitrogen and Total Carbon," *Sensors*, vol. 17, no. 10, p. 2428, Oct. 2017.
- [41] Y. Belina and A. Kebede, "Comparative study of Artificial Neural Network (ANN) and Support Vector Regression (SVR) in rainfall-runoff modeling of Awash Belo Watershed, Awash River Basin, Ethiopia.," *Research Square (Research Square)*, May 2023.
- [42] B. Vahdani, S. H. Iranmanesh, S. M. Mousavi, and M. Abdollahzade, "A locally linear neuro-fuzzy model for supplier selection in cosmetics industry," *Applied Mathematical Modelling*, vol. 36, no. 10, pp. 4714–4727, Oct. 2012.
- [43] S. Velliangiri, S. Alagumuthukrishnan, and S. I. T. Joseph, "A review of Dimensionality Reduction Techniques for Efficient Computation," *Procedia Computer Science*, vol. 165, pp. 104–111, Jan. 2019.
- [44] "Lower body modeling with Plug-in Gait - Nexus 2.5 Documentation - Vicon Documentation." [Online]. Available: <https://docs.vicon.com/pages/viewpage.action?pageId=50888857>.

- [45] E. Matijevich, P. Völgyesi, and K. E. Zelik, “A promising wearable solution for the practical and accurate monitoring of low back loading in manual material handling,” *Sensors*, vol. 21, no. 2, p. 340, Jan. 2021.
- [46] R. Di Gregorio and L. Vocenas, “Identification of Gait-Cycle phases for prosthesis control,” *Biomimetics*, vol. 6, no. 2, p. 22, Mar. 2021.
- [47] N. A. Albatayneh, K. I. Ghauth, and F.-F. Chua, “Utilizing learners’ negative ratings in Semantic Content-Based Recommender System for e-Learning Forum.,” *Educational Technology & Society*, vol. 21, no. 1, pp. 112–125, Jan. 2018.
- [48] R. Kohavi and G. H. John, “Wrappers for feature subset selection,” *Artificial Intelligence*, vol. 97, no. 1–2, pp. 273–324, Dec. 1997.
- [49] G. Chandrashekar and F. Sahin, “A survey on feature selection methods,” *Computers & Electrical Engineering*, vol. 40, no. 1, pp. 16–28, Jan. 2014.
- [50] C. E. Shannon, “A mathematical theory of communication,” *Bell System Technical Journal*, vol. 27, no. 3, pp. 379–423, Jul. 1948.
- [51] J. M. De La Rubia, “Rice University rule to determine the number of bins,” *Open Journal of Statistics*, vol. 14, no. 01, pp. 119–149, Jan. 2024.
- [52] F. L. Gewers, G. R. Ferreira, H. F. De Arruda, F. N. Silva, C. H. Comin, D. R. Amancio, and L. Da F Costa, “Principal Component Analysis: A Natural Approach to Data Exploration,” *ACM Computing Surveys*, vol. 54, no. 4, pp.1-34, Apr. 2018.
- [53] S. Nanga, A. T. Bawah, B. A. Acquaye, M.-I. Billa, F. D. Baeta, N. A. Odai, S. K. Obeng, and A. D. Nsiah, “Review of dimension reduction methods,” *Journal of Data Analysis and Information Processing*, vol. 09, no. 03, pp. 189–231, Jan. 2021.
- [54] E. Fix and J. L. Hodges, “Discriminatory analysis: Nonparametric discrimination: Consistency properties,” *PsycEXTRA Dataset*. 01-Jan-1951. 56= 54
- [55] B. Schölkopf, A. Smola, and K. Müller, “Kernel principal component analysis,” in *Lecture Notes in Computer Science*, 1997, pp. 583–588.
- [56] M. Melek, N. Melek, and T. Kayikcioglu, “A novel simple method to select optimal K in K-Nearest Neighbor Classifier,” *International Journal of Computer Science and Information Security*, vol. 15, no. 2, Dec. 2017. 58=56
- [57] W. Gani, H. Taleb, and M. Limam, “Support vector regression based residual control charts,” *Journal of Applied Statistics*, vol. 37, no. 2, pp. 309–324, Jan. 2010.
- [58] N. Bansal, M. Defo, and M. A. Lacasse, “Application of support vector regression to the prediction of the Long-Term impacts of climate change on the moisture performance of wood frame and massive timber walls,” *Buildings*, vol. 11, no. 5, p. 188, Apr. 2021.
- [59] A. Smola and B. Schölkopf, “A tutorial on support vector regression,” *Statistics and Computing*, vol. 14, no. 3, pp. 199–222, Aug. 2004.
- [60] C.-W. Hsu, C.-C. Chang, and C.-J. Lin, “A practical guide to support vector classification,” <http://www.csie.ntu.edu.tw/~cjlin>, May-2016.
- [61] B. Koseoglu, “Understanding Ordinary Least Square in Matrix Form with R,” *Medium*, 13-Jun-2018.
- [62] P. J. G. Teunissen, “Nonlinear least-squares,” *Manuscripta Geodaetica*, vol. 15, no. 3, pp. 137–150, Jan. 1990.
- [63] Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32.
- [64] F. B. Fitch, “Warren S. McCulloch and Walter Pitts. A logical calculus of the ideas immanent in nervous activity. Bulletin of mathematical biophysics, vol. 5 (1943), pp. 115–133.,” *The Journal of Symbolic Logic*, vol. 9, no. 2, pp. 49–50, Jun. 1944.
- [65] “The perceptron — a perceiving and recognizing automaton – brain wars.” [Online]. Available: <https://websites.umass.edu/brain-wars/1957-the-birth-of-cognitive-science/the-perceptron-a-perceiving-and-recognizing-automaton/>.
- [66] Q. Zhang and A. Benveniste, “Wavelet networks,” *IEEE Transactions on Neural Networks*, vol. 3, no. 6, pp. 889–898, Jan. 1992.
- [67] G.-G. Wang, L. Guo, and H. Duan, “Wavelet Neural network using multiple WaveLet functions in target threat assessment,” *The Scientific World Journal*, vol. 2013, pp. 1–7, Jan. 2013.
- [68] M. Alfarraj and G. AlRegib, “Petrophysical-property estimation from seismic data using recurrent neural networks,” *Society of Exploration Geophysicists*, Aug. 2018.
- [69] F. J. Ordóñez and D. Roggen, “Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition,” *Sensors*, vol. 16, no. 1, p. 115, Jan. 2016.
- [70] M. Schuster and K. K. Paliwal, “Bidirectional recurrent neural networks,” *IEEE Transactions on Signal Processing*, vol. 45, no. 11, pp. 2673–2681, Jan. 1997.
- [71] S. Yang, X. Yu, and Y. Zhou, “LSTM and GRU Neural Network Performance Comparison Study: Taking Yelp Review Dataset as an Example,” *International Workshop on Electronic Communication and Artificial Intelligence*, pp. 98–101, Jun. 2020.
- [72] Merzougui, “Chapitre 3: Réseau de neurones convolutionel CNN,” [Online]. Available: <https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKewifovQ3NqEAXU5VqQEHeiwDewQFnoECBAQAQ&url=https%3A%2F%2Fstaff.univ->

batna2.dz%2Fsites%2Fdefault%2Ffiles%2Fmerzougui_ghalia%2Ffiles%2Fsupport_de_cours_-deep_learning-chapitre3-cnn.pdf&usg=AOvVaw0lZMsTCvx0Ly5HHJqhb0Pz&opi=89978449.

[73] “Conv1d — PyTorch 2.2 documentation.” [Online]. Available: <https://pytorch.org/docs/stable/generated/torch.nn.Conv1d.html>.

[74] **A. Kammoun, P. Ravier, and O. Buttelli, “Impact of PCA Pre-Normalization Methods on Ground Reaction Force estimation accuracy,” *Sensors*, vol. 24, no. 4, p. 1137, Feb. 2024.**

[75] A. K. Jain, K. Nsandakumar, and A. Ross, “Score normalization in multimodal biometric systems,” *Pattern Recognition*, vol. 38, no. 12, pp. 2270–2285, Dec. 2005.

[76] D. Ruppert, F. R. Hampel, E. Ronchetti, P. J. Rousseeuw, and W. A. Stahel, “Robust Statistics: the approach based on influence functions,” *Technometrics*, vol. 29, no. 2, p. 240, May 1987.

[77] G. Aksu, C. O. Güzeller, and M. T. Eser, “The effect of the normalization method used in different sample sizes on the success of artificial neural network model,” *International Journal of Assessment Tools in Education*, vol. 6, no. 2, pp. 170–192, Jul. 2019.

[78] H. Anysz, A. Zbiciak, and N. Ibadov, “The influence of input data standardization method on prediction accuracy of artificial neural networks,” *Procedia Engineering*, vol. 153, pp. 66–70, Jan. 2016.

[79] L. Amorim, G. D. C. Cavalcanti, and R. M. O. Cruz, “The choice of scaling technique matters for classification performance,” *Applied Soft Computing*, vol. 133, p. 109924, Jan. 2023.

[80] **A. Kammoun, P. Ravier, and O. Buttelli, “Selection of insole pressure sensors for Ground Reaction Force estimation by Artificial Neural Network through studying Principal Component Analysis,” *Biomedical Signal Processing and Control*, Submitted, August 2024.**

[81] R. E. Kati, S. E. Forrester, and P. R. Fleming, “Evaluation of pressure insoles during running,” *Procedia Engineering*, vol. 2, no. 2, pp. 3053–3058, Jun. 2010.

[82] H. G. Chambers and D. H. Sutherland, “A practical guide to GAIT analysis,” *Journal of the American Academy of Orthopaedic Surgeons*, vol. 10, no. 3, pp. 222–231, May 2002.

[83] **A. Kammoun, P. Ravier, and O. Buttelli, “Comparison of the Accuracy of Ground Reaction Force Component Estimation between Supervised Machine Learning and Deep Learning Methods Using Pressure Insoles,” *Sensors*, vol. 24, no. 16, p. 5318, Aug. 2024.**

Amal KAMMOUN

Estimation des forces de réaction au sol à partir des mesures de semelles instrumentées

Résumé :

Les approches de la biomécanique, en particulier celles basées sur les valeurs des composantes de la Forces de Réaction au Sol (FRS), sont largement utilisées dans plusieurs domaines tels que la médecine pour évaluer les conditions de marche, le sport et l'ergonomie. La FRS représente la force exercée par le sol sur un corps (dans notre cas, le pied) en contact avec lui. À l'heure actuelle, les composantes de la FRS sont évaluées à l'aide de plateformes de force. Généralement, ces plateformes ne sont pas mobiles, ce qui rend difficile l'évaluation de la FRS dans des situations réelles en dehors d'un laboratoire d'analyse, telles que les activités sportives et la marche. De plus, il a été montré que notre motricité est dépendante du contexte d'activité, il est donc pertinent de réinvestir en conditions réelles d'activité (écologiques). C'est pourquoi il est important de développer des dispositifs embarqués et portables.

Depuis plus d'une décennie, des travaux ont été menés pour estimer la FRS à partir d'une semelle instrumentée équipée de capteurs de pression, ce qui offre une perspective de mesure de composants de la FRS portables à faible coût, indépendamment d'un environnement dédié à l'analyse du mouvement. Dans le marché industriel, il existe des semelles de pression qui sont capables d'estimer seulement la composante verticale F_z , à l'extérieur et à l'intérieur du laboratoire. Néanmoins, les deux composantes F_y et F_x doivent être aussi évaluées.

L'intérêt des travaux de thèse est d'estimer les trois composantes de la FRS à partir des données de semelle de pression, pour les activités de marche et de port de charge. L'estimation sera réalisée en utilisant différentes méthodes d'apprentissage automatique. Afin d'évaluer la précision de l'estimation des composantes de la FRS, nous utilisons également les données des deux plateformes de force comme référence. Nous nous intéressons également à réduire la dimension des données de pression et à sélectionner les capteurs pertinents dans l'estimation de la FRS afin d'obtenir un dispositif à faible coût.

Mots clés : forces de réaction au sol, mesure de pression de la semelle, mesure de la plateforme de force, apprentissage automatique, sélection des capteurs de pression, réduction de dimension

Estimation of ground reaction forces from instrumented insoles measurements

Summary :

Biomechanical approaches, in particular those based on the values of the components of the Ground Reaction Force (GRF), are widely used in many fields such as medicine to evaluate walking conditions, sport and ergonomics. GRF represents the force exerted by the ground on a body (in our case, the foot) in contact with it. Currently, GRF components are assessed using force plate. Generally speaking, these platforms are not mobile, which makes it difficult to assess GRF in real-life situations outside an analysis laboratory, such as sports activities and walking. Furthermore, it has been shown that our motor skills are dependent on the context of activity, so it is relevant to reinvestigate in real (ecological) activity conditions. That's why it's important to develop portable, on-board devices.

For more than a decade, work has been carried out to estimate the GRF from an instrumented footplate equipped with pressure sensors, offering the prospect of measuring low-cost, portable GRF components independently of a dedicated motion analysis environment. In the industrial market, there are pressure plates capable of estimating only the vertical component F_z , both inside and outside the laboratory. However, the two components F_y and F_x must also be evaluated.

The interest of the thesis work is to estimate all three components of GRF from pressure sole data, for walking and load-bearing activities. The estimation will be carried out using different machine learning methods. To assess the accuracy of GRF component estimation, we are also using data from the two force platforms as a reference. We are also interested in reducing the dimension of the pressure data and selecting the relevant sensors in the GRF estimation in order to obtain a low-cost device.

Keywords : ground reaction force, insole pressure measurement, force plate measurement, machine learning, pressure sensor selection, dimension reduction