

ENTRAÎNEMENT D'UN RÉSEAU DE NEURONES
BILSTM POUR ESTIMER LA CINÉMATIQUE DES
TROIS AXES DE ROTATION DU GENOU À PARTIR DE
DONNÉES ISSUES DE CENTRALES INERTIELLES :
ÉTUDE PRÉLIMINAIRE

par

Daphnée LALONDE-LAROCQUE

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAÎTRISE
AVEC MÉMOIRE EN GÉNIE DES TECHNOLOGIES DE LA SANTÉ
M. Sc. A.

MONTREAL, LE 5 MAI 2025

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Daphnée Lalonde-Larocque, 2025



Cette licence [Creative Commons](https://creativecommons.org/licenses/by-nc-nd/4.0/) signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette œuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'œuvre n'ait pas été modifié.

PRÉSENTATION DU JURY
CE MÉMOIRE A ÉTÉ ÉVALUÉ
PAR UN JURY COMPOSÉ DE :

Mme Nicola Hagemeister, directrice de mémoire
Département de génie des systèmes à l'École de technologie supérieure

Mme Neila Mezghani, codirectrice de mémoire
Département de science et technologie à l'Université TÉLUQ

M. Rachid Aissaoui, président du jury
Département de génie des systèmes à l'École de technologie supérieure

M. Éric Granger, membre du jury
Département de génie des systèmes à l'École de technologie supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 23 AVRIL 2025

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

AVANT-PROPOS

Une partie du travail présenté dans ce mémoire a été réalisée dans le cadre d'un projet final pour le cours SYS843 (Réseaux de neurones et systèmes flous), offert à l'École de technologie supérieure (ÉTS). Ce cours, dispensé par M. Éric Granger au département de génie des systèmes, a constitué une base importante pour le développement de cette recherche. Une reformulation adaptée des éléments issus de ce travail sera effectuée afin d'assurer leur intégration harmonieuse dans ce mémoire.

Par ailleurs, bien que l'usage d'acronymes en français soit privilégié dans un mémoire rédigé en français, certains termes demeureront en anglais, conformément à leur emploi courant dans la littérature scientifique du domaine. Soucieuse du respect de la langue française, l'autrice fournira une traduction en note de bas de page ainsi que dans la liste des abréviations, sigles et acronymes. Ces traductions seront principalement issues de la vitrine linguistique de l'Office québécois de la langue française (OQLF) (<https://vitrinelinguistique.oqlf.gouv.qc.ca/>). Lorsqu'aucune traduction officielle ne sera disponible, une traduction libre sera proposée, accompagnée de la mention « traduction libre » en note de bas de page.

REMERCIEMENTS

La concision n'a jamais été ma force, et il me semble presque impossible de réduire en quelques paragraphes toute la reconnaissance que j'éprouve envers les personnes qui m'ont soutenue, non seulement dans la rédaction de ce mémoire, mais aussi tout au long du parcours qui m'y a menée.

Tout d'abord, un immense merci à ma directrice, Nicola, pour toutes les opportunités que tu m'as offertes. Merci pour ton soutien et, surtout, pour ton incommensurable humanité. Ces dernières années ont mis ma santé mentale à rude épreuve, et je doute que j'aurais pu terminer ma maîtrise sans ton écoute attentive et la sécurité que tu offres à tes étudiant.e.s pour exprimer leurs émotions et leurs difficultés. Merci également à ma co-directrice, Neila, pour ton soutien et tes précieuses suggestions.

Un grand merci aussi à Youssef pour ta patience et ton aide, que j'aurais dû solliciter plus souvent. Je sais que cela compliquait parfois ton travail, mais tes nombreuses explications ont fait toute la différence. Merci d'avoir pris le temps d'optimiser mon code.

Rachid et Éric, je vous remercie d'avoir accepté de faire partie de mon jury de soutenance. Merci pour vos enseignements et pour la passion avec laquelle vous transmettez vos connaissances.

Je souhaite aussi exprimer ma gratitude envers mes proches et toutes les personnes qui ont croisé mon chemin ces dernières années. Chaque conversation et expérience partagée a joué un rôle dans la construction de mon parcours atypique. Parmi eux, certains méritent une mention toute particulière.

Papa, Maman, merci d'être des modèles de résilience et d'amour. Depuis que j'ai su aligner deux mots, vous avez toujours pris le temps de répondre à mes mille-et-une questions. Vous m'avez appris à accepter le refus, mais aussi à foncer et à dépasser les obstacles. Merci d'avoir

VIII

continué à me soutenir inconditionnellement à travers chaque changement de programme et chaque redéfinition de mes objectifs de vie, même lorsque cela devenait difficile à expliquer à vos collègues. Merci pour tous les soupers de ma jeunesse où vous m'avez écouté discourir sur mes apprentissages de la journée, ils sont à la base même des fondations de mon identité : quelqu'un qui adore non seulement apprendre, mais aussi aider les autres à apprendre. Votre intérêt pour mes études, même quand elles dépassaient votre compréhension, a fait de moi une personne qui croit (de façon peut-être un peu trop optimiste) que tout peut être compris, tant que l'explication est bien adaptée. Merci pour ce cadeau, je vous aime.

Flo, ma petite sœur, je t'aime vraiment fort. Savoir que tu as pu éviter certaines de mes épreuves est un baume pour mon cœur de grande sœur. Je suis heureuse de te voir t'épanouir aux côtés de Jason et de ma « *dog-niece* » Leela. Prends le temps de te découvrir, d'apprendre, d'aimer et être aimée. Même à distance, je suis ton admiratrice numéro un. Le jour de ton premier spectacle d'humour, je serai celle qui rit fort dans la première rangée, juste à côté du drôle de rire de Maman et du reste de la famille. C'est maintenant inscrit noir sur blanc : tu es, sans conteste, la plus drôle de la famille. Je t'aime.

Papy et Mamie, merci de m'avoir offert un endroit confortable où vivre en sécurité. Merci de laisser votre petite-fille passer en tornade une fois de temps en temps et l'écouter parler à 100 milles à l'heure des nouveautés dans sa vie en lui offrant une oreille sage et remplie de tendresse. Je vous aime.

Mémé et Rolland, merci de m'avoir permis de vivre ma première conférence internationale accompagnée de mes parents. Je vous aime.

George, *my love*, ce chapitre touche enfin à sa fin. C'est toi qui as trouvé ce programme de maîtrise alors que je ne savais pas quoi faire après mon baccalauréat. Tu m'as fait réaliser ce que j'aurais dû savoir depuis longtemps : que l'ingénierie se conjugue aussi au féminin. Merci d'avoir été à mes côtés au travers des hauts, mais surtout des très bas. Merci de m'aider chaque jour à guérir mes blessures, même si les tiennes sont encore bien vives. Merci de secouer mon

confort et d'accueillir la Québécoise très souverainiste que je suis dans ta famille et ta culture arménienne-libanaise. Merci pour ta façon unique que tu as de m'aimer et pour le support que tu as envers mes idées folles. Maintenant que mes études sont terminées, j'ai hâte au prochain chapitre afin de partager cet amour avec nos futurs mini-nous, entourée de ta famille, Alexie, Rita, Alexia et Gabriella. Je t'aime d'amour, bibi.

Laurent, depuis nos dix ans, merci de m'avoir accompagnée dans les hauts et les bas. Merci de me rappeler chaque jour la force de la parole et la puissance d'une oreille attentive. La vie fait bien plus peur que la mort, mais chaque année nous entraîne à devenir de meilleurs soldats. Je t'aime.

Shophika, merci de m'avoir guidée quand mon programme universitaire ne m'inspirait pas. Merci de m'avoir poussé hors de ma zone de confort à travers tes projets aussi ambitieux que passionnants. Merci de m'avoir appris l'importance d'atteindre nos objectifs aux bons moments tout en sachant poser nos limites. Tu brilles Momzie, et tu illumines chaque endroit où tu mets les pieds. Petit train va loin, je t'aime.

Juliette, bien que tu ne sois plus dans ma vie en cette fin de rédaction, merci de m'avoir enseigné la joie de chaque réussite personnelle à l'aide de la patience, de la force de l'esprit et de la reconnaissance de chaque effort. Merci de m'avoir appris l'importance de l'inclusivité et d'avoir nourri mon intérêt pour la mise en place d'outils plus adaptés. Merci d'avoir été ma petite sœur l'espace d'un instant. Je t'aime.

Dan, merci d'avoir été mon confident pendant mes années de rédaction. Merci d'avoir fait l'effort pour prendre de mes nouvelles à l'aide de soirées jeux vidéo et de t'être assuré de mon bien-être en même temps que tu me parlais du tien. Merci d'avoir été un ami sincère au travers de mes difficultés à communiquer mes émotions. Je t'aime.

Enfin, tant d'autres noms me viennent à l'esprit : Maude et Léo, Annie et Joe, Dan L-H, Alec. Votre présence dans ma vie compte infiniment pour moi. Merci, je vous aime.

Entraînement d'un réseau de neurones BiLSTM pour estimer la cinématique des trois axes de rotation du genou à partir de données issues de centrales inertielles : étude préliminaire

Daphnée LALONDE-LAROCQUE

RÉSUMÉ

L'analyse du mouvement du genou est essentielle pour comprendre la dynamique de la marche et optimiser le diagnostic et la rééducation des patients. Actuellement, les courbes cinématiques sont obtenues via des systèmes optoélectroniques précis, mais coûteux et contraignants. Les centrales inertielles (IMUs) apparaissent comme une alternative prometteuse, permettant une acquisition en temps réel dans des environnements non contrôlés. Toutefois, assurer un référentiel anatomique stable reste un défi majeur pour garantir la précision clinique des mesures. L'apprentissage machine, notamment les réseaux de neurones, offre une solution efficace pour exploiter les données IMU sans référentiel et réduire les erreurs d'estimation. Cependant, leur fiabilité reste perfectible, notamment dans les plans anatomiques où les amplitudes de mouvement sont faibles. De plus, si l'ajout de plusieurs IMUs améliore la précision, il complexifie également le protocole expérimental.

Cette étude propose un algorithme fondé sur un réseau de mémoire longue à court terme bidirectionnel (BiLSTM), conçu pour estimer avec précision les courbes cinématiques du genou dans les trois plans anatomiques, en utilisant seulement deux IMUs. L'objectif est d'allier précision et praticité, en visant une généralisation à une population plus hétérogène.

Une analyse préliminaire a démontré la cohérence des facteurs biomécaniques obtenus, indépendamment du choix des cycles de marche, éliminant ainsi la nécessité d'un prétraitement supplémentaire. L'évaluation du modèle BiLSTM a révélé que la séparation des couches de sortie par axes limite la propagation des erreurs, améliorant ainsi la précision des mesures sur les axes de rotation tibiale interne/externe et de flexion/extension. Comparée aux approches existantes, la méthode proposée atteint des performances élevées tout en réduisant le nombre d'IMUs nécessaires. Cependant, un phénomène de surapprentissage a été observé, malgré un partitionnement des données respectant la distribution des niveaux pathologiques. Cette observation interroge la reproductibilité des résultats présentés dans la littérature et souligne la nécessité d'adapter le partitionnement et la complexité du modèle.

L'approche développée se révèle particulièrement prometteuse, et plusieurs optimisations restent envisageables afin d'améliorer sa robustesse et sa capacité de généralisation.

Mots-clés : biomécanique, cinématique du genou, centrales inertielles, apprentissage machine, réseaux de neurones

Training a BiLSTM neural network to estimate triaxial knee joint kinematics from inertial measurement unit data: preliminary study

Daphnée LALONDE-LAROCQUE

ABSTRACT

Knee motion analysis is essential for understanding gait dynamics and optimizing patient diagnosis and rehabilitation. Currently, kinematic curves are obtained using precise but costly and restrictive optoelectronic systems. Inertial measurement units (IMUs) have emerged as a promising alternative, enabling real-time acquisition in uncontrolled environments. However, ensuring a stable anatomical reference frame remains a major challenge in achieving clinically accurate measurements. Machine learning, particularly neural networks, provides an effective solution for leveraging IMU data without a reference frame, thereby reducing estimation errors. Nonetheless, their reliability remains suboptimal, especially in anatomical planes where motion amplitudes are low. Moreover, while increasing the number of IMUs improves accuracy, it also complicates the experimental protocol.

This study proposes an algorithm based on a bidirectional long short-term memory (BiLSTM) network designed to accurately estimate knee kinematic curves in all three anatomical planes using only two IMUs. The objective is to balance accuracy and practicality while aiming for generalization to a more heterogeneous population.

A preliminary analysis demonstrated the consistency of the obtained biomechanical factors, regardless of the choice of gait cycles, thereby eliminating the need for additional preprocessing. The evaluation of the BiLSTM model revealed that separating the output layers by axis limits error propagation, thus improving measurement accuracy for tibial internal/external rotation and flexion/extension axes. Compared to existing approaches, the proposed method achieves high performance while reducing the number of required IMUs. However, an overfitting phenomenon was observed despite a data partitioning strategy that preserved the distribution of pathological levels. This observation raises concerns about the reproducibility of results reported in the literature and highlights the need to refine both data partitioning strategies and model complexity.

The proposed approach proves particularly promising, with several optimizations still possible to enhance its robustness and generalization capability.

Keywords: biomechanics, knee kinematics, inertial measurement units, machine learning, neural networks

TABLE DES MATIÈRES

Page

CHAPITRE 4	Méthodologie de l'objectif principal	75
4.1	Préprocessus sur les données	75
4.1.1	Calcul des vitesses angulaires	76
4.1.2	Mise en forme de la base de données.....	77
4.2	Apprentissage du réseau de neurones BiLSTM.....	80
4.2.1	Augmentation du nombre d'échantillons par segmentation	80
4.2.2	Architecture du réseau de neurones BiLSTM.....	81
4.2.3	Protocole d'évaluation des performances	84
CHAPITRE 5	Résultats.....	91
5.1	Résultats de l'apprentissage du réseau.....	91
5.2	Résultats des métriques et des prédictions sur la base de test.....	93
CHAPITRE 6	Discussion	97
6.1	Interprétation des résultats du protocole d'évaluation des performances du réseau....	97
6.1.1	Observations sur les métriques évaluées sur la base de test	97
6.1.2	Observations sur les prédictions faites sur la base de test	104
6.2	Interprétation des résultats de l'apprentissage du réseau.....	106
6.3	Apports à la recherche	108
CONCLUSION	111
RECOMMANDATIONS	115
ANNEXE I	Liste des facteurs biomécaniques traduits.....	119
ANNEXE II	Définitions des facteurs biomécaniques.....	121
ANNEXE III	Tableaux des résultats d'erreurs absolues de comparaison entre les facteurs biomécaniques calculés sur tous les cycles par rapport à ceux calculés sur les 15 cycles les plus répétables	129
ANNEXE IV	Tableaux des résultats de concordance des catégories obtenues entre les facteurs biomécaniques calculés sur tous les cycles par rapport à ceux calculés sur les 15 cycles les plus répétables	133
ANNEXE V	Diagramme du calcul de la vitesse angulaire par Moveck	137
ANNEXE VI	Tableaux des distributions détaillées des bases de données d'entraînement et de test décrivant les quantités et les proportions des échantillons et des patients uniques de chaque grade pour chaque partition.....	139
ANNEXE VII	Tableaux descriptifs des architectures et des hyperparamètres utilisés dans la littérature pour l'apprentissage de réseaux de neurones en analyse de la marche.....	143

ANNEXE VIII	Graphiques des fonctions de perte lors de l'entraînement de chaque partition.....	147
ANNEXE IX	Résultats des métriques évaluées sur les bases de test de chaque partition en différenciant les calculs retirant les valeurs extrêmes	153
APPENDICE A	Article soumis portant sur ce projet de maîtrise	155
BIBLIOGRAPHIE	159

LISTE DES TABLEAUX

	Page
Tableau 1.1 Association des axes de rotation du genou avec les axes et plans anatomiques	6
Tableau 1.2 Facteurs biomécaniques observés sur les courbes de patron de marche pour les patients gonarthrosiques	16
Tableau 1.3 Résumé des architectures et méthodologies utilisées dans la littérature pour l'apprentissage par réseaux de neurones en analyse de la marche	39
Tableau 1.4 Résumé des mesures de performance évaluées dans la littérature par les études faisant usage d'un LSTM ou d'un BiLSTM	41
Tableau 3.1 Description de la population des bases de données MonArthrose et HMR	55
Tableau 3.2 Données démographiques associées à chacun des groupes et sous-groupes formés par les deux bases de données pour l'étape préliminaire	59
Tableau 3.3 Bornes associées aux catégories possibles de chaque facteur biomécanique selon une valeur numérique obtenue de x (en degrés)	63
Tableau 3.4 Moyenne et écart-type des écarts absolus obtenus par la comparaison des méthodes de calcul pour chaque facteur biomécanique	65
Tableau 3.5 Moyenne et écart-type (en degrés) par groupe des erreurs absolues de calcul des facteurs biomécaniques en fonction de chaque axe	66
Tableau 3.6 Moyenne des taux de concordance obtenus par la comparaison des catégories évaluées par les deux méthodes de calcul pour chaque facteur biomécanique	70
Tableau 3.7 Moyenne par groupe des taux de concordance des catégories évaluées pour les facteurs biomécaniques en fonction de chaque axe	71
Tableau 4.1 Distribution des quantités d'échantillons et des quantités de patients uniques dans les bases de données d'entraînement et de test pour chaque partition.....	85
Tableau 4.2 Liste des valeurs testées pour chaque hyperparamètre du réseau	90
Tableau 5.1 Sommaire de la complexité et du temps de calcul du RNA final	91

Tableau 5.2	Résultats des mesures de performance du réseau en fonction de chaque couche de sortie94
Tableau 6.1	Comparaison des valeurs de RMSE de notre modèle par rapport à celles retrouvées dans la littérature100
Tableau 6.2	Comparaison des valeurs de nRMSE de notre modèle par rapport à celles retrouvées dans la littérature101

LISTE DES FIGURES

	Page
Figure 1.1	Représentation des axes et plans anatomiques par rapport au corps humain.....6
Figure 1.2	Schéma anatomique du genou7
Figure 1.3	Illustration des six degrés de liberté du genou.....8
Figure 1.4	Comparaison entre des genoux désaxés en varus (à gauche) et en valgus (à droite)11
Figure 1.5	Courbes partielles d'angles au genou d'un patient sain pour les trois mouvements de rotation d'un essai complet de marche12
Figure 1.6	Phases du cycle de marche.....13
Figure 1.7	Identification d'éléments importants retrouvés sur une courbe partielle du mouvement de Fl/Ex (plan sagittal) d'un patient sain pour un essai complet.....14
Figure 1.8	Identification de quelques points associés à des facteurs biomécaniques sur les cycles moyens d'un patient sain pour les plans sagittal, frontal et transversal, respectivement.....17
Figure 1.9	Représentation des deux chemins possibles pour le passage d'une variable cinématique à une autre.....18
Figure 1.10	(a) Représentation simplifiée de l'espace de travail et de la disposition des caméras infrarouges d'un système optoélectronique pour l'analyse du mouvement (b) Disposition des marqueurs réfléchissants sur un participant (c) Reconstruction 3D des segments corporels à partir des informations obtenues par les capteurs optoélectroniques.....20
Figure 1.11	Système d'attaches KneeKG®, muni de deux grappes de marqueurs optoélectroniques21
Figure 1.12	Types et combinaisons de centrales inertielles utilisés dans la littérature scientifique23
Figure 1.13	Ratio des différentes applications de l'analyse du mouvement à l'aide de centrales inertielles.....24

Figure 1.14	Architecture type d'un RNA de type FFNN avec rétropropagation	27
Figure 1.15	Architecture d'une cellule de réseau LSTM avec représentation des trois types de portes	35
Figure 1.16	Architecture simplifiée d'une cellule BiLSTM	37
Figure 1.17	Illustration de la méthode de validation croisée en k partitions pour $k = 5$	46
Figure 3.1	Prévalence de l'arthrose diagnostiquée au Canada, selon le sexe et le groupe d'âge.....	58
Figure 3.2	Diagramme simplifié du processus suivi par le script MATLAB pour chaque essai de l'étape préliminaire	61
Figure 4.1	Diagramme de la structure du fichier associé à un patient X à la première étape de construction de la base de données combinée	78
Figure 4.2	Diagramme de la structure du fichier associé à un essai X dans la base de données combinée	79
Figure 4.3	Diagramme bloc de l'architecture du réseau BiLSTM final.....	82
Figure 4.4	Nombre d'échantillons en fonction du grade d'arthrose du genou évalué	85
Figure 4.5	Nombre de patients uniques en fonction du grade d'arthrose du genou évalué	86
Figure 5.1	Courbes de la fonction de perte (MSE) pour la partition 1	92
Figure 5.2	Graphiques des courbes prédites et attendues de chaque axe de rotation pour trois échantillons de la base de test	95

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

1D-CNN	<i>Convolutional Neural Networks in one dimension</i> Français : Réseaux de neurones à convolutions en une dimension
Ab/Ad	Abduction/Adduction
BiLSTM	<i>Bidirectional Long Short-term Memory</i> Français : Réseau de mémoire longue à court terme bidirectionnel
CIUSSS	Centre intégré universitaire de santé et de services sociaux
CNN	<i>Convolutional Neural Networks</i> Français : Réseaux de neurones à convolutions
CRCHUM	Centre de recherche du centre hospitalier de l'Université de Montréal
DNN	<i>Deep Neural Networks</i> Français : Réseaux de neurones profonds
ET	Écart-type
ÉTS	École de technologie supérieure
Fl/Ex	Flexion/Extension
FFNN	<i>Feedforward Neural Networks</i> Français : Réseaux de neurones à propagation avant
GRNN	<i>Generalized Regression Neural Networks</i> Français : Réseaux de neurones de régression généralisée
GRU	<i>Gated Recurrent Unit</i> Français : Unité récurrente à porte
HMR	Hôpital Maisonneuve-Rosemont
IA	Intelligence artificielle
IMU	<i>Inertial Measurement Units</i> Français : Centrale inertielle
LIO-ÉTS	Laboratoire d'Innovation Ouverte en technologie de la santé

LSTM	<i>Long Short-term Memory</i> Français : Réseau de mémoire longue à court terme (MLCT)
MAE	<i>Mean Absolute Error</i> Français : Erreur absolue moyenne
MLP	<i>Multi-layer Perceptrons</i> Français : Perceptrons multicouches
MLP-BP	<i>Multi-layer Perceptrons with Back Propagation</i> Français : Perceptrons multicouches avec rétropropagation
MSE	<i>Mean Squared Error</i> Français : Erreur quadratique moyenne
NARX	<i>Nonlinear Autoregressive Neural Networks with Exogenous Inputs</i> Français : Réseaux de neurones autorégressifs non linéaires avec entrées exogènes
nRMSE	<i>Normalized Root Mean Squared Error</i> Français : Racine de l'erreur quadratique moyenne normalisée
OA	<i>Osteoarthritis</i> Français : Arthrose (dans le cadre de ce mémoire, plus spécifiquement gonarthrose)
OQLF	Office québécois de la langue française
PCA	<i>Principal Component Analysis</i> Français : Analyse en composantes principales
R	Coefficient de corrélation
RBNN	<i>Radial Basis Neural Networks</i> Français : Réseaux de neurones à bases radiales
RESNET	Réseaux résiduels
Ri/Re	Rotations interne/externe
RMSE	<i>Root Mean Squared Error</i> Français : Racine de l'erreur quadratique moyenne
RNA	Réseaux de neurones artificiels

RNN	<i>Recurrent Neural Networks</i> Français : Réseaux de neurones récurrents
TKA	<i>Total Knee Arthroplasty</i> Français : Arthroplastie totale du genou
UKA	<i>Unicompartmental Knee Arthroplasty</i> Français : Arthroplastie unicompartmentale du genou
VGG	<i>Visual Geometry Group</i> Français : Groupe de géométrie visuelle

LISTE DES SYMBOLES ET UNITÉS DE MESURE

SYMBOLES DE CINÉMATIQUE

a	Accélération
r	Position
r_0	Position au temps t_0 , position initiale
t	Temps
t_0	Temps initial
v	Vitesse
v_0	Vitesse au temps t_0 , vitesse initiale

SYMBOLES EN APPRENTISSAGE MACHINE

σ	Fonction d'activation sigmoïde
\tanh	Fonction d'activation tangente hyperbolique
k	Nombre de partitions
n	Nombre d'échantillons

SYMBOLES DE RÉSEAUX *LONG SHORT-TERM MEMORY*

c_t	État interne d'une cellule t
f_t	Porte d'oubli d'une cellule t
g_t	Nouvelles valeurs candidates d'une cellule t
h_t	État caché (sortie) d'une cellule t
i_t	Porte d'entrée d'une cellule t
o_t	Porte de sortie d'une cellule t
W_{ij}	Matrice de poids du vecteur i dans la porte j
x_t	Entrée d'une cellule t

SYMBOLE EN ÉLECTRICITÉ

Hz	Hertz, unité de fréquence, nombre de répétitions par seconde d'un évènement
------	---

INTRODUCTION

Les articulations du corps humain jouent un rôle essentiel dans les activités quotidiennes, en assurant à la fois mobilité et stabilité. Parmi elles, les genoux sont particulièrement sollicités, supportant le poids du corps et permettant des mouvements complexes indispensables à la locomotion. L'analyse du mouvement du genou revêt ainsi une importance capitale pour la compréhension de la dynamique de la marche humaine, un processus sophistiqué qui conditionne l'autonomie et la mobilité des individus. Cette analyse repose sur l'acquisition de courbes cinématiques précises, fournissant des valeurs caractéristiques essentielles à l'évaluation biomécanique. Bien que technique, cette approche possède une valeur clinique majeure, notamment pour le diagnostic, la rééducation et le suivi des patients souffrant de pathologies affectant les membres inférieurs.

Actuellement, l'acquisition de ces courbes cinématiques repose principalement sur des systèmes optoélectroniques relativement précis. Ces dispositifs, bien qu'efficaces, présentent plusieurs inconvénients : leur coût élevé, leur encombrement et la nécessité de poser un grand nombre de marqueurs réfléchissants sur le patient avant de capturer les mouvements. Cette procédure exige du temps et du personnel qualifié, limitant ainsi leur accessibilité dans un cadre clinique courant. Face à ces contraintes, les recherches s'orientent vers des solutions alternatives plus flexibles et économiquement viables, parmi lesquelles les centrales inertielles, ou *Inertial Measurement Units* [traduction de l'OQLF] (IMU), qui constituent une option prometteuse. Ces centrales intègrent des accéléromètres, des gyroscopes et des magnétomètres, offrant ainsi une capture des données en temps réel sans nécessiter un environnement contrôlé comme celui des laboratoires d'analyse du mouvement. Cependant, une limitation majeure des IMUs réside dans la définition d'un référentiel anatomique stable, condition nécessaire pour assurer une équivalence clinique avec les systèmes optoélectroniques. Les erreurs de mesure sont d'autant plus marquées dans les plans anatomiques où les amplitudes de mouvement sont faibles, ce qui peut compromettre la fiabilité des données obtenues. Malgré ces défis, les IMUs constituent une voie de recherche intéressante, à condition de développer des méthodes avancées de traitement du signal pour améliorer la précision des estimations.

L'apprentissage machine, et en particulier les réseaux de neurones, représente une approche novatrice pour optimiser l'exploitation des données issues des IMUs. En modélisant les relations complexes entre les signaux inertiels et les angles articulaires, ces algorithmes peuvent réduire les erreurs d'estimation et limiter la nécessité d'un traitement manuel et fastidieux des données. Toutefois, les écarts de précision persistent, notamment dans les axes où les amplitudes de mouvement sont réduites. De ce fait, de nombreuses études se concentrent exclusivement sur l'axe de flexion-extension du genou, restreignant ainsi la portée clinique des résultats obtenus. Pour pallier ces limitations, certaines approches intègrent un nombre plus important de centrales inertielles afin d'améliorer la fiabilité des prédictions. Néanmoins, cette stratégie entre en contradiction avec l'objectif initial de simplifier la procédure et de minimiser le nombre de capteurs à poser sur le patient.

Dans ce contexte, l'objectif principal de ce mémoire est de concevoir et d'entraîner un algorithme basé sur un réseau de neurones, visant à estimer avec précision les courbes cinématiques du genou dans les trois plans anatomiques, à savoir la flexion/extension, l'abduction/adduction et la rotation tibiale interne/externe. Cette estimation sera réalisée à partir des données issues de seulement deux centrales inertielles.

Ce mémoire est organisé en six chapitres. Le premier chapitre présente une revue de la littérature, introduisant d'abord l'anatomie du genou et sa cinématique, en passant par les caractéristiques du cycle de marche et les méthodes de mesure actuelles. Ce chapitre met également en lumière l'utilisation de l'apprentissage machine dans le domaine de l'analyse du mouvement, en mettant l'accent sur certains réseaux de neurones. Le second chapitre précise la problématique et l'objectif de recherche de ce mémoire. Le troisième chapitre aborde une phase préliminaire de l'étude, en évaluant l'impact de l'utilisation de tous les cycles de marche dans le calcul des facteurs biomécaniques, en comparaison avec l'utilisation des 15 cycles les plus répétables. Le quatrième chapitre détaille la méthodologie du projet, y compris les étapes de prétraitement des données et l'architecture du réseau de neurones développé. Le cinquième chapitre présente les résultats de l'apprentissage du réseau, tandis que le sixième chapitre

interprète ces résultats et les compare aux données de la littérature. Enfin, le mémoire se termine par une conclusion, suivie de recommandations et de perspectives futures.

CHAPITRE 1

Revue de littérature

1.1 Articulation du genou

L'articulation du genou constitue un élément clé du système musculosquelettique humain, reliant la cuisse et la jambe grâce à un ensemble complexe de structures osseuses, musculaires, ligamentaires et de tissus mous. Sa complexité anatomique se reflète dans ses six degrés de liberté, qui permettent une vaste gamme de mouvements. Ces mouvements sont essentiels à la locomotion et à la stabilité du corps, et leur analyse revêt une importance capitale pour comprendre les mécanismes biomécaniques de la marche ainsi que l'impact des pathologies sur ces fonctions.

1.1.1 Terminologie de l'analyse des mouvements du genou

L'analyse des mouvements du genou repose sur une terminologie précise qui fait référence aux axes et plans anatomiques. Ces termes permettent de décrire de manière détaillée et rigoureuse les mouvements tridimensionnels complexes de l'articulation. Le corps humain, en tant que structure tridimensionnelle, est souvent étudié à travers des repères définis par des axes et des plans orthogonaux qui facilitent cette analyse. L'axe vertical, par exemple, est perpendiculaire au sol et normal au plan transversal (également appelé plan axial). L'axe transverse, quant à lui, s'étend d'un côté à l'autre du corps et est normal au plan sagittal (ou médian). Enfin, l'axe sagittal traverse le corps d'avant en arrière et est normal au plan frontal.

Les trois axes illustrés à la figure 1.1 (p.6) sont fondamentaux pour décrire les trois principaux types de mouvements de l'articulation du genou, et sont associés à des plans anatomiques spécifiques qui structurent l'analyse biomécanique. Les mouvements du genou sont souvent observés dans un cadre tridimensionnel, ce qui rend l'étude de ces axes d'autant plus essentielle pour comprendre la cinématique du genou dans les activités fonctionnelles comme la marche, la course, ou encore les mouvements de saut et de torsion.




Figure 1.1 Représentation des axes et plans anatomiques par rapport au corps humain

L'intérêt principal de ce mémoire porte particulièrement sur les trois axes de rotation du genou, car ils permettent une description précise de la cinématique articulaire dans les trois dimensions de l'espace. Comme indiqué dans le tableau 1.1, chaque axe de rotation est associé à un plan anatomique spécifique : l'abduction/adduction (Ab/Ad) se fait autour de l'axe vertical et dans le plan frontal, la flexion/extension (Fl/Ex) autour de l'axe sagittal dans le plan sagittal, et la rotation interne/externe (Ri/Re) autour de l'axe transverse dans le plan transversal. Ces mouvements sont cruciaux pour la compréhension du comportement du genou pendant les activités fonctionnelles.

Tableau 1.1 Association des axes de rotation du genou avec les axes et plans anatomiques

Axe de rotation du genou	Axe anatomique associé	Plan anatomique associé
Abduction/Adduction (Ab/Ad)	Vertical	Frontal
Flexion/Extension (Fl/Ex)	Sagittal	Sagittal (Médian)
Rotation interne/externe (Ri/Re)	Transverse	Transversal (Axial)

L'étude et la distinction de ces axes sont essentielles pour caractériser les mouvements du genou et leur impact sur les activités quotidiennes et sportives. Les axes de rotation permettent de mieux comprendre la dynamique du genou et d'évaluer sa fonction dans divers contextes biomécaniques.

1.1.2 Description anatomique

L'articulation du genou, représentée à la figure 1.2, est constituée de trois os principaux : le fémur, le tibia et la rotule. Ces structures osseuses participent à la formation de deux articulations principales. La première, l'articulation fémoro-tibiale, se situe entre le fémur et le tibia, et elle est responsable des principaux mouvements de flexion et d'extension du genou. La seconde, l'articulation fémoro-patellaire, est formée entre le fémur et la rotule, et permet des mouvements de glissement de la rotule lors de l'extension du genou. Bien que la fibula soit située à proximité de l'articulation du genou, elle ne participe pas directement aux mouvements articulaires du genou et joue plutôt un rôle secondaire en contribuant à la stabilité latérale de la partie inférieure du genou (Marieb, 2005).




Figure 1.2 Schéma anatomique du genou
Tirée du site de Soins MSQ Champlain (2019)

La rotule, en tant qu'os sésamoïde, est logée dans le tendon du muscle quadriceps, situé à l'avant de la cuisse, près de l'articulation du genou. Elle joue un rôle clé dans l'optimisation de la fonction du quadriceps, en augmentant le bras de levier de ce muscle pendant l'extension du genou (Marieb, 2005). Cette augmentation du bras de levier permet une contraction musculaire plus efficace et une meilleure force d'extension, essentielle pour des mouvements comme la marche, la montée des escaliers ou la course. De plus, la rotule protège l'articulation fémoro-patellaire en la maintenant dans une position optimale pendant l'extension, réduisant ainsi le risque de blessures liées à des tensions excessives.




Figure 1.3 Illustration des six degrés de liberté du genou
Tirée de Planckaert (2016), p.13

Comme mentionné précédemment, l'articulation du genou se distingue par sa complexité fonctionnelle, en raison de ses six degrés de liberté qui lui confèrent une grande polyvalence dans le mouvement (*Voir* figure 1.3). Ces degrés de liberté sont répartis entre trois axes de rotation — Fl/Ex, Ab/Ad, et Ri/Re — ainsi que trois types de translations — antéropostérieure, médio-latérale et proximodistale (Planckaert, 2016). Cette configuration permet au genou d'effectuer une variété de mouvements nécessaires au maintien de la posture et à la marche,

tout en garantissant une stabilité essentielle pour supporter les charges corporelles pendant les activités de locomotion et de transfert de poids. Les mouvements de l'articulation du genou sont rendus possibles grâce à diverses structures anatomiques, notamment le cartilage articulaire, qui recouvre les surfaces osseuses du fémur, du tibia et de la rotule.

Le cartilage, principalement composé d'eau et de collagène, joue un rôle fondamental dans la fonction articulaire. Sa structure et ses propriétés viscoélastiques permettent de réduire les frottements entre les surfaces osseuses lors du mouvement, ce qui facilite non seulement le glissement, mais aussi la transmission des forces de manière plus efficace. En outre, le cartilage joue un rôle crucial dans la distribution des charges articulaires, ce qui contribue à la protection des os sous-jacents et à la prévention des lésions liées aux impacts répétitifs (Planckaert, 2016). Ce phénomène est particulièrement important dans le contexte de la biomécanique du genou, car des altérations du cartilage, telles que l'arthrose, peuvent entraîner des dysfonctionnements et des douleurs invalidantes, affectant ainsi la qualité de vie du patient.

Dans l'ensemble, la complexité du genou réside non seulement dans sa capacité à effectuer des mouvements diversifiés et coordonnés, mais également dans la nécessité d'un équilibre précis entre la mobilité et la stabilité. Toute perturbation dans la mécanique de cette articulation, que ce soit par une pathologie articulaire, telle que l'arthrose, ou une blessure, peut entraîner des répercussions considérables sur la fonctionnalité des membres inférieurs et, par extension, sur la mobilité et la qualité de vie de la personne affectée.

1.1.3 Gonarthrose

La gonarthrose, forme spécifique d'arthrose affectant l'articulation du genou, se caractérise par une dégradation progressive du cartilage articulaire. Ce processus dégénératif, qui perturbe l'intégrité de la surface cartilagineuse, compromet le bon fonctionnement de l'articulation. Cette dégradation conduit à des douleurs chroniques et à une limitation fonctionnelle, notamment lors de l'exécution de mouvements de marche, mais également dans d'autres activités physiques quotidiennes. Avec l'évolution de la pathologie, la perte de cartilage

devient plus marquée, jusqu'à sa disparition totale. Cette absence de cartilage articulaire entraîne un contact direct entre les os, provoquant des frottements mécaniques intenses. Ces frottements sont responsables de l'aggravation de la douleur et de l'inflammation observées chez les patients souffrant de gonarthrose, accentuant ainsi leurs difficultés motrices (Mon Arthrose, 2024).

L'évaluation du degré de dégradation du cartilage se fait principalement par radiographies, qui permettent de classifier l'arthrose selon un système de grades allant de 0 à 4, ce dernier indiquant une dégradation sévère. Cette évaluation est largement utilisée pour suivre la progression de la maladie. Dès le grade 2, un individu est diagnostiqué comme souffrant de gonarthrose (Kellgren & Lawrence, 1957). Il est important de noter que la gonarthrose touche fréquemment les deux genoux chez près de deux tiers des patients, augmentant ainsi la complexité du traitement et de la gestion de la pathologie (Mon Arthrose, 2024). Dans certains cas, la dégradation du cartilage peut provoquer un désalignement de l'articulation, notamment sous la forme d'un genou en varus (jambes arquées) ou en valgus (jambes en « X »), tel qu'illustré à la figure 1.4 (p.11). Bien que ces déformations ne soient pas spécifiques à la gonarthrose, elles sont fréquemment observées dans les cas avancés et ont un impact significatif sur la cinématique du genou.

Le désaxement du genou modifie l'alignement articulaire et altère la mécanique de la marche, ce qui complique l'analyse cinématique du genou. Ces déviations affectent les trajectoires normales des segments corporels pendant la marche, entraînant des compensations dans la manière de se déplacer (Gaudreault, De Guise, Hagemeister, & Poitras, 2011). De plus, la nature même de la gonarthrose étant dégénérative, de nombreux patients atteints font partie d'une population plus âgée. Étant donné qu'il existe déjà une association significative entre l'âge et l'instabilité de la marche dans le plan frontal (Terrier & Reynard, 2015), une analyse cinématique approfondie faite à l'aide de méthodes de mesure précises devient essentielle non seulement pour évaluer l'étendue de la pathologie, mais aussi pour mieux comprendre son

impact sur la fonction du genou et adapter les traitements thérapeutiques afin d'assurer le confort et la sécurité des patients.




Figure 1.4 Comparaison entre des genoux désaxés en varus (à gauche) et en valgus (à droite)
Tirée du site de ICR – Nice (2024)

1.2 Cinématique du genou

Dans le contexte de l'analyse cinématique des membres inférieurs, l'interprétation clinique repose principalement sur des paramètres biomécaniques clés. Ces paramètres, souvent appelés « facteurs ou marqueurs biomécaniques », sont calculés à partir des courbes d'angles articulaires. Ces courbes sont généralement représentées selon les trois plans anatomiques : sagittal, frontal et transverse (*Voir figure 1.5, p.12*).

Il est essentiel de noter que la marche humaine, bien que répétitive, n'est jamais parfaitement symétrique et peut varier en fonction de nombreux facteurs, tels que l'âge, la condition physique ou la présence de pathologies. Pour une meilleure interprétation des résultats, les courbes d'angles articulaires sont généralement segmentées en fonction des cycles de marche, eux-mêmes subdivisés en plusieurs phases correspondant aux différentes étapes du mouvement. Cette subdivision permet une analyse plus fine des variations de la cinématique articulaire et facilite la détection d'éventuelles anomalies dans la démarche du patient.

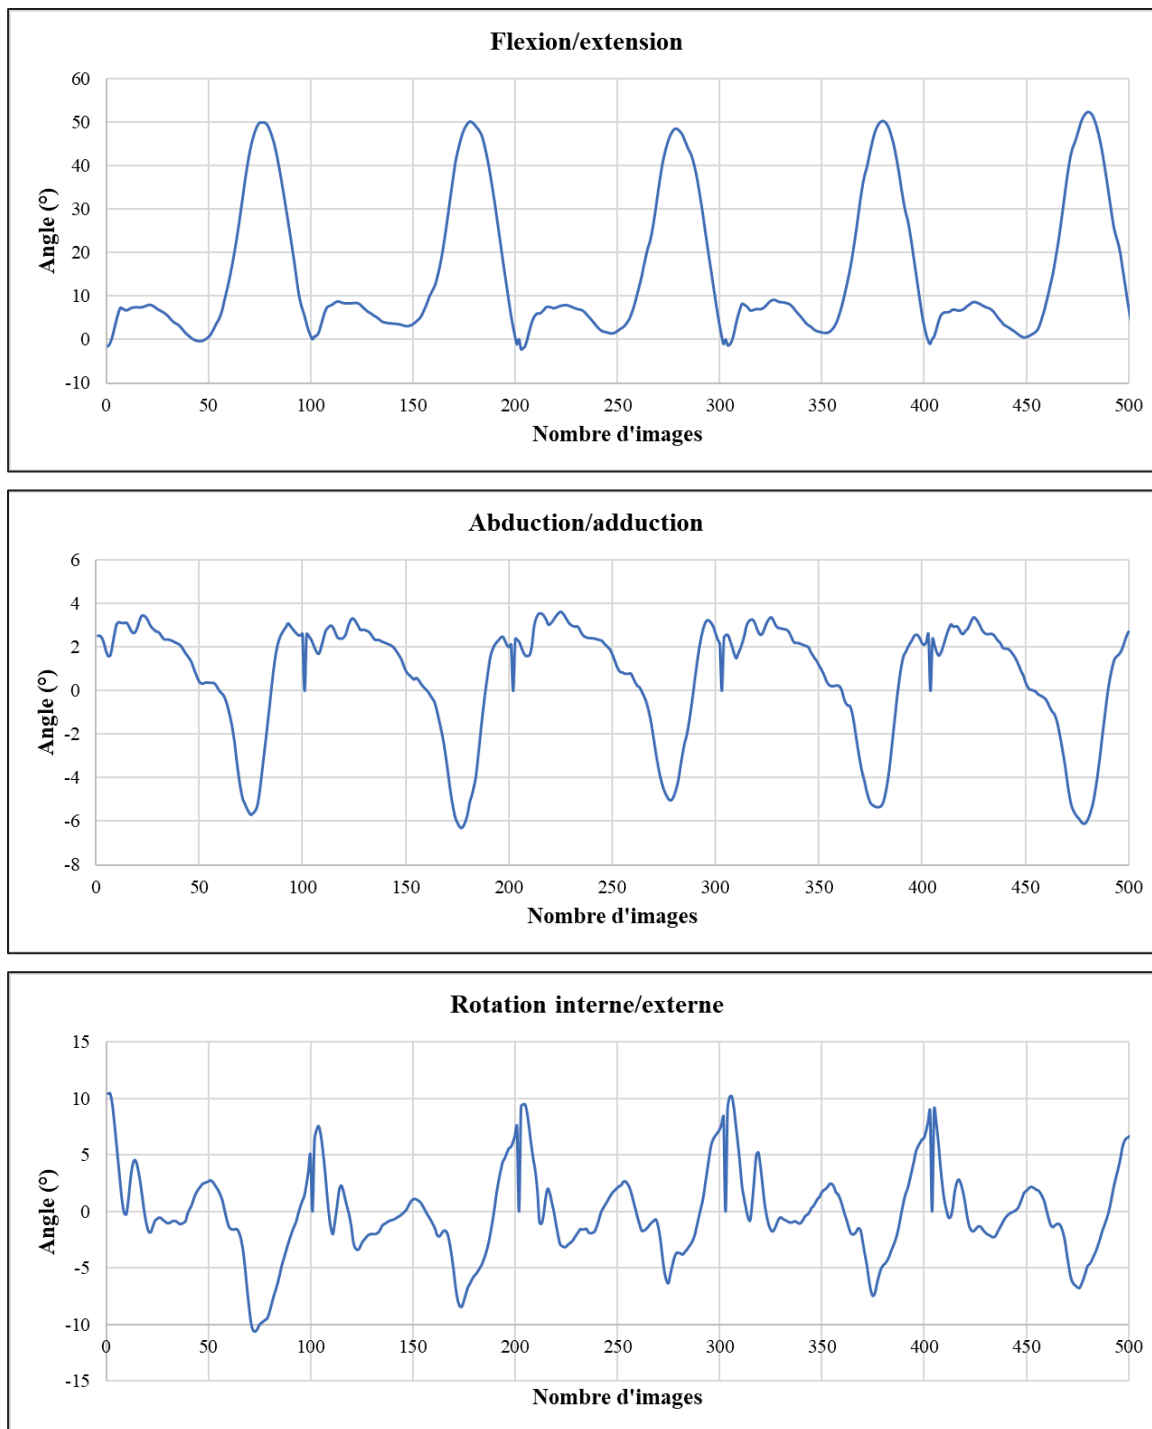


Figure 1.5 Courbes partielles d'angles au genou d'un patient sain pour les trois mouvements de rotation d'un essai complet de marche

1.2.1 Cycle de marche

La marche est un mouvement cyclique au cours duquel l'individu progresse en alternant les déplacements de ses pieds, permettant ainsi la translation du corps vers l'avant. En raison de la bipédie humaine, ce mouvement se répète de manière régulière, formant une séquence rythmique caractéristique.

Un cycle de marche débute lorsque le talon d'un pied entre en contact avec le sol et se termine lorsque ce même talon touche à nouveau le sol après avoir complété une phase complète de déplacement (Dyas, 2019). Ce cycle, illustré dans la figure 1.6, est traditionnellement divisé en plusieurs phases successives, chacune ayant une signification biomécanique spécifique et jouant un rôle clé dans la dynamique du mouvement. Ces phases incluent notamment la phase de chargement, la phase d'appui unilatéral, la phase de pré-envol et la phase d'envol, qui garantissent la continuité et la stabilité du déplacement.

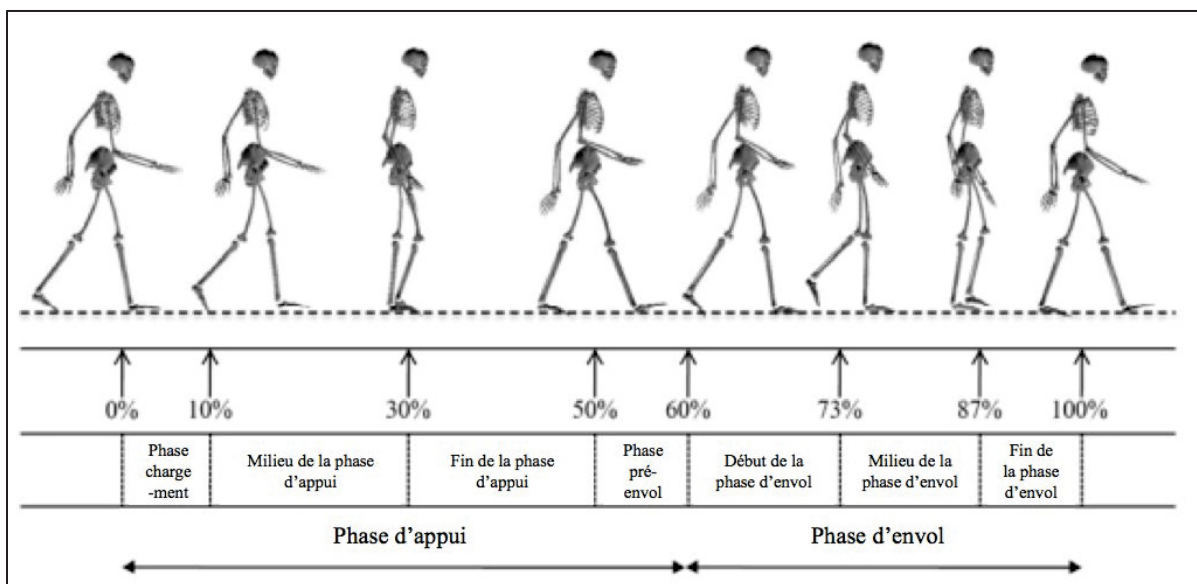


Figure 1.6 Phases du cycle de marche

Adaptée et traduite de de Guise, Mezghani, Aissaoui & Hagemester (2011), tirée de Dyas (2019), p.10

Dans le cadre de ce mémoire, le cycle de la marche est analysé comme une unité globale, ce qui permet de simplifier l'analyse et de saisir l'ensemble du mouvement. Cependant, une approche qui considère les différentes phases du cycle de manière distincte pourrait également

offrir des perspectives intéressantes, en permettant d'examiner plus en détail les interactions spécifiques entre les différentes étapes du mouvement et d'évaluer leur impact sur la cinématique du genou et du corps dans son ensemble.

Comme mentionné précédemment, les courbes cinématiques du mouvement de marche sont cycliques, il est donc possible de segmenter un essai complet en fonction de ces cycles de marche afin de faciliter l'analyse. Une méthode courante consiste à utiliser la courbe du plan sagittal (mouvement de flexion/extension), car elle est généralement la plus répétable. À partir de cette courbe, on identifie les maxima et repère le premier minimum atteint après chaque maximum. Ces minima correspondent à chaque dépôt du talon au sol, marquant ainsi le début de chaque cycle de marche (*Voir figure 1.7*). Une fois ces minima identifiés, les courbes des trois plans sont segmentées en fonction des repères temporels associés (nombre d'images), permettant de définir les courbes pour chaque cycle.

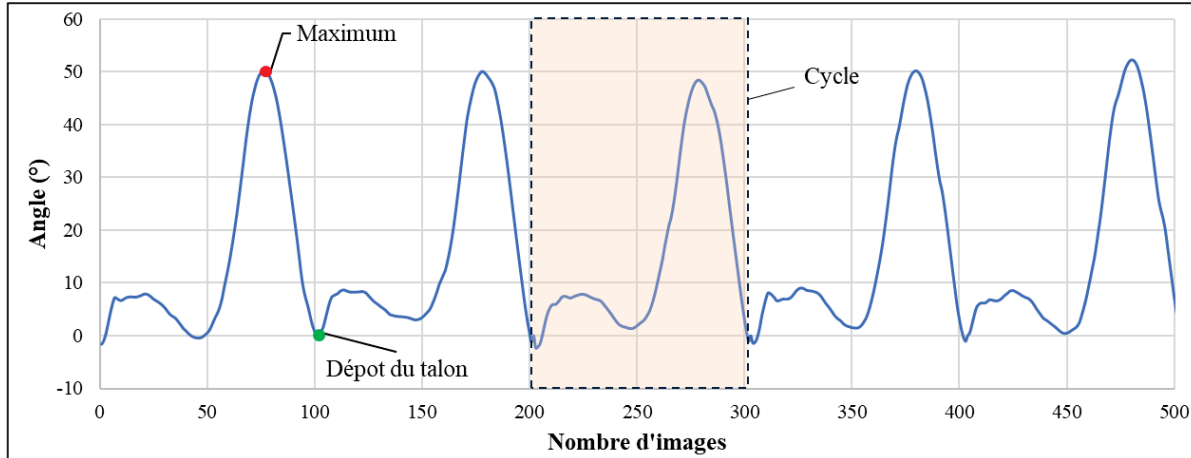


Figure 1.7 Identification d'éléments importants retrouvés sur une courbe partielle du mouvement de Fl/Ex (plan sagittal) d'un patient sain pour un essai complet

Une fois ces cycles isolés, chaque cycle est normalisé sur 100 points sur l'axe de flexion/extension afin de calculer la moyenne et l'écart-type. Seuls les cycles présentant une répétabilité suffisante (c'est-à-dire ayant un écart-type inférieur à 1,5 de la moyenne) sont retenus pour l'analyse. Ces cycles sont dits « les plus répétables ». Les cycles correspondants sur les autres axes (frontal et transversal) sont également conservés, ce qui permet de créer de

nouvelles courbes moyennes. C'est sur ces courbes moyennes évaluées dans chaque axe anatomique que des valeurs caractéristiques, appelées « facteurs biomécaniques » sont calculées.

1.2.2 Facteurs biomécaniques

Les cliniciens, dans leur pratique quotidienne, ne se basent généralement pas sur les courbes de cycles moyens ou sur les courbes cinématiques complètes en raison de leur complexité et de la quantité d'informations qu'elles génèrent. Au contraire, l'interprétation clinique pertinente pour l'évaluation, le traitement et le suivi des patients repose sur des facteurs biomécaniques. Ces derniers représentent des points spécifiques, des moyennes ou des intervalles extraits des courbes d'angles au genou, généralement décomposées dans les trois plans anatomiques (sagittal, frontal, et transversal). La littérature regorge de ces facteurs, bien que des variations existent quant à leur méthode de calcul, ce qui témoigne de la diversité des approches dans l'évaluation biomécanique.

En dépit de cette variabilité, de nombreux facteurs sont équivalents dans leur signification clinique, en particulier ceux qui concernent des positions antagonistes. Par exemple, les facteurs relatifs aux déviations du genou en varus et en valgus sur l'axe frontal sont souvent calculés de manière similaire, ce qui permet une certaine homogénéité dans les interprétations. Afin de simplifier l'analyse et d'assurer une approche cohérente, un ensemble de treize facteurs biomécaniques a été retenu, notamment pour analyser la cinématique de personnes souffrant d'arthrose. Ces facteurs résument les marqueurs les plus pertinents pour l'évaluation clinique des patients et sont listés dans le tableau 1.2 (p.16). Une version anglaise est également fournie en annexe (*Voir annexe I, tableau-A I-1, p.119*).

Tableau 1.2 Facteurs biomécaniques observés sur les courbes de patron de marche pour les patients gonarthrosiques

Plan	Facteurs biomécaniques
Sagittal (Fl/Ex)	*Contracture dynamique en flexion au contact au sol *Flexion limitée lors du chargement **Limitation de l'extension en appui *Diminution de la flexion à l'envol **Diminution de l'amplitude de mouvement Fl/Ex
Frontal (Ab/Ad)	*Augmentation du varus lors du chargement *Genou varum au contact au sol +Genou varum durant l'appui (V1, V2, V3) *Augmentation du valgus lors du chargement
Transversal (Ri/Re)	*Rotation externe tibiale au contact au sol +Rotation interne tibiale lors du chargement

* : Points ; ** : Intervalle de valeurs ; + : Moyenne

La figure 1.8 (p.17) illustre certains de ces facteurs (ceux correspondant à des points) sur les courbes moyennes évaluées selon la méthode établie précédemment. Les valeurs numériques obtenues par le calcul de ces facteurs sur les courbes cinématiques sont classées en trois catégories : « négatif » pour un facteur asymptomatique, « positif » pour un facteur présentant des symptômes modérés, et « positif plus » pour un facteur indiquant des symptômes plus avancés. Ces catégories permettent de poser un diagnostic précis et sont fréquemment incluses dans les rapports cliniques.

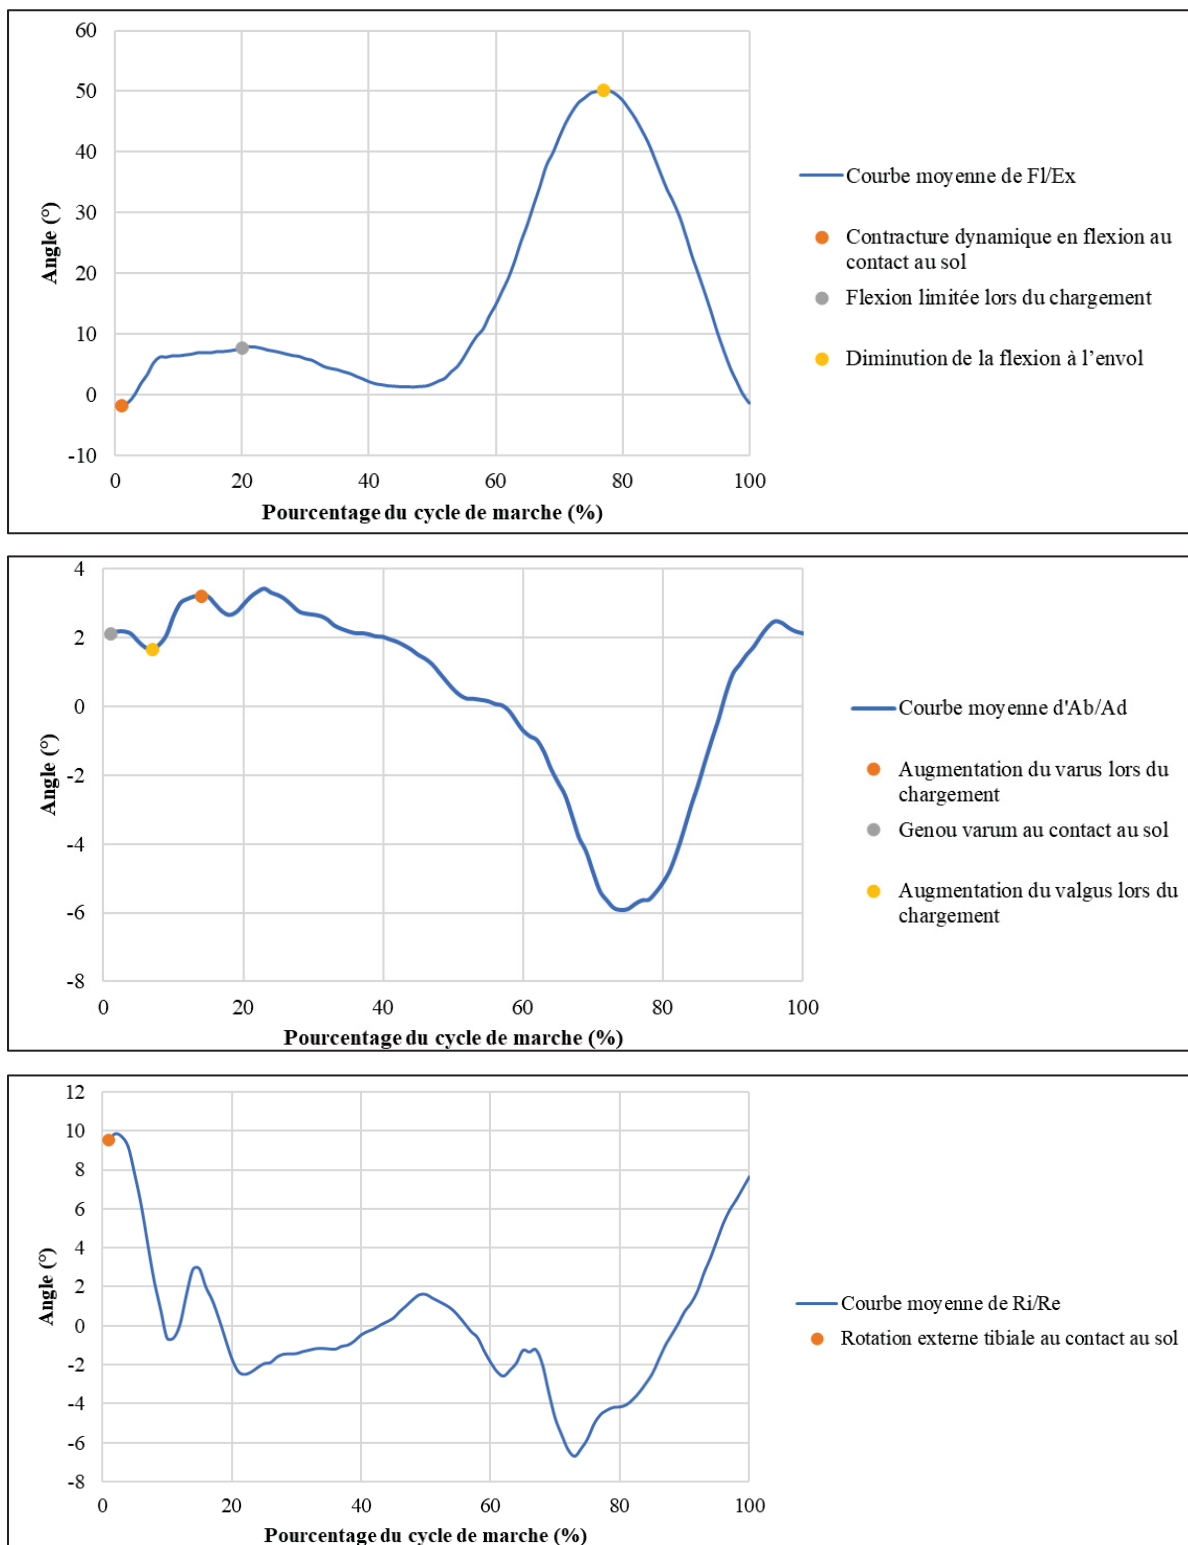


Figure 1.8 Identification de quelques points associés à des facteurs biomécaniques sur les cycles moyens d'un patient sain pour les plans sagittal, frontal et transversal, respectivement

1.3 Méthodes de mesure

Dans le domaine de l'analyse du mouvement, il n'existe pas de méthode universelle de mesure qui soit à la fois parfaite et applicable dans tous les contextes. Néanmoins, certaines méthodes se distinguent par leur popularité, principalement en raison de leur grande précision. Cependant, cette précision s'accompagne souvent de coûts matériels élevés et de systèmes qui, en raison de leur complexité, peuvent interférer indirectement avec le mouvement naturel observé. En dépit des nombreux travaux publiés, les résultats présentés dans la littérature n'ont pas encore permis de converger vers une méthode unique qui soit simultanément précise, économique et suffisamment flexible pour être adaptée à divers environnements cliniques et de recherche.

L'étude de la cinématique du corps humain repose sur l'analyse de la position, de la vitesse et de l'accélération des segments corporels au fil du temps, actuellement effectuée à l'aide de la dynamique inverse. Cette discipline s'appuie sur des techniques de mesure, associées à divers systèmes, qui permettent d'obtenir des courbes précises représentant la position et l'orientation des segments étudiés dans l'espace. À partir de ces données, il est possible de calculer les vitesses en effectuant une première dérivation par rapport au temps, puis d'obtenir les accélérations par une seconde dérivation (*Voir figure 1.9*).

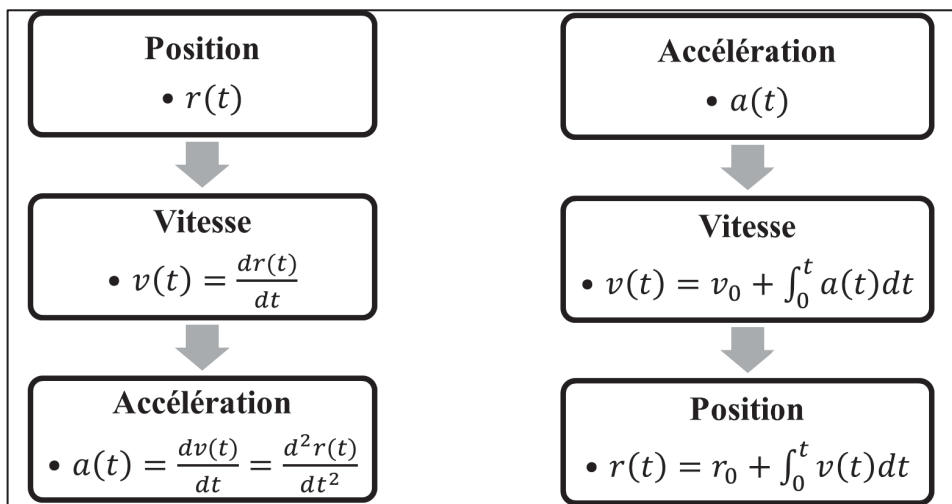


Figure 1.9 Représentation des deux chemins possibles pour le passage d'une variable cinématique à une autre

En parallèle, d'autres systèmes offrent une approche différente en mesurant directement les accélérations linéaires et angulaires. Toutefois, dans ce cas, il est nécessaire d'intégrer ces données pour estimer successivement les vitesses, puis les positions. Ce processus d'intégration successif introduit des constantes inconnues à chaque étape, pouvant entraîner une dérive des résultats si aucune correction adéquate n'est appliquée.

1.3.1 Les systèmes optoélectroniques

Les systèmes optoélectroniques, bien qu'ils soient complexes, coûteux et généralement confinés à des environnements de laboratoire, demeurent parmi les plus utilisés en analyse du mouvement en raison de leur haute précision. Le principe de fonctionnement de ces systèmes repose sur l'utilisation de marqueurs réfléchissants placés sur les segments corporels du participant (*Voir figure 1.10(b), p.20*). Ce dernier réalise ensuite un essai de marche, généralement sur un tapis roulant, qui peut être instrumenté ou non. Dans un espace équipé de plusieurs caméras optiques positionnées sous différents angles (*Voir figure 1.10(a), p.20*), ces caméras émettent une lumière infrarouge qui, après avoir frappé les marqueurs, est réfléchiée vers les caméras. L'objectif de l'installation est de garantir que chaque marqueur soit toujours visible par au moins deux caméras, assurant ainsi une triangulation précise de sa position dans l'espace à l'aide d'algorithmes calibrés à chaque caméra. En combinant les données tridimensionnelles obtenues par l'ensemble des caméras, le système est capable de reconstruire les trajectoires complètes des marqueurs et, par extension, de modéliser en trois dimensions les mouvements observés (*Voir figure 1.10(c), p.20*).

Un des avantages majeurs de ces systèmes est la possibilité de calibrer l'appareil avant la collecte de données, en définissant les axes fonctionnels du genou par pointage des points anatomiques. Ce processus garantit le respect d'un référentiel précis lors de la reconstruction du modèle tridimensionnel, ainsi que lors du calcul des angles au genou. Ces angles sont ensuite interprétés dans un cadre anatomique, offrant ainsi une interprétation clinique fiable. Toutefois, malgré leur précision, les systèmes optoélectroniques ne sont pas exempts d'imperfections. Les trajectoires des marqueurs, censées représenter les os sous-jacents,

peuvent être affectées par les mouvements de la peau, ce qui entraîne des erreurs de mesure (Hagemeister et al., 2005). C'est pourquoi ces systèmes, bien que largement utilisés comme référence dans le domaine, sont considérés comme imparfaits.

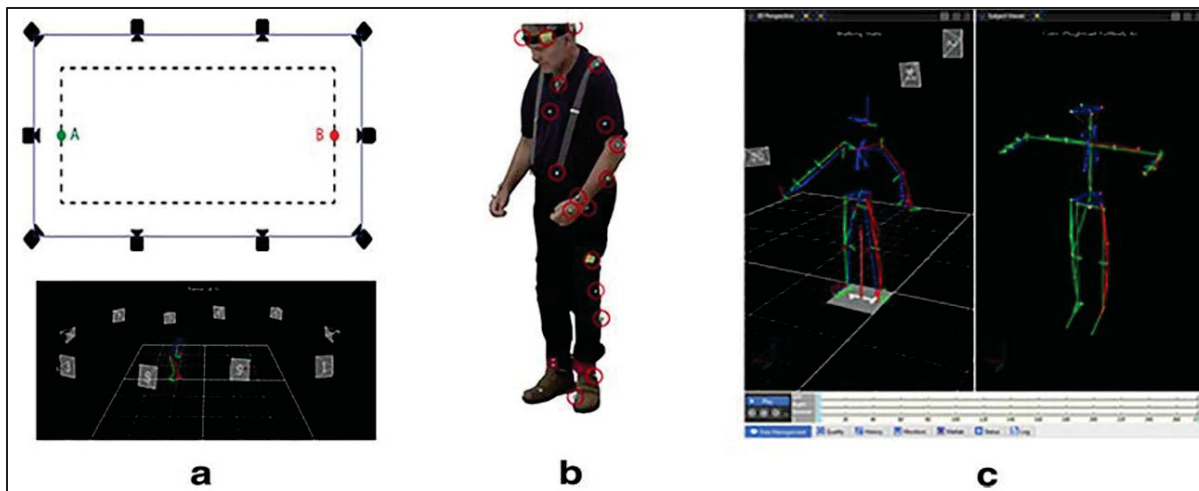


Figure 1.10 (a) Représentation simplifiée de l'espace de travail et de la disposition des caméras infrarouges d'un système optoélectronique pour l'analyse du mouvement
 (b) Disposition des marqueurs réfléchissants sur un participant
 (c) Reconstruction 3D des segments corporels à partir des informations obtenues par les capteurs optoélectroniques

Tirée de Rossi et al. (2020), p.4

Dans ce contexte, la recherche en analyse du mouvement s'oriente de plus en plus vers le développement de solutions innovantes visant à garantir des résultats à la fois fiables et interprétables en genougraphie, tout en optimisant les contraintes matérielles et financières. En effet, la mise en place d'un système optoélectronique de haute précision pour l'analyse du mouvement représente un investissement considérable, pouvant excéder 15 000 \$ CAD, en fonction du nombre de caméras et de la qualité du dispositif. Ainsi, de nombreuses méthodes et outils cliniques ont été expérimentés dans le domaine; toutefois, la plupart présentent des limites en termes de champ d'analyse, de précision et de reproductibilité des mesures. Bien que certaines approches récentes aient démontré un potentiel encourageant pour surmonter ces obstacles, leur transposition dans un environnement clinique opérationnel reste un défi majeur, en raison des exigences spécifiques de ce cadre d'application (Lustig, Magnussen, Cheze, & Neyret, 2012).

Certaines solutions émergent comme plus prometteuses que d'autres, attirant ainsi un intérêt croissant de la part des chercheurs. Les deux sous-sections suivantes exploreront en détail deux de ces alternatives : le système d'attaches KneeKG® et les centrales inertielles.

1.3.2 Le système KneeKG®

Le Laboratoire d'Innovation Ouverte en technologie de la santé (LIO-ÉTS) a développé un harnais, inspiré par les travaux antérieurs de Sati, de Guise, Larouche & Drouin (1996), permettant la fixation de capteurs optoélectroniques sur deux corps rigides, l'un au niveau du fémur et l'autre au niveau du tibia (*Voir figure 1.11*). Chaque corps rigide est fixé à un segment corporel spécifique et comporte son propre repère local. Afin d'assurer une mesure précise du mouvement des segments inférieurs dans un repère global, une méthode de calibrage a été conçue en parallèle avec ce harnais (Hagemeister et al., 2005).




Figure 1.11 Système d'attaches KneeKG®, muni de deux grappes de marqueurs optoélectroniques
 Tirée de Clément, Dumas, Hagemeister, & de Guise (2017), p.3
 © 2017, utilisée avec la permission de Informa UK Limited, opérant sous le nom de Taylor & Francis Group

L'étude de Sati et al. (1996) repose sur l'idée que l'évaluation des données cinématiques tridimensionnelles du genou doit être réalisée *in vivo* pour en assurer la précision. En effet, les mesures obtenues à partir de capteurs optoélectroniques génériques sont souvent perturbées par des artéfacts induits par les déplacements des tissus mous sous les capteurs (Lustig et al., 2012). En fixant les capteurs sur des corps rigides et en les ancrant de manière quasi statique sur les os des membres inférieurs, il devient possible de réduire les mouvements relatifs entre les capteurs et les structures osseuses sous-jacentes. Cela minimise ainsi les artéfacts associés aux tissus mous, permettant une mesure plus fiable du mouvement de l'articulation du genou (Labbe, Hagemester, Tremblay, & de Guise, 2008).

Ce dispositif, qui présente un potentiel considérable pour l'évaluation clinique dynamique de la cinématique tridimensionnelle du genou, a été commercialisé sous le nom de KneeKG® par l'entreprise Emovi en 2014 (<https://emovi.ca/>). Actuellement utilisé en milieu clinique, le KneeKG® permet une évaluation rapide et précise de la cinématique du genou d'un patient. Grâce à l'emplacement stratégique des corps rigides, le nombre de caméras optiques nécessaires est considérablement réduit, se limitant à une seule caméra 3D Polaris Spectra™ capable de capturer les trajectoires des marqueurs placés sur les segments de la cuisse et de la jambe, à une fréquence de 60 Hz. Bien que cette technologie surmonte certaines des limitations des systèmes antérieurs, elle reste confinée à des évaluations effectuées sur tapis roulant. Cette contrainte géographique et le potentiel inconfort occasionné par l'utilisation du tapis roulant et le port du dispositif peuvent limiter son applicabilité clinique et influencer potentiellement les résultats obtenus pendant l'essai de marche.

1.3.3 Les centrales inertielles

Dans un monde de plus en plus axé sur des technologies discrètes et invisibles, la recherche scientifique n'échappe pas à cette tendance. Les centrales inertielles, qui combinent dans un boîtier compact des accéléromètres, des gyroscopes et parfois des magnétomètres, sont devenues les outils favoris des chercheurs. Ces centrales, en raison de leur petite taille et de leur coût abordable, sont omniprésentes dans notre environnement quotidien. De nombreux

appareils modernes, tels que les smartphones, les tablettes, ainsi que certaines montres connectées, intègrent des IMUs pour mesurer les mouvements, l'orientation et la position de l'appareil.

Le marché des centrales inertielles est vaste et offre une grande variété de modèles adaptés à des objectifs spécifiques. La figure 1.12 présente une vue d'ensemble des types et combinaisons d'IMUs les plus couramment utilisés dans la littérature scientifique. Toutefois, il convient de noter que bien que certaines centrales inertielles intègrent des magnétomètres, les données magnétiques sont rarement exploitées dans les études. Cela s'explique par le fait que le champ magnétique terrestre, capté par ces centrales, peut être perturbé par les éléments environnants du laboratoire, ce qui peut introduire des biais et fausser les résultats (Fong & Chan, 2010). Par conséquent, la majorité des études privilégient l'utilisation des données d'accélération linéaire triaxiale et des mesures triaxiales des gyroscopes. Les gyroscopes mesurent les taux de rotation autour des trois axes (roulis, tangage et lacet), produisant ainsi des mesures de vitesses angulaires triaxiales. Dans le cadre de ce mémoire, seules les vitesses angulaires triaxiales sont utilisées comme données d'entrée.




Figure 1.12 Types et combinaisons de centrales inertielles utilisés dans la littérature scientifique
(AS : accéléromètre; GS : gyroscope; MS : magnétomètre)
Tirée de Garcia-de-Villa et al. (2023), p.4

Le domaine de l'analyse du mouvement a rapidement intégré les IMUs en raison de leur capacité à répondre à l'un des objectifs fondamentaux de la recherche dans ce domaine : concevoir des systèmes de mesure à la fois plus accessibles, plus économiques et moins contraignants, tout en garantissant une précision suffisante et une interprétabilité clinique pertinente. En effet, une centrale inertielle de haute qualité représente un investissement d'environ 2 000 \$ CAD, ce qui en fait une alternative nettement plus abordable que les systèmes optoélectroniques traditionnels. Grâce à ces avantages, les IMUs sont largement utilisées pour l'analyse du mouvement humain, comme l'illustre la figure 1.13. Toutefois, comme le souligne également la figure 1.12 (p.23), la diversité des centrales inertielles employées dans les études scientifiques témoigne d'un manque d'uniformisation des protocoles et des équipements. Cette hétérogénéité met en évidence la nécessité d'approfondir les recherches afin de déterminer la combinaison optimale d'IMUs et d'algorithmes garantissant la meilleure précision et reproductibilité des mesures.




Figure 1.13 Ratio des différentes applications de l'analyse du mouvement à l'aide de centrales inertielles
Adaptée et traduite de Garcia-de-Villa et al. (2023), p.6

Bien que les centrales inertielles soient largement utilisées, elles présentent aussi des limitations notables. En effet, ces centrales sont sujettes à une dérive inhérente et leurs mesures

peuvent être affectées par du bruit, causé par les mouvements corporels et les impacts au sol, ce qui rend les données peu fiables, notamment lors d'activités de forte intensité (Hernandez, Dadkhah, Babakeshizadeh, & Kulić, 2021). Par ailleurs, ces centrales mesurent principalement des accélérations linéaires, plutôt que des positions. Par conséquent, afin de rendre les données issues des IMUs utiles en contexte clinique, il serait nécessaire de calculer des facteurs biomécaniques à partir des courbes de vitesses angulaires ou d'accélérations linéaires. Bien que des études antérieures aient exploré cette avenue (Dyas, 2019), l'interprétation clinique des facteurs ainsi obtenus demeure incertaine. Afin d'en assurer l'utilité clinique, il faudrait faire l'intégration des courbes d'accélération linéaire ou de vitesse angulaire pour obtenir les courbes cinématiques de position sur lesquelles évaluer les facteurs biomécaniques utilisés pour l'évaluation et le suivi des pathologies. Toutefois, ces intégrations introduisent une constante inconnue, ce qui perturbe davantage la précision des résultats déjà sensibles aux erreurs.

Face à ces défis, la recherche se trouve confrontée à une impasse, car les outils actuels ne permettent pas de surmonter ces limitations de manière satisfaisante. C'est dans ce contexte que l'intelligence artificielle (IA), et en particulier l'apprentissage machine, pourrait jouer un rôle crucial. Ces technologies, en permettant une analyse plus fine et adaptative des données, offrent des perspectives prometteuses pour pallier les limitations actuelles des centrales inertiels et améliorer la précision des mesures cinématiques.

1.4 L'apprentissage machine

Au cours des dernières décennies, l'utilisation de l'apprentissage machine dans l'analyse et la classification de la marche a suscité un intérêt croissant, en raison de son potentiel à offrir des résultats précis et reproductibles dans des contextes variés. Bien que les méthodes traditionnelles d'apprentissage machine, telles que les processus gaussiens, les arbres de décision ou les « machines à vecteurs de support [traduction de l'OQLF] » (*Support Vector Machines* – SVM), aient permis d'obtenir des résultats intéressants dans certaines applications passées (García-de-Villa, Casillas-Pérez, Jiménez-Martín, & García-Domínguez, 2023), ces

approches semblent désormais moins prometteuses que celles basées sur l'utilisation de réseaux de neurones artificiels (RNA). En effet, les RNA se distinguent par leur capacité à apprendre à partir de données brutes sans nécessiter de modèles biomécaniques complexes. De plus, ils parviennent à générer des modèles de régression capables de minimiser les biais associés aux variations naturelles de la marche humaine, offrant ainsi des prédictions plus robustes et généralisables (Figueiredo et al., 2020).

Les RNA sont des modèles informatiques inspirés du fonctionnement du cerveau humain. Ils sont constitués de plusieurs couches de « neurones artificiels » interconnectés, où chaque neurone reçoit des informations en entrée, les traite à l'aide d'une fonction mathématique définie, puis transmet le résultat aux neurones de la couche suivante. Ce traitement s'effectue à travers une combinaison de pondérations et de biais, ce qui permet de moduler et d'affiner la transmission des informations. Les couches neuronales et les connexions entre elles sont illustrées dans la figure 1.14 (p. 27, partie supérieure de la figure).

Un RNA standard comporte au moins une couche d'entrée et une couche de sortie. La couche d'entrée est responsable de l'acquisition des données initiales, qui peuvent être de natures variées, allant des pixels d'une image aux valeurs numériques ou autres types de données. La couche de sortie, quant à elle, fournit la prédiction du modèle, que ce soit sous forme de régression ou de classification. Ce qui distingue les différents types de RNA, cependant, réside principalement dans leur structure interne. Entre la couche d'entrée et la couche de sortie se trouvent des couches intermédiaires, communément appelées « couches cachées ». Ces couches sont responsables du traitement complexe des informations, et leur nombre ainsi que leur type peuvent varier considérablement d'un réseau à l'autre. Ce sont ces caractéristiques qui déterminent en grande partie la capacité du réseau à résoudre des problèmes spécifiques. La figure 1.14 (p.27) présente un exemple de RNA composé de deux couches cachées, conçu pour traiter des valeurs numériques dans une tâche de régression.

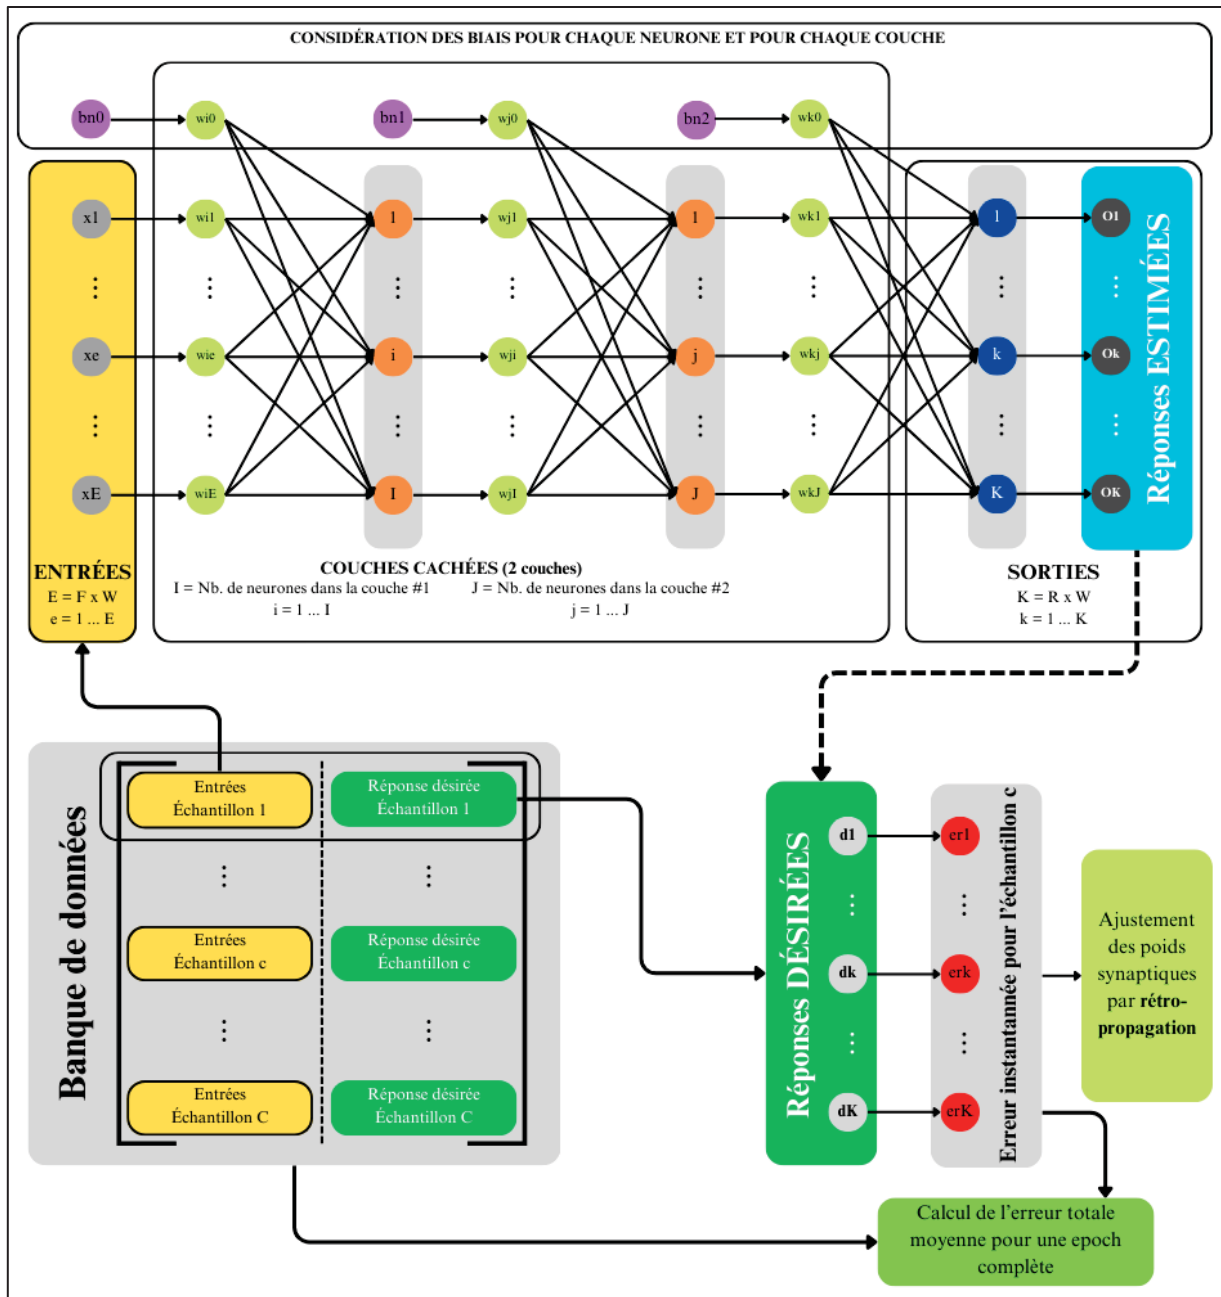


Figure 1.14 Architecture type d'un RNA de type FFNN avec rétropropagation

Il existe une grande diversité de types de RNA, chacun ayant des avantages spécifiques en fonction des objectifs visés. De plus, des recherches récentes tentent de combiner différentes architectures de RNA afin d'en maximiser l'efficacité. Par conséquent, la majorité des études utilisant des RNA dans le domaine de l'analyse du mouvement sont motivées par la recherche

de l'algorithme le mieux adapté à leur problématique spécifique. L'étendue de la liste des algorithmes de RNA disponibles, combinée à la diversité des objectifs poursuivis dans ce domaine, crée une large gamme d'options, parfois en nombre de centaines, voire de milliers. Néanmoins, il est important de souligner que toutes ces options ne sont pas nécessairement optimales ni pertinentes pour tous les types d'analyse. Le choix de l'architecture du RNA doit ainsi se baser sur une compréhension approfondie des caractéristiques des données ainsi que des objectifs cliniques ou biomécaniques visés, afin d'assurer la validité et la reproductibilité des résultats obtenus.

1.4.1 Synthèse générale des techniques et utilité dans le domaine de l'analyse du mouvement

L'utilisation des RNA dans le domaine de l'analyse de la marche n'est pas un phénomène récent. En effet, les premiers travaux explorant diverses applications biomédicales des *Multi-layer Perceptrons*¹ (MLP) datent des années 1980. Cependant, les algorithmes de cette époque, et ce jusqu'à l'étude de Kohle, Merkl et Kastner en 1997, étaient limités dans leur capacité à fournir une analyse détaillée des patrons de marche. Les résultats obtenus par ces réseaux étaient souvent restreints à une classification binaire des patrons de marche, généralement entre sain et pathologique. Bien que ces approches aient permis d'initier des recherches intéressantes, leur portée clinique restait limitée, les résultats obtenus n'apportant pas suffisamment de précision pour une application clinique directe. Néanmoins, ces premières explorations ont ouvert la voie à des applications plus ambitieuses et complexes.

Dans une étude menée par Findlow et al. (2008), les chercheurs ont exploré l'utilisation des *Generalized Regression Neural Networks*² (GRNN), une variante des *Radial Basis Neural Networks*³ (RBNN). Les GRNN partagent une architecture similaire avec les RBNN, notamment la présence d'une première couche intermédiaire dite « à bases radiales ».

¹ Perceptrons multicouches [traduction de l'OQLF]

² Réseaux de neurones de régression généralisée [traduction libre]

³ Réseaux de neurones à bases radiales [traduction de l'OQLF]

Cependant, les GRNN introduisent une seconde couche intermédiaire, nommée « couche linéaire spéciale », qui diffère de celle des RBNN. Bien que cette approche ait montré des résultats intéressants dans d'autres domaines, son application à l'analyse cinématique de la marche n'a pas fait l'objet de recherches supplémentaires, ce qui suggère que cette méthode ne soit pas entièrement adaptée aux spécificités du mouvement humain.

Plus récemment, les MLP ont été classés dans une catégorie plus générale de réseaux, appelés *Feedforward Neural Networks*⁴ (FFNN). C'est au sein de cette catégorie que l'on retrouve le RNA présenté précédemment (*Voir figure 1.14, p.27*). Le principe des FFNN est relativement simple : chaque neurone d'une couche est connecté à la couche suivante dans un flux « vers l'avant », sans rétroaction ni boucle. Nombreuses sont les études dans ce domaine qui utilisent des FFNN, notamment sous la forme de MLP avec rétropropagation⁵ (MLP-BP), pour estimer des paramètres biomécaniques tels que les angles et les moments angulaires des articulations dans un ou plusieurs plans anatomiques (Bennett, Odom, & Ben-Asher, 2013 ; Mundt et al., 2019 ; M. Lee & Park, 2020 ; Lim, Kim, & Park, 2020 ; Mundt, Koeppe, David, et al., 2020 ; Stetter, Krafft, Ringhof, Stein, & Sell, 2020 ; T. Lee, Kim, & Lee, 2021).

La popularité de cette approche réside dans sa simplicité d'implémentation, ainsi que dans les résultats pertinents qu'elle offre en termes d'estimation de paramètres biomécaniques (Mundt et al., 2021). Toutefois, une limitation importante réside dans le nombre de centrales inertielles utilisées dans ces études, souvent au nombre de cinq (placés sur le pelvis, les cuisses et les tibias). Cette utilisation multiple d'IMUs va à l'encontre de l'objectif principal, qui est de simplifier la prise de mesures pour les cliniciens. De plus, la majorité de ces études ne permettent l'estimation des angles au genou que dans l'axe de la flexion/extension, ce qui limite leur applicabilité dans un cadre clinique visant à évaluer des facteurs biomécaniques complexes.

⁴ Réseaux de neurones à propagation avant [traduction de l'OQLF]

⁵ *Multi-layer Perceptrons with Back Propagation* [traduction de l'OQLF]

Au sein de la vaste catégorie des FFNN, on retrouve également des réseaux dits « profonds » ou *Deep Neural Networks*⁶ (DNN), qui sont caractérisés par un nombre important de couches d'apprentissage. Grâce à la quantité colossale de connexions et d'architectures disponibles dans les DNN, il est possible de réduire le nombre de centrales inertielles au minimum, jusqu'à un seul IMU (Gholami, Napier, & Menon, 2020). Bien que l'augmentation du nombre de couches dans un DNN puisse entraîner une consommation accrue de mémoire et un allongement des temps de traitement, la capacité des DNN à extraire des caractéristiques locales intrinsèques, ou « caractéristiques profondes », leur permet souvent d'atteindre des performances proches de celles des systèmes de capture du mouvement optoélectroniques, qui sont généralement utilisés comme référence dans ce domaine. En conséquence, de nombreuses études (Dorschky et al., 2020 ; Gholami et al., 2020 ; Mundt et al., 2021 ; Rapp, Shin, Thomsen, Ferber, & Halilaj, 2021) ont exploré l'utilisation des *Convolutional Neural Networks*⁷ (CNN), un type spécifique de DNN, qui a montré des résultats prometteurs dans l'analyse du mouvement humain à l'aide de centrales inertielles (Gholami, Rezaei, Cuthbert, Napier, & Menon, 2019).

Les CNN, généralement utilisés pour traiter des données visuelles, sont composés de couches non complètement connectées (couches de convolution, de *max pooling*⁸, ReLU, etc.), suivies de couches entièrement connectées (dites couches denses). Dans le contexte de l'analyse de la marche, on utilise souvent des CNN en une dimension (1D-CNN), car les données sont des séries temporelles. D'autres types de CNN, comme les *Visual Geometry Groups*⁹ (VGG) (Simonyan & Zisserman, 2014) et les réseaux résiduels (RESNET) (He, Zhang, Ren, & Sun, 2016), sont également utilisés, bien que leur utilisation demeure moins répandue.

Les réseaux de neurones profonds étant une catégorie vaste et hétérogène, certains DNN se distinguent par leur capacité à traiter des séquences temporelles. Parmi eux, on trouve les

⁶ Réseaux de neurones profonds [traduction de l'OQLF]

⁷ Réseaux de neurones à convolutions [traduction de l'OQLF]

⁸ Échantillonnage par maximum [traduction libre]

⁹ Groupe de géométrie visuelle [traduction libre]

réseaux de neurones récurrents¹⁰ (RNN) (Huang et al., 2019), qui ont pour particularité de conserver l'état interne d'un réseau, rendant leur exploitation particulièrement adaptée aux séries temporelles. Parmi les variantes récentes de RNN, on trouve les réseaux *Long Short-Term Memory*¹¹ (LSTM) (Mundt et al., 2019 ; Mundt, Koeppe, Bamer, David, & Markert, 2020 ; Barua, Zakia, Menon, & Jiang, 2021 ; Conte Alcaraz, Moghaddamnia, & Peissig, 2021 ; Liang, Gao, & Liao, 2021 ; Mundt et al., 2021 ; Rapp et al., 2021), les réseaux et *Bidirectional Long Short-Term Memory*¹² (BiLSTM) (Sharifi-Renani, Eustace, Myers, & Clary, 2021 ; Tan et al., 2022) et les réseaux *Gated Recurrent Unit*¹³ (GRU) (Cho et al., 2014). Toutefois, en raison de leur rareté dans les études appliquées à l'analyse de la marche, les réseaux GRU et *Nonlinear Autoregressive Neural Networks with Exogenous Inputs*¹⁴ (NARX) (Tsunngnan Lin, Horne, Tino, & Giles, 1996) ne seront pas approfondis dans le cadre de ce mémoire.

En raison de leur capacité à gérer des informations temporelles et leur architecture adaptée pour contrer les problèmes de disparition ou d'explosion du gradient, les LSTM semblent être la solution la plus prometteuse pour l'analyse de la cinématique de la marche (Conte Alcaraz et al., 2021). Les LSTM se composent de cellules capables de conserver les informations de leurs états précédents et actuels grâce à des portes de mémoire, ce qui leur confère une grande flexibilité face à des données cinématiques. De plus, en raison de leurs portes d'oubli, les LSTM sont particulièrement performants dans l'adaptation aux changements dans les données, un aspect crucial pour l'analyse de la marche humaine (García-de-Villa et al., 2023).

Contrairement aux réseaux LSTM qui sont unidirectionnels, les réseaux BiLSTM effectuent une lecture temporelle bidirectionnelle des données afin de considérer non seulement les données des états précédents, mais également les données des états futurs (Sharifi-Renani et al., 2021). Cette approche permet potentiellement d'améliorer la précision des prédictions, en

¹⁰ *Recurrent Neural Networks* [traduction de l'OQLF]

¹¹ Réseaux de mémoire longue à court terme [traduction de l'OQLF]

¹² Réseaux de mémoire longue à court terme bidirectionnels [traduction libre]

¹³ Unité récurrente à porte [traduction libre]

¹⁴ Réseaux de neurones autorégressifs non linéaires avec entrées exogènes [traduction libre]

offrant à chaque état un plus large éventail d'informations contextuelles (Siami-Namini, Tavakoli, & Namin, 2019). Cette amélioration de la précision des prédictions grâce aux BiLSTM est l'un des principaux objectifs de ce mémoire, puisque plusieurs études dans le domaine de l'analyse de la marche ont obtenu des résultats intéressants en faisant l'usage de réseaux LSTM.

Enfin, pour atteindre une précision encore supérieure, certaines études récentes tentent de combiner différentes approches de RNA pour l'estimation des angles articulaires pendant la marche. Hernandez et al. (2021), par exemple, ont proposé une approche combinant CNN et LSTM dans une architecture appelée DeepConvLSTM. C'est une approche suggérée au préalable par Ordóñez et Roggen (2016) après leur exploration de multiples codes ayant été soumis dans le cadre d'un défi de reconnaissance de l'activité humaine mesurée à l'aide de centrales inertielles sur une base de données préexistante : la base de données OPPORTUNITY (<https://archive.ics.uci.edu/dataset/226/opportunity+activity+recognition>). La différence entre la méthode DeepConvLSTM suggérée et un CNN de base réside au niveau de l'architecture des couches denses. Pour le DeepConvLSTM, les unités des couches denses sont des cellules récurrentes LSTM alors que pour le CNN de base, les unités sont plutôt non-récurrentes et entièrement connectées. Le DeepConvLSTM combine ainsi les avantages des CNN pour l'extraction de caractéristiques locales avec ceux des LSTM pour l'analyse des données temporelles. Bien que cette méthode ait montré des résultats prometteurs, l'objectif de ce mémoire est de conserver une approche plus simple en termes d'architecture de RNA, sans recourir à des combinaisons complexes de modèles.

Enfin, Hossain, Dranetz, Choi et Guo (2022) ont proposé une approche combinant CNN et GRU afin de former la base d'un modèle RNN. Bien que leurs résultats soient intéressants, la complexité de leur modèle, le placement atypique des IMUs et l'utilisation d'un seul plan anatomique dans l'estimation des angles limitent l'applicabilité de ce modèle dans le cadre de notre étude.

1.4.2 Fonctionnement de réseaux BiLSTM

Un réseau BiLSTM repose sur l'apprentissage simultané bidirectionnel de deux réseaux LSTM. Pour bien comprendre le fonctionnement de ces réseaux BiLSTM, il est crucial de saisir la structure des réseaux LSTM, dont l'objectif principal est de résoudre des problèmes liés à la prédiction de séquences temporelles (Mundt et al., 2021). Ce type de RNA est particulièrement adapté pour traiter des données séquentielles, car il permet d'éviter le prétraitement souvent nécessaire, tel que l'aplatissement des données, et ainsi de maintenir l'intégrité de la structure temporelle sans allonger indûment le vecteur de caractéristiques présenté aux neurones de la couche d'entrée.

Les réseaux LSTM exploitent les dépendances temporelles au sein des séquences de données, ce qui les rend particulièrement pertinents pour des applications telles que l'estimation de la cinématique du mouvement. Bien que d'autres types de réseaux de neurones récurrents (RNN) partagent également cette capacité, les LSTM se distinguent par leur aptitude à conserver une partie de leur mémoire au lieu de la totalité de leurs états passés. Cette caractéristique permet aux LSTM de maintenir une mémoire sur des intervalles de temps beaucoup plus longs que les autres RNN classiques, ce qui est un atout majeur pour l'analyse des séries temporelles longues, comme celles rencontrées dans les études de marche humaine (Conte Alcaraz et al., 2021). Néanmoins, les réseaux LSTM nécessitent une grande quantité de données pour l'entraînement et une optimisation approfondie afin d'atteindre des performances élevées (Mundt et al., 2021).

La structure d'une cellule LSTM repose sur trois types de portes fondamentales : la porte d'oubli (*forget gate*), la porte d'entrée (*input gate*) et la porte de sortie (*output gate*). Ces portes ont été introduites pour résoudre le problème de la disparition et de l'explosion du gradient, des phénomènes qui surviennent lors de l'entraînement de réseaux profonds, en particulier avec la rétropropagation. Le gradient dans l'apprentissage d'un RNA est un vecteur qui représente la direction et l'intensité de la variation d'une fonction de perte par rapport aux paramètres (poids et biais) du modèle. Il joue un rôle important dans l'amélioration des

performances d'un réseau. La disparition du gradient se produit lorsque les gradients deviennent trop petits au fur et à mesure qu'ils remontent dans les couches, rendant ainsi les mises à jour des poids presque nulles et ralentissant l'apprentissage. L'explosion du gradient, en revanche, se produit lorsque les gradients deviennent excessivement grands, ce qui entraîne des mises à jour instables et rend l'apprentissage difficile.

La figure 1.15 (p.35) illustre l'architecture d'une cellule LSTM, où x_t représente les données d'entrée. Cette cellule utilise deux vecteurs principaux : c et h . Le premier vecteur, c , correspond à l'état interne de la cellule (*internal state*), ou sa mémoire, tandis que le deuxième, h , est l'état caché (*hidden state*), ou la sortie de la cellule. Ces deux vecteurs sont transmis et modifiés à chaque étape temporelle grâce à l'interaction des portes (Conte Alcaraz et al., 2021). L'élément distinctif des réseaux LSTM, soit la porte d'oubli f_t (Voir équation 1.1, p.36), est la première étape de cette interaction. Elle décide de la proportion de l'état précédent (c_{t-1}) à conserver ou à oublier, en combinant les informations de l'entrée actuelle (x_t) et de l'état caché (donc la sortie) de la cellule précédente (h_{t-1}) afin de générer, habituellement à l'aide d'une fonction sigmoïde, une valeur entre 0 et 1, où 0 signifie « tout oublier » et 1 signifie « tout garder ».

La porte d'entrée i_t , quant à elle, décide des informations qui sont ajoutées à l'état de la cellule (c_t). Cela se fait en combinant une fonction sigmoïde pour sélectionner les valeurs à mettre à jour dans l'état de la cellule c_t (Voir équation 1.2, p.36), et une fonction tangente hyperbolique (\tanh) pour générer de nouvelles valeurs candidates (g_t) qui seront intégrés à l'état de la cellule (Voir équation 1.3, p.36). Avant de passer à la dernière porte, l'état de la cellule (c_t) est mis à jour à l'aide d'une concaténation des informations fournies par les portes d'oubli et d'entrée (Voir équation 1.4, p.36). De ce fait, l'ancienne mémoire c_{t-1} est oubliée en fonction des résultats de la porte d'oubli f_t et de nouvelles informations sont ajoutées en fonction des résultats de la porte d'entrée i_t et des nouvelles valeurs candidates g_t .

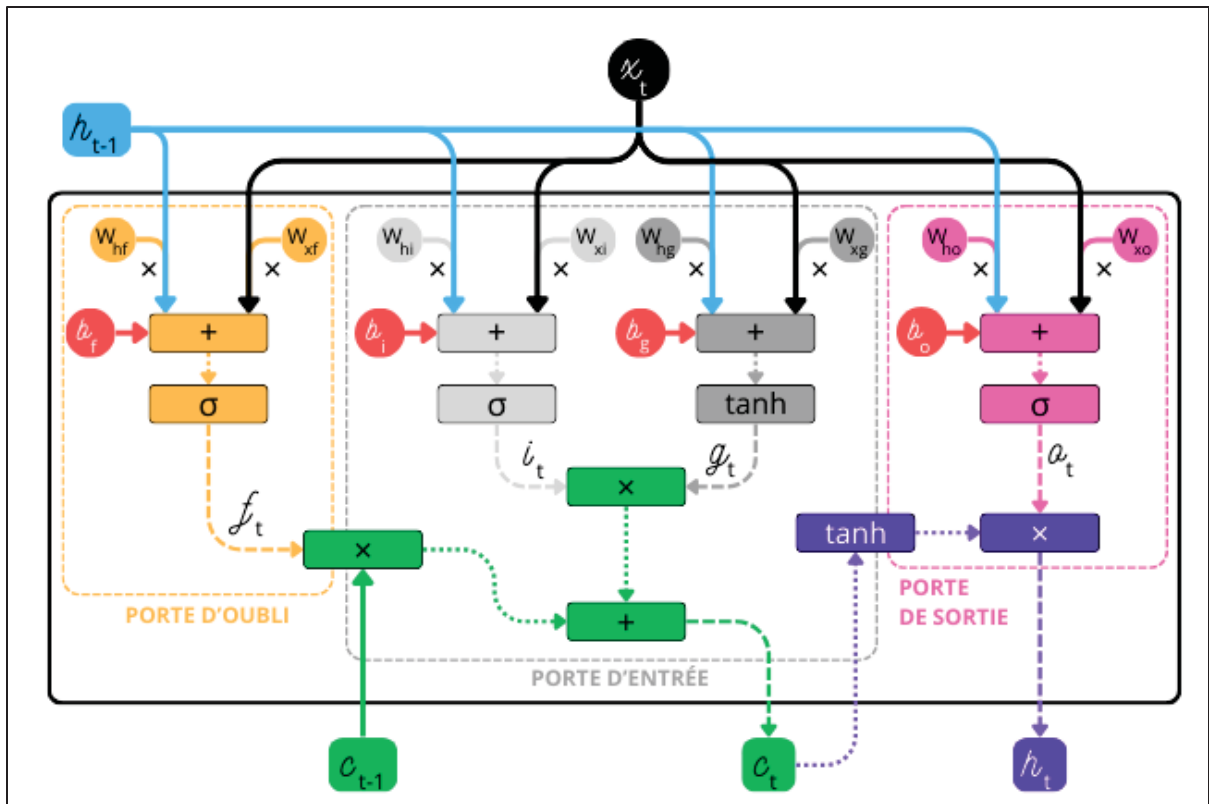


Figure 1.15 Architecture d'une cellule de réseau LSTM avec représentation des trois types de portes

La porte de sortie o_t contrôle la partie de l'état de la cellule (c_t) qui sera utilisée pour produire l'état caché, donc la sortie de la cellule (h_t). Elle est également composée de deux parties, soit une première équation qui est régulée par la sortie de la cellule précédente (h_{t-1}) et l'entrée de la cellule actuelle (x_t), puis une seconde équation qui combine le résultat de la première avec l'état de la cellule (c_t) filtré par une fonction \tanh (Voir équations 1.5 et 1.6, respectivement, p.36).

Les matrices de poids, représentées par W_{ij} , et les paramètres de biais, représentés par b_i , jouent un rôle fondamental dans la précision du modèle. Ces paramètres sont ajustés au cours de l'entraînement à travers un processus de rétropropagation dit « à travers le temps [traduction libre] » (*Backpropagation Through Time*) qui tient compte des données séquentielles et de leur temporalité (Liang et al., 2021).

Les équations suivantes, traduites et adaptées de Hochreiter & Schmidhuber (1997), définissent les différentes étapes de mise à jour dans une cellule t d'un réseau LSTM :

$$\text{Porte d'oubli : } \mathbf{f}_t = \sigma(W_{xf}\mathbf{x}_t + W_{hf}\mathbf{h}_{t-1} + \mathbf{b}_f) \quad (1.1)$$

$$\text{Porte d'entrée : } \mathbf{i}_t = \sigma(W_{xi}\mathbf{x}_t + W_{hi}\mathbf{h}_{t-1} + \mathbf{b}_i) \quad (1.2)$$

$$\text{Nouvelles valeurs candidates : } \mathbf{g}_t = \tanh(W_{xg}\mathbf{x}_t + W_{hg}\mathbf{h}_{t-1} + \mathbf{b}_g) \quad (1.3)$$

$$\text{État de la cellule : } \mathbf{c}_t = \mathbf{f}_t \cdot \mathbf{c}_{t-1} + \mathbf{i}_t \cdot \mathbf{g}_t \quad (1.4)$$

$$\text{Porte de sortie : } \mathbf{o}_t = \sigma(W_{xo}\mathbf{x}_t + W_{ho}\mathbf{h}_{t-1} + \mathbf{b}_o) \quad (1.5)$$

$$\text{État caché : } \mathbf{h}_t = \mathbf{o}_t \cdot \tanh(\mathbf{c}_t) \quad (1.6)$$

Les réseaux BiLSTM, en revanche, représentent une évolution de cette structure, avec deux réseaux LSTM qui fonctionnent simultanément en propagation avant et en rétropropagation. (Voir figure 1.16, p.37). Les informations issues de la cellule LSTM au temps $t - 1$ sont utilisées dans les portes de la première cellule LSTM au temps t , tandis que celles issues du temps $t + 1$ sont utilisées dans les portes de la seconde cellule LSTM au temps t . Cette architecture bidirectionnelle permet au réseau d'intégrer à chaque étape les informations provenant à la fois du passé et du futur de la séquence temporelle. Ainsi, l'utilisation de réseaux BiLSTM permet de produire des prédictions plus robustes et précises, notamment pour des applications impliquant des données temporelles complexes, telles que celles de la cinématique de la marche.

En pratique, les données de sortie y_t d'une unité BiLSTM au temps t sont obtenues par la concaténation des sorties h_{t_i} des deux cellules LSTM qui composent le réseau. Cette capacité de prendre en compte des informations passées et futures dans un même modèle améliore considérablement la qualité des prédictions, rendant les réseaux BiLSTM particulièrement adaptés pour des tâches d'estimation de paramètres biomécaniques, comme les angles articulaires, où la dépendance temporelle joue un rôle crucial dans l'exactitude des résultats.

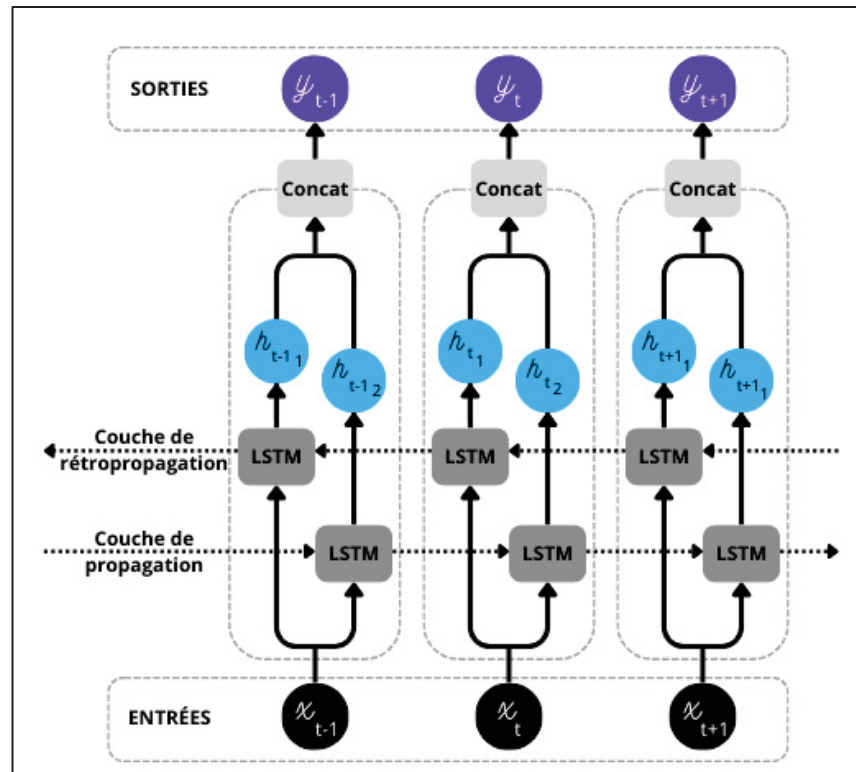


Figure 1.16 Architecture simplifiée d'une cellule BiLSTM

1.4.3 Résumé des méthodes de réseaux LSTM et BiLSTM observées dans la littérature

Le tableau 1.3 (p.39) présente une synthèse des approches adoptées dans diverses études exploitant les réseaux de neurones LSTM et BiLSTM pour estimer les angles du genou pendant la marche à partir de données issues de centrales inertielles. Certaines de ces études intègrent des centrales inertielles virtuelles (générées par des algorithmes) plutôt que des centrales physiques (ou « réelles »). Une seule étude compare et combine ces deux types de centrales afin d'évaluer la fiabilité des données obtenues par les centrales virtuelles (Sharifi-Renani et al., 2021).

Les études recensées ont souvent recours à plusieurs types de réseaux de neurones. Toutefois, seuls les résultats obtenus avec les architectures LSTM et BiLSTM sont pris en compte pour la comparaison. De plus, bien que la plupart des travaux visent à estimer non seulement les

angles du genou, mais aussi ceux de la hanche et de la cheville, l'analyse comparative se focalise uniquement sur les estimations des angles du genou. Enfin, les études menées exclusivement sur des populations saines sont d'un intérêt moindre pour cette comparaison, car les différences cinématiques entre des sujets sains et des patients pathologiques peuvent influencer l'apprentissage des réseaux.

L'analyse des populations étudiées dans le tableau 1.3 (p.39) met en évidence que la majorité des recherches se focalisent sur des sujets sains ou ayant subi une arthroplastie totale ou unicompartmentale du genou (TKA ou UKA). En revanche, les études intégrant une cohorte importante de patients atteints de gonarthrose (OA) demeurent rares. Par exemple, Sharifi-Renani et al. (2021) analysent un groupe restreint de 17 patients ayant subi une TKA et 13 patients OA, ce qui limite la représentativité des données. Cette observation illustre la nécessité de disposer d'un ensemble de données suffisamment large et varié pour garantir un apprentissage robuste des modèles de réseaux de neurones, en tenant compte d'une diversité adéquate des mouvements et des conditions pathologiques.

Par ailleurs, Rapp et al. (2021) proposent l'une des cohortes les plus étendues et diversifiées en termes de pathologies parmi les études recensées. Cependant, les participants étudiés sont des coureurs blessés, qui, en raison de leur niveau athlétique élevé et de leur âge relativement jeune, présentent des patrons de marche moins variables que ceux observés chez des patients OA ou ayant subi une TKA ou une UKA (Terrier & Reynard, 2015 ; Ponzio et al., 2018). Cette homogénéité pourrait ainsi favoriser un apprentissage plus aisé du réseau de neurones sur ces données, tout en limitant la généralisation des résultats à d'autres populations pathologiques.

Tableau 1.3 Résumé des architectures et méthodologies utilisées dans la littérature pour l'apprentissage par réseaux de neurones en analyse de la marche

Référence	Type de RNA	Standard comparatif	Nb. d'axes	Qté. de IMUs	Population étudiée
Mundt et al. (2019)	- FFNN - LSTM	SO + DI	3 (H, G, C)	NA* (V)	- Sains - TKA et UKA - Total de 115 sujets
Mundt, Koeppe, Bamer, et al. (2020)	- LSTM	SO + DI	3 (H, G, C)	1-3-5 (V)	- Sains - TKA et UKA - Total de 115 sujets
Conte Alcaraz et al. (2021)	- GRNN - NARX - LSTM	<i>Sensor Fusion algorithm</i>	1 (H, G, C)	1 (R)	- Sains (20 sujets)
Liang et al. (2021)	- LSTM	Quaternions	1 (G)	1 (R)	- Sains (8 sujets)
Rapp et al. (2021)	- 1D-CNN - LSTM	SO + DI	3 (H, G, C)	7 (V)	- Sains (35 sujets) - Coureurs blessés aux membres inférieurs** (266 sujets)
Sharifi-Renani et al. (2021)	- BiLSTM	SO + DI	3 (H, G)	4 (R + V)	- TKA (17 sujets) - OA (13 sujets)

* NA signifie que la valeur précise associée à la donnée n'était pas disponible dans la référence.

** Emplacement des blessures : 72 au genou, 58 à la cheville ou au pied, 51 au bassin ou à la hanche, 42 à la cuisse et 39 au niveau du tibia.

Abréviations : SO : Système optoélectronique, DI : Dynamique inverse, H : Angle de la hanche, G : Angle du genou, C : Angle de la cheville, R : Réel, V : Virtuel

Le tableau 1.4 (p.41) présente une synthèse des performances des modèles évalués dans la littérature. Une tendance générale s'en dégage : les études employant un nombre réduit de centrales inertielles affichent généralement des performances moindres. Cependant, ces mêmes études disposent également de bases de données d'apprentissage plus restreintes, ce qui peut expliquer en partie ces résultats. Il est possible d'observer cette double tendance d'abord avec l'étude de Rapp et al. (2021), qui utilisent le plus d'IMUs et ont la plus grande population, et obtiennent une *Root Mean Squared Error*¹⁵ (RMSE) aussi basse que 0,97° en flexion/extension. À l'inverse, les études avec un nombre limité de centrales et une petite population, comme celle de Liang et al. (2021), montrent des RMSE plus élevées, atteignant 3,89° pour l'axe de flexion/extension.

Une autre observation issue du tableau 1.4 (p.41) est que les performances sont également influencées par la disposition des centrales inertielles sur le corps. Par exemple, les études positionnant des centrales sur le bassin, la cuisse et le tibia tendent à obtenir des résultats plus précis que celles utilisant uniquement des centrales placées sur un seul segment. Cela suggère que l'apport d'informations provenant de plusieurs segments corporels peut améliorer la précision des estimations. De plus, concernant le type d'IMU utilisé, Sharifi-Renani et al. (2021), obtiennent de meilleures performances sur leur modèle entraîné uniquement avec les valeurs d'IMUs virtuels par rapport à celui entraîné uniquement avec les valeurs d'IMUs réels. Toutefois, leur modèle le plus performant est celui entraîné sur une combinaison des valeurs d'IMUs réels et virtuels, suggérant que la fiabilité des centrales virtuelles peut être acceptable dans certaines conditions.

¹⁵ Racine de l'erreur quadratique moyenne [traduction libre basée sur celle de l'OQLF]

Tableau 1.4 Résumé des mesures de performance évaluées dans la littérature par les études faisant usage d'un LSTM ou d'un BiLSTM

Référence	Position IMUs	Axe	<i>RMSE</i> (ET) (°)	<i>nRMSE</i> (ET) (%)	<i>R</i> (ET)
Mundt et al. (2019)	NA	F/E	1,92	NA	0,997
		A/A	1,92	NA	0,681
		Ri/Re	3,73	NA	0,945
		Moyenne	2,15 (0,08)	NA	0,923 (0,005)
Mundt, Koeppe, Bamer, et al. (2020)	B, 2C, 2T	Fl/Ex	1,77 (0,38)	/	0,992 (0,003)
		Ab/Ad	1,58 (0,66)		0,947 (0,036)
		Ri/Re	2,62 (1,06)		0,929 (0,059)
	B, 2C	Fl/Ex	1,98 (0,51)	/	0,990 (0,004)
		Ab/Ad	1,77 (0,82)		0,940 (0,039)
		Ri/Re	2,85 (1,25)		0,926 (0,057)
	B, 2T	Fl/Ex	1,69 (0,44)	/	0,993 (0,003)
		Ab/Ad	1,54 (0,72)		0,950 (0,032)
		Ri/Re	2,48(1,09)		0,936 (0,054)
	B	Fl/Ex	2,97 (0,55)	/	0,978 (0,007)
		Ab/Ad	2,18 (0,85)		0,928 (0,052)
		Ri/Re	3,36 (1,27)		0,913 (0,063)
Conte Alcaraz et al. (2021)	P	Fl/Ex	2,87	/	/
Liang et al. (2021)	C	Fl/Ex	3,89	/	0,98
Rapp et al. (2021)	B, 2C, 2T, 2P	Fl/Ex	0,97 (0,38)	/	/
		Ab/Ad	2,16 (0,85)		
		Ri/Re	2,75 (0,66)		

Référence	Position IMUs	Axe	RMSE (ET) (°)	nRMSE (ET) (%)	R (ET)
Sharifi-Renani et al. (2021)	B, C, T, P (Virtuels)	Fl/Ex	2,1 (0,6)	2,9 (0,8)	0,99 (0,01)
		Ab/Ad	2,0 (0,6)	15,1 (4,5)	0,82 (0,13)
		Ri/Re	6,4 (2,8)	24,0 (11,3)	0,70 (0,24)
		Moyenne	2,9 (0,7)	14,0 (5,5)	0,84 (0,12)
	B, C, T, P (Réels)	Fl/Ex	2,9 (1,1)	3,9 (1,6)	0,99 (0,01)
		Ab/Ad	2,0 (0,8)	15,2 (6,3)	0,75 (0,22)
		Ri/Re	7,0 (1,8)	25,5 (6,3)	0,77 (0,14)
		Moyenne	3,3 (0,2)	14,9 (4,7)	0,83 (0,12)
	B, C, T, P (Réels + Virtuels)	Fl/Ex	1,4 (0,5)	1,9 (0,7)	0,99 (0,01)
		Ab/Ad	1,2 (0,4)	6,6 (2,3)	0,94 (0,06)
		Ri/Re	3,8 (1,6)	14,1 (6,4)	0,93 (0,07)
		Moyenne	1,7 (0,4)	7,5 (3,1)	0,96 (0,04)

* Une barre oblique signifie que la valeur précise associée à la donnée n'était pas disponible dans la référence

** NA signifie que la valeur précise associée à la donnée nécessitait la lecture imprécise d'un graphique.

Abréviations : ET : Écart-type, B : Bassin, C : Cuisse, T : Tibia, P : Pied

Une autre observation notable concerne l'absence de corrélation systématique entre des valeurs faibles de RMSE et des valeurs élevées du coefficient de corrélation (R) pour un même axe de mouvement (voir tableau 1.4, p.41). Cette divergence pourrait résulter de l'utilisation de coefficients de corrélation distincts, tels que ceux de Pearson ou de Spearman, bien que cette distinction ne soit pas toujours explicitée dans les études. Par ailleurs, la RMSE étant une mesure absolue de l'erreur, elle ne tient pas compte de l'échelle des données et ne permet donc pas d'évaluer l'ampleur relative de l'erreur en fonction de la dispersion des valeurs observées.

Dans le cadre de la comparaison des performances de modèles entraînés sur des ensembles de données différents, l'utilisation de la *Normalized Root Mean Squared Error*¹⁶ (nRMSE) s'avère plus appropriée, car elle prend en compte l'amplitude des données observées et permet

¹⁶ Racine de l'erreur quadratique moyenne normalisée [traduction libre]

une analyse comparative plus robuste (Miller, Portlock, Nyaga, & O’Sullivan, 2024). La nRMSE est obtenue en normalisant la RMSE par l’amplitude (soit l’écart entre la valeur maximale et la valeur minimale) des données observées, selon l’équation 1.7 :

$$nRMSE = \frac{RMSE}{\max(y_{obs}) - \min(y_{obs})} \quad (1.7)$$

où $\max(y_{obs})$ et $\min(y_{obs})$ représentent respectivement les valeurs maximale et minimale des données observées. Ces données, considérées comme les valeurs de référence, représentent les données « attendues » en sortie du modèle. Elles sont généralement issues d’un standard de comparaison tel qu’un système optoélectronique. Le tableau 1.3 (p.39) précise le standard de comparaison utilisé pour chaque modèle étudié.

Toutefois, bien que la normalisation de la RMSE améliore la robustesse de l’analyse comparative, il convient de rester prudent quant aux interprétations des résultats. En effet, la nRMSE peut être influencée par la manière dont les rotations sont calculées. Les valeurs obtenues sur les axes d’Ab/Ad et de Ri/Re peuvent varier considérablement en fonction de la procédure de calibration et de la méthodologie employée. Ainsi, des différences dans les procédures de calcul peuvent modifier l’amplitude totale d’une même base de données, impactant la valeur de la nRMSE obtenue.

Par exemple, dans le cadre de cette étude, les angles sont calculés selon la méthode de Grood et Suntay (1983), qui décompose les rotations selon une séquence XYZ dans un système de coordonnées propre à l’articulation. Ce système repose sur un repère cartésien où l’axe Z positif est orienté de façon proximale, vers l’insertion la plus proche du membre étudié. En revanche, une autre étude recensée dans le tableau 1.4 (p.41), menée par Sharifi-Renani et al. (2021), utilise également la nRMSE pour évaluer les performances de leur réseau, mais sans préciser la séquence adoptée. Leur calcul des angles repose sur le logiciel OpenSim (<https://simtk.org/projects/opensim>), qui emploie un système de coordonnées cartésiennes avec un axe Y positif dirigé vers le haut. OpenSim permet de choisir la séquence de rotation utilisée (OpenSim, 2024), mais en l’absence de précisions à ce sujet dans l’étude, une

comparaison directe avec les résultats de la présente recherche doit être réalisée avec précaution.

En conclusion, bien que la nRMSE semble constituer un indicateur plus pertinent que la RMSE pour la comparaison des modèles, son interprétation nécessite une attention particulière à la méthodologie employée. L'harmonisation des procédures de calcul et la transparence quant aux choix méthodologiques sont essentielles pour garantir des comparaisons fiables entre différentes études. De ce fait, la comparaison des performances de notre modèle par rapport à celles retrouvées dans la littérature se basera principalement sur les valeurs de RMSE.

1.4.4 Méthodes d'évaluation des performances

Le choix du modèle n'est qu'une composante d'une démarche d'apprentissage machine efficace. En effet, la qualité d'un modèle ne se limite pas à sa capacité d'effectuer la tâche demandée sur les données d'entraînement, mais repose sur sa capacité de généralisation, c'est-à-dire sa faculté à obtenir de bons résultats sur de nouvelles données non vues auparavant. Ainsi, pour évaluer la performance d'un modèle et garantir cette capacité de généralisation, il est essentiel de recourir à des méthodes d'évaluation spécifiques (James, Witten, Hastie, Tibshirani, & Taylor, 2023).

L'évaluation des performances permet tout d'abord de comparer différents algorithmes et modèles, et ainsi de sélectionner celui offrant les meilleures performances pour une tâche donnée (Hanna et al., 2023). Cette comparaison se base sur des métriques d'évaluation qui varient selon le type de problème (classification, régression, regroupements, etc.) et le contexte d'application. Les mesures de performance identifiées dans la sous-section précédente reflètent ces métriques pour chaque étude (*Voir* tableau 1.4, p.41).

Un autre objectif crucial de l'évaluation des performances est la détection de phénomènes de surapprentissage¹⁷. Ce dernier se produit lorsque le modèle mémorise les données d'entraînement au lieu d'apprendre les tendances générales sous-jacentes, compromettant ainsi sa capacité à généraliser. Pour éviter ce biais, il est recommandé de diviser les données en plusieurs sous-ensembles : une base de données d'entraînement, une base de données de test et une base de validation au sein de l'ensemble d'entraînement. Cette séparation permet d'évaluer le modèle sur des données inédites, réduisant ainsi le risque de surapprentissage (Antoniou & Mamdani, 2021).

Afin d'assurer une évaluation robuste, plusieurs méthodes de validation croisée sont couramment utilisées. Celles-ci permettent de tester chaque échantillon sans entraîner de surapprentissage. Parmi celles-ci, deux méthodes apparaissent fréquemment dans la littérature présentée à la sous-section précédente : la validation croisée en k partitions¹⁸ (Mundt, Koeppe, Bamer, et al., 2020 ; Rapp et al., 2021 ; Sharifi-Renani et al., 2021) et la validation croisée par exclusion d'un sujet¹⁹ (Mundt et al., 2021 ; Tan et al., 2022).

La validation croisée en k partitions, comme illustrée à la figure 1.17 (p.46), repose sur l'itération de l'entraînement du modèle k fois, en divisant la base de données en k sous-ensembles. Lors de chaque itération, un sous-ensemble est utilisé comme ensemble de test, tandis que les $k - 1$ autres sous-ensembles sont combinés et utilisés pour entraîner le modèle (Raschka, 2020). Les performances sont ensuite évaluées à chaque itération, puis une moyenne des résultats obtenus sur l'ensemble des entraînements peut être évaluée.

La validation croisée par exclusion d'un sujet, quant à elle, est une variante de la validation croisée en k partitions, dans laquelle k est égal au nombre n de sujets distincts dans l'ensemble de données. À chaque itération, un seul sujet est retenu pour le test, et les échantillons des $n -$

¹⁷ *Overfitting* [traduction de l'OQLF]

¹⁸ *K-Fold Cross-Validation* [traduction libre]

¹⁹ *Leave-One-Subject-Out* [traduction libre]

1 autres sujets sont combinés et utilisés pour l'entraînement du modèle (Raschka, 2020). Cette méthode est particulièrement pertinente dans le cadre de l'analyse du mouvement, où plusieurs échantillons peuvent être associés à un même sujet. Dans ce cas, la validation croisée par exclusion permet d'éviter que les données d'un même sujet ne soient à la fois dans l'ensemble d'entraînement et de test, ce qui pourrait induire un surapprentissage et altérer la généralisation du modèle. Cependant, cette méthode est plus coûteuse en termes de ressources, en particulier avec des bases de données volumineuses.

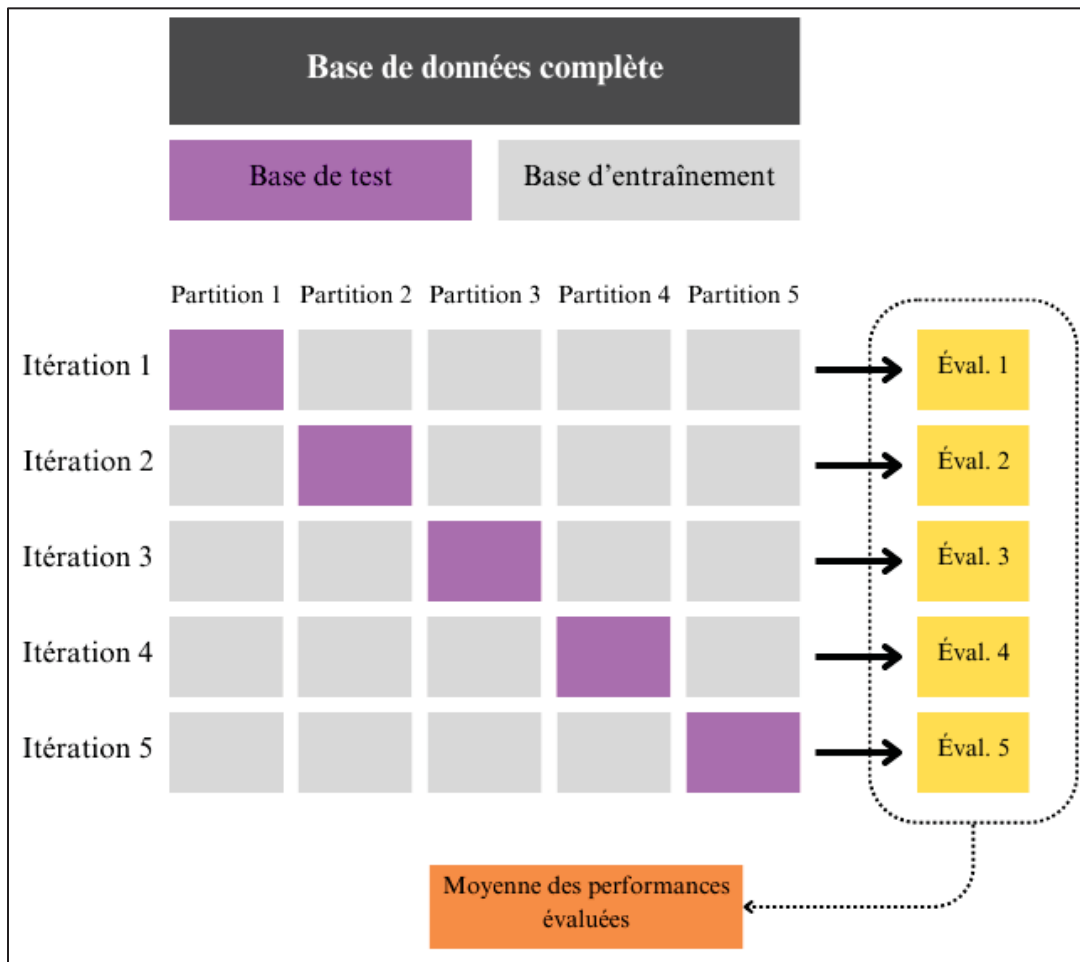


Figure 1.17 Illustration de la méthode de validation croisée en k partitions pour $k = 5$

Enfin, il est important de souligner que la performance d'un modèle dépend également du choix et de l'optimisation de ses hyperparamètres. Un hyperparamètre est une variable qui

influence le fonctionnement d'un modèle d'apprentissage machine, mais qui n'est pas directement appris à partir des données. Contrairement aux paramètres internes du modèle (tels que les poids dans un réseau de neurones), les hyperparamètres doivent être définis avant l'entraînement. L'optimisation des hyperparamètres est donc essentielle pour améliorer les performances du modèle. Parmi les études mentionnées à la sous-section précédente, un moyen utilisé pour effectuer cette optimisation est la recherche Hyperband.

La recherche Hyperband est une méthode d'allocation dynamique des ressources, visant à optimiser la recherche des meilleurs hyperparamètres plus efficacement que les approches traditionnelles, telles que la recherche aléatoire ou la recherche sur grille²⁰. Elle repose sur une optimisation par bandit multi-bras combinée à un système de réduction des ressources²¹, où un budget (en temps ou en essais de validation) est alloué à plusieurs configurations d'hyperparamètres, et les moins performantes sont éliminées progressivement. Cette approche permet de tester un large éventail de configurations tout en optimisant le temps de calcul. Cependant, il est à noter qu'elle ne garantit pas l'évaluation de toutes les combinaisons possibles (Li, Jamieson, DeSalvo, Rostamizadeh, & Talwalkar, 2018).

²⁰ *Grid Search* [traduction libre]

²¹ *Halving System* [traduction libre]

CHAPITRE 2

Problématique et objectif de recherche

L'analyse du patron de marche constitue une approche spécifique pour examiner les mouvements du genou, centrée sur l'évaluation des angles de rotation dans les trois axes de mouvement du genou pendant la marche. L'analyse des facteurs biomécaniques obtenus à partir des courbes triaxiales d'angles du genou au cours d'un cycle de marche représente un outil de diagnostic essentiel pour les cliniciens. En effet, elles permettent d'évaluer de manière objective et quantifiable les patients souffrant de troubles moteurs ou de pathologies au niveau des membres inférieurs, telles que l'arthrose du genou (gonarthrose). À cet égard, la précision des courbes cinématiques obtenues est cruciale, car elle fournit des données fiables qui facilitent le diagnostic et le suivi des pathologies, ainsi que la planification des traitements.

2.1 Problématique abordée

Actuellement, l'obtention des courbes cinématiques précises nécessaires pour une analyse détaillée du patron de marche repose principalement sur des systèmes de capture optique. Ces systèmes, souvent considérés comme la référence en matière d'analyse du mouvement (García-de-Villa et al., 2023), sont néanmoins complexes, coûteux et nécessitent des espaces dédiés pour accueillir un grand nombre de caméras infrarouges disposées autour du participant. Bien que ces systèmes offrent une grande précision et permettent d'étudier les mouvements du genou avec un niveau de détail élevé, leur coût et leur infrastructure restreignent leur accessibilité dans les milieux cliniques de routine.

En réponse à ces défis, les chercheurs se tournent de plus en plus vers l'utilisation de centrales inertielles, qui intègrent des accéléromètres, des gyroscopes et, dans certains cas, des magnétomètres. Ces centrales sont relativement peu coûteuses, portables et faciles à déployer, offrant ainsi une alternative intéressante aux systèmes optoélectroniques. Cependant, leur utilisation dans l'analyse du mouvement du genou nécessite des méthodes de traitement des données complexes. Les IMUs fournissent des courbes de vitesse angulaire et d'accélération

linéaire localisées sur le membre auquel ils sont fixés. En utilisant des techniques d'intégration, ces données peuvent être converties en courbes de rotation angulaire. Cependant, ces rotations présentent souvent des écarts par rapport à celles calculées avec des systèmes optoélectroniques, rendant l'extraction de caractéristiques pertinentes à l'interprétation clinique plus difficile.

Une des principales différences entre les systèmes optoélectroniques et les centrales inertielles réside dans la capacité à définir un référentiel anatomique stable. Les systèmes optoélectroniques permettent de déterminer précisément les axes fonctionnels du genou en identifiant des points anatomiques spécifiques lors de la capture des données, créant ainsi un repère de référence pour l'analyse des mouvements qui est interprétable cliniquement. En revanche, cette méthode n'est pas applicable aux centrales inertielles, qui nécessitent plutôt un calibrage fonctionnel, tel que la méthode Palermo, afin de lier chaque centrale à un repère anatomique spécifique (Palermo, Rossi, Marini, Patanè, & Cappa, 2014 ; Robert-Lachaine, Parent, Fuentes, Hagemeister, & Aissaoui, 2020 ; di Falco, Aissaoui, & Hagemeister, 2025). Bien que des méthodes du genre soient utilisées dans la littérature, elles restent difficiles à implémenter et produisent des résultats qui diffèrent des mesures obtenues via des systèmes optoélectroniques.

Par ailleurs, le bruit généré lors de l'intégration des données affecte de manière inégale les différents axes de rotation du genou. En effet, l'amplitude de mouvement observée dans l'axe de flexion-extension est bien plus grande que celle des axes d'abduction/adduction et de rotation interne/externe. Ainsi, une même erreur d'estimation impacte davantage les deux derniers axes, dont l'amplitude est moindre, ce qui limite la précision des estimations cliniques dans ces plans de mouvement.

Des avancées récentes dans le domaine de l'analyse du mouvement, en particulier l'intégration de l'apprentissage machine, ont montré un potentiel intéressant pour réduire ces erreurs d'estimation, en particulier celles liées aux centrales inertielles. L'apprentissage machine, notamment à travers l'utilisation de réseaux de neurones récurrents, comme les LSTM et

BiLSTM, permet d'identifier des motifs dans les données temporelles et d'améliorer la précision des estimations des mouvements complexes. Cependant, les erreurs persistent, notamment pour les axes de rotation moins amples (abduction/adduction et rotation tibiale interne/externe), ce qui conduit de nombreuses études à se concentrer uniquement sur l'axe flexion/extension, réduisant ainsi l'applicabilité clinique des résultats, puisque les valeurs caractéristiques, aussi nommées facteurs biomécaniques, utilisées par les cliniciens requièrent une analyse complète sur les trois axes de mouvement.

2.2 Objectifs du projet

Les défis actuels concernent principalement la réduction du nombre de centrales nécessaires et la simplification de leur mise en œuvre, souvent réalisée par des professionnels spécialisés. De plus, de nombreuses études sont menées sur de petites populations ou sur des participants jeunes et en bonne santé. Il est donc essentiel d'évaluer la répétabilité des résultats sur des populations plus diverses, incluant différents âges, genres et niveaux de pathologies. Un autre objectif majeur est de minimiser les erreurs d'estimation des angles articulaires dans tous les axes du mouvement, notamment dans les axes d'abduction/adduction et de rotation tibiale interne/externe, afin de garantir la fiabilité des données utilisées dans l'évaluation clinique complète du patron de marche.

L'objectif principal de ce mémoire est ainsi de concevoir et d'évaluer l'efficacité d'un algorithme basé sur un réseau de neurones de type BiLSTM, capable d'inférer avec précision les courbes cinématiques dans les trois axes anatomiques à partir de données provenant de deux centrales inertielles virtuellement placées sur les membres inférieurs (fémur et tibia) pendant la marche. Cette étude sera réalisée avec des patients sains et des patients souffrant de gonarthrose. L'inférence précise de ces courbes cinématiques, au-delà des limitations actuelles des centrales inertielles, pourrait permettre une évaluation complète des facteurs biomécaniques utilisés dans les analyses cliniques, rendant ces évaluations plus accessibles et pratiques dans des environnements en dehors du laboratoire.

CHAPITRE 3

Étape préliminaire pour l'utilisation de tous les cycles

3.1 Introduction de l'étape préliminaire

La caractérisation des courbes cinématiques à l'aide de facteurs biomécaniques a été présentée dans le premier chapitre de ce mémoire. Actuellement, ces facteurs sont utilisés en clinique sous deux formats principaux : des valeurs numériques et des catégories. Toutefois, ce sont surtout ces dernières qui servent de base aux diagnostics.

À ce jour, les facteurs biomécaniques appliqués en clinique sont dérivés de la courbe d'un cycle moyen. Cependant, cette courbe moyenne n'est pas calculée à partir de l'ensemble des cycles de marche captés pendant un essai, mais plutôt à partir des 15 cycles²² les plus répétables²³ (ou « cycles valides »). Ce processus implique donc un découpage préalable des cycles à partir du signal complet enregistré pendant l'essai de marche. Cette méthode, que nous désignerons par « méthode standard » pour la suite de ce chapitre, n'a cependant pas été rigoureusement validée. Une question se pose alors concernant la pertinence du retrait des cycles jugés aberrants (ou « cycles rejetés ») dans le calcul des valeurs numériques et, par conséquent, des catégories associées aux différents facteurs biomécaniques.

En effet, la méthode standard ajoute une étape de traitement supplémentaire aux données provenant des systèmes optoélectroniques. La confirmation de la nécessité de cette étape pour le calcul des facteurs biomécaniques impliquerait de l'intégrer également dans le traitement des données issues des centrales inertielles. Cela impliquerait alors un découpage des courbes d'accélérations triaxiales en fonction des cycles de marche, ne conservant que les cycles les

²² Il faut un minimum de 15 cycles considérés « répétables » dans un même essai afin d'évaluer la courbe moyenne et les facteurs biomécaniques. Si plus de 15 cycles sont considérés de la sorte, l'ensemble des cycles qui répondent au critère seront considérés dans les calculs subséquents.

²³ Un cycle est considéré « répétable » s'il se retrouve à moins de 1,5 écart-types de la moyenne des cycles d'un essai.

plus répétables. Cependant, comme mentionné dans le chapitre précédent, un réseau de neurones de type LSTM ou BiLSTM nécessite une large base de données d'apprentissage pour produire des résultats pertinents et significatifs. Ainsi, découper une partie des signaux enregistrés réduit du même fait la taille de la base de données d'apprentissage, ce qui peut alors affecter la précision des estimations produites.

L'objectif de cette étape préliminaire est donc de vérifier si le découpage et le tri des cycles de marche sont réellement nécessaires pour le calcul des facteurs biomécaniques. Pour cela, les valeurs numériques et les catégories des facteurs biomécaniques, calculées à partir de l'ensemble des cycles d'un essai, seront comparées à celles obtenues par la méthode standard.

3.2 Description des bases de données initiales

Deux bases de données seront utilisées pour effectuer cette vérification. Elles ont été collectées par le centre intégré universitaire de santé et de services sociaux (CIUSSS) de l'Est-de-l'Île-de-Montréal et l'Hôpital Maisonneuve-Rosemont (HMR), en collaboration avec le Centre de recherche du centre hospitalier de l'Université de Montréal (CRCHUM), la TÉLUQ et l'École de technologie supérieure (ÉTS). Les patients et sujets inclus dans ces bases de données ont signé un formulaire de consentement approuvé par les institutions.

La première base de données, intitulée MonArthrose, a été constituée dans le cadre d'un projet clinique visant à améliorer le traitement et le diagnostic de l'arthrose du genou (Projet Arthrose – Mieux traiter et diagnostiquer l'arthrose du genou : un impératif clinique et économique pour notre système de santé). Son numéro de certificat éthique au CRCHUM est CE14.339. Les acquisitions de la seconde base de données, nommée HMR, ont été réalisées à l'HMR sous le certificat éthique numéro 2011-462. Des acquisitions provenant de la base de données du LIO-ÉTS (numéro de certificat éthique : BD07.001) sont incluses dans cette seconde base de données. Le tableau 3.1 (p.55) présente un résumé de la description de la population de chacune de ces deux bases de données.

Tableau 3.1 Description de la population des bases de données MonArthrose et HMR

	MonArthrose	HMR
Type	OA à divers stades	Sains/asymptomatiques
Répartition	428 participants 265 femmes; 163 hommes	90 participants 49 femmes; 41 hommes
Âge moyen	62,9 \pm 9,47 ans	34,8 \pm 12,3 ans

Les deux bases de données suivent un protocole expérimental identique pour l’acquisition des données. Les participants ont été invités à réaliser plusieurs essais de marche de 45 secondes sur un tapis roulant non instrumenté, à une vitesse confortable et contrôlée de 0,8 m/s. Pendant ces essais, chaque participant portait le système KneeKG® sur un genou (un essai étant généralement effectué sur chaque genou lors d’une même consultation), permettant à une caméra 3D de type Polaris Spectra™ de capturer les trajectoires des grappes de marqueurs placées sur les segments de la cuisse et de la jambe, à une fréquence de 60 Hz.

Les fichiers présents dans ces bases de données sont au format « .kkg », une nomenclature inspirée par le nom du système, KneeKG®. Ce format protège les données pour garantir l’anonymat des participants. Chaque fichier contient non seulement des informations générales sur le participant, mais également l’ensemble des matrices de rotations et de translations des grappes de capteurs du système KneeKG®, classées selon la consultation et l’essai. À partir de ces matrices, les courbes des angles au genou dans les trois plans anatomiques sont évaluées, en utilisant le référentiel obtenu par calibration par pointage des points anatomiques. Ces courbes, ainsi que les courbes des cycles valides, rejetés et moyen pour chaque axe fonctionnel du genou, sont aussi intégrées dans le fichier KKG de chaque participant. Pour garantir la reproductibilité des résultats, les informations de calibration par pointage de chaque essai sont également conservées dans les fichiers KKG. Bien que ces fichiers contiennent une multitude d’informations supplémentaires, seules celles nécessaires à l’étape préliminaire du présent projet de mémoire seront utilisées et détaillées.

3.3 Méthodologie de l'étape préliminaire

Chaque base de données est accompagnée d'un fichier Excel regroupant les informations démographiques des participants. Dans la base de données MonArthrose, ce fichier recense le grade d'arthrose pour chaque genou, le sexe, l'âge, ainsi que le numéro du fichier KKG correspondant à chaque participant. Pour la base de données HMR, les mêmes informations sont consignées, à l'exception du grade d'arthrose. Sur la base de ces données, des groupes et sous-groupes ont été constitués afin d'optimiser les comparaisons et d'assurer une discussion plus approfondie des résultats.

3.3.1 Constitution des groupes à partir des données démographiques

Sur la base de ces données, des groupes et sous-groupes ont été constitués afin d'optimiser les comparaisons et d'assurer une discussion plus approfondie des résultats. Le tableau 3.2 (p.59) présente les données démographiques associées à chacun des groupes formés lors de cette étape préliminaire.

Les participants atteints de gonarthrose ont été regroupés en trois catégories principales, correspondant aux grades OA2, OA3 et OA4. Bien que la plupart des participants présentent un degré d'atteinte articulaire similaire aux deux genoux, certains présentent une atteinte asymétrique. Afin de structurer les analyses, seuls les sujets ayant une différence de grade d'un seul niveau entre les deux genoux ont été retenus. Les sous-groupes « gauche » et « droite » correspondant à leur grade d'arthrose le plus élevé permettent d'identifier ces cas où l'atteinte est plus marquée d'un côté. Par exemple, les participants du sous-groupe « gauche » du groupe OA4 ont tous un genou gauche de grade 4 et un genou droit de grade 3. Cette stratégie de regroupement repose sur des études antérieures indiquant que la plupart des patients atteints de gonarthrose présentent une atteinte bilatérale (Mon Arthrose, 2024). Cette distinction est particulièrement visible dans les groupes OA3 et OA4, où le nombre de patients atteints des deux genoux est largement supérieur à ceux atteints d'un seul côté. Ainsi, en réduisant la variabilité au sein des groupes, cette approche permet de simplifier l'analyse sans altérer la

représentativité des données. Toutefois, elle a entraîné une diminution du nombre total de participants retenus, passant de 428 à 350 dans la base MonArthrose.

Une réduction similaire est observée dans le groupe des participants asymptomatiques : sur les 90 participants initiaux, seuls 58 ont été conservés dans l'étape préliminaire. Cette diminution s'explique par plusieurs facteurs. D'abord, certains participants n'ont pas donné leur consentement pour l'utilisation de leurs données. Ensuite, l'algorithme de sélection a restreint l'analyse de cette base de données aux essais portant uniquement sur des genoux de grade 0. En effet, comme présenté au premier chapitre de ce mémoire, certains patients peuvent être considérés asymptomatiques, mais tout de même être classés OA1. Ce grade ne correspond pas à celui d'un patient gonarthrosique, mais indique simplement la présence d'un « ostéophyte²⁴ de signification douteuse [traduction libre] » à la radiographie du genou (Kellgren & Lawrence, 1957).

L'analyse des données du tableau 3.2 (p.59) met également en évidence quelques tendances marquantes concernant la distribution des participants selon sexe, leur statut (OA ou asymptomatiques) et leur âge.

D'abord, on observe que les femmes sont nettement plus nombreuses que les hommes dans chaque groupe atteint de gonarthrose (OA2, OA3 et OA4), avec un total de 205 femmes contre 145 hommes. Cette tendance est conforme aux observations cliniques indiquant une prévalence plus élevée de l'arthrose chez les femmes (*Voir* figure 3.1, p.58). En effet, il est estimé qu'au Canada, la prévalence de l'arthrose diagnostiquée chez les femmes est de 16,1 %, alors qu'elle est de 11,1 % chez les hommes (Agence de la santé publique du Canada, 2020).

Ensuite, la fusion des groupes arthrosiques et asymptomatiques entraîne un âge moyen global de 58,48 ans pour les hommes et 59,09 ans pour les femmes. Cette moyenne, bien

²⁴ « [Les ostéophytes sont des] excroissances osseuses localisées au niveau des articulations. Les ostéophytes sont secondaires à [...] des maladies dégénératives, majoritairement l'arthrose. » (Elsan, 2024)

qu’informatrice, masque les écarts significatifs entre les patients asymptomatiques et ceux atteints de gonarthrose avancée. En effet, contrairement aux groupes arthrosiques (moyenne de 63,85 ans pour les hommes et 62,85 ans pour les femmes), on observe que les participants asymptomatiques sont significativement plus jeunes (31,62 ans pour les hommes et 32,52 ans pour les femmes). Cette différence d’âge suggère une nette distinction entre les populations étudiées, ce qui corrobore les informations fournies par la figure 3.1 et renforce la pertinence de leur comparaison pour évaluer les effets d’un changement de méthode de calcul sur les facteurs biomécaniques obtenus.




Figure 3.1 Prévalence de l’arthrose diagnostiquée au Canada, selon le sexe et le groupe d’âge
Tirée du site de l’Agence de la santé publique du Canada (2020)

De plus, on observe également une augmentation de l’âge moyen des participants avec la sévérité du grade d’arthrose observé. Les participants du groupe OA4 (arthrose sévère) ont un âge moyen plus élevé (69,36 ans pour les hommes et 65,12 ans pour les femmes) que ceux du groupe OA3 (63,42 ans pour les hommes et 62,87 ans pour les femmes) et du groupe OA2 (60,23 ans pour les hommes et 60,71 ans pour les femmes). Cette tendance respecte le lien bien établi entre l’âge avancé et la progression de la gonarthrose, puisqu’il est estimé qu’environ 73% des personnes atteintes d’arthrose sont âgées de plus de 55 ans (Organisation mondiale de la santé, 2023).

Tableau 3.2 Données démographiques associées à chacun des groupes et sous-groupes formés par les deux bases de données pour l'étape préliminaire

Groupe	Sous-groupe	Sexe	Nb de patients	Âge moyen
OA4	Gauche (G)	M	3	69,67
		F	6	64,17
	Droite (D)	M	7	69,57
		F	11	66,45
	Deux genoux (G+D)	M	29	69,28
		F	41	64,90
Total	M	39	69,36	
	F	58	65,12	
OA3	Gauche (G)	M	8	58,75
		F	12	56,92
	Droite (D)	M	12	63,67
		F	21	61,14
	Deux genoux (G+D)	M	33	64,45
		F	52	64,94
Total	M	53	63,42	
	F	85	62,87	
OA2	Gauche (G)	M	1	79,00
		F	3	64,00
	Droite (D)	M	3	60,00
		F	5	59,80
	Deux genoux (G+D)	M	49	59,86
		F	54	60,61
Total	M	53	60,23	
	F	62	60,71	
Total OA		M	145	63,85
		F	205	62,85
Asymptomatique (ASYMPT)		M	29	31,62
		F	29	32,52
Total OA + ASYMPT		M	174	58,48
		F	234	59,09

3.3.2 Extraction et traitement des courbes de cycles

Après l'identification des groupes et sous-groupes, les courbes des cycles valides, des cycles rejetés, ainsi que la courbe moyenne de chaque axe de rotation (flexion/extension, abduction/adduction et rotation tibiale interne/externe) ont été extraites des fichiers KKG. Ces courbes ont ensuite été centralisées et organisées dans des fichiers Excel structurés par sous-groupe, facilitant ainsi les analyses ultérieures.

Afin de comparer les facteurs biomécaniques obtenus selon deux méthodes différentes, une étape supplémentaire a été mise en place. En effet, bien que les facteurs biomécaniques soient calculés à partir des courbes moyennes directement extraites des fichiers KKG pour la méthode standard, ce n'est pas le cas pour la seconde approche, qui sera désignée sous le terme « méthode test » dans la suite de ce chapitre. Pour la méthode test, c'est plutôt l'ensemble des cycles (valides et rejetés) qui est pris en compte. Puisque les cycles sont déjà normalisés sur 100 points, la courbe moyenne pour cette méthode est obtenue en calculant la moyenne de chaque point sur l'ensemble des cycles d'un même essai.

Un script MATLAB a ensuite été développé afin de calculer les valeurs numériques et les catégories des facteurs biomécaniques pour chaque essai (*Voir figure 3.2, p.61*). Ce code calcule les divers facteurs biomécaniques sur les courbes moyennes de chaque méthode conformément aux définitions présentées en annexe II (p.121). Il compare ensuite les résultats obtenus et enregistre les erreurs absolues, définies comme la différence entre les valeurs issues des deux méthodes, et la concordance des catégories, indiquant si les deux méthodes attribuent la même catégorie à un facteur donné (1 en cas d'accord, 0 sinon).

Afin d'assurer une comparaison robuste, la moyenne et l'écart-type des erreurs absolues ont été calculés pour chaque facteur biomécanique, tant à l'échelle des sous-groupes qu'à celle des groupes globaux. De plus, des taux de concordance ont été calculés à la même échelle pour les catégories, représentant le pourcentage d'essais pour lesquels les deux méthodes attribuent la même classification.

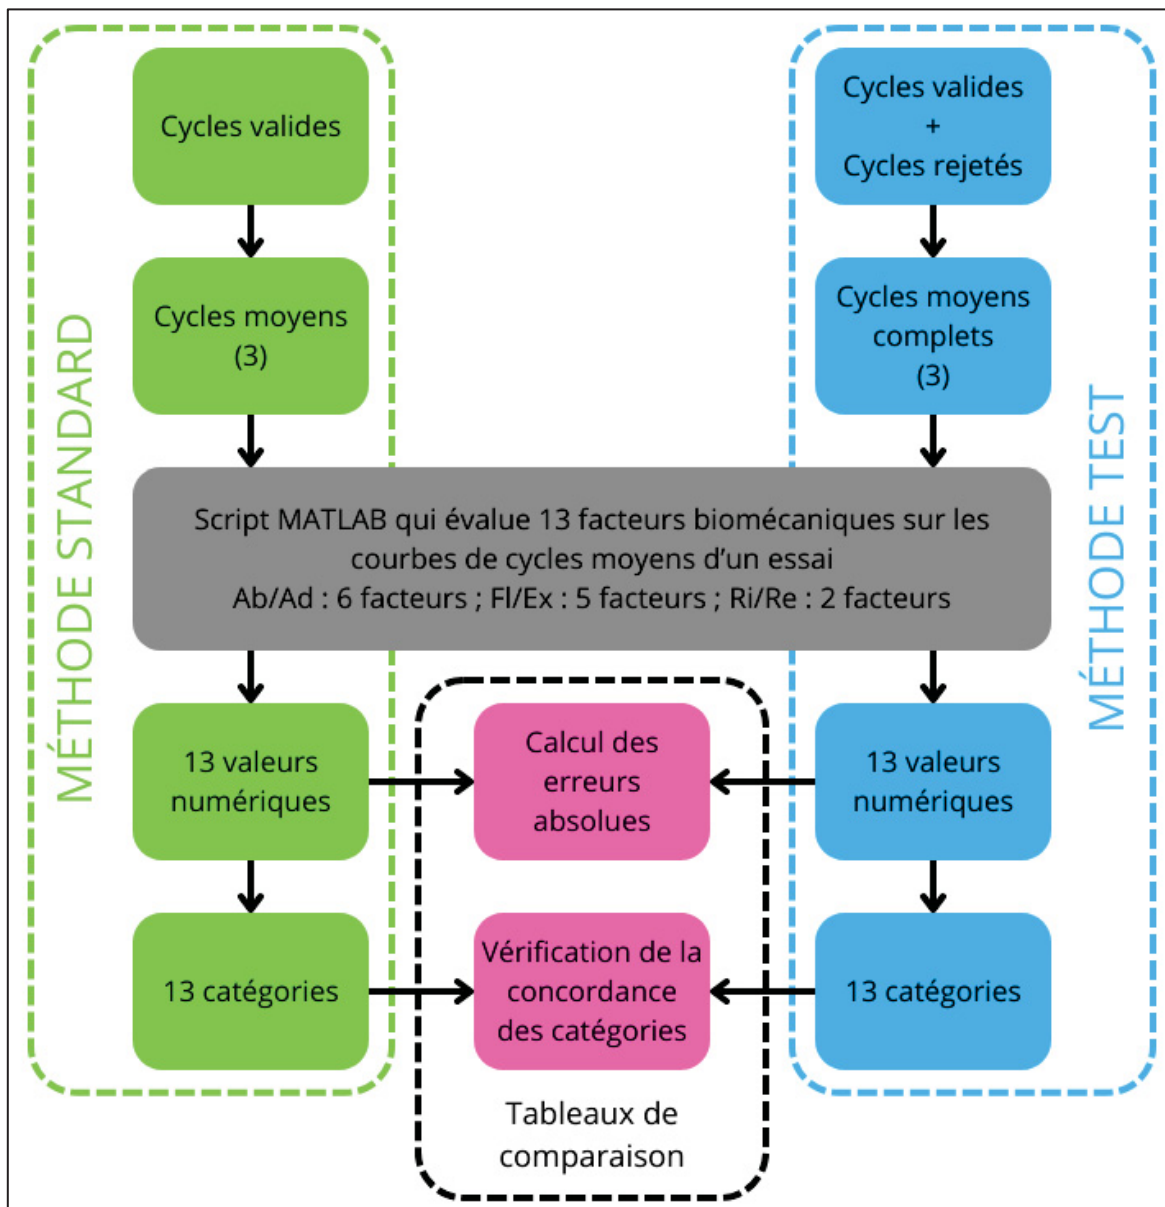


Figure 3.2 Diagramme simplifié du processus suivi par le script MATLAB pour chaque essai de l'étape préliminaire

3.3.3 Influence des seuils sur la classification des facteurs biomécaniques

Les diagnostics cliniques reposent principalement sur la classification des facteurs biomécaniques selon des catégories préétablies (*Voir* tableau 3.3, p.63). À des fins de rappel, la catégorie « négatif » signifie que la valeur numérique associée au facteur biomécanique n'est pas pathologique. Au contraire, la catégorie « positif plus » est associée à un facteur considéré sévèrement pathologique. Ces classifications sont définies selon des seuils stricts. De ce fait, une variation minime dans les valeurs calculées peut suffire à induire une discordance entre les deux méthodes (standard et test).

Il est également important de noter que les seuils pour l'axe de Fl/Ex sont beaucoup plus larges que ceux des axes d'Ab/Ad et de Ri/Re. Cette différence s'explique par l'amplitude naturelle des mouvements dans chaque plan anatomique, influençant ainsi la sensibilité des classifications. En effet, alors que l'amplitude du mouvement de flexion/extension pendant la marche tourne autour du 65° (Gasparutto, Moissenet, Lafon, Chèze, & Dumas, 2017), les mouvements d'abduction/adduction et de rotation interne/externe sont beaucoup plus limités et présentent des amplitudes respectives tournant plutôt autour de 10° et 20° pour un genou pathologique. De ce fait, une erreur de même valeur ne porte pas le même poids dans tous les axes.

Ainsi, l'analyse des erreurs doit prendre en compte non seulement les discordances de catégories, mais aussi l'ampleur des écarts numériques observés. Une faible variation peut parfois entraîner un changement de classification sans pour autant refléter une différence clinique significative. Il est donc crucial d'évaluer ces écarts sous l'angle de leur pertinence biomécanique et diagnostique.

Tableau 3.3 Bornes associées aux catégories possibles de chaque facteur biomécanique selon une valeur numérique obtenue de x (en degrés)

Axe	Facteur	Négatif	Positif	Positif plus
Sagittal Fl/Ex	Contracture dynamique en flexion au contact au sol	$-2 < x$	$x \leq -2$	/
	Flexion limitée lors du chargement	$14 \leq x$	$8 < x < 14$	$x \leq 8$
	Limitation de l'extension en appui	$17 \leq x$	$0 < x < 17$	$x \leq 0$
	Diminution de la flexion à l'envol	$47 < x$	$x \leq 47$	/
	Diminution de l'amplitude de mouvement Fl/Ex	$58 \leq x$	$50 < x < 58$	$x \leq 50$
Vertical Ab/Ad	Augmentation du varus lors du chargement	$x < 2,5$	$2,5 \leq x \leq 7$	$7 < x$
	Genou varum au contact au sol	$x < 2$	$2 \leq x$	/
	Genou varum durant l'appui (V1, V2, V3)	$x < 2$	$2 \leq x \leq 5$	$5 < x$
	Augmentation du valgus lors du chargement	$x < 2,5$	$2,5 \leq x \leq 7$	$7 < x$
Transverse Ri/Re	Rotation externe tibiale au contact au sol	$x < 4,5$	$4,5 \leq x < 7,5$	$7,5 \leq x$
	Rotation interne tibiale lors du chargement	$-1 \leq x$	$x < -1$	/

3.4 Comparaison des valeurs numériques obtenues

Le tableau 3.4 (p.65) présente la moyenne et l'écart-type des écarts absolus obtenus en comparant les différentes méthodes de calcul pour chaque facteur biomécanique. Ces résultats sont établis sur l'ensemble des deux bases de données, totalisant 408 participants. Afin de mieux refléter les spécificités biomécaniques propres à chaque sexe, les résultats sont segmentés en fonction du sexe. Cette distinction est justifiée par des travaux antérieurs, notamment ceux de Clément et al. (2018), qui ont démontré l'existence de différences dans le patron de marche entre les hommes et les femmes.

Il est essentiel de préciser que le tableau 3.4 (p.65) ne prend pas en compte les divers groupes et sous-groupes définis précédemment. En revanche, le tableau 3.5 (p.66) regroupe les moyennes et écarts-types de tous les facteurs biomécaniques combinés pour chaque groupe et sous-groupe en fonction de chaque axe. Des analyses détaillées pour chaque facteur sont disponibles en annexe III (p.129) et sont regroupées par axe :

- Abduction/Adduction – *Voir* tableau-A III-1 (p.129);
- Flexion/Extension – *Voir* tableau-A III-2 (p.130);
- Rotation interne/externe – *Voir* tableau-A III-3 (p.131).

Cette structuration en annexes permet une lecture plus fluide des résultats globaux tout en conservant un accès détaillé aux données spécifiques. L'ensemble des résultats est tout de même considéré pour la discussion. De plus, il importe de préciser que les résultats de moyennes obtenues dans l'ensemble de ces tableaux sont pondérés en fonction de la proportion que représente chaque groupe et sous-groupe.

Tableau 3.4 Moyenne et écart-type des écarts absolus obtenus par la comparaison des méthodes de calcul pour chaque facteur biomécanique

Axe	Facteur biomécanique	Sexe	Moyenne (°)	Écart-type (°)
Vertical Ab/Ad	Augmentation du varus lors du chargement	M	0,113	0,114
		F	0,123	0,110
	Genou varum au contact au sol	M	0,078	0,076
		F	0,083	0,098
	Genou varum durant l'appui V1	M	0,050	0,044
		F	0,052	0,061
	Genou varum durant l'appui V2	M	0,046	0,041
		F	0,048	0,059
Sagittal Fl/Ex	Augmentation du valgus lors du chargement	M	0,074	0,103
		F	0,065	0,095
	Contracture dynamique en flexion au contact au sol	M	0,331	0,316
		F	0,360	0,371
	Flexion limitée lors du chargement	M	0,397	0,310
		F	0,411	0,389
	Limitation de l'extension en appui	M	0,404	0,364
		F	0,414	0,410
Transverse Ri/Re	Diminution de la flexion à l'envol	M	0,292	0,268
		F	0,303	0,255
	Diminution de l'amplitude de mouvement Fl/Ex	M	0,420	0,356
		F	0,467	0,465
	Rotation externe tibiale au contact au sol	M	0,192	0,178
		F	0,219	0,241
	Rotation interne tibiale lors du chargement	M	0,113	0,105
		F	0,118	0,163

Tableau 3.5 Moyenne et écart-type (en degrés) par groupe des erreurs absolues de calcul des facteurs biomécaniques en fonction de chaque axe

Groupe	Sous- groupe	Sexe	Axe Ab/Ad		Axe Fl/Ex		Axe Ri/Re		Moyenne	
			Moy.	ET	Moy.	ET	Moy.	ET	Moy.	ET
OA4	G	M	0,058	0,050	0,305	0,221	0,257	0,106	0,184	0,124
		F	0,075	0,083	0,580	0,459	0,162	0,086	0,283	0,228
	D	M	0,052	0,049	0,291	0,291	0,169	0,144	0,162	0,157
		F	0,056	0,051	0,375	0,272	0,142	0,118	0,192	0,144
	G+D	M	0,077	0,082	0,395	0,336	0,170	0,177	0,213	0,194
		F	0,076	0,078	0,333	0,296	0,160	0,154	0,188	0,174
Tot.	M	0,071	0,073	0,369	0,319	0,177	0,166	0,202	0,182	
	F	0,072	0,074	0,367	0,308	0,157	0,140	0,199	0,174	
OA3	G	M	0,061	0,048	0,333	0,291	0,102	0,091	0,172	0,148
		F	0,065	0,056	0,287	0,242	0,136	0,142	0,161	0,141
	D	M	0,070	0,061	0,471	0,525	0,152	0,147	0,237	0,253
		F	0,057	0,050	0,356	0,352	0,144	0,109	0,185	0,175
	G+D	M	0,073	0,089	0,337	0,295	0,178	0,183	0,191	0,183
		F	0,066	0,062	0,387	0,341	0,157	0,201	0,204	0,191
Tot.	M	0,070	0,077	0,367	0,346	0,161	0,161	0,198	0,193	
	F	0,064	0,058	0,365	0,329	0,151	0,170	0,193	0,180	
OA2	G	M	0,082	0,000	0,625	0,000	0,146	0,000	0,301	0,000
		F	0,016	0,013	0,123	0,092	0,068	0,095	0,065	0,056
	D	M	0,069	0,074	0,379	0,240	0,071	0,063	0,188	0,136
		F	0,050	0,051	0,365	0,303	0,182	0,137	0,191	0,161
	G+D	M	0,066	0,067	0,359	0,300	0,123	0,116	0,187	0,164
		F	0,080	0,138	0,467	0,568	0,218	0,366	0,250	0,338
Tot.	M	0,066	0,066	0,365	0,291	0,121	0,111	0,189	0,159	
	F	0,075	0,125	0,442	0,523	0,208	0,334	0,236	0,311	
Total OA		M	0,069	0,072	0,367	0,319	0,150	0,144	0,196	0,178
		F	0,069	0,083	0,389	0,382	0,170	0,211	0,208	0,218
ASYMPT		M	0,057	0,056	0,378	0,343	0,164	0,127	0,197	0,177
		F	0,067	0,059	0,404	0,347	0,162	0,139	0,211	0,182
Total OA + ASYMPT		M	0,067	0,069	0,369	0,323	0,153	0,141	0,196	0,178
		F	0,069	0,080	0,391	0,378	0,169	0,202	0,208	0,213

3.4.1 Discussion sur les écarts absolus

En bref, les écarts absolus observés représentent moins de 1 % de l'amplitude totale de chaque mouvement. Ainsi, la divergence entre les valeurs obtenues par la méthode test et celles issues de la méthode standard demeure minime, ne remettant pas en cause la fiabilité de la méthode test.

Afin d'aller un peu plus en détails, l'analyse des écarts absolus moyens (*Voir* tableau 3.4, p.65) révèle une augmentation proportionnelle de ces écarts avec l'amplitude des mouvements. À l'exception du facteur « augmentation du varus lors du chargement », une hiérarchisation est observée : les écarts les plus faibles concernent l'axe vertical, les intermédiaires l'axe transverse et les plus élevés l'axe sagittal. Étant donné la complémentarité entre le varus et le valgus, il pourrait être plus pertinent de ne retenir que l'indicateur biomécanique en valgus.

Les écarts absolus varient selon la méthode de calcul employée pour les trois versions du « genou varum durant l'appui » (V1, V2, V3). V1 présente les écarts les plus élevés, tandis que V3 affiche les plus faibles. Ainsi, si l'ensemble des cycles doit être pris en compte (méthode test), la méthode V3 semble la plus appropriée.

Les erreurs sont plus marquées chez les femmes, suggérant une plus grande variabilité des patrons de marche. Toutefois, cette différence pourrait être partiellement attribuable à une surreprésentation féminine (+25,6 %).

L'analyse des écarts par axes et groupes de patients (*Voir* tableau 3.5, p.66) met en évidence l'influence du sexe et du degré d'atteinte articulaire. Pour l'axe d'Ab/Ad, contrairement à la tendance générale, les hommes du groupe OA3 présentent des écarts plus élevés. Par ailleurs, l'augmentation progressive des écarts avec la sévérité de la pathologie indique que les individus asymptomatiques enregistrent les valeurs les plus faibles.

Concernant l'axe de FI/Ex, les écarts absolus sont plus marqués chez les individus asymptomatiques, ce qui pourrait s'expliquer par une absence de douleur articulaire leur permettant une plus grande liberté de mouvement. Les femmes des groupes OA2 et asymptomatiques présentent des écarts supérieurs à ceux des hommes, tandis que les différences entre sexes restent marginales dans les autres groupes.

Enfin, pour l'axe de Ri/Re, les écarts les plus élevés sont observés chez les individus des groupes OA4 et asymptomatiques. Contrairement à la tendance générale, les femmes présentent des écarts moindres par rapport aux hommes, sauf dans le groupe OA2 où leurs écarts sont près de deux fois plus importants.

3.5 Comparaison des catégories obtenues

Le tableau 3.6 (p.70) présente la moyenne des taux de concordance des catégories évaluées selon les deux méthodes de calcul pour chaque facteur biomécanique. Ces résultats sont établis sur l'ensemble des deux bases de données, totalisant 408 participants. Afin de mieux refléter les spécificités biomécaniques propres à chaque sexe, les résultats y sont également segmentés en fonction du sexe.

Il convient de souligner que le tableau 3.6 (p.70) ne prend pas en compte la distinction entre les différents groupes et sous-groupes définis précédemment. En revanche, le tableau 3.7 (p.71) regroupe les moyennes des taux de concordance de l'ensemble des facteurs biomécaniques combinés, en fonction de chaque axe et pour chaque groupe et sous-groupe. Une analyse plus détaillée de chaque facteur est disponible en annexe IV (p. 133), où les données sont organisées par axe :

- Abduction/Adduction – Voir tableau-A IV-1 (p.133);
- Flexion/Extension – Voir tableau-A IV-2 (p.134);
- Rotation interne/externe – Voir tableau-A IV-3 (p.135).

Cette organisation en annexes facilite la lecture des résultats globaux tout en garantissant un accès détaillé aux données spécifiques. Tous les résultats restent pris en compte dans la

discussion. Par ailleurs, il est important de noter que les moyennes présentées dans ces tableaux sont pondérées en fonction de la proportion de chaque groupe et sous-groupe, assurant ainsi une représentation équilibrée des données.

Tableau 3.6 Moyenne des taux de concordance obtenus par la comparaison des catégories évaluées par les deux méthodes de calcul pour chaque facteur biomécanique

Axe	Facteur biomécanique	Sexe	Taux
Vertical Ab/Ad	Augmentation du varus lors du chargement	M	95,98%
		F	96,58%
	Genou varum au contact au sol	M	100,00%
		F	99,57%
	Genou varum durant l'appui V1	M	98,85%
		F	99,15%
Sagittal Fl/Ex	Genou varum durant l'appui V2	M	99,43%
		F	99,57%
	Genou varum durant l'appui V3	M	99,43%
		F	99,57%
	Augmentation du valgus lors du chargement	M	98,85%
		F	98,72%
	Contracture dynamique en flexion au contact au sol	M	99,43%
		F	100,00%
	Flexion limitée lors du chargement	M	95,98%
		F	95,30%
Transverse Ri/Re	Limitation de l'extension en appui	M	98,28%
		F	97,44%
	Diminution de la flexion à l'envol	M	99,43%
		F	100,00%
	Diminution de l'amplitude de mouvement Fl/Ex	M	95,98%
		F	94,44%
	Rotation externe tibiale au contact au sol	M	98,85%
		F	95,30%
	Rotation interne tibiale lors du chargement	M	99,43%
		F	99,57%

Tableau 3.7 Moyenne par groupe des taux de concordance des catégories évaluées pour les facteurs biomécaniques en fonction de chaque axe

Groupe	Sous- groupe	Sexe	Axe Ab/Ad	Axe FI/Ex	Axe Ri/Re	Moyenne
OA4	G	M	100,00%	100,00%	100,00%	100,00%
		F	100,00%	86,67%	91,67%	93,59%
	D	M	97,62%	100,00%	100,00%	98,90%
		F	96,97%	100,00%	95,45%	97,90%
	G+D	M	98,28%	97,93%	98,28%	98,14%
		F	99,19%	99,51%	98,78%	99,25%
	Tot.	M	98,29%	98,46%	98,72%	98,42%
		F	98,85%	98,28%	97,41%	98,41%
OA3	G	M	100,00%	100,00%	100,00%	100,00%
		F	97,22%	98,33%	100,00%	98,08%
	D	M	98,61%	96,67%	100,00%	98,08%
		F	98,41%	97,14%	100,00%	98,17%
	G+D	M	97,98%	98,18%	100,00%	98,37%
		F	98,72%	96,92%	97,12%	97,78%
	Tot.	M	98,43%	98,11%	100,00%	98,55%
		F	98,43%	97,18%	98,24%	97,92%
OA2	G	M	100,00%	100,00%	100,00%	100,00%
		F	100,00%	100,00%	100,00%	100,00%
	D	M	100,00%	93,33%	100,00%	97,44%
		F	100,00%	88,00%	90,00%	93,85%
	G+D	M	98,98%	97,55%	98,98%	98,43%
		F	99,07%	97,04%	97,22%	98,01%
	Tot.	M	99,06%	97,36%	99,06%	98,40%
		F	99,19%	96,45%	96,77%	97,77%
Total OA		M	98,62%	97,93%	99,31%	98,46%
		F	98,78%	97,27%	97,56%	98,01%
ASYMPT		M	99,43%	97,24%	98,28%	98,41%
		F	99,43%	98,62%	96,55%	98,67%
Total OA + ASYMPT		M	98,75%	97,82%	99,14%	98,45%
		F	98,86%	97,44%	97,44%	98,09%

3.5.1 Discussion sur les taux de concordance de catégories

L'analyse des résultats du tableau 3.6 (p.70) met en évidence des taux de concordance très élevés pour l'ensemble des facteurs biomécaniques évalués, majoritairement compris entre 95 % et 100 %.

Malgré cette forte cohérence entre les méthodes de calcul, certains facteurs présentent une variabilité accrue, notamment l'augmentation du varus lors du chargement (axe d'Ab/Ad), la flexion limitée lors du chargement (axe de Fl/Ex) et la diminution de l'amplitude de mouvement sur cet axe. Ces facteurs sont également associés à des erreurs absolues élevées, particulièrement pour l'augmentation du varus. Cependant, comme le mouvement en varus est lié au valgus, et que ce dernier affiche des taux de concordance plus élevés, il pourrait être judicieux de privilégier l'indicateur en valgus dans les rapports d'analyse.

Globalement, les données du tableau 3.6 (p.70) révèlent peu de différences entre hommes et femmes, bien que les hommes présentent des taux de concordance légèrement supérieurs pour certains facteurs. Une tendance notable chez les femmes est une variabilité accrue pour plusieurs paramètres biomécaniques, confirmée par les données du tableau 3.7 (p.71), qui montrent une légère diminution des taux de concordance chez les femmes, notamment sur l'axe de Fl/Ex dans les groupes OA4 et OA2.

Le tableau 3.7 (p.71) suggère également une homogénéité relative des résultats entre les groupes asymptomatiques et OA. Cependant, une variabilité légèrement plus marquée est observée dans certains sous-groupes féminins du groupe OA2. De plus, les taux de concordance sont plus élevés chez les individus asymétriquement atteints (sous-groupes « G » et « D »), ce qui pourrait refléter une meilleure reproductibilité des mesures dans ces conditions spécifiques, quoique ces sous-groupes sont nettement plus petits et peuvent potentiellement présenter moins de variabilité.

Enfin, bien que les variations restent faibles, l'axe de Fl/Ex présente les taux de concordance les plus bas, bien que toujours très élevés. Cela pourrait indiquer une plus grande sensibilité de cet axe aux différences individuelles.

3.6 Conclusion sur l'utilisation de tous les cycles

L'analyse des écarts absolus et des taux de concordance des facteurs biomécaniques met en évidence une forte cohérence entre les deux méthodes de calcul employées, avec des taux de concordance généralement supérieurs à 95 %. Cette robustesse des résultats valide la fiabilité de la méthode test, malgré certaines variations spécifiques à certains axes ou groupes de participants.

Les écarts absolus augmentent proportionnellement à l'amplitude des mouvements, avec une hiérarchisation claire selon les axes : les plus faibles sur l'axe vertical, intermédiaires sur l'axe transverse et les plus élevés sur l'axe sagittal. Toutefois, le facteur « augmentation du varus lors du chargement » présente une variabilité plus marquée, suggérant que son complémentaire, le valgus, pourrait être un indicateur plus fiable à privilégier.

Les différences entre sexes révèlent une plus grande variabilité des patrons de marche féminins, associée à des erreurs absolues plus élevées. Cette disparité pourrait en partie s'expliquer par une surreprésentation des femmes dans l'échantillon étudié. Par ailleurs, les écarts observés selon le degré d'atteinte arthrosique indiquent une progression de la variabilité avec l'évolution de la pathologie, tandis que les individus asymptomatiques affichent les écarts les plus faibles.

Enfin, bien que certaines variations persistent, notamment sur l'axe de flexion/extension où les taux de concordance sont légèrement plus faibles, les différences entre les méthodes de calcul demeurent minimales et ne compromettent pas la validité des résultats. Ces éléments suggèrent que la méthode test constitue une approche fiable et reproductible pour l'analyse de la marche à l'aide de facteurs biomécaniques.

Ainsi, l'étape de traitement supplémentaire qu'impliquent le découpage et le tri des cycles de marche n'est pas obligatoire pour le calcul des facteurs biomécaniques, puisque les courbes brutes fournissent des informations similaires. De ce fait, il est possible d'utiliser directement les données captées en continu par des centrales inertielles pour faire l'entraînement d'un réseau de neurones.

CHAPITRE 4

Méthodologie de l'objectif principal

L'objectif principal de ce projet de mémoire est de concevoir et d'évaluer l'efficacité d'un algorithme basé sur un réseau de neurones bidirectionnel de type BiLSTM. Cet algorithme vise à estimer avec précision les courbes cinématiques tridimensionnelles dans les axes anatomiques à partir de données issues de centrales inertielles virtuelles. Ces centrales, positionnées de manière simulée sur les membres inférieurs (fémur et tibia), permettent de modéliser les mouvements du genou au cours de la marche.

4.1 Préprocessus sur les données

Les données utilisées dans ce projet proviennent des bases de données MonArthrose et HMR, qui contiennent des fichiers KKG regroupant les informations anonymisées relatives aux participants. Ces fichiers sont organisés en quatre niveaux distincts :

1. **Fichier KKG** : fichier maître répertoriant l'ensemble des consultations disponibles pour un participant donné;
2. **Consultation N** : ensemble des informations relatives à une consultation spécifique, incluant la liste des essais effectués lors de cette visite;
3. **Essai N** : données spécifiques à un essai particulier (p. ex. genou gauche ou droit, courbes d'angles mesurées, cycles valides et rejetés, etc.), ainsi que les paramètres de calibration associés;
4. **Calibration** : informations détaillées obtenues par pointage anatomique lors de la calibration du système pour un essai donné;

Le système KneeKG® utilisé dans ces bases de données ne comprend pas de centrales inertielles, ce qui le rend insuffisant pour l'apprentissage automatique comme envisagé dans ce projet. L'objectif étant de prédire les courbes angulaires triaxiales du genou à partir de données inertielles, une approche alternative était nécessaire. Plutôt que de constituer une nouvelle base de données expérimentale contenant ces informations, une solution plus

pragmatique consiste à simuler ces signaux à l'aide de centrales inertielles virtuelles. Cette méthode permet de générer des données exploitables pour entraîner le modèle BiLSTM tout en conservant une cohérence avec les informations biomécaniques issues du système KneeKG®.

4.1.1 Calcul des vitesses angulaires

Le système KneeKG® étant équipé de deux grappes de capteurs optoélectroniques, l'une alignée avec le fémur et l'autre avec le tibia, les données simulées de centrales inertielles virtuelles sont directement associées à ces emplacements.

L'entreprise Moveck (<https://moveck.com/fr/>) a développé un algorithme permettant de générer des données inertielles simulées à partir des matrices de rotation obtenues via les trajectoires de chaque grappe de capteurs enregistrées dans les fichiers KKG. Le diagramme de calcul détaillant cet algorithme est présenté à l'annexe V (p.137).

Leur script exploite les matrices de rotation aux instants $t - 1$, t et $t + 1$ pour évaluer une dérivée centrale avec précision d'ordre 2. En sortie, les courbes triaxiales des vitesses angulaires de chaque segment sont obtenues. Ces vitesses angulaires sont non filtrées et exprimées dans le repère local du segment auquel elles sont associées. En complément, l'algorithme fournit également les vitesses angulaires et accélérations linéaires de chaque segment, exprimées dans le repère global, aussi appelé « repère du laboratoire ».

Toutefois, comme l'objectif est de simuler des données comparables à celles mesurées par des centrales inertielles, seules les données exprimées dans le repère local de chaque segment sont considérées pertinentes. Ainsi, chaque fichier KKG est désormais lié à un fichier de type « .h5 » contenant les vitesses angulaires exprimées à la fois dans le repère local et global, ainsi que les accélérations linéaires exprimées dans le repère global pour le tibia et le fémur. Ces informations sont classées dans le fichier H5 en fonction de chaque essai identifié dans le fichier KKG.

4.1.2 Mise en forme de la base de données

Afin de simplifier la structure de l'algorithme final, un script Python a été conçu pour traiter les données en trois étapes successives. Son objectif est de générer les fichiers d'entrée ainsi que les fichiers contenant les réponses attendues pour l'apprentissage du réseau de neurones. Ces étapes sont les suivantes :

1. Fusion des données d'entrée avec les données de sortie attendues;
2. Regroupement des bases de données et distinction des essais;
3. Extraction des courbes et génération des fichiers CSV.

4.1.2.1 Fusion des données d'entrée et des sorties attendues

Lors de cette première étape, le script analyse successivement les fichiers KKG et leurs fichiers H5 associés. À partir du fichier KKG, il extrait plusieurs informations clés, notamment :

- le sexe du participant;
- son âge;
- le grade d'arthrose pour chacun de ses genoux;
- les courbes des angles du genou dans les trois plans anatomiques, associées à chaque essai et consultation.

En parallèle, le fichier H5 fournit les courbes de vitesses angulaires évaluées dans le repère local du fémur et du tibia pour chaque essai référencé dans le fichier KKG. Ces informations sont ensuite fusionnées pour chaque participant en respectant la structure présentée à la figure 4.1 (p.78). Enfin, l'ensemble des participants d'une même base de données initiale (MonArthrose ou HMR) est regroupé dans un fichier unique au format HDF5, générant ainsi les fichiers « MonArthrose.hdf5 » et « HMR.hdf5 ».

Étant donné que chaque essai dure 45 secondes et est capté à une fréquence de 60 *Hz*, une courbe devrait en principe comporter $45 \times 60 = 2\,700$ points. Toutefois, des imprécisions dues à la latence humaine lors de l'acquisition des données entraînent de légères variations. Afin d'uniformiser la base de données et simplifier l'algorithme, toutes les courbes sont

tronquées à 2 600 points avant d'être sauvegardées à leur emplacement respectif (*Voir figure 4.1*).

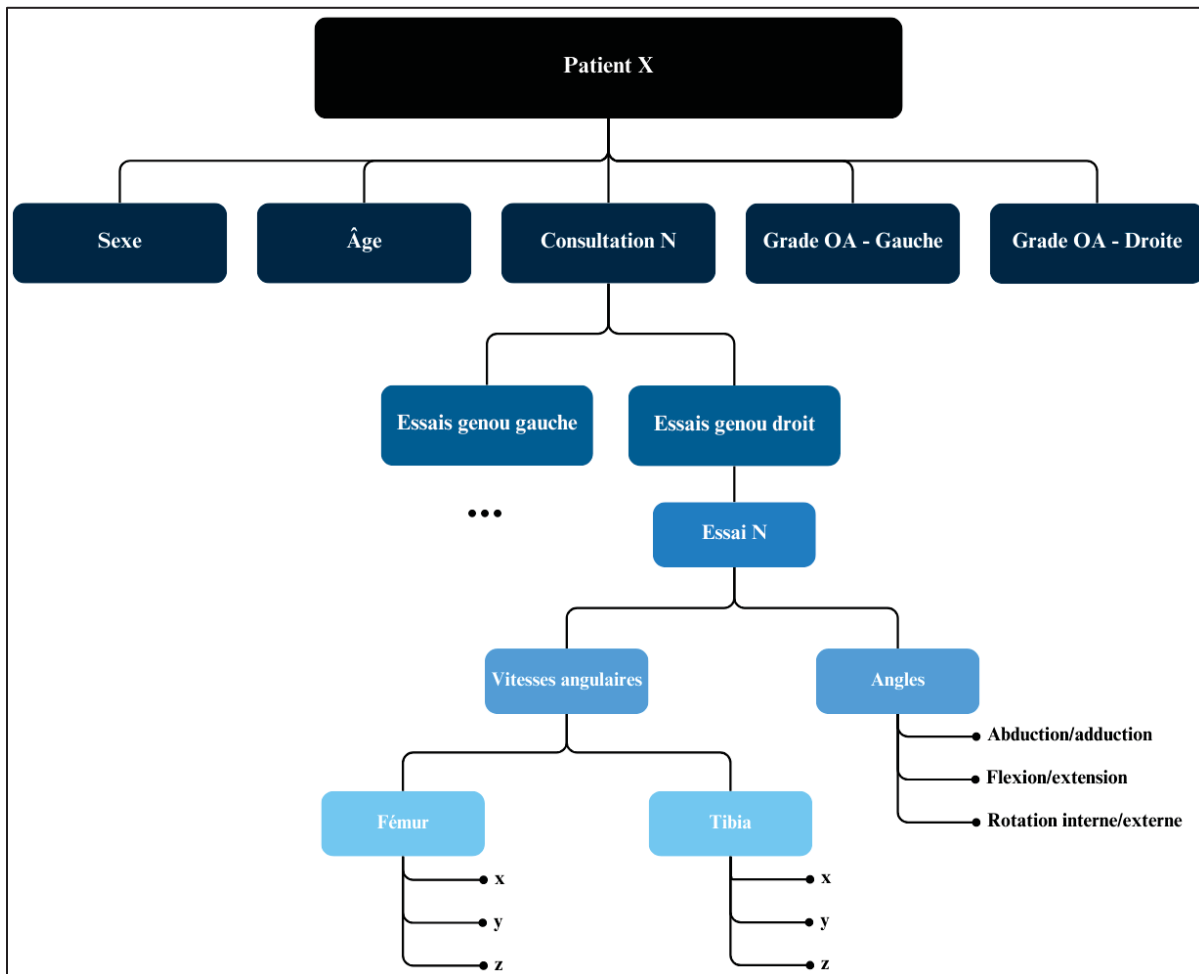


Figure 4.1 Diagramme de la structure du fichier associé à un patient X à la première étape de construction de la base de données combinée

4.1.2.2 Regroupement des bases de données et distinction des essais

La deuxième étape consiste à concaténer les fichiers HDF5 créés précédemment afin de structurer les données de manière plus précise. Après cette fusion, chaque essai est stocké individuellement dans un dossier propre, organisé dans un nouveau fichier HDF5 selon le schéma illustré à la figure 4.2 (p.79). Ce nouveau fichier HDF5 contient un total de 2 555

essais, soient 2 089 provenant de la base de données MonArthrose et 466 provenant de la base de données HMR.

En plus des informations identifiées à l'étape précédente dans le fichier KKG, chaque dossier d'essai contient :

- les courbes d'angles;
- les courbes de vitesses angulaires associées à chaque segment anatomique;
- un identifiant unique attribué au participant;
- un numéro propre à chaque essai.

L'utilité de ces deux derniers points est d'éviter qu'un même participant soit réparti sur plusieurs partitions lors de l'apprentissage par validation croisée, garantissant ainsi une séparation cohérente des données.

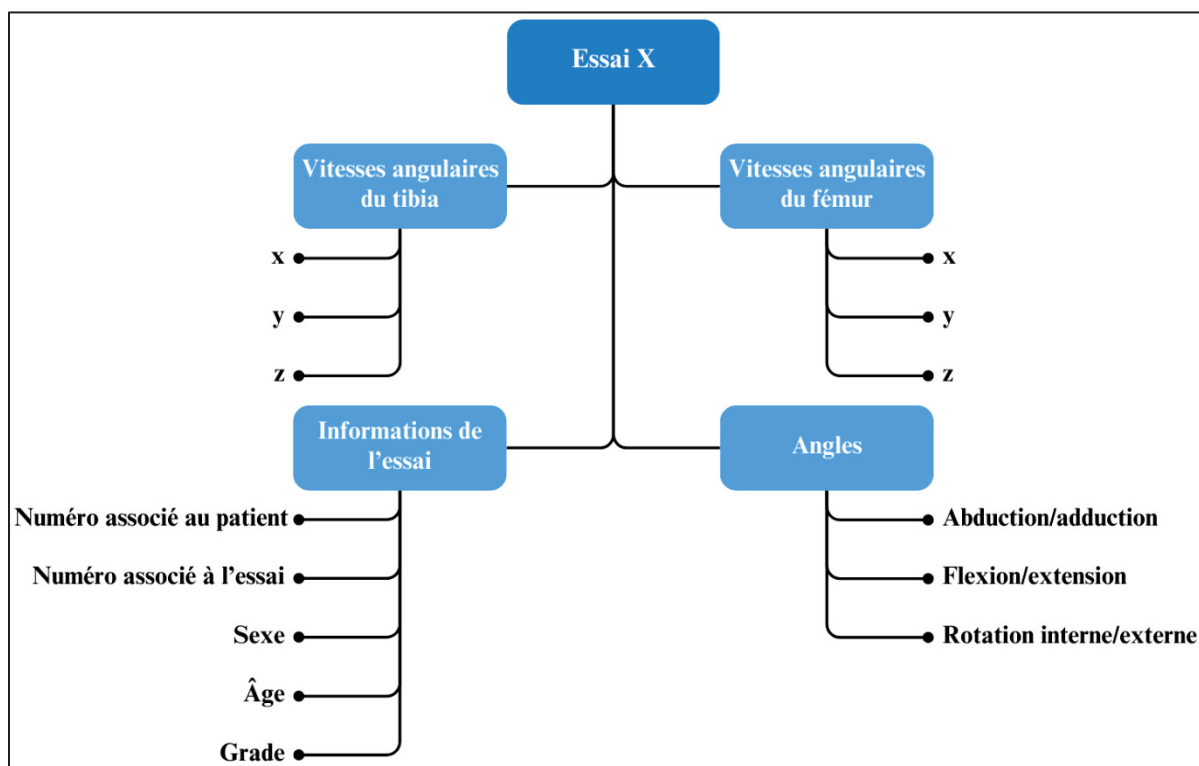


Figure 4.2 Diagramme de la structure du fichier associé à un essai X dans la base de données combinée

4.1.2.3 Extraction des courbes et génération des fichiers CSV

Lors de cette dernière phase de prétraitement, les courbes de tous les essais sont extraites et organisées dans neuf fichiers CSV distincts, respectant l'ordre des essais numérotés. Ainsi, on obtient trois fichiers dédiés aux courbes de vitesses angulaires (par segment, soit un total de six fichiers) et trois fichiers dédiés aux courbes d'angles.

Grâce à cette méthodologie, les données sont prétraitées de manière rigoureuse, assurant leur cohérence et facilitant leur exploitation lors de l'apprentissage du réseau de neurones.

4.2 Apprentissage du réseau de neurones BiLSTM

Une fois les étapes de prétraitement appliquées aux bases de données, des opérations supplémentaires ont été mises en œuvre afin d'optimiser l'architecture du réseau de neurones. Ces étapes incluent l'augmentation du nombre d'échantillons par segmentation ainsi que la mise en place d'un protocole rigoureux d'évaluation des performances.

4.2.1 Augmentation du nombre d'échantillons par segmentation

Pour accroître le volume d'échantillons utilisés lors de l'apprentissage et, parallèlement, réduire la dimensionnalité des vecteurs d'entrée, une segmentation des données a été réalisée à l'aide d'une fenêtre roulante. Cette approche permet de générer des segments de taille fixe en appliquant une superposition de 50 % entre chaque segment successif.

Les segments générés sont systématiquement associés aux informations conservées dans le dossier de l'essai via des matrices de données, garantissant ainsi une organisation cohérente pour la validation croisée. En conséquence, un total de huit matrices a été constitué :

- Trois matrices de format $[nb_{segments} \times taille_{fenêtre} \times 3]$ correspondant aux entrées du réseau (segments des courbes de vitesses angulaires du fémur et du tibia) et aux réponses attendues (segments des courbes d'angles articulaires);

- Cinq matrices de format $[nb_{segments} \times 1]$ contenant les métadonnées associées à chaque segment, à savoir l'identifiant unique du participant, le numéro de l'essai, le sexe, l'âge et le grade d'arthrose du genou évalué.

Après de multiples essais, une fenêtre roulante de 100 images a été retenue pour segmenter les 2 555 essais individuels, générant ainsi un total de 94 452 segments. Cette approche permet d'augmenter significativement le nombre d'échantillons présentés au réseau.

4.2.2 Architecture du réseau de neurones BiLSTM

L'architecture du réseau de neurones adopté repose sur un BiLSTM, conçu pour traiter des séquences temporelles en capturant simultanément les dépendances passées et futures afin d'optimiser la précision des prédictions à l'instant présent. La figure 4.3 (p.82) présente un schéma bloc de l'architecture finale du RNA, offrant une représentation visuelle de son fonctionnement interne.

L'entrée du modèle est constituée d'une séquence temporelle représentée sous forme matricielle de dimensions (100,6). Le premier paramètre, fixé à 100, correspond à la taille de la fenêtre roulante temporelle utilisée afin de segmenter le signal. Le second paramètre, égal à 6, indique le nombre de caractéristiques par échantillon, correspondant aux vecteurs tridimensionnels de vitesses angulaires mesurées pour chacune des deux centrales inertielles virtuelles (fémur et tibia).

Le cœur du réseau repose sur une couche BiLSTM, composée de deux couches LSTM bidirectionnelles de 150 unités chacune. La première couche renvoie une séquence complète, préservant ainsi l'organisation temporelle des données afin de garantir une transmission optimale aux couches subséquentes et une préservation de la structure temporelle. La seconde couche affine l'extraction des dépendances temporelles en exploitant les représentations apprises par la première couche. Les sorties des unités LSTM sont ensuite concaténées afin de produire une sortie enrichie au niveau de l'unité BiLSTM, permettant ainsi d'intégrer des

informations temporelles bidirectionnelles. Comme mentionné précédemment, cette approche est particulièrement pertinente pour des applications impliquant des séquences temporelles complexes, telles que l'analyse cinématique de la marche, où la cohérence entre passé, présent et futur joue un rôle fondamental.

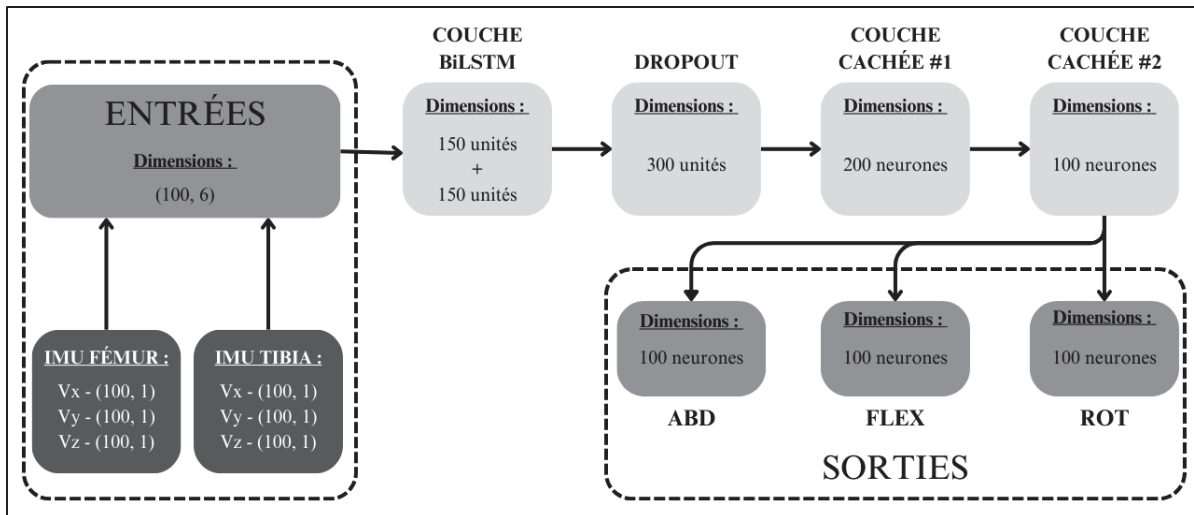


Figure 4.3 Diagramme bloc de l'architecture du réseau BiLSTM final

Afin d'améliorer la généralisation du réseau et de réduire le risque de surapprentissage, une couche de *dropout*²⁵ avec un taux de 0,5 est appliquée à la sortie de la couche BiLSTM. L'objectif est de minimiser l'impact du bruit et des dérives inhérentes aux données issues des centrales inertielles sur la qualité des prédictions du réseau. Dans un réseau profond, le surapprentissage peut se manifester par une trop forte dépendance aux données d'entraînement, au détriment de la capacité à généraliser sur de nouvelles observations. La couche de *dropout* pallie ce problème en désactivant aléatoirement 50 % des neurones de sortie à chaque itération d'entraînement, empêchant ainsi une interdépendance excessive des poids synaptiques et favorisant une meilleure robustesse du modèle.

²⁵ Abandon d'informations [traduction libre]

Les couches suivantes sont deux couches denses temporellement distribuées²⁶, comprenant respectivement 200 et 100 neurones. Ces couches, en appliquant des transformations non linéaires à chaque pas temporel, participent à l'apprentissage de représentations plus abstraites des données. La première couche assure une transformation intermédiaire et introduit une non-linéarité essentielle à la modélisation des relations complexes entre les caractéristiques extraites. La seconde couche affine ces représentations en approfondissant l'interaction entre les différents neurones. Chaque neurone d'une couche dense étant connecté à tous les neurones des couches adjacentes, l'apprentissage repose sur l'ajustement itératif des poids synaptiques selon la somme pondérée des activations précédentes. La fonction d'activation employée dans les couches cachées de ce réseau est la tangente hyperbolique (*tanh*), qui confère une meilleure capacité à capturer des variations subtiles en sortie. L'optimisation des poids est réalisée par rétropropagation en minimisant une fonction de perte d'erreur quadratique moyenne²⁷ (MSE), qui est une fonction de perte adaptée aux problèmes de régression.

En sortie du réseau, trois couches denses temporellement distribuées sont dédiées à l'estimation des trois axes de rotation du genou. Chaque séquence de sortie comprend 100 instants temporels, correspondant aux prédictions effectuées à chaque instant des séquences d'entrées. Contrairement aux couches cachées, ces couches de sortie utilisent une fonction d'activation linéaire, permettant de générer des prédictions continues, essentielles pour une tâche de régression. Cette structure permet d'obtenir des estimations distinctes pour chaque plan anatomique, tout en réduisant l'impact des erreurs sur l'axe sagittal par rapport aux axes de moindres amplitudes, optimisant ainsi la précision globale du modèle dans l'analyse cinématique de la marche.

²⁶ *Time distributed* [traduction libre]

²⁷ *Mean Squared Error* [traduction de l'OQLF]

4.2.3 Protocole d'évaluation des performances

Pour garantir une évaluation rigoureuse des performances du modèle, plusieurs stratégies complémentaires ont été mises en place. D'une part, une validation croisée a été employée afin d'assurer une estimation fiable de la généralisation du modèle. D'autre part, des mesures de performance soigneusement sélectionnées ont permis une comparaison pertinente avec les résultats de la littérature. Par ailleurs, une attention particulière a été portée au choix des hyperparamètres, afin d'affiner les performances du modèle et d'en maximiser la robustesse.

4.2.3.1 Validation croisée en 5 partitions

Étant donné la grande variabilité des patrons de marche, une validation croisée en k partitions a été utilisée. Conformément aux standards de la littérature, une valeur de $k = 5$ a été retenue.

Une attention particulière a été portée à la structuration des partitions pour éviter toute contamination des données entre les ensembles d'entraînement et de test. En effet, les informations d'identification des participants sont conservées, grâce à la segmentation préalablement effectuée, dans une matrice dédiée, garantissant que l'ensemble des essais relatifs à un même individu ne se retrouvent jamais simultanément dans les deux ensembles.

Le tableau 4.1 (p.85) résume la distribution des échantillons et des patients uniques après partitionnement. Des détails supplémentaires concernant ces distributions à l'intérieur de chaque partition sont fournis en annexe VI (p.139).

Tableau 4.1 Distribution des quantités d'échantillons et des quantités de patients uniques dans les bases de données d'entraînement et de test pour chaque partition

Partition	Nombre d'échantillons		Nombre de patients uniques	
	Entraînement	Test	Entraînement	Test
1	75 582	18 870	517	132
2	75 531	18 921	522	127
3	75 582	18 870	520	129
4	75 531	18 921	520	129
5	75 582	18 870	517	132
Total	94 452		649	

L'équilibre des proportions d'échantillons et de patients uniques a été maintenu dans chaque partition en fonction des différents grades d'arthrose. La figure 4.4 illustre la répartition des échantillons avant partitionnement, tandis que la figure 4.5 (p.86) présente la répartition des patients uniques selon leur grade d'arthrose. Les tableaux-A VI-1, VI-2, VI-3, VI-4 et VI-5 (pp.139-141) présentés à l'annexe VI détaillent la répartition des échantillons et des patients uniques pour chaque partition.




Figure 4.4 Nombre d'échantillons en fonction du grade d'arthrose du genou évalué




Figure 4.5 Nombre de patients uniques en fonction du grade d'arthrose du genou évalué

Enfin, il convient de rappeler qu'un même participant peut présenter des grades d'arthrose différents pour chacun de ses genoux. Par conséquent, les essais correspondant à chaque genou sont classés dans des catégories distinctes. Toutefois, l'ensemble des essais d'un même participant est toujours maintenu au sein d'une unique partition afin de préserver la cohérence de la validation croisée.

4.2.3.2 Mesures de performances

Dans le premier chapitre de ce mémoire, le tableau 1.4 (p.41) présente une synthèse des mesures de performance employées dans plusieurs études pertinentes. Ces études ont été sélectionnées en raison de leur objectif commun avec celui du présent travail : estimer les angles du genou durant la marche à partir de données issues de centrales inertielles, en utilisant un réseau de neurones de type LSTM ou BiLSTM.

Afin d'assurer une comparaison pertinente avec les résultats rapportés dans la littérature, deux métriques ont été retenues : la RMSE et la nRMSE. Bien que la nRMSE offre une analyse comparative plus robuste en tenant compte de l'amplitude des données observées (Miller et al., 2024), son utilisation demeure marginale dans les études existantes. De plus, cette métrique

est particulièrement sensible à la méthodologie employée pour son calcul, ce qui peut engendrer des variations notables dans les résultats. L'absence de standardisation dans son application compromet ainsi la pertinence des comparaisons inter-études.

Compte tenu de ces limites, nous avons choisi de privilégier la RMSE comme indicateur principal de performance, tout en conservant la nRMSE par curiosité. Il est toutefois essentiel de souligner que la méthodologie de calcul de ces deux métriques est rarement détaillée dans la littérature, bien que celle-ci n'influence habituellement pas autant les résultats de RMSE obtenus que ceux de nRMSE. Malgré tout, cette absence de transparence constitue un frein à l'établissement de comparaisons rigoureuses entre les différentes études et souligne la nécessité d'une harmonisation des pratiques méthodologiques.

Lors de l'apprentissage d'un RNA, il est fortement recommandé de normaliser les données d'entrée entre 0 et 1 ou entre -1 et 1. Cette mise à l'échelle facilite l'optimisation des poids durant l'entraînement et limite les problèmes liés aux estimations finales du modèle. Ainsi, dans notre approche, les entrées (X) et les réponses attendues (Y) du modèle sont normalisées avant chaque phase d'entraînement selon les étapes suivantes :

1. Segmentation des données en ensembles d'entraînement et de test : $X_{\text{entraînement}}$, X_{test} , $Y_{\text{entraînement}}$ et Y_{test} ;
2. Aplatissement (*flatten*) complet de l'ensemble $X_{\text{entraînement}}$ et en fonction de chaque angle pour l'ensemble $Y_{\text{entraînement}}$ afin de préparer les fonctions de transformation pour les mises à l'échelle (*scaling*);
3. Initialisation des transformateurs *MinMaxScaler* avec une plage de valeurs comprise entre -1 et 1 ;
4. Adaptation des transformateurs sur les données d'entraînement aplaties à l'aide de la fonction *fit*, pour obtenir les transformateurs $scaler_x$, $scaler_{y_0}$, $scaler_{y_1}$ et $scaler_{y_2}$;
5. Transformation des ensembles d'entraînement et de test à l'aide des transformateurs adaptés afin de produire les ensembles $X_{\text{entraînement}_{\text{normalisé}}}$, $X_{\text{test}_{\text{normalisé}}}$, $Y_{\text{entraînement}_{\text{normalisé}}}$ et $Y_{\text{test}_{\text{normalisé}}}$.

Toutefois, les valeurs de RMSE calculées sur des données normalisées ne reflètent pas directement l'erreur absolue en unités physiques. Pour pallier ce problème, il convient d'ignorer les valeurs produites par la fonction d'évaluation du modèle et d'appliquer les étapes correctives suivantes :

1. Entraîner le réseau sur les ensembles normalisés $X_{\text{entraînement}_{\text{normalisé}}}$ et $Y_{\text{entraînement}_{\text{normalisé}}}$;
2. Obtenir les prédictions $Y_{\text{prédictions}_{\text{normalisé}}}$ du modèle sur $X_{\text{test}_{\text{normalisé}}}$;
3. Remodeler les ensembles $Y_{\text{test}_{\text{normalisé}}}$ et $Y_{\text{prédictions}_{\text{normalisé}}}$ à l'aide de la fonction *reshape* pour préparer la transformation inverse;
4. Appliquer la transformation inverse aux ensembles remodelés afin de récupérer les ensembles à l'échelle initiale $Y_{\text{prédictions}_{\text{inverse}_i}}$ et $Y_{\text{test}_{\text{inverse}_i}}$, pour $i \in [0,2]$;
5. Restaurer les ensembles inversés sous forme de séquences exploitables pour le calcul final de la RMSE.

Une fois ces corrections appliquées, il devient possible d'évaluer correctement la RMSE dans son unité d'origine, c'est-à-dire sans normalisation. Par la suite, la nRMSE est calculée individuellement pour chaque sortie et chaque échantillon, plutôt que sur l'ensemble d'un essai. Enfin, les valeurs moyennes de RMSE et de nRMSE sont estimées sur l'ensemble des échantillons pour chaque angle, permettant ainsi une comparaison pertinente des performances entre les différentes partitions du modèle.

4.2.3.3 Choix des hyperparamètres

Les hyperparamètres jouent un rôle déterminant dans la qualité des prédictions d'un réseau de neurones. L'optimisation d'un réseau est intrinsèquement liée au choix judicieux de ces hyperparamètres, influençant directement la performance du modèle en termes de précision et de généralisation. Toutefois, toute procédure d'optimisation des hyperparamètres implique une consommation importante de ressources computationnelles et un allongement du temps de calcul.

Dans le cadre de cette étude, l'entraînement du réseau a été réalisé sur un ordinateur personnel équipé d'un processeur (CPU - AMD Ryzen 7 5825U avec graphiques Radeon, 2000 MHz, 8 cœurs, 16 processeurs logiques) et de 16 Go de mémoire vive. Cette configuration matérielle s'est avérée insuffisante pour permettre une optimisation exhaustive des hyperparamètres, tout en maintenant l'accessibilité à l'ordinateur pour d'autres tâches. Par conséquent, une sélection manuelle a été effectuée en testant diverses configurations afin de retenir celle produisant les meilleurs résultats. Cette approche, bien que pragmatique, présente des limitations : de nombreuses configurations n'ont pas pu être explorées et pourraient potentiellement améliorer davantage la performance du modèle. En guise d'exemple, les résultats du modèle présenté dans l'article retrouvé à l'appendice A (p.155) correspondent à ceux d'une des configurations testées.

Les valeurs testées pour chaque hyperparamètre sont répertoriées dans le tableau 4.2 (p.90), où les valeurs finalement retenues sont mises en évidence en caractères gras. Il est à noter que la majorité des valeurs évaluées proviennent de la littérature scientifique, garantissant ainsi une sélection fondée sur des références empiriques solides. Ces valeurs sont retrouvées à l'annexe VII dans le tableau-A VII-1 (p.143) et le tableau-A VII-2 (p.144).

L'entraînement du modèle repose sur la mise à jour des poids après traitement simultané d'un lot de 32 échantillons. Cette taille de lot représente un compromis optimal entre efficacité de calcul et stabilité de l'apprentissage. Le réseau a été entraîné sur un total de 200 époques complètes du jeu de données, permettant d'assurer une assimilation adéquate des structures temporelles complexes. En fonction de la partition des données, et en prenant en compte la taille du lot et celle de l'ensemble d'apprentissage, une époque complète requiert entre 2 360 et 2 362 itérations avant d'être complétée.

Le taux d'apprentissage est un paramètre clé qui contrôle la vitesse d'ajustement des poids synaptiques du réseau durant l'entraînement. Un taux trop élevé risque d'entraîner une convergence prématurée vers un minimum sous-optimal, tandis qu'un taux trop faible peut ralentir considérablement l'apprentissage et conduire à un état de stagnation. Afin de trouver

un équilibre entre stabilité et rapidité de convergence, le taux d'apprentissage a été fixé à 0,001. Cette valeur permet d'assurer une progression efficace vers un minimum local ou global, évitant ainsi les risques d'instabilité ou de stagnation excessive.

Les justifications détaillées des choix effectués pour chacun des autres hyperparamètres sont présentées dans la sous-section 4.2.2, dédiée à la description de l'architecture du réseau BiLSTM (p. 81).

Tableau 4.2 Liste des valeurs testées pour chaque hyperparamètre du réseau

Hyperparamètre	Valeurs testées
Taille de la fenêtre roulante	17 – 20 – 51 – 100 – 153
Dimension de la couche BiLSTM	200 – 150
Valeur de dropout	0,3 – 0,5 – 0,7
Dimension de la 1 ^{re} couche cachée	128 – 150 – 200
Dimension de la 2 ^e couche cachée	64 – 100
Taille de lot	30 – 32 – 40 – 50 – 100 – 200
Nombre d'époques d'entraînement	20 – 50 – 100 – 150 – 200
Fonction de perte	<i>MAE</i> ²⁸ – <i>MSE</i>
Taux d'apprentissage	0,0001 – 0,0003 – 0,001

²⁸ *Mean Absolute Error* (Erreur absolue moyenne [traduction libre basée sur celle de l'OQLF])

CHAPITRE 5

Résultats

5.1 Résultats de l'apprentissage du réseau

Le tableau 5.1 présente le temps requis pour l'entraînement de chaque pas, époque et partition du réseau de neurones final. Il est essentiel de noter que ces valeurs peuvent fluctuer de manière significative en fonction des différentes configurations des hyperparamètres testés, ce qui souligne l'importance d'une sélection appropriée pour optimiser les performances du modèle.

Tableau 5.1 Sommaire de la complexité et du temps de calcul du RNA final

Complexité (nombre de paramètres entraîables)	840 200
Temps/pas	Environ 30 <i>millisecondes</i>
Temps/époque	Environ 70 <i>secondes</i>
Temps/partition	Environ 233 <i>minutes</i>

Lors du processus d'apprentissage du réseau de neurones, la fonction de perte retenue, à savoir la MSE, était calculée à la fin de chaque époque afin d'évaluer la performance du modèle. De plus, la RMSE était également déterminée au même moment. Ces deux métriques étaient d'abord évaluées sur l'ensemble des données d'entraînement normalisées de la partition en cours, l'objectif étant de minimiser ces valeurs pour améliorer l'apprentissage du réseau. Ainsi, le modèle ajustait dynamiquement ses poids en réponse aux résultats obtenus.

Parallèlement, ces mêmes indicateurs de performance étaient évalués sur un ensemble de validation indépendant de l'ensemble d'entraînement, mais également normalisé. Cette évaluation avait pour but de vérifier la capacité de généralisation du réseau et d'éviter un sur-apprentissage. À l'issue de chaque partition, deux graphiques étaient générés, représentant respectivement l'évolution des valeurs moyennes de MSE et de RMSE en fonction du nombre d'époques pour les ensembles d'entraînement et de validation. Étant donné la similitude des

tendances observées sur ces graphiques, seul le graphique de la courbe de MSE correspondant à la première partition est présenté dans la figure 5.1. L'annexe VIII (p.147) rassemble l'intégralité des graphiques pour chacune des partitions :

- Partition 1 : Voir figure-A VIII-1 (p.147);
- Partition 2 : Voir figure-A VIII-2 (p.148);
- Partition 3 : Voir figure-A VIII-3 (p.149);
- Partition 4 : Voir figure-A VIII-4 (p.150);
- Partition 5 : Voir figure-A VIII-5 (p.151).

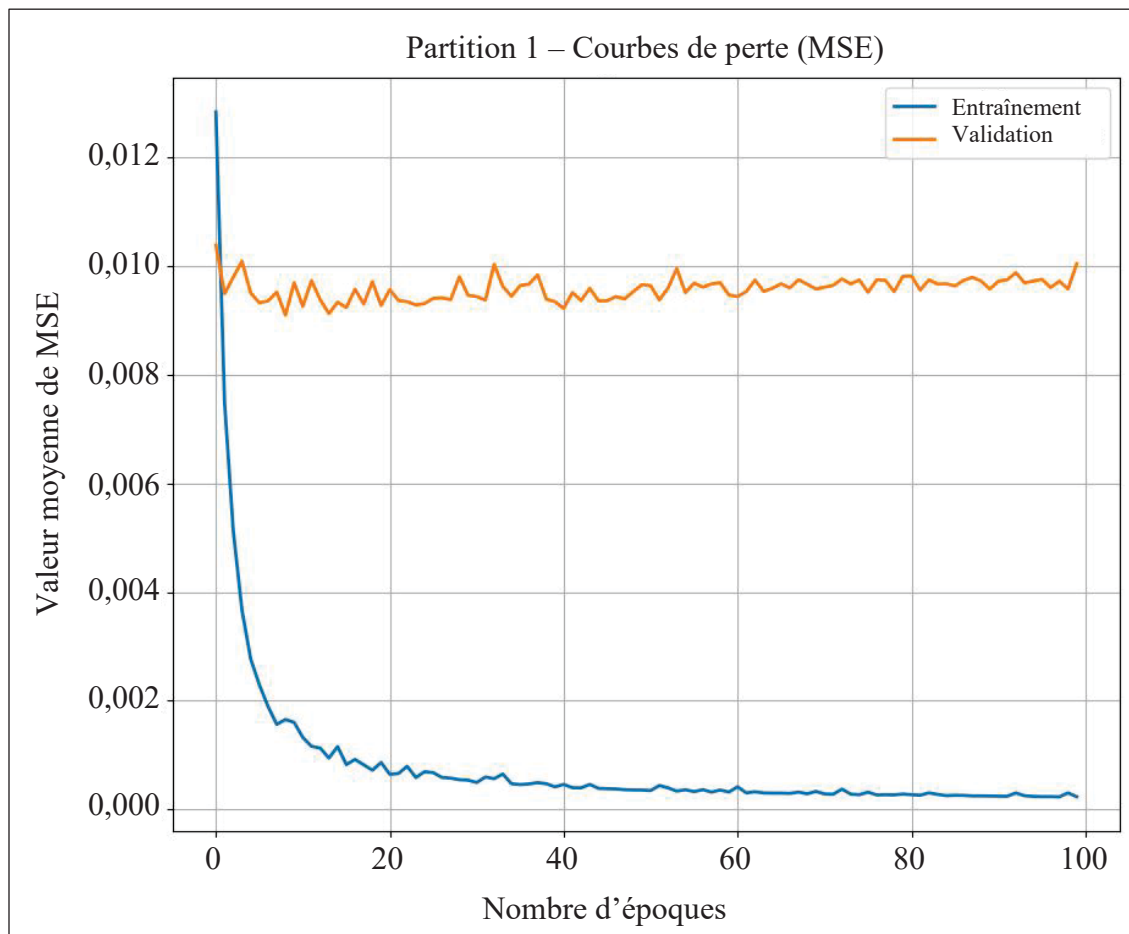


Figure 5.1 Courbes de la fonction de perte (MSE) pour la partition 1

5.2 Résultats des métriques et des prédictions sur la base de test

À l'issue de l'entraînement de chaque partition, les RMSE et les nRMSE ont été calculées sur les données de test dénormalisées, conformément à la méthodologie décrite dans le chapitre précédent. Pour chaque partition, la moyenne de ces métriques de performance a été déterminée sur l'ensemble des couches de sortie, permettant ainsi d'obtenir une valeur globale représentative des performances du modèle.

Afin d'affiner l'analyse et de mieux caractériser la distribution des erreurs, la médiane ainsi que l'écart-type des valeurs de RMSE et nRMSE ont également été calculés pour l'ensemble des échantillons de test, et ce, pour chaque couche de sortie de chaque partition. De plus, afin de limiter l'influence des valeurs aberrantes susceptibles de biaiser les estimations, une moyenne ajustée a été introduite. Cette dernière a été obtenue en excluant les valeurs situées à plus d'un écart-type au-dessus de la moyenne initiale, garantissant ainsi une mesure plus robuste des performances du réseau.

Les résultats synthétisés de ces analyses sont présentés dans le tableau 5.2 (p.94). Ce tableau regroupe les moyennes des métriques de performance obtenues sur l'ensemble des partitions utilisées lors de l'entraînement. Afin de faciliter l'interprétation des résultats, les valeurs mises en évidence par une trame de fond rouge correspondent aux estimations effectuées selon la méthodologie standard décrite précédemment, tandis que celles sur fond vert correspondent aux valeurs recalculées en excluant les données extrêmes.

Une analyse plus détaillée des performances du réseau en fonction des partitions est disponible dans le tableau-A IX-1 (p.153), de l'annexe IX. Cette analyse comparative permet d'évaluer la stabilité du modèle selon les différentes partitions et d'identifier d'éventuelles variations de performance en fonction des axes de mouvement étudiés.

Tableau 5.2 Résultats des mesures de performance du réseau en fonction de chaque couche de sortie

Métrique		Ab/Ad	Fl/Ex	Ri/Re	Total
RMSE (°)	Médiane	2,989 ± 0,120	1,993 ± 0,213	2,523 ± 0,132	2,502 ± 0,155
	Moyenne	3,534 ± 0,143	2,471 ± 0,383	2,930 ± 0,142	2,978 ± 0,118
	Écart-type	2,241 ± 0,140	2,236 ± 1,596	1,794 ± 0,194	2,090 ± 0,525
	Moy. ajustée	2,839 ± 0,114	1,988 ± 0,349	2,409 ± 0,105	2,412 ± 0,109
nRMSE (%)	Médiane	30,82 ± 1,22	3,59 ± 0,38	19,86 ± 0,79	18,09 ± 0,80
	Moyenne	39,28 ± 2,41	4,69 ± 0,93	24,12 ± 1,04	22,70 ± 1,16
	Écart-type	30,05 ± 4,44	5,23 ± 4,60	16,19 ± 0,61	17,16 ± 2,48
	Moy. ajustée	30,41 ± 1,69	3,68 ± 0,68	19,40 ± 0,64	17,83 ± 0,72

Par ailleurs, pour chaque partition, un échantillon de 100 observations a été sélectionné aléatoirement dans la base de test afin d'examiner la concordance entre les courbes prédites et les courbes attendues sur les différents axes de rotation. Ces comparaisons ont été représentées graphiquement afin d'illustrer la précision et la fiabilité des prédictions du modèle. La figure 5.2 (p.95) illustre ces comparaisons à travers trois échantillons distincts, soit les échantillons 18 089, 15 035 et 17 856, issues des bases de test de diverses partitions. Les courbes tracées en bleu correspondent aux courbes attendues, alors que celles tracées en orange représentent les courbes prédites.

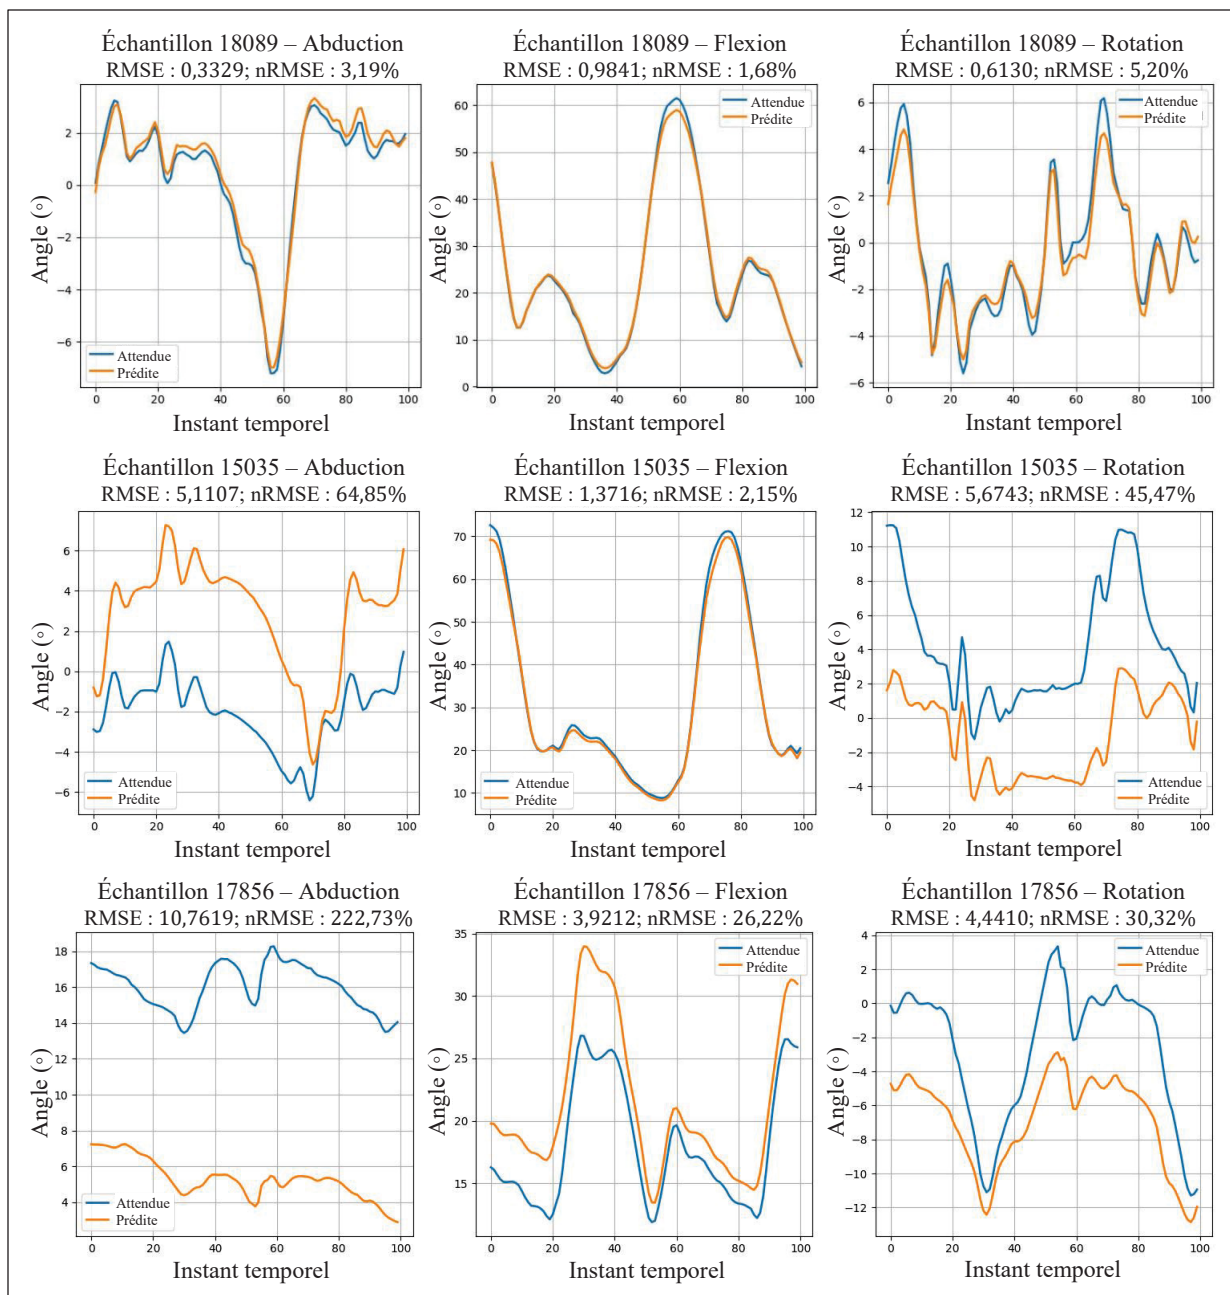


Figure 5.2 Graphiques des courbes prédites et attendues de chaque axe de rotation pour trois échantillons de la base de test

CHAPITRE 6

Discussion

6.1 Interprétation des résultats du protocole d'évaluation des performances du réseau

L'évaluation des performances du réseau BiLSTM repose sur une double approche complémentaire. D'une part, elle implique une analyse comparative des métriques obtenues sur la base de test, en les confrontant aux références issues de la littérature. D'autre part, elle consiste à examiner les divergences entre les courbes prédites et celles attendues. Cette stratégie permet d'appréhender avec précision les points forts et les limites du modèle dans la prédiction des mouvements articulaires.

6.1.1 Observations sur les métriques évaluées sur la base de test

L'évaluation des performances du modèle repose sur l'analyse des métriques d'erreur appliquées aux trois axes de mouvement étudiés : Ab/Ad, Fl/Ex et Ri/Re. Cette démarche vise à examiner les variations de performance en fonction des spécificités dynamiques propres à chaque mouvement.

Les résultats présentés dans le tableau-A IX-1 (p.153) indiquent que les médianes des erreurs sont systématiquement inférieures aux moyennes, suggérant la présence de valeurs extrêmes significativement supérieures à la moyenne. Afin de réduire l'impact de ces valeurs aberrantes, une moyenne ajustée a été calculée en excluant les points situés à plus d'un écart-type au-dessus de la moyenne. Afin d'assurer une interprétation transparente des résultats, les moyennes brutes et ajustées sont systématiquement rapportées dans les analyses suivantes. Le tableau 6.1 (p.100) et le tableau 6.2 (p.101) fournissent, respectivement, une comparaison de ces résultats avec les valeurs de RMSE et nRMSE issues de la littérature.

L'axe d'Ab/Ad présente les performances les plus faibles parmi les trois axes étudiés. Notre modèle affiche une RMSE brute de $3,534 \pm 0,143^\circ$ et ajustée de $2,839 \pm 0,114^\circ$, tandis que les valeurs rapportées dans la littérature pour cet axe sont légèrement meilleures, variant principalement entre $1,2^\circ$ et $2,18^\circ$. En ce qui concerne la nRMSE, notre modèle atteint une valeur brute de $39,28 \pm 2,41 \%$ et ajustée de $30,41 \pm 1,69 \%$, correspondant à des prédictions nettement moins précises que celles obtenues par Sharifi-Renani et al. (2021), comprise entre $6,6 \%$ et $15,2 \%$. Toutefois, comme mentionné au premier chapitre de ce mémoire, la comparaison des nRMSE doit être interprétée avec prudence, puisque divers facteurs peuvent faire varier les résultats d'autant plus que les valeurs de nRMSE ne sont pas systématiquement rapportées dans toutes les études.

Étant donné que l'amplitude de mouvement de l'axe d'Ab/Ad avoisine les 10° durant la marche, ces résultats de RMSE et de nRMSE témoignent d'une difficulté marquée à modéliser précisément ce mouvement, aussi bien pour notre réseau que pour ceux décrits dans la littérature. Cette performance moindre peut s'expliquer par la complexité biomécanique de l'abduction/adduction, qui présente une forte variabilité interindividuelle et est influencée par des mécanismes compensatoires musculaires modifiant la trajectoire articulaire, rendant ainsi la prédiction plus difficile.

L'axe de Fl/Ex est globalement le mieux prédit par tous les modèles. Pour notre réseau, la RMSE brute est de $2,471 \pm 0,383^\circ$, correspondant à une nRMSE de $4,69 \pm 0,93 \%$. Après ajustement, la RMSE atteint $1,988 \pm 0,349^\circ$ et la nRMSE $3,68 \pm 0,68 \%$. Ces performances ajustées surpassent celles obtenues par certaines études utilisant un plus grand nombre de centrales inertielle. Par exemple, Mundt, Koeppe, Bamer et al. (2020) rapportent une RMSE de $1,98 \pm 0,51^\circ$ en utilisant trois IMUs, tandis que Sharifi-Renani et al. (2021) obtiennent une RMSE de $2,1 \pm 0,6^\circ$ avec quatre IMUs virtuels et de $2,9 \pm 1,1^\circ$ avec quatre IMUs réels. Le modèle de Rapp et al. (2021) est celui qui présente les meilleurs résultats sur cet axe, avec une RMSE de $0,97 \pm 0,38^\circ$, mais en faisant l'usage de sept IMUs, augmentant ainsi considérablement le coût du système. En effet, au prix d'environ 2 000 \$ CAD par centrale inertielle, leur système est aussi dispendieux qu'un système optoélectronique, sans présenter

d'avantages significatifs. Il importe justement de souligner que peu d'études s'intéressent à l'utilisation d'un nombre limité d'IMUs, démarquant ainsi les résultats de notre modèle ainsi que son apport à la littérature.

Dans notre modèle, l'axe de Fl/Ex présente des écarts-types plus élevés que les autres axes. Cette variabilité supérieure pourrait s'expliquer par la plus grande amplitude de mouvement par rapport aux autres ($\sim 65^\circ$ en phase de marche), ainsi que par l'hétérogénéité des amplitudes dans l'ensemble des données. De plus, certaines partitions incluent des cas extrêmes de flexion, introduisant ainsi une incertitude accrue dans la prédiction.

Bien que les performances de notre modèle sur l'axe de Ri/Re se situent entre celles des deux autres axes, c'est cet axe qui se distingue le plus. Dans la littérature, cet axe est généralement le plus difficile à estimer, avec des RMSE variant entre $2,48^\circ$ et $7,0^\circ$. Cependant, notre modèle présente une meilleure précision sur cet axe, avec une RMSE brute de $2,930 \pm 0,142^\circ$ et ajustée de $2,409 \pm 0,105^\circ$, correspondant à des nRMSE de $24,12 \pm 1,04 \%$ et $19,40 \pm 0,64 \%$. Ces résultats ajustés de notre modèle n'utilisant que deux IMUs surpassent ceux retrouvés dans la littérature, potentiellement en raison d'une base de données plus vaste ou d'une approche architecturale du réseau limitant l'impact des erreurs de l'axe de Fl/Ex sur les autres axes.

Bien que la précision des prédictions sur l'axe de Ri/Re puisse être influencée par des différences interindividuelles dans la posture initiale des participants, l'amplitude de mouvement environ deux fois plus grande que celle de l'axe d'Ab/Ad semble atténuer l'impact des erreurs relatives, contribuant ainsi à une réduction des écarts d'erreur observés.

Tableau 6.1 Comparaison des valeurs de RMSE de notre modèle par rapport à celles retrouvées dans la littérature

Référence	Nombre d'IMUs (Position)	RMSE \pm ET (°)			
		Fl/Ex	Ab/Ad	Ri/Re	Moyenne
Notre modèle	2 (C, T)	2,471 $\pm 0,383$	3,534 $\pm 0,143$	2,930 $\pm 0,142$	2,978 $\pm 0,118$
Notre modèle (Moy. ajustée)	2 (C, T)	1,988 $\pm 0,349$	2,839 $\pm 0,114$	2,409 $\pm 0,105$	2,412 $\pm 0,109$
Mundt et al. (2019)	/	1,92	1,92	3,73	2,15 \pm 0,08
Mundt, Koeppe, Bamer, et al. (2020)	5 (B, 2C, 2T)	1,77 \pm 0,38	1,58 \pm 0,66	2,62 \pm 1,06	/
	3 (B, 2C)	1,98 \pm 0,51	1,77 \pm 0,82	2,85 \pm 1,25	/
	3 (B, 2T)	1,69 \pm 0,44	1,54 \pm 0,72	2,48 \pm 1,09	/
	1 (B)	2,97 \pm 0,55	2,18 \pm 0,85	3,36 \pm 1,27	/
Conte Alcaraz et al. (2021)	1 (P)	2,87	/	/	/
Liang et al. (2021)	1 (C)	3,89	/	/	/
Rapp et al. (2021)	7 (B, 2C, 2T, 2P)	0,97 \pm 0,38	2,16 \pm 0,85	2,75 \pm 0,66	/

Référence	Nombre d'IMUs (Position)	RMSE \pm ET (°)			
		Fl/Ex	Ab/Ad	Ri/Re	Moyenne
Sharifi-Renani et al. (2021)	4 V (B, C, T, P)	2,1 \pm 0,6	2,0 \pm 0,6	6,4 \pm 2,8	2,9 \pm 0,7
	4 R (B, C, T, P)	2,9 \pm 1,1	2,0 \pm 0,8	7,0 \pm 1,8	3,3 \pm 0,2
	4 R + V (B, C, T, P)	1,4 \pm 0,5	1,2 \pm 0,4	3,8 \pm 1,6	1,7 \pm 0,4

Abréviations : ET : Écart-type, B : Bassin, C : Cuisse, T : Tibia, P : Pied, V : Virtuel, R : Réel

Tableau 6.2 Comparaison des valeurs de nRMSE de notre modèle par rapport à celles retrouvées dans la littérature

Référence	Nombre d'IMUs (Position)	nRMSE \pm ET (%)			
		Fl/Ex	Ab/Ad	Ri/Re	Moyenne
Notre modèle	2 (C, T)	4,69 \pm 0,93	39,28 \pm 2,41	24,12 \pm 1,04	22,70 \pm 1,16
Notre modèle (Moy. ajustée)	2 (C, T)	3,68 \pm 0,68	30,41 \pm 1,69	19,40 \pm 0,64	17,83 \pm 0,72
Sharifi-Renani et al. (2021)	4 V (B, C, T, P)	2,9 \pm 0,8	15,1 \pm 4,5	24,0 \pm 11,3	14,0 \pm 5,5
	4 R (B, C, T, P)	3,9 \pm 1,6	15,2 \pm 6,3	25,5 \pm 6,3	14,9 \pm 4,7
	4 R + V (B, C, T, P)	1,9 \pm 0,7	6,6 \pm 2,3	14,1 \pm 6,4	7,5 \pm 3,1

Abréviations : ET : Écart-type, B : Bassin, C : Cuisse, T : Tibia, P : Pied, V : Virtuel, R : Réel

L'analyse des résultats met en évidence que la précision du modèle est fortement influencée par le type de mouvement étudié. Les variations de performance entre les différents axes de mouvement peuvent être attribuées à plusieurs facteurs :

1. La complexité biomécanique des mouvements : Les mouvements d'Ab/Ad et de Ri/Re lors de la marche impliquent des compensations musculaires et des interactions complexes avec d'autres segments corporels. Cette dynamique rend leur modélisation plus complexe que celle du mouvement de Fl/Ex, qui est plus isolé, naturel et répétitif;
2. La qualité et la répartition des données d'entraînement : Certaines partitions du jeu de données peuvent inclure des scénarios plus complexes, notamment des mouvements extrêmes ou des amplitudes inhabituelles. Cette distribution non homogène des données peut altérer la capacité de généralisation du modèle;
3. La sensibilité du réseau aux perturbations des capteurs : Malgré l'utilisation de centrales inertielles virtuelles (supposées limiter le bruit sur les courbes), les axes d'Ab/Ad et de Ri/Re, du fait de leurs trajectoires plus irrégulières, sont plus sensibles aux erreurs de capture et aux bruits des capteurs que l'axe de Fl/Ex.

L'analyse comparative des bases de données utilisées dans la littérature (*Voir* tableau 1.3, p.39) met en évidence une différence significative avec notre propre base de données. En effet, notre modèle a été entraîné sur un ensemble de données substantiellement plus vaste, comprenant les essais de 90 participants sains et 428 atteints de gonarthrose. En principe, un ensemble de données plus volumineux devrait favoriser un apprentissage plus robuste des RNA. Toutefois, cette hypothèse ne se vérifie pas systématiquement ici, soulevant ainsi des interrogations sur la reproductibilité des résultats rapportés dans la littérature lorsque la diversité des populations étudiées est augmentée.

Par ailleurs, une comparaison avec les modèles de la littérature révèle plusieurs points saillants. D'abord, la majorité des études existantes visent à estimer non seulement les angles du genou, mais aussi ceux de la hanche et de la cheville (*Voir* tableau 1.3, p.39). Pourtant, la complexité de notre architecture (*Voir* figure 4.3, p.82) reste comparable à celles rapportées dans la

littérature (*Voir* tableau-A VII-2, p.144). Cette observation suggère que notre modèle pourrait être excessivement complexe au regard de son objectif, ce qui favoriserait le surapprentissage et limiterait potentiellement sa capacité de généralisation.

Ensuite, les modèles les plus performants décrits dans la littérature exploitent généralement un plus grand nombre de centrales inertielles, typiquement entre trois et sept. Cependant, un des objectifs principaux de notre approche réside dans la simplification du protocole de mesure pour réduire les coûts et améliorer l'applicabilité clinique. Ainsi, bien qu'une augmentation du nombre d'IMUs soit corrélée avec une amélioration des prédictions, il est crucial d'en limiter le nombre afin de trouver un équilibre entre précision et contraintes pratiques. Notre modèle, qui utilise uniquement deux centrales inertielles virtuelles, obtient des performances comparables à celles rapportées dans la littérature pour l'axe de Fl/Ex et supérieures pour l'axe de Ri/Re. Toutefois, des améliorations restent à apporter sur l'axe d'Ab/Ad.

Un autre élément important concerne la nature des caractéristiques d'entrée utilisées. Les modèles de la littérature exploitent généralement un ensemble de variables plus diversifié. L'analyse du tableau-A VII-2 (p.144) montre que plusieurs modèles intègrent les vitesses angulaires triaxiales ainsi que les accélérations linéaires triaxiales issues des centrales inertielles, ce qui enrichit les informations disponibles pour l'apprentissage.

En revanche, notre approche repose uniquement sur les vitesses angulaires triaxiales, ce qui limite la diversité des paramètres exploités pour la reconnaissance des motifs. Cette restriction est liée aux limitations techniques de l'algorithme fourni par Moveck, qui ne permettait pas d'obtenir des accélérations linéaires dans un repère local à chaque segment en raison du bruit inhérent à ces calculs. Afin de garantir la cohérence et la fiabilité des données par rapport à celles obtenues avec une centrale inertielle réelle, seules les informations exprimées dans un repère local ont été considérées comme pertinentes. Par conséquent, seules les vitesses angulaires ont été retenues comme variables d'entrée, excluant ainsi les données issues d'un repère global. Cette limitation pourrait affecter la précision et la robustesse des prédictions en réduisant la richesse des informations exploitable par le modèle.

En synthèse, notre modèle parvient à limiter le nombre d'IMUs nécessaires tout en affichant des performances comparables, voire supérieures, à la littérature sur les axes de FI/Ex et de Ri/Re, bien que des efforts restent à fournir pour améliorer la précision sur l'axe d'Ab/Ad. Une évaluation comparative des modèles issus de la littérature sur une base de données commune permettrait une comparaison plus robuste et objective, notamment en termes de nRMSE. Enfin, une optimisation des caractéristiques d'entrée pourrait constituer une piste pertinente pour améliorer davantage les performances du modèle.

6.1.2 Observations sur les prédictions faites sur la base de test

L'analyse des courbes prédites par rapport aux courbes de référence issues de la base de test met en évidence plusieurs tendances notables.

L'examen des échantillons révèle que, dans de nombreux cas, les courbes prédites reproduisent fidèlement les courbes attendues. À titre d'exemple, l'échantillon 18 089 illustre une excellente concordance entre les deux jeux de courbes (*Voir* figure 5.2, p.95). Toutefois, certains échantillons affichent des écarts significatifs, particulièrement sur les axes d'Ab/Ad et de Ri/Re. Par exemple, bien que l'échantillon 15 035 présente une bonne correspondance sur l'axe de FI/Ex, des divergences notables émergent sur les autres axes de rotation.

Par ailleurs, en ce qui concerne les axes de rotation et d'abduction, une translation verticale des courbes prédites par rapport aux courbes attendues est observée dans plusieurs cas, sans altération ou déformation majeure de la forme globale du signal. Ce phénomène, visible sur les échantillons 17 856 et 15 035 (*Voir* figure 5.2, p.95), suggère que le modèle présente une certaine difficulté à ajuster précisément les valeurs absolues des prédictions. La courbe de profil atypique de l'échantillon 17 856 illustre également un des rares échantillons où la nRMSE sur la courbe de flexion dépasse les 10 %.

Un autre biais observé concerne une sous-estimation systématique des amplitudes extrêmes, entraînant une atténuation des fluctuations abruptes ou atypiques. Ce phénomène est particulièrement marqué dans les profils de marche des patients pathologiques, où ces variations extrêmes sont plus fréquentes. Il est envisageable que l'âge moyen avancé des participants contribue à cette tendance, car certaines irrégularités perçues dans leurs cycles de marche pourraient résulter de déséquilibres ponctuels échappant à la cyclicité normale du mouvement. Toutefois, ces fluctuations atypiques ne sont pas exclusivement observées chez les patients pathologiques : elles apparaissent également chez certains individus sains, en fonction des caractéristiques biomécaniques spécifiques à leur phénotype de marche. Cette limitation du modèle pourrait découler d'une représentation insuffisante des cas extrêmes au sein des données d'entraînement ou d'une distribution sous-optimale des phénotypes entre les ensembles de données, restreignant ainsi sa capacité à capturer la variabilité interindividuelle.

L'évaluation des valeurs de RMSE et de nRMSE pour chaque échantillon révèle une variabilité importante des performances du modèle. Par exemple, pour l'axe Ab/Ad, même sur un ensemble restreint d'échantillons (*Voir figure 5.2, p.95*), les valeurs de RMSE fluctuent entre $0,3329^\circ$ et $10,7619^\circ$, tandis que les valeurs de nRMSE varient entre 3,19 % et 222,73 %. Face à cette dispersion, la décision d'évaluer une moyenne ajustée excluant les valeurs extrêmes excédant un écart-type au-dessus de la moyenne repose sur l'observation d'une forte similarité entre les courbes prédites et attendues. En effet, comme mentionné précédemment, l'erreur élevée entre ces courbes semble souvent résulter d'un décalage vertical plutôt que d'une prédiction fondamentalement erronée, c'est pourquoi les résultats élevés, tel que celui de l'échantillon 17 856, sont considérés aberrants.

L'ensemble de ces observations souligne l'impact majeur des caractéristiques biomécaniques et des conditions expérimentales sur les performances du réseau BiLSTM. Si le modèle parvient globalement à capturer la dynamique du mouvement, certaines limitations persistent, en particulier sur les axes marqués par une forte variabilité interindividuelle, tels que l'Ab/Ad et la Ri/Re. Bien que les résultats obtenus soient comparables à ceux retrouvés dans la littérature, ils suggèrent tout de même la nécessité d'un affinement du modèle, notamment par

une meilleure représentation des cas atypiques dans les données d'apprentissage, afin d'améliorer la précision des prédictions sur l'ensemble des axes de mouvement.

6.2 Interprétation des résultats de l'apprentissage du réseau

L'analyse de l'entraînement du réseau met en évidence plusieurs limitations et pistes d'amélioration susceptibles d'accroître la robustesse et la précision du modèle.

Tout d'abord, la distribution des données présente un déséquilibre significatif entre les différents grades d'arthrose, ce qui est susceptible d'introduire un biais dans le processus d'apprentissage. En effet, comme l'illustrent la figure 4.4 et la figure 4.5 (pp.85-86), la répartition des échantillons n'est pas homogène : les grades 0 (asymptomatiques), 2 et 3 représentent respectivement 26 %, 28 % et 26 % de l'ensemble de la base de données, tandis que les grades 1 et 4 sont sous-représentés, avec seulement 2 % et 18 % des échantillons. Idéalement, une distribution équilibrée autour de 20 % par grade serait préférable afin de garantir une meilleure généralisation du modèle. Pour atténuer cet effet de biais, plusieurs approches peuvent être envisagées :

1. Suréchantillonnage des classes minoritaires : Augmentation artificielle de la proportion des échantillons sous-représentés en dupliquant des exemples existants ou en générant des données synthétiques à l'aide de techniques telles que la synthétisation par GANs (Generative Adversarial Networks) ou le SMOTE (Synthetic Minority Over-sampling Technique);
2. Sous-échantillonnage des classes majoritaires : Réduction du nombre d'échantillons des grades sur-représentés en sélectionnant un sous-ensemble représentatif à l'aide d'algorithmes de groupement (*clustering* [traduction de l'OQLF]) ou d'une stratégie de sous-échantillonnage aléatoire, de manière à préserver la diversité intra-grade;
3. Pondération de la fonction de perte : Plutôt que de modifier directement les données, cette approche ajuste la fonction de coût en attribuant un poids plus élevé aux erreurs provenant des classes minoritaires. Cette stratégie permet ainsi de

compenser le déséquilibre tout en préservant l'intégralité de l'information disponible.

En parallèle, la méthodologie actuelle de partitionnement des données pourrait également être optimisée. Actuellement, les grades d'arthrose sont équitablement répartis dans chaque ensemble de données (entraînement et test), mais une stratégie alternative basée sur les phénotypes biomécaniques pourrait s'avérer plus pertinente. Un phénotype de marche est défini comme un ensemble de caractéristiques cinématiques et cinétiques distinctes, influencées par divers facteurs tels que la morphologie, la condition musculaire, les pathologies articulaires et les compensations posturales. Or, ces phénotypes ne sont pas directement corrélés au grade d'arthrose, mais ils exercent une influence notable sur les courbes cinématiques de la marche. Une distribution inadéquate de ces phénotypes entre les différents ensembles de données pourrait ainsi nuire à la capacité du modèle à capturer efficacement la variabilité interindividuelle.

Ensuite, une autre limite réside dans l'optimisation des hyperparamètres et de l'architecture du réseau. Bien que plusieurs configurations aient été testées, le choix final n'a pas encore été optimisé de manière systématique. Des différences notables ont été observées entre les modèles testés (MLP, LSTM, BiLSTM), mettant en évidence la nécessité d'explorer différentes architectures. L'intégration de nouvelles caractéristiques, notamment issues d'une analyse approfondie des phénotypes, pourrait également améliorer la performance globale du modèle.

Enfin, bien que les courbes de perte sur la base de données d'entraînement de chaque partition diminuent continuellement et convergent vers une valeur très faible, celles évaluées sur la base de validation (donc de test) restent relativement constantes et ne diminuent pas significativement (*Voir* figure 5.1, p.92, et annexe VII, p.143). Cela signifie que le modèle apprend très bien avec les données d'entraînement, mais qu'il ne parvient pas à généraliser correctement sur de nouvelles données, ce qui suggère un surapprentissage du réseau. Également, la stabilité légèrement bruitée de la courbe de perte sur la base de validation suggère que le modèle n'améliore pas ses performances sur des données inédites, probablement

en raison d'une trop grande complexité. Ainsi, plutôt que d'extraire des motifs généralisables, le réseau mémorise trop les données d'entraînement.

6.3 Apports à la recherche

Les performances atteintes par notre modèle sur les différents axes démontrent la possibilité d'obtenir des prédictions de précisions semblables, voire supérieures, à la littérature, tout en limitant le nombre de centrales inertielles à devoir exploiter. Cela ouvre la voie vers une possibilité de simplification clinique des prises de mesures.

Ce mémoire apporte également plusieurs contributions pertinentes pour les recherches futures. Si de nombreuses pistes d'amélioration ont été discutées précédemment, les éléments suivants concernent plus spécifiquement les outils méthodologiques mis à disposition des futurs chercheurs poursuivant l'objectif principal de cette étude : concevoir et évaluer l'efficacité d'un algorithme capable d'inférer avec précision les courbes cinématiques dans les trois axes anatomiques à partir des données issues de deux centrales inertielles virtuellement placées sur les membres inférieurs (fémur et tibia) lors de la marche.

Tout d'abord, un travail conséquent a été réalisé pour structurer une base de données unique combinant les enregistrements de patients sains et pathologiques. Cette uniformisation facilite son intégration dans des algorithmes d'apprentissage machine. De plus, la conservation systématique des métadonnées associées à chaque essai permet d'explorer différentes stratégies de partitionnement des données sans nécessiter une répétition du processus de prétraitement, souvent long et fastidieux.

Ensuite, le script Python développé dans le cadre de cette étude intègre plusieurs fonctions essentielles à l'exploitation des données, notamment une fonction de fenêtrage glissant pour la segmentation et une autre dédiée au partitionnement des ensembles d'apprentissage et de validation. Ces fonctions ont été rigoureusement optimisées pour s'adapter à la structure de la

base de données unifiée, garantissant ainsi une intégration aisée dans de futurs développements algorithmiques.

Enfin, les performances du réseau de neurones selon les différentes configurations d'hyperparamètres et d'architectures testées ont été systématiquement archivées dans un document Excel. Cette documentation permet non seulement de retracer les observations obtenues pour chaque configuration, mais aussi d'orienter efficacement les futurs travaux en évitant une redondance des expérimentations.

Ainsi, au-delà des résultats intéressants obtenus, ce mémoire fournit des bases solides et reproductibles pour les recherches ultérieures, contribuant à l'amélioration continue des méthodes d'inférence des courbes cinématiques à partir des données inertielles.

CONCLUSION

Ce mémoire avait pour objectif principal la conception et l'évaluation d'un algorithme basé sur un réseau de neurones BiLSTM afin d'estimer les courbes cinématiques du genou lors de la marche. L'étude s'est articulée autour de trois axes majeurs : l'impact de la séparation des couches de sortie en fonction des axes anatomiques sur la précision de l'inférence, la pertinence de restreindre les données d'entrée aux seules vitesses angulaires triaxiales issues de deux centrales inertielles placées sur le fémur et le tibia, et la capacité du modèle à généraliser ses prédictions sur une population plus variée en termes d'âge, de genre et de condition pathologique.

Une première analyse, détaillée au chapitre 3 (p.53), a mis en évidence une cohérence des résultats obtenus indépendamment du choix de l'ensemble des cycles de marche ou de la sélection des cycles les plus répétables pour le calcul des facteurs biomécaniques. Cette validation préliminaire a ainsi permis d'écarter la nécessité d'un prétraitement supplémentaire des données d'entrée.

L'évaluation du modèle BiLSTM a conduit à plusieurs observations significatives. Tout d'abord, la séparation des couches de sortie en fonction des axes anatomiques a permis de limiter la propagation des erreurs entre les axes. Plus spécifiquement, elle a réduit l'influence des erreurs sur l'axe de Fl/Ex sur celles des axes d'Ab/Ad et de Ri/Re. Cette approche a contribué à une amélioration de la précision des estimations sur l'axe de Ri/Re, ainsi qu'à une légère amélioration de la précision des estimations sur l'axe de Fl/Ex. Elle n'a pas eu d'effet positif sur l'axe d'Ab/Ad.

Par ailleurs, un des objectifs initiaux était de minimiser le nombre de centrales inertielles utilisées. Bien que les résultats de la littérature montrent que les modèles intégrant un plus grand nombre d'IMUs génèrent généralement des estimations plus précises, notre modèle a produit des résultats comparables, voire supérieurs, à la littérature en se limitant à deux centrales inertielles.

Au niveau de l'architecture du réseau, l'analyse a révélé que l'augmentation du nombre de caractéristiques différentes en entrée améliore l'apprentissage du réseau. Ces observations suggèrent que la seule utilisation des vitesses angulaires triaxiales pourrait constituer une limitation du modèle, en restreignant la quantité d'informations disponibles pour l'inférence.

Enfin, concernant la généralisation du modèle à une population plus hétérogène, les résultats indiquent un phénomène de surapprentissage, malgré une partition des données respectant la distribution des niveaux pathologiques. Ce constat soulève des questions quant à la reproductibilité des résultats rapportés dans la littérature. Il suggère également que le critère de partitionnement basé exclusivement sur le niveau pathologique pourrait être insuffisant et que d'autres stratégies devraient être envisagées.

En conclusion, l'utilisation d'un réseau de neurones pour l'estimation de la cinématique du genou lors de la marche à partir de données issues de deux centrales inertielles se révèle très prometteuse. En considérant les divers aspects nécessitant encore une optimisation, le potentiel de précision de notre réseau pourrait surpasser de loin la précision des modèles décrits dans la littérature. Avant d'envisager l'exploration d'une architecture de réseau alternative, il apparaît essentiel de traiter en priorité les problèmes suivants :

1. **Partitionnement des données** : Il conviendrait d'adopter un critère différent du niveau pathologique pour la formation des groupes de distribution, par exemple en se basant sur les phénotypes. Une autre approche consisterait à équilibrer les groupes grâce à diverses techniques d'augmentation des données;
2. **Enrichissement des entrées du modèle** : L'ajout des accélérations linéaires triaxiales locales des deux IMUs virtuellement créées semble indispensable, cette information étant systématiquement intégrée dans les modèles présentés dans la littérature;
3. **Optimisation des hyperparamètres** : Une optimisation systématique est nécessaire afin d'exploiter pleinement les capacités du réseau et de déterminer si une architecture différente s'avèrerait plus pertinente pour accomplir cette tâche.

Ces ajustements devraient permettre d'améliorer la robustesse et la performance du modèle, tout en facilitant la comparaison avec d'autres approches existantes. Des recommandations supplémentaires sont présentées à la section suivante.

RECOMMANDATIONS

Bien que notre modèle ait atteint des performances intéressantes, les conclusions de ce mémoire mettent en exergue plusieurs recommandations stratégiques visant à optimiser la pertinence clinique, la robustesse évaluative et l'efficacité architecturale du modèle d'apprentissage machine développé. Afin d'assurer une compréhension plus approfondie des axes d'amélioration prioritaires, une analyse détaillée des points clés est présentée ci-dessous.

Tout d'abord, l'influence des fluctuations atypiques observées dans les courbes cinématiques sur les prédictions du modèle requiert une stratégie d'atténuation adaptée. Une approche pertinente consisterait à partitionner la base de données selon les phénotypes plutôt que les grades, ce qui permettrait une classification plus homogène des profils biomécaniques. En complément, l'application de techniques d'augmentation des données contribuerait à assurer une distribution équilibrée des catégories (phénotypes ou grades) dans les ensembles d'entraînement et de validation, réduisant ainsi l'impact des biais structurels.

Ensuite, l'enrichissement des caractéristiques en entrée pourrait renforcer l'apprentissage du modèle. L'intégration des accélérations linéaires triaxiales locales à chaque IMU représente une piste prometteuse pour améliorer la précision des prédictions. Par ailleurs, l'utilisation de techniques avancées de réduction dimensionnelle, telles que l'analyse en composantes principales (*Principal Component Analysis* [traduction de l'OQLF] – PCA), permettrait d'extraire les caractéristiques les plus pertinentes, tout en préservant la capacité de généralisation du modèle.

Concernant l'optimisation des hyperparamètres, l'adoption d'une stratégie plus sophistiquée, comme la recherche Hyperband, offrirait une exploration plus efficace de l'espace des hyperparamètres, améliorant ainsi la convergence du modèle vers des performances optimales. En parallèle, la gestion du surapprentissage demeure un enjeu central. Si une régularisation par couche *dropout* est déjà en place, d'autres techniques, telles que les régularisations L1 et L2, pourraient être envisagées pour introduire une pénalisation adaptative sur les poids du réseau,

limitant ainsi le surajustement aux données d'entraînement. En outre, l'analyse des courbes de la fonction de perte (*Voir* annexe VIII, p.147) suggère que l'implémentation d'un arrêt anticipé (*early stopping* [traduction libre]) pourrait être bénéfique afin d'interrompre l'entraînement avant que le surapprentissage ne devienne trop marqué.

En complément de ces recommandations, trois axes stratégiques méritent une attention particulière : l'analyse *post hoc* des prédictions, l'optimisation du protocole d'évaluation des performances et la restructuration de l'architecture du réseau de neurones.

Actuellement, les prédictions du modèle reposent sur les courbes cinématiques triaxiales complètes. Cependant, les cliniciens exploitent majoritairement des valeurs ou des catégories de facteurs biomécaniques extraits de ces courbes. Ainsi, bien que les performances du modèle ne surpassent pas encore celles rapportées dans la littérature, une évaluation plus fine de ces facteurs biomécaniques sur les courbes prédites permettrait de mieux appréhender la viabilité clinique de la combinaison entre centrales inertielles et réseaux de neurones. Une avancée supplémentaire consisterait à explorer un modèle d'apprentissage machine capable d'estimer directement ces facteurs biomécaniques à partir des données brutes des centrales inertielles, évitant ainsi l'étape de prédiction des courbes cinématiques complètes.

Concernant les mesures de performance, l'intégration du coefficient de corrélation R constituerait un levier d'évaluation supplémentaire pour permettre une comparaison plus directe avec les modèles préexistants. De surcroît, une analyse comparative rigoureuse pourrait être menée en évaluant les différents modèles issus de la littérature sur un même ensemble de données.

Enfin, la complexité du réseau neuronal pourrait être réduite par plusieurs moyens, notamment en diminuant le nombre de couches et de neurones ou en explorant des architectures alternatives. Bien que le réseau BiLSTM soit conçu pour la gestion des dépendances temporelles longues, il demeure relativement complexe et coûteux en termes de calcul. Une alternative intéressante serait le remplacement du BiLSTM par un réseau GRU, qui conserve

une bonne capacité de mémorisation tout en allégeant la charge de calcul. Le GRU, en fusionnant les portes d'entrée et d'oubli du LSTM en une seule porte de mise à jour, simplifie ainsi la structure du réseau tout en améliorant son efficacité computationnelle.

En somme, ces recommandations visent à améliorer la pertinence clinique, la fiabilité des évaluations et l'efficacité de l'architecture du réseau de neurones. Leur mise en œuvre contribuerait non seulement à renforcer la validité des prédictions, mais aussi à optimiser les performances et la robustesse du modèle dans un contexte clinique réel.

ANNEXE I

Liste des facteurs biomécaniques traduits

Tableau-A I-1 Traduction français-anglais du nom des facteurs biomécaniques utilisés

Axe	Nom anglais	Nom français
Sagittal (Fl/Ex)	<i>Knee flexum during initial contact</i>	Contracture dynamique en flexion au contact au sol
	<i>Limited flexion excursion during loading</i>	Flexion limitée lors du chargement
	<i>Fixed flexion during stance</i>	Limitation de l'extension en appui
	<i>Decreased maximum flexion during swing phase</i>	Diminution de la flexion à l'envol
	<i>Decreased sagittal plane range motion</i>	Diminution de l'amplitude de mouvement Fl/Ex
Frontal (Ab/Ad)	<i>Varus thrust during loading</i>	Augmentation du varus lors du chargement
	<i>Knee varus during initial contact</i>	Genou varum au contact au sol
	<i>Knee varus during stance (V1, V2, V3)</i>	Genou varum durant l'appui (V1, V2, V3)
	<i>Valgus thrust during loading</i>	Augmentation du valgus lors du chargement
Transverse (Ri/Re)	<i>External tibia rotation during initial contact</i>	Rotation externe tibiale au contact au sol
	<i>Internal rotation tibia femur loading</i>	Rotation interne tibiale lors du chargement

ANNEXE II

Définitions des facteurs biomécaniques

KNEE FLEXUM DURING INITIAL CONTACT (kfdic)

Valeur numérique :

P1 = 1 ;

kfdic_valeur = Flexion_Curve(:,P1) ;

Catégorie :

```
if (kfdic_valeur > -2)
    kfdic_categorie = 'Résultat négatif' ;
else
    kfdic_categorie = 'Résultat positif' ;
end
```

LIMITED FLEXION EXCURSION DURING LOADING (lfedl)

Valeur numérique :

P1 = 1 ;

P2 = 20 ;

Zone = Flexion_Curve(:,P1:P2) ;

Initial = Flexion_Curve(:,P1) ;

Max = max(Zone(:)) ;

lfedl_valeur = Max - Initial ;

Catégorie :

```
if (lfedl_valeur >= 14)
    lfedl_categorie = ['Résultat négatif'] ;
elseif (lfedl_valeur > 8 && lfedl_valeur < 14)
    lfedl_categorie = ['Résultat positif'] ;
else
    lfedl_categorie = ['Résultat positif plus'] ;
end
```

FIXED FLEXION DURING STANCE (ffds)Valeur numérique :

```
P1 = 1 ;
P2 = 20 ;
P3 = 69 ;
```

```
Zone1 = Flexion_Curve(:,P1:P2) ;
Zone2 = Flexion_Curve(:,P2:P3) ;
```

```
Max = max(Zone1(:)) ;
Min = min(Zone2(:)) ;
```

```
ffds_valeur = Max - Min ;
```

Catégorie :

```
if (ffds_valeur >= 17)
    ffds_categorie = 'Résultat négatif' ;

elseif (ffds_valeur > 0 && ffds_valeur < 17)
    ffds_categorie = 'Résultat positif' ;

else
    ffds_categorie = 'Résultat positif plus' ;

end
```

DECREASED MAXIMUM FLEXION DURING SWING PHASE (dmfdsp)Valeur numérique :

```
dmfdsp_valeur = max(Flexion_Curve(:)) ;
```

Catégorie :

```
if (dmfdsp_valeur > 47)
    dmfdsp_categorie = ['Résultat négatif'] ;

else
    dmfdsp_categorie = ['Résultat positif'] ;

end
```

DECREASED SAGITTAL PLANE RANGE MOTION (dsprm)

Valeur numérique :

```
Max = max(Flexion_Curve(:)) ;
Min = min(Flexion_Curve(:)) ;
```

```
dsprm_valeur = Max - Min ;
```

Catégorie :

```
if (dsprm_valeur >= 58)
    dsprm_categorie = 'Résultat négatif' ;

elseif (dsprm_valeur > 50 && dsprm_valeur < 58)
    dsprm_categorie = 'Résultat positif' ;

else
    dsprm_categorie = ['Résultat positif plus'] ;

end
```

VARUS THRUST DURING LOADING (vartdl)

Valeur numérique :

```
P1 = 1 ;
P2 = 20 ;
```

```
Zone = Abduction_Curve(:,P1:P2) ;
```

```
Initial = Abduction_Curve(:,P1) ;
Max      = max(Zone(:)) ;
```

```
vartdl_valeur = Max - Initial ;
```

Catégorie :

```
if (vartdl_valeur < 2.5)
    vartdl_categorie = 'Résultat négatif' ;

elseif (vartdl_valeur >= 2.5 && vartdl_valeur <= 7)
    vartdl_categorie = 'Résultat positif' ;

else
    vartdl_categorie = 'Résultat positif plus' ;

end
```

KNEE VARUS DURING INITIAL CONTACT (kvdic)Valeur numérique :

P1 = 1 ;

kvdic_valeur = Abduction_Curve(:,P1) ;

Catégorie :

```
if (kvdic_valeur < 2)
    kvdic_categorie = 'Résultat négatif';
```

```
else
    kvdic_categorie = 'Résultat positif';
```

```
end
```

KNEE VARUS DURING STANCE V1 (kvds1)Valeur numérique :

P1 = 20 ;

P2 = 54 ;

Zone = Abduction_Curve(:,P1:P2) ;

kvds1_valeur = mean(Zone(:)) ;

Catégorie :

```
if (kvds1_valeur < 2)
    kvds1_categorie = 'Résultat négatif' ;
```

```
elseif (kvds1_valeur >= 2 && kvds1_valeur < 5)
    kvds1_categorie = 'Résultat positif' ;
```

```
else
    kvds1_categorie = 'Résultat positif plus' ;
```

```
end
```


KNEE VARUS DURING STANCE V2 (kvds2)

Valeur numérique :

```
P1 = 10 ;
P2 = 54 ;
```

```
Zone = Abduction_Curve(:,P1:P2) ;
```

```
kvds2_valeur = mean(Zone(:)) ;
```

Catégorie :

```
if (kvds2_valeur < 2)
    kvds2_categorie = 'Résultat négatif' ;

elseif (kvds2_valeur >= 2 && kvds2_valeur < 5)
    kvds2_categorie = 'Résultat positif' ;

else
    kvds2_categorie = 'Résultat positif plus' ;

end
```

KNEE VARUS DURING STANCE V3 (kvds3)

Valeur numérique :

```
P1 = 1 ;
P2 = 60 ;
```

```
Zone = Abduction_Curve(:,P1:P2) ;
```

```
kvds3_valeur = mean(Zone(:)) ;
```

Catégorie :

```
if (kvds3_valeur < 2)
    kvds3_categorie = 'Résultat négatif' ;

elseif (kvds3_valeur >= 2 && kvds3_valeur < 5)
    kvds3_categorie = 'Résultat positif' ;

else
    kvds3_categorie = 'Résultat positif plus' ;

end
```

VALGUS THRUST DURING LOADING (valtdl)

Valeur numérique :

```
P1 = 1 ;
P2 = 20 ;

Zone = Abduction_Curve(:,P1:P2) ;

Initial = Abduction_Curve(:,P1) ;
Min      = min(Zone(:))          ;

valtdl_valeur = Initial - Min ;
```

Catégorie :

```
if (valtdl_valeur < 2.5)
    valtdl_categorie = 'Résultat négatif' ;

elseif (valtdl_valeur >= 2.5 && valtdl_valeur <= 7)
    valtdl_categorie = 'Résultat positif' ;

else
    valtdl_categorie = 'Résultat positif plus' ;

end
```

EXTERNAL TIBIA ROTATION DURING INITIAL CONTACT (etrdic)

Valeur numérique :

```
P1 = 1 ;

etrdic_valeur = Rotation_Curve(:,P1) ;
```

Catégorie :

```
if (etrdic_valeur < 0)
    etrdic_categorie = ['Résultat négatif'] ;

elseif (etrdic_valeur >= 0 && etrdic_valeur < 4.5)
    etrdic_categorie = ['Résultat négatif'] ;

elseif (etrdic_valeur >= 4.5 && etrdic_valeur < 7.5)
    etrdic_categorie = ['Résultat positif'] ;

else
    etrdic_categorie = ['Résultat positif plus'] ;

end
```

INTERNAL ROTATION TIBIA-FEMUR LOADING (irtfl)

Valeur numérique :

```
P1 = 1 ;  
P2 = 30 ;
```

```
Zone = Rotation_Curve(:,P1:P2) ;
```

```
irtfl_valeur = mean(Zone(:)) ;
```

Catégorie :

```
if (irtfl_valeur >= -1)  
    irtfl_categorie = 'Résultat négatif' ;  
  
else  
    irtfl_categorie = 'Résultat positif' ;  
  
end
```


ANNEXE III

Tableaux des résultats d'erreurs absolues de comparaison entre les facteurs biomécaniques calculés sur tous les cycles par rapport à ceux calculés sur les 15 cycles les plus répétables

Tableau-A III-1 Erreurs absolues de calcul des facteurs biomécaniques sur l'axe d'Ab/Ad

Groupes et sous-groupes		Sexe	Augmentation du varus lors du chargement		Genou varum au contact au sol		Genou varum durant l'appui V1		Genou varum durant l'appui V2		Genou varum durant l'appui V3		Augmentation du valgus lors du chargement	
			Moy. (°)	ET (°)	Moy. (°)	ET (°)	Moy. (°)	ET (°)	Moy. (°)	ET (°)	Moy. (°)	ET (°)	Moy. (°)	ET (°)
OA4	G	M	0,099	0,061	0,076	0,068	0,037	0,015	0,031	0,008	0,027	0,018	0,076	0,130
		F	0,134	0,196	0,064	0,033	0,052	0,071	0,051	0,065	0,052	0,050	0,097	0,086
	D	M	0,095	0,080	0,050	0,028	0,037	0,031	0,041	0,034	0,029	0,033	0,057	0,086
		F	0,103	0,084	0,076	0,058	0,030	0,020	0,030	0,017	0,023	0,016	0,075	0,109
	G + D	M	0,150	0,128	0,081	0,095	0,054	0,048	0,049	0,042	0,045	0,037	0,081	0,140
		F	0,142	0,112	0,107	0,098	0,051	0,052	0,047	0,045	0,041	0,039	0,070	0,125
	Tot.	M	0,136	0,114	0,075	0,081	0,050	0,042	0,046	0,038	0,040	0,035	0,076	0,129
		F	0,134	0,115	0,096	0,084	0,047	0,048	0,044	0,041	0,039	0,036	0,074	0,118
OA3	G	M	0,135	0,087	0,045	0,040	0,042	0,028	0,037	0,030	0,034	0,028	0,072	0,076
		F	0,123	0,109	0,070	0,053	0,066	0,049	0,053	0,037	0,045	0,029	0,030	0,056
	D	M	0,141	0,103	0,074	0,069	0,053	0,046	0,056	0,045	0,048	0,047	0,050	0,057
		F	0,135	0,117	0,075	0,072	0,026	0,017	0,028	0,023	0,027	0,019	0,047	0,054
	G + D	M	0,095	0,144	0,081	0,079	0,062	0,066	0,054	0,060	0,049	0,048	0,097	0,137
		F	0,123	0,103	0,072	0,061	0,049	0,037	0,042	0,035	0,041	0,034	0,071	0,102
	Tot.	M	0,111	0,126	0,074	0,071	0,057	0,056	0,052	0,052	0,046	0,044	0,082	0,110
		F	0,126	0,107	0,073	0,063	0,046	0,034	0,040	0,032	0,038	0,030	0,059	0,083
OA2	G	M	0,086	0,000	0,069	0,000	0,068	0,000	0,047	0,000	0,060	0,000	0,161	0,000
		F	0,063	0,050	0,007	0,008	0,011	0,009	0,008	0,006	0,006	0,003	0,000	0,000
	D	M	0,097	0,086	0,127	0,106	0,046	0,062	0,042	0,063	0,034	0,051	0,067	0,074
		F	0,058	0,061	0,059	0,056	0,029	0,023	0,019	0,013	0,029	0,028	0,106	0,126
	G + D	M	0,118	0,120	0,084	0,080	0,044	0,039	0,040	0,037	0,037	0,031	0,071	0,094
		F	0,135	0,135	0,088	0,189	0,066	0,136	0,064	0,136	0,061	0,139	0,068	0,095
	Tot.	M	0,116	0,115	0,086	0,080	0,044	0,040	0,040	0,038	0,037	0,031	0,073	0,091
		F	0,125	0,125	0,081	0,170	0,060	0,120	0,057	0,120	0,056	0,124	0,067	0,093
Total OA		M	0,120	0,119	0,079	0,077	0,050	0,046	0,046	0,043	0,041	0,037	0,077	0,108
		F	0,128	0,115	0,082	0,101	0,051	0,064	0,047	0,061	0,044	0,060	0,066	0,096
ASYMPT		M	0,076	0,090	0,073	0,075	0,048	0,034	0,043	0,030	0,042	0,033	0,061	0,077
		F	0,089	0,074	0,088	0,074	0,058	0,042	0,056	0,041	0,046	0,036	0,063	0,083
Total OA + ASYMPT		M	0,113	0,114	0,078	0,076	0,050	0,044	0,046	0,041	0,041	0,036	0,074	0,103
		F	0,123	0,110	0,083	0,098	0,052	0,061	0,048	0,059	0,044	0,057	0,065	0,095

Tableau-A III-2 Erreurs absolues de calcul des facteurs biomécaniques sur l'axe de Fl/Ex

Groupes et sous-groupes		Sexe	Contracture dynamique en flexion au contact au sol		Flexion limitée lors du chargement		Limitation de l'extension en appui		Diminution de la flexion à l'envol		Diminution de l'amplitude de mouvement Fl/Ex	
			Moy. (°)	ET (°)	Moy. (°)	ET (°)	Moy. (°)	ET (°)	Moy. (°)	ET (°)	Moy. (°)	ET (°)
OA4	G	M	0,209	0,214	0,325	0,189	0,220	0,151	0,390	0,303	0,383	0,249
		F	0,327	0,102	0,635	0,562	0,745	0,566	0,485	0,552	0,709	0,515
	D	M	0,278	0,268	0,358	0,328	0,268	0,279	0,206	0,205	0,346	0,376
		F	0,327	0,233	0,295	0,294	0,345	0,148	0,442	0,387	0,466	0,295
	G + D	M	0,293	0,190	0,396	0,317	0,382	0,324	0,346	0,374	0,559	0,475
		F	0,322	0,244	0,312	0,268	0,323	0,279	0,290	0,259	0,418	0,429
	Tot.	M	0,284	0,205	0,383	0,309	0,349	0,303	0,324	0,338	0,507	0,440
		F	0,323	0,227	0,342	0,303	0,371	0,284	0,339	0,314	0,457	0,412
OA3	G	M	0,397	0,304	0,318	0,381	0,290	0,250	0,253	0,165	0,409	0,357
		F	0,303	0,287	0,346	0,304	0,311	0,230	0,206	0,183	0,270	0,208
	D	M	0,546	0,865	0,298	0,217	0,711	0,944	0,284	0,234	0,513	0,365
		F	0,309	0,309	0,556	0,608	0,340	0,405	0,232	0,176	0,345	0,262
	G + D	M	0,316	0,277	0,397	0,353	0,368	0,318	0,282	0,236	0,323	0,291
		F	0,353	0,394	0,410	0,311	0,421	0,417	0,295	0,190	0,455	0,391
	Tot.	M	0,380	0,414	0,363	0,326	0,434	0,449	0,278	0,225	0,379	0,318
		F	0,335	0,358	0,437	0,383	0,386	0,387	0,267	0,186	0,402	0,333
OA2	G	M	0,494	0,000	0,763	0,000	0,040	0,000	0,800	0,000	1,029	0,000
		F	0,075	0,061	0,200	0,110	0,184	0,136	0,063	0,047	0,094	0,106
	D	M	0,471	0,205	0,345	0,183	0,179	0,106	0,430	0,261	0,470	0,443
		F	0,298	0,302	0,517	0,205	0,501	0,501	0,110	0,141	0,397	0,366
	G + D	M	0,306	0,319	0,422	0,314	0,420	0,378	0,272	0,216	0,374	0,272
		F	0,440	0,605	0,439	0,475	0,517	0,588	0,358	0,354	0,582	0,818
	Tot.	M	0,319	0,307	0,424	0,301	0,399	0,355	0,291	0,215	0,392	0,277
		F	0,411	0,554	0,433	0,435	0,500	0,559	0,324	0,322	0,543	0,747
Total OA		M	0,332	0,319	0,391	0,312	0,398	0,376	0,295	0,252	0,418	0,336
		F	0,355	0,380	0,409	0,376	0,416	0,410	0,304	0,263	0,460	0,481
ASYMPT		M	0,324	0,304	0,428	0,297	0,433	0,304	0,278	0,351	0,428	0,457
		F	0,394	0,305	0,425	0,478	0,397	0,408	0,291	0,196	0,512	0,350
Total OA + ASYMPT		M	0,331	0,316	0,397	0,310	0,404	0,364	0,292	0,268	0,420	0,356
		F	0,360	0,371	0,411	0,389	0,414	0,410	0,303	0,255	0,467	0,465

Tableau-A III-3 Erreurs absolues de calcul des facteurs biomécaniques sur l'axe de Ri/Re

Groupes et sous-groupes		Sexe	Rotation externe tibiale au contact au sol		Rotation interne tibiale lors du chargement	
			Moy. (°)	ET (°)	Moy. (°)	ET (°)
OA4	G	M	0,319	0,156	0,195	0,056
		F	0,225	0,111	0,099	0,061
	D	M	0,222	0,193	0,116	0,095
		F	0,203	0,164	0,081	0,071
	G + D	M	0,232	0,273	0,108	0,081
		F	0,208	0,174	0,112	0,134
	Tot.	M	0,237	0,249	0,116	0,082
		F	0,209	0,166	0,105	0,114
OA3	G	M	0,120	0,100	0,083	0,083
		F	0,137	0,106	0,135	0,179
	D	M	0,182	0,191	0,122	0,104
		F	0,202	0,126	0,085	0,092
	G + D	M	0,215	0,197	0,141	0,169
		F	0,205	0,268	0,109	0,134
	Tot.	M	0,193	0,181	0,128	0,141
		F	0,194	0,210	0,107	0,130
OA2	G	M	0,236	0,000	0,057	0,000
		F	0,100	0,149	0,036	0,040
	D	M	0,104	0,106	0,038	0,020
		F	0,230	0,202	0,134	0,071
	G + D	M	0,163	0,135	0,083	0,097
		F	0,263	0,399	0,172	0,332
	Tot.	M	0,161	0,131	0,080	0,091
		F	0,253	0,371	0,163	0,297
Total OA		M	0,193	0,181	0,107	0,107
		F	0,216	0,246	0,123	0,176
ASYMPT		M	0,186	0,161	0,142	0,094
		F	0,240	0,208	0,083	0,071
Total OA + ASYMPT		M	0,192	0,178	0,113	0,105
		F	0,219	0,241	0,118	0,163

ANNEXE IV

Tableaux des résultats de concordance des catégories obtenues entre les facteurs biomécaniques calculés sur tous les cycles par rapport à ceux calculés sur les 15 cycles les plus répétables

Tableau-A IV-1 Taux de concordance des catégories évaluées pour les facteurs biomécaniques de l'axe d'Ab/Ad

Groupes et sous-groupes		Sexe	Augmentation du varus lors du chargement	Genou varum au contact au sol	Genou varum durant l'appui V1	Genou varum durant l'appui V2	Genou varum durant l'appui V3	Augmentation du valgus lors du chargement
OA4	G	M	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
		F	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
	D	M	85,71%	100,00%	100,00%	100,00%	100,00%	100,00%
		F	81,82%	100,00%	100,00%	100,00%	100,00%	100,00%
	G + D	M	93,10%	100,00%	100,00%	100,00%	96,55%	100,00%
		F	95,12%	100,00%	100,00%	100,00%	100,00%	100,00%
	Tot.	M	92,31%	100,00%	100,00%	100,00%	97,44%	100,00%
		F	93,10%	100,00%	100,00%	100,00%	100,00%	100,00%
OA3	G	M	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
		F	100,00%	100,00%	91,67%	100,00%	100,00%	91,67%
	D	M	91,67%	100,00%	100,00%	100,00%	100,00%	100,00%
		F	95,24%	100,00%	100,00%	95,24%	100,00%	100,00%
	G + D	M	96,97%	100,00%	96,97%	100,00%	100,00%	93,94%
		F	94,23%	98,08%	100,00%	100,00%	100,00%	100,00%
	Tot.	M	96,23%	100,00%	98,11%	100,00%	100,00%	96,23%
		F	95,29%	98,82%	98,82%	98,82%	100,00%	98,82%
OA2	G	M	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
		F	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
	D	M	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
		F	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
	G + D	M	95,92%	100,00%	100,00%	97,96%	100,00%	100,00%
		F	100,00%	100,00%	98,15%	100,00%	98,15%	98,15%
	Tot.	M	96,23%	100,00%	100,00%	98,11%	100,00%	100,00%
		F	100,00%	100,00%	98,39%	100,00%	98,39%	98,39%
Total OA		M	95,17%	100,00%	99,31%	99,31%	99,31%	98,62%
		F	96,10%	99,51%	99,02%	99,51%	99,51%	99,02%
ASYMPT		M	100,00%	100,00%	96,55%	100,00%	100,00%	100,00%
		F	100,00%	100,00%	100,00%	100,00%	100,00%	96,55%
Total OA + ASYMPT		M	95,98%	100,00%	98,85%	99,43%	99,43%	98,85%
		F	96,58%	99,57%	99,15%	99,57%	99,57%	98,72%

Tableau-A IV-2 Taux de concordance des catégories évaluées pour les facteurs biomécaniques de l'axe de FI/Ex

Groupes et sous-groupes		Sexe	Contracture dynamique en flexion au contact au sol	Flexion limitée lors du chargement	Limitation de l'extension en appui	Diminution de la flexion à l'envol	Diminution de l'amplitude de mouvement FI/Ex
OA4	G	M	100,00%	100,00%	100,00%	100,00%	100,00%
		F	100,00%	83,33%	50,00%	100,00%	100,00%
	D	M	100,00%	100,00%	100,00%	100,00%	100,00%
		F	100,00%	100,00%	100,00%	100,00%	100,00%
	G + D	M	100,00%	96,55%	96,55%	100,00%	96,55%
		F	100,00%	97,56%	100,00%	100,00%	100,00%
	Tot.	M	100,00%	97,44%	97,44%	100,00%	97,44%
		F	100,00%	96,55%	94,83%	100,00%	100,00%
OA3	G	M	100,00%	100,00%	100,00%	100,00%	100,00%
		F	100,00%	100,00%	100,00%	100,00%	91,67%
	D	M	100,00%	100,00%	91,67%	100,00%	91,67%
		F	100,00%	90,48%	100,00%	100,00%	95,24%
	G + D	M	100,00%	96,97%	100,00%	100,00%	93,94%
		F	100,00%	96,15%	96,15%	100,00%	92,31%
	Tot.	M	100,00%	98,11%	98,11%	100,00%	94,34%
		F	100,00%	95,29%	97,65%	100,00%	92,94%
OA2	G	M	100,00%	100,00%	100,00%	100,00%	100,00%
		F	100,00%	100,00%	100,00%	100,00%	100,00%
	D	M	100,00%	66,67%	100,00%	100,00%	100,00%
		F	100,00%	60,00%	100,00%	100,00%	80,00%
	G + D	M	100,00%	93,88%	97,96%	97,96%	97,96%
		F	100,00%	98,15%	98,15%	100,00%	88,89%
	Tot.	M	100,00%	92,45%	98,11%	98,11%	98,11%
		F	100,00%	95,16%	98,39%	100,00%	88,71%
Total OA		M	100,00%	95,86%	97,93%	99,31%	96,55%
		F	100,00%	95,61%	97,07%	100,00%	93,66%
ASYMPT		M	96,55%	96,55%	100,00%	100,00%	93,10%
		F	100,00%	93,10%	100,00%	100,00%	100,00%
Total OA + ASYMPT		M	99,43%	95,98%	98,28%	99,43%	95,98%
		F	100,00%	95,30%	97,44%	100,00%	94,44%

Tableau-A IV-3 Taux de concordance des catégories évaluées pour les facteurs biomécaniques de l'axe de Ri/Re

Groupes et sous-groupes		Sexe	Rotation externe tibiale au contact au sol	Rotation interne tibiale lors du chargement
OA4	G	M	100,00%	100,00%
		F	83,33%	100,00%
	D	M	100,00%	100,00%
		F	100,00%	90,91%
	G + D	M	100,00%	96,55%
		F	97,56%	100,00%
	Tot.	M	100,00%	97,44%
		F	96,55%	98,28%
OA3	G	M	100,00%	100,00%
		F	100,00%	100,00%
	D	M	100,00%	100,00%
		F	100,00%	100,00%
	G + D	M	100,00%	100,00%
		F	94,23%	100,00%
	Tot.	M	100,00%	100,00%
		F	96,47%	100,00%
OA2	G	M	100,00%	100,00%
		F	100,00%	100,00%
	D	M	100,00%	100,00%
		F	80,00%	100,00%
	G + D	M	97,96%	100,00%
		F	94,44%	100,00%
	Tot.	M	98,11%	100,00%
		F	93,55%	100,00%
Total OA		M	99,31%	99,31%
		F	95,61%	99,51%
ASYMPT		M	96,55%	100,00%
		F	93,10%	100,00%
Total OA + ASYMPT		M	98,85%	99,43%
		F	95,30%	99,57%

ANNEXE V

Diagramme du calcul de la vitesse angulaire par Moveck

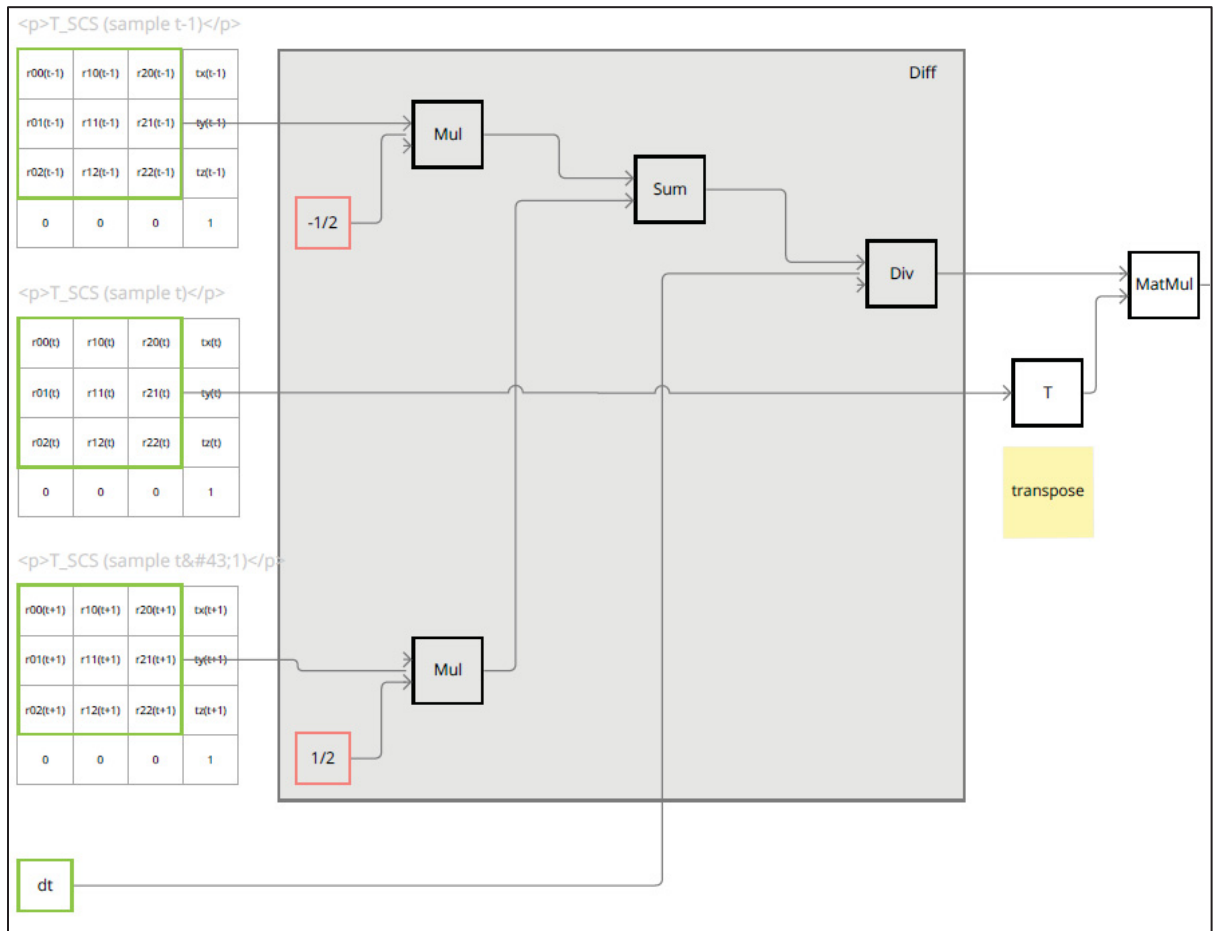


Figure-A V-1 Première partie du diagramme de calcul de la vitesse angulaire fait par Moveck

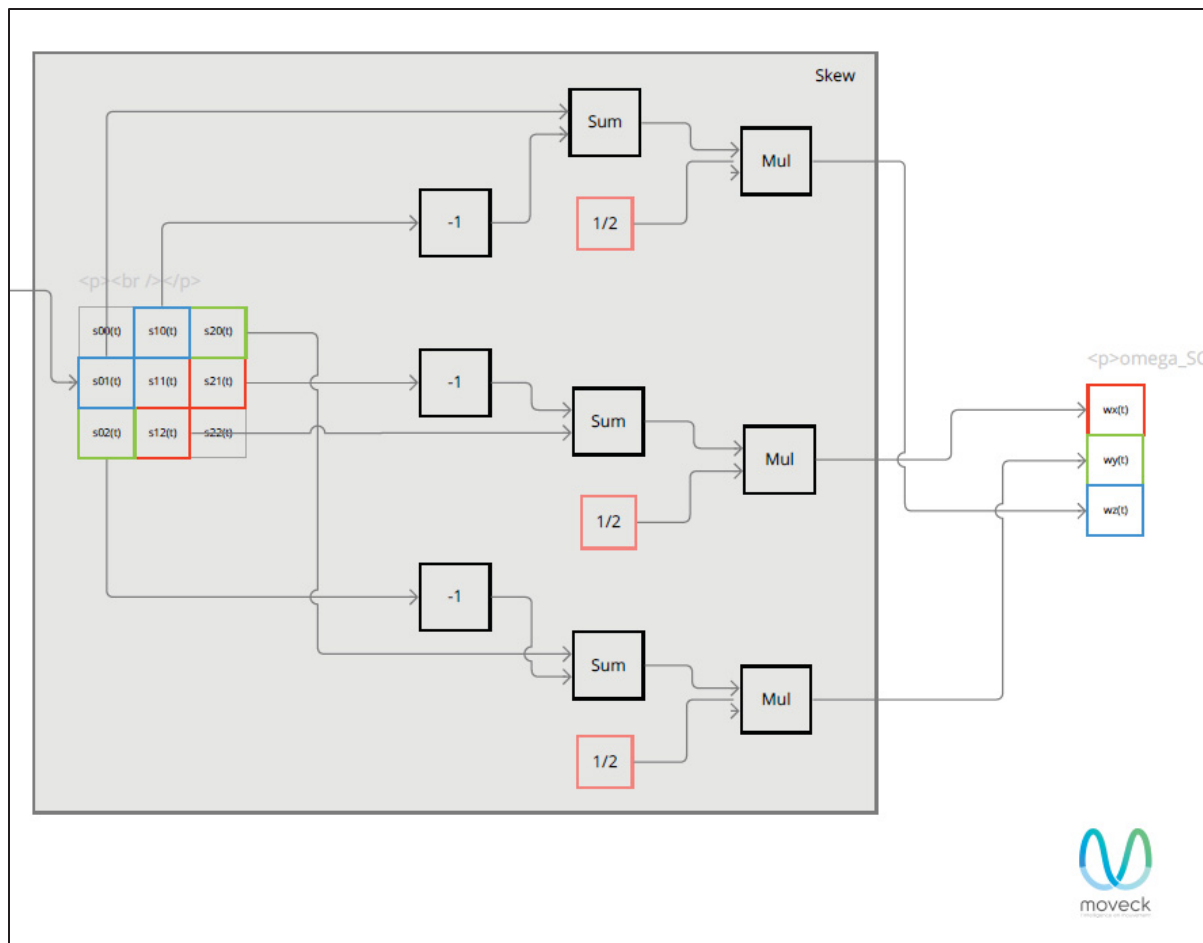


Figure-A V-2 Deuxième partie du diagramme de calcul de la vitesse angulaire fait par Moveck

ANNEXE VI

Tableaux des distributions détaillées des bases de données d'entraînement et de test décrivant les quantités et les proportions des échantillons et des patients uniques de chaque grade pour chaque partition

Tableau-A VI-1 Distribution des bases de données pour la partition 1

Grade	Nombre d'échantillons				Nombre de patients uniques			
	Entraînement		Test		Entraînement		Test	
	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.
0	19686	26%	4947	26%	99	19%	25	19%
1	1632	2%	306	2%	15	3%	3	2%
2	21267	28%	5049	27%	156	30%	39	30%
3	19584	26%	5049	27%	152	29%	40	30%
4	13413	18%	3519	19%	95	18%	25	19%
Total	75582		18870		517		132	

Tableau-A VI-2 Distribution des bases de données pour la partition 2

Grade	Nombre d'échantillons				Nombre de patients uniques			
	Entraînement		Test		Entraînement		Test	
	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.
0	19584	26%	5049	27%	99	19%	25	20%
1	1632	2%	306	2%	15	3%	3	2%
2	21012	28%	5304	28%	157	30%	38	30%
3	19890	26%	4743	25%	155	30%	37	29%
4	13413	18%	3519	19%	96	18%	24	19%
Total	75531		18921		522		127	

Tableau-A VI-3 Distribution des bases de données pour la partition 3

Grade	Nombre d'échantillons				Nombre de patients uniques			
	Entraînement		Test		Entraînement		Test	
	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.
0	19788	26%	4845	26%	100	19%	24	19%
1	1479	2%	459	2%	14	3%	4	3%
2	21267	28%	5049	27%	158	30%	37	29%
3	19890	26%	4743	25%	154	30%	38	29%
4	13158	17%	3774	20%	94	18%	26	20%
Total	75582		18870		520		129	

Tableau-A VI-4 Distribution des bases de données pour la partition 4

Grade	Nombre d'échantillons				Nombre de patients uniques			
	Entraînement		Test		Entraînement		Test	
	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.
0	19686	26%	4947	26%	99	19%	25	19%
1	1275	2%	663	4%	12	2%	6	5%
2	20757	27%	5559	29%	155	30%	40	31%
3	19737	26%	4896	26%	155	30%	37	29%
4	14076	19%	2856	15%	99	19%	21	16%
Total	75531		18921		520		129	

Tableau-A VI-5 Distribution des bases de données pour la partition 5

Grade	Nombre d'échantillons				Nombre de patients uniques			
	Entraînement		Test		Entraînement		Test	
	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.	Qté.	Prop.
0	19788	26%	4845	26%	99	19%	25	19%
1	1734	2%	204	1%	16	3%	2	2%
2	20961	28%	5355	28%	154	30%	41	31%
3	19431	26%	5202	28%	152	29%	40	30%
4	13668	18%	3264	17%	96	19%	24	18%
Total	75582		18870		517		132	

ANNEXE VII

Tableaux descriptifs des architectures et des hyperparamètres utilisés dans la littérature pour l'apprentissage de réseaux de neurones en analyse de la marche

Tableau-A VII-1 Résumé des hyperparamètres utilisés dans la littérature pour l'apprentissage de RNA de type BiLSTM en analyse de la marche

Référence	TA	Taille de lot	Nb. époque	FO	MR	VC
Mundt et al. (2019)	/	/	/	/	- Méthode d'optimisation des hyperparamètres	K-partitions ($k = 10$)
Mundt, Koeppe, Bamer, et al. (2020)	0,0003	/	/	/	- $DO = 0,4$ - ACP	K-partitions ($k = 5$)
Conte Alcaraz et al. (2021)	0,01	100	50	ADAM	- $DO = 0,3$ - Algorithme d'optimisation des poids Xavier - Arrêt anticipé	/
Liang et al. (2021)	/	/	50	/	/	/
Mundt et al. (2021)	0,0003	/	40	/	- $DO = 0,7$ - Recherche Hyperband	VC par exclusion d'un sujet
Rapp et al. (2021)	/	/	/	/	- Estimateur Parzen structuré en arbre ²⁹	K-partitions ($k = 5$)
Sharifi-Renani et al. (2021)	0,001	50	100	ADAM	- $DO = 0,5$	K-partitions ($k = 5$)

Abréviations : TA : Taux d'apprentissage, FO : Fonction d'optimisation, MR : Méthode de régularisation, VC : Validation croisée, DO = *Dropout*, ACP : Analyse en composantes principales³⁰

²⁹ *Tree-structured Parzen Estimator* [traduction libre]

³⁰ *Principal Component Analysis* [traduction de l'OQLF]

Tableau-A VII-2 Résumé des architectures utilisés dans la littérature pour l'apprentissage de RNA de type BiLSTM en analyse de la marche

Référence	Données d'entrée	Disposition interne	Données de sortie
Mundt et al. (2019)	<u>Séquence –</u> <u>30 caract.×</u> <u>101 images</u> 5 × IMU <ul style="list-style-type: none"> • 3 × ACC. (x, y, z) • 3 × vit. ang. (x, y, z) 	NA	<u>Séquence –</u> <u>18 caract.×</u> <u>101 images</u> 3 × axes <ul style="list-style-type: none"> • 2 × ang. hanche • 2 × ang. genou • 2 × ang. cheville
Mundt, Koeppe, Bamer, et al. (2020)	<u>Séquence –</u> <u>{6, 18, 30} caract.×</u> <u>101 images</u> {1, 3, 5} × IMU <ul style="list-style-type: none"> • 3 × ACC. (x, y, z) • 3 × vit. ang. (x, y, z) 1 × cycle <ul style="list-style-type: none"> • 101 × images /cycle 	<u>2 couches LSTM</u> PT-net, PS-net, PCA-net <ul style="list-style-type: none"> • 512 – 1024 unités PTS-net, P-net <ul style="list-style-type: none"> • 256 – 256 unités 	<u>Séquence –</u> <u>18 caract.×</u> <u>101 images</u> 3 × axes <ul style="list-style-type: none"> • 2 × angle hanche • 2 × angle genou • 2 × angle cheville 1 × cycle <ul style="list-style-type: none"> • 101 × images / cycle
Conte Alcaraz et al. (2021)	<u>Séquence –</u> <u>{6, 8, 24, 40, 56} caract.</u> <u>× 124 400 images</u> {1, ..., 5} × IMU <ul style="list-style-type: none"> • 3 × ACC. (x, y, z) • 3 × vit. ang. (x, y, z) 1 × échantillon <ul style="list-style-type: none"> • 124 400 × sec/éch. 	<u>3 couches LSTM</u> <ul style="list-style-type: none"> • Chaque couche LSTM est suivie d'une couche dropout <u>1 couche cachée</u> <u>1 couche linéaire</u>	<u>Séquence –</u> <u>3 caract.×</u> <u>124 400 images</u> 1 × axe <ul style="list-style-type: none"> • 1 × angle hanche • 1 × angle genou • 1 × angle cheville 1 × échantillon <ul style="list-style-type: none"> • 124 400 × sec/éch.
Liang et al. (2021)	<u>Séquence -</u> <u>6 caract.</u> <u>× 5 pas de temps</u> 1 × IMU <ul style="list-style-type: none"> • 3 × ACC. (x, y, z) • 3 × vit. ang. (x, y, z) 5 × pas de temps	<u>1 couche LSTM</u> <u>1 couche cachée</u> <ul style="list-style-type: none"> • 50 neurones 	<u>1 caract.</u> 1 × axe <ul style="list-style-type: none"> • 1 × angle genou

Référence	Données d'entrée	Disposition interne	Données de sortie
Mundt et al. (2021)	<u>Séquence –</u> <u>30 caract.×</u> <u>101 images</u> 5 × IMU <ul style="list-style-type: none"> • 3 × ACC. (x, y, z) • 3 × vit. ang. (x, y, z) 1 × cycle <ul style="list-style-type: none"> • 101 × images / cycle 	<u>2 couches LSTM</u> <ul style="list-style-type: none"> • 32 – 32 unités 	<u>Séquence –</u> <u>18 caract.×</u> <u>101 images</u> 3 × axes <ul style="list-style-type: none"> • 2 × angle hanche • 2 × angle genou • 2 × angle cheville 1 × cycle <ul style="list-style-type: none"> • 101 × images / cycle
Rapp et al. (2021)	<u>Séquence -</u> <u>4 caract.× 60 images</u> 1 × IMU <ul style="list-style-type: none"> • 3 × ACC. (x, y, z) • 1 × ACC 1 × échantillon <ul style="list-style-type: none"> • 60 × sec/éch. 	NA	<u>Séquence –</u> <u>3 caract.× 60 images</u> 3 × axes <ul style="list-style-type: none"> • 3 × angle genou 1 × échantillon <ul style="list-style-type: none"> • 60 × sec/éch.
Sharifi-Renani et al. (2021)	<u>Matrice –</u> <u>200 images</u> <u>× 24 caract.</u> 4 × IMU <ul style="list-style-type: none"> • 3 × ACC. (x, y, z) • 3 × vit. ang. (x, y, z) 2 × pas de temps <ul style="list-style-type: none"> • 100 × images / pas de temps 	<u>1 couche BiLSTM</u> <u>1 couche cachée</u> <ul style="list-style-type: none"> • 128 neurones 	<u>Matrice –</u> <u>200 images</u> <u>× 3 caract.</u> 3 × axes <ul style="list-style-type: none"> • 3 × angle genou 2 × pas de temps <ul style="list-style-type: none"> • 100 × images / pas de temps

ANNEXE VIII

Graphiques des fonctions de perte lors de l'entraînement de chaque partition




Figure-A VIII-1 Courbes de la fonction RMSE pour la partition 1




Figure-A VIII-2 Courbes de la fonction de perte (MSE) et de la RMSE pour la partition 2

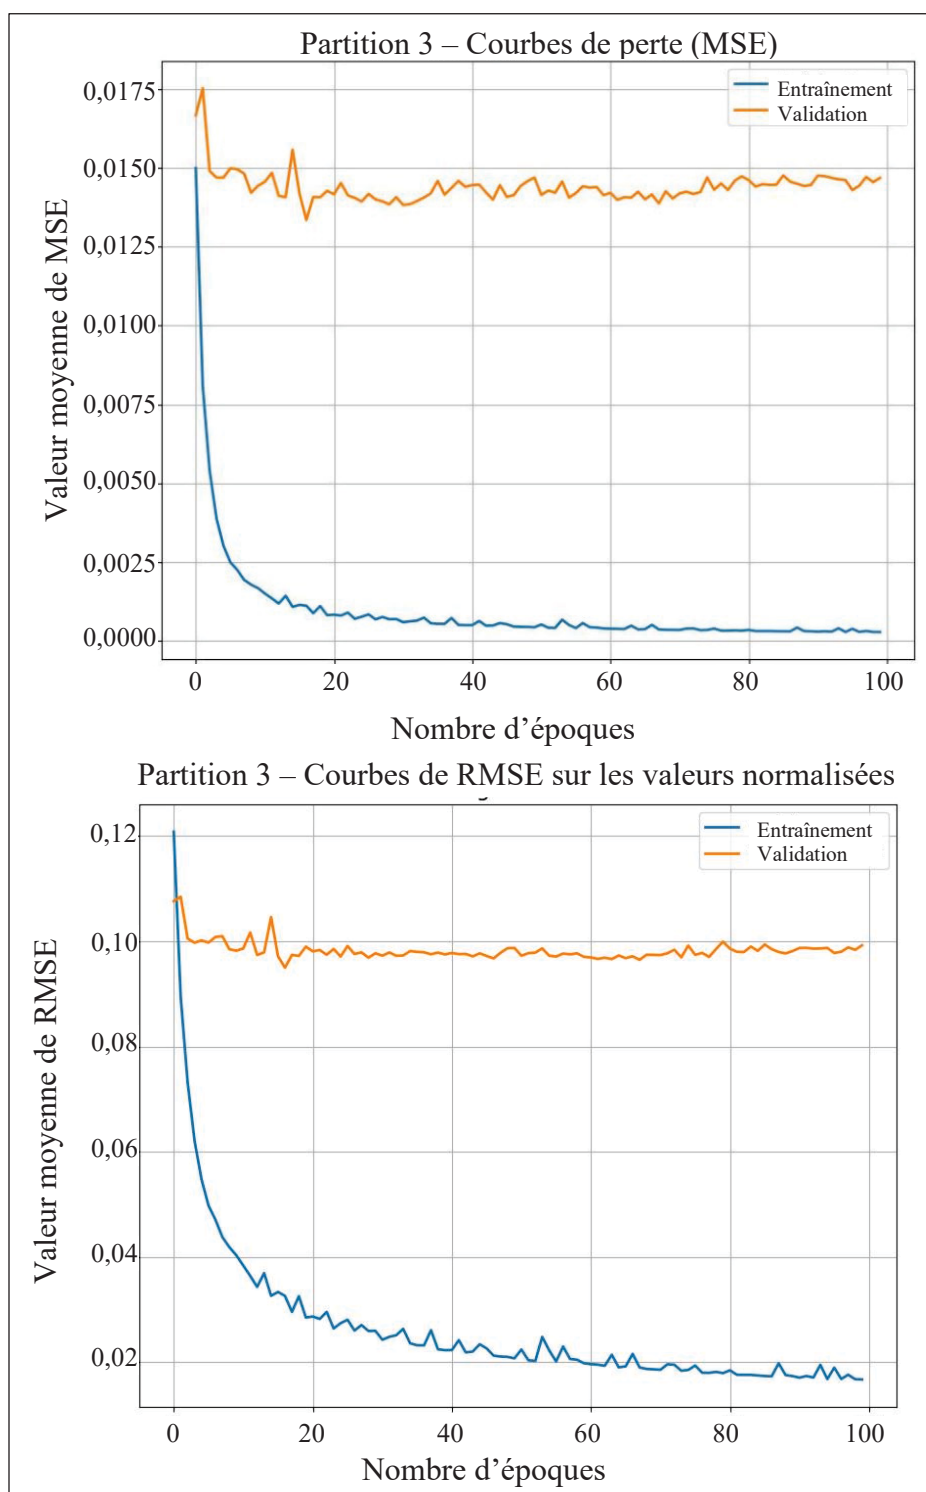


Figure-A VIII-3 Courbes de la fonction de perte (MSE) et de la RMSE pour la partition 3

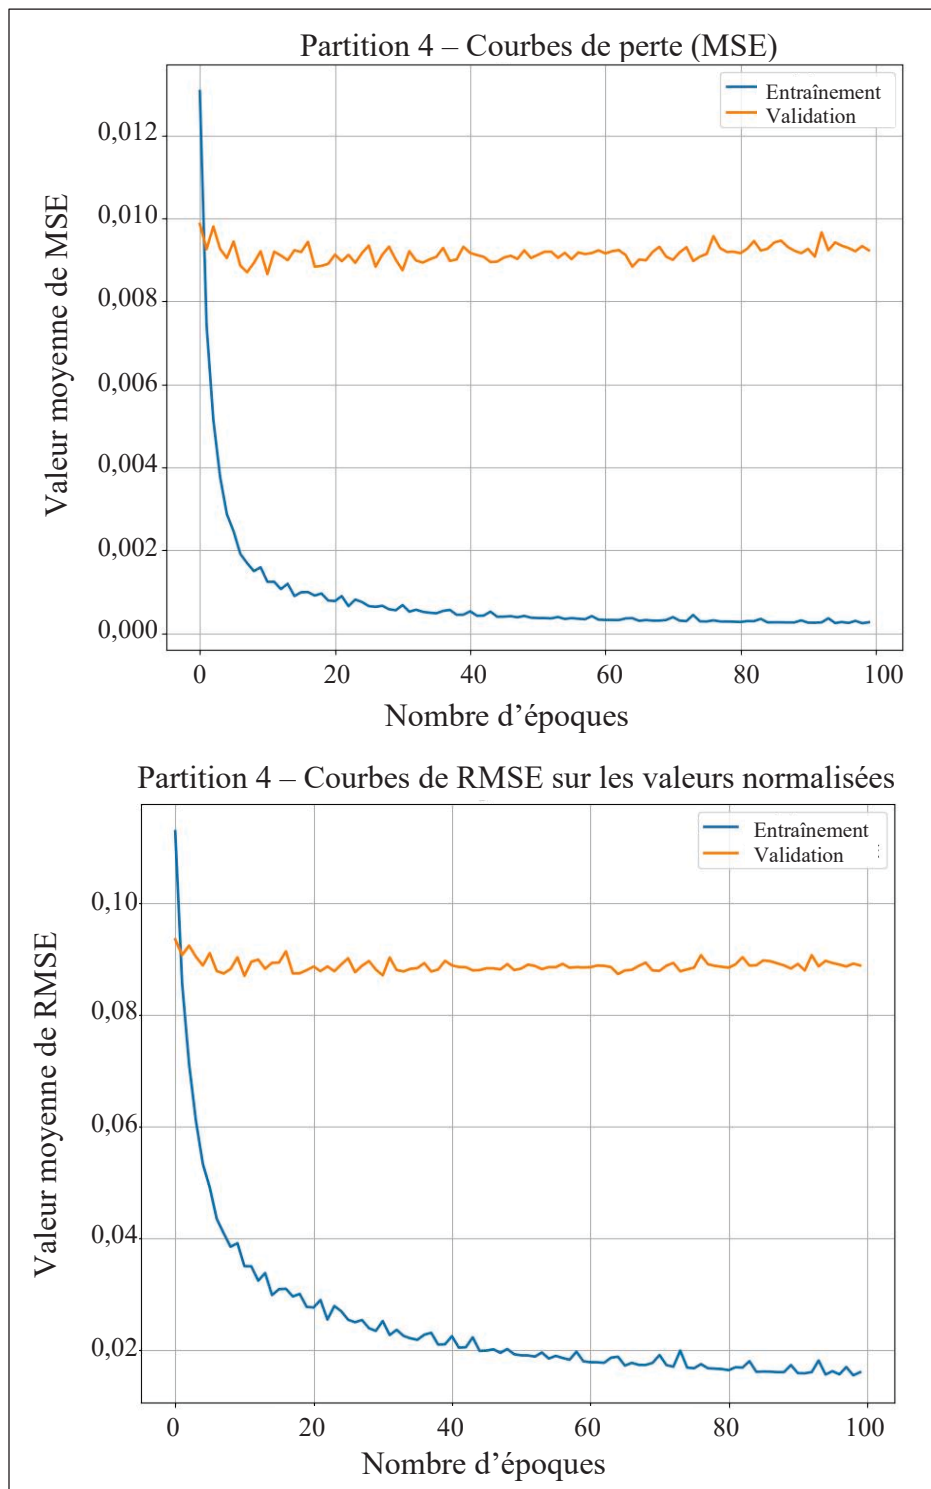


Figure-A VIII-4 Courbes de la fonction de perte (MSE) et de la RMSE pour la partition 4




Figure-A VIII-5 Courbes de la fonction de perte (MSE) et de la RMSE pour la partition 5

ANNEXE IX

Résultats des métriques évaluées sur les bases de test de chaque partition en différenciant les calculs retirant les valeurs extrêmes

Tableau-A IX-1 Résultats des mesures de performance du réseau en fonction de chaque partition en considérant la médiane, la moyenne et la moyenne sans valeurs extrêmes

Axe	Part.	RMSE (°)				nRMSE (%)			
		Méd.	Moy.	ET*	Moy. Ajust.	Méd.	Moy.	ET*	Moy. Ajust.
Ab/Ad	1	3,104	3,695	2,392	2,951	31,01	39,71	30,64	30,68
	2	2,837	3,368	2,026	2,662	28,87	36,31	25,78	27,94
	3	2,848	3,372	2,304	2,780	30,37	39,18	32,57	30,31
	4	3,077	3,553	2,128	2,831	31,26	37,74	24,59	29,92
	5	3,078	3,681	2,352	2,972	32,60	43,48	36,66	33,22
	Moy. ET**	2,989 0,120	3,534 0,143	2,241 0,140	2,839 0,114	30,82 1,22	39,28 2,41	30,05 4,44	30,41 1,69
FI/Ex	1	1,964	2,335	1,308	1,890	3,56	4,48	3,14	3,59
	2	1,759	2,136	1,418	1,692	3,10	3,87	2,72	3,03
	3	2,386	3,222	5,422	2,673	4,28	6,50	14,43	4,98
	4	1,866	2,319	1,621	1,819	3,45	4,29	3,06	3,38
	5	1,991	2,343	1,413	1,867	3,57	4,33	2,81	3,42
	Moy. ET**	1,993 0,213	2,471 0,383	2,236 1,596	1,988 0,349	3,59 0,38	4,69 0,93	5,23 4,60	3,68 0,68
Ri/Re	1	2,447	2,842	1,709	2,333	19,49	24,10	16,57	19,15
	2	2,477	2,928	2,143	2,509	19,92	23,34	16,00	19,56
	3	2,414	2,829	1,689	2,322	18,87	23,29	15,87	18,62
	4	2,494	2,844	1,580	2,318	19,72	23,77	15,37	19,14
	5	2,782	3,205	1,850	2,564	21,28	26,11	17,15	20,52
	Moy. ET**	2,523 0,132	2,930 0,142	1,794 0,194	2,409 0,105	19,86 0,79	24,12 1,04	16,19 0,61	19,40 0,64

Axe	Part.	RMSE (°)				nRMSE (%)			
		Méd.	Moy.	ET*	Moy. Ajust.	Méd.	Moy.	ET*	Moy. Ajust.
Total	1	2,505	2,957	1,803	2,391	18,02	22,76	16,78	17,80
	2	2,358	2,811	1,862	2,287	17,30	21,18	14,83	16,84
	3	2,549	3,141	3,138	2,592	17,84	22,99	20,96	17,97
	4	2,479	2,905	1,777	2,323	18,14	21,93	14,34	17,48
	5	2,617	3,077	1,871	2,468	19,15	24,64	18,88	19,05
	Moy.	2,502	2,978	2,090	2,412	18,09	22,70	17,16	17,83
	ET**	0,155	0,118	0,525	0,109	0,80	1,16	2,48	0,72

*Écart-type évalué sur les résultats de la métrique (RMSE ou nRMSE) pour l'ensemble des échantillons de la base de test de la partition.

**Écart-type évalué sur les résultats de chaque mesure pour l'ensemble des partitions.

APPENDICE A

Article soumis portant sur ce projet de maîtrise

Article soumis dans le cadre du 49^e congrès de la Société de Biomécanique ayant eu lieu du 29 au 31 octobre 2024 à Compiègne (France).

Publication officielle dans le *Multidisciplinary Biomechanics Journal* en date du 31 janvier 2025.

Référence complète de cet article :

Lalonde-Larocque, D., Mezghani, N., J Bureau, N., Aissaoui, R., & Hagemeister, N. (2025). Triaxial knee joint kinematics estimation from inertial measurement units using LSTM neural networks. *Multidisciplinary Biomechanics Journal*, 1(49th congress of the Société de Biomécanique), 253-255. <https://doi.org/10.46298/mbj.14518>

Triaxial knee joint kinematics estimation from inertial measurement units using LSTM neural networks

Daphnée Lalonde-Larocque^{a*}, Neila Mezghani^b, Nathalie J Bureau^c, Rachid Aissaoui^a, Nicola Hagemester^a

^a École de technologie supérieure (ÉTS), Montréal, Canada

^b Université TÉLUQ, Montréal, Canada

^c Université de Montréal, Montréal, Canada

* Corresponding author: daphnee.lalonde-larocque.1@ens.etsmtl.ca

Received date: 05/04/2024

Accepted date: 28/06/2024

Publication date: 31/01/2025

Keywords: gait analysis, LSTM neural networks, knee joint kinematics, IMU

© 2025 The Authors

Licence CC-BY 4.0

Published by Société de Biomécanique

1. Introduction

Gait analysis yields useful data to healthcare providers, whether it be in diagnosis, treatment, or rehabilitation of their patients. Optical motion capture systems are the current standard used in the industry since they generate the best accuracy. However, the complexity of this type of system restricts their usage to a lab environment. To overcome this limitation, the use of inertial measurement units (IMU) is explored as it offers an unconstrained condition alternative. Nonetheless, noise and drift induce inaccuracies, even more so for lower range of motion (ROM) movements such as the knee internal/external rotations (Ir/Er) and abduction/adduction (Ab/Ad) (Poitras et al. 2019).

Combined with proper optimization algorithms, integration of machine learning approaches such as neural networks (NN) offer an improvement in the accuracy of the predicted joint kinematics (Sharifi-Renani et al. 2021). Long short-term memory (LSTM) networks are a class of recurrent NN very well suited for time series data. By making predictions one frame at a time, LSTM uses feedback to remember long-term time dependencies (Mundt et al. 2021) and upgrade its internal state, thus propagating previous information while addressing the vanishing gradient problem (Rapp et al. 2021).

Multiple previous LSTM networks have been trained on databases usually containing not more than 75 different patients to estimate knee joint kinematics from IMUs data. While they usually perform great on angle estimations for higher ROM movements such as flexion/

extension (Fl/Ex), normalized-RMSEs (nRMSE) for lower ROM movements such as Ab/Ad and Ir/Er are usually very high, respectively representing around 12% and 14% of the actual range of the expected values (Rapp et al. 2021; Sharifi-Renani et al. 2021).

The goal of the present study is to train an LSTM network on a larger database and to separate the estimations of each movement to possibly prevent the larger domain of Fl/Ex data to affect the estimations on the lower ROM movements and obtain lower nRMSEs.

2. Methods

2.1 Database and pre-processing

To train the model, we merged marker-based motion capture data from two databases previously collected by CIUSSS de l'Est-de-l'Île-de-Montréal and Maisonneuve-Rosemont hospital, in collaboration with CHUM Research Center, TÉLUQ and ÉTS. The first database consists of 115 healthy subjects (52 men and 63 women, age: 38 ± 17). The second one consists of 560 patients suffering of knee osteoarthritis (OA) to various degrees (216 men and 344 women, age: 62 ± 9 , OA grades 2-4).

Participants were asked to perform multiple 45 seconds walking trials (speed of 0.8 m/s) on a treadmill wearing the KneeKG system (Emovi inc, Canada) on one knee. The trajectories of the shank and thigh clusters of markers were captured at a speed of 60Hz using the Polaris Spectra™ camera system. Inertial data was simulated by deriving the clusters' markers positions,

hence providing 3D angular velocity data from the shank and thigh segments which are used as inputs for the model. Output data was the 3D rotations directly obtained from gait analysis using the KneeKG system.

2.2 LSTM Network

The model used for this study is an LSTM network which combines six (6) normalized angle vectors into a matrix to estimate three (3) knee joint kinematics vectors for each trial. The network contains an LSTM of 200 units, followed by a dropout layer of 0.3, then two hidden layers of sizes 150 and 100, respectively, both using a tanh activation function. Output layers all used a linear activation function.

A window size of 17 frames (W17) was tested using a window function to walk through each trial, providing 722 545 samples. Thus, the model's input is a $[17 \times 6]$ matrix and the outputs are three $[17 \times 1]$ matrices. Model training was performed on a total of 50 epochs with a batch size of 100. The learning rate was set to 0.0001 using an Adam optimizer.

The LSTM network was trained using a 10-folds cross-validation method. Prior to partitioning, 50 subjects were removed from the database to provide a final testing database for further analysis. Each partition contained 62 ± 3 subjects. The models' estimation accuracy was quantified using nRMSE.

3. Results and discussion

Mean nRMSEs over the 10-folds was evaluated for each movement and is presented in Table 1. The model had an overall mean nRMSE of 5.15 ± 0.45 %. Ab/Ad nRMSE was 5.67 ± 0.52 %, Fl/Ex nRMSE was 3.00 ± 0.60 % and Ir/Er nRMSE was 6.57 ± 0.30 %. The model's estimation over each fold for the Fl/Ex axis had consistently the highest accuracy, as opposed to the estimations of the Ir/Er and Ab/Ad axes.

Table 1. 10-folds cross-validation's mean nRMSEs of each output layers

Win. size	Ab/Ad (%)	Fl/Ex (%)	Ir/Er (%)	Mean (%)
W17	5.94 ± 0.53	3.00 ± 0.60	6.57 ± 0.30	5.17 ± 0.48

Credit: Daphnée Lalonde-Larocque (2024)

Multiple studies have trained LSTM networks to predict joint angles of the knee in a similar manner, but

only Sharifi-Renani et al. (2021) provides nRMSE values for all three axes. Their study obtained an overall mean nRMSE of 7.5 ± 3.1 % (6.6 ± 2.3 % for Ab/Ad, 1.9 ± 0.7 % for Fl/Ex and 14.1 ± 6.4 % for Ir/Er). The model we trained yielded better accuracies for the lower ROM movements, as well as a better overall accuracy. On the other hand, nRMSE for the Fl/Ex movement of our model was 1% more than the one of Sharifi-Renani et al. (2021).

This study has a few limitations, such as the number of metrics used to quantify the model's estimations accuracy. To offer better grounds of comparison with the literature, more metrics will be added in the future. Also, it should be noted that gait measurements were taken in a laboratory environment, which could influence the subjects' normal gait patterns.

4. Conclusions

The proposed LSTM network yielded nRMSEs lower than what can currently be seen in the literature for Ab/Ad and Ir/Er movements, which leads us to continue exploring the hypothesis that outputs need to be separated from one another to prevent Fl/Ex data to affect estimations on the other axes.

Acknowledgements

We would like to acknowledge the researchers who contributed to the databases: PA Vendittoli, M Choinière, M Durand, N Gaudreault.

Funding

Funded by Marcelle Gauvreau's research chair of ÉTS.

Conflict of Interest Statement

All authors have no conflicts of interest.

References

- Mundt, M., Johnson, W. R., Potthast, W., Markert, B., Mian, A., & Alderson, J. (2021). A comparison of three neural network approaches for estimating joint angles and moments from inertial measurement units. *Sensors*, 21(13), 4535. doi: [10.3390/s21134535](https://doi.org/10.3390/s21134535)
- Poitras, I., Dupuis, F., Biemann, M., Campeau-Lecours, A., Mercier, C., Bouyer, L. J., & Roy, J.-S. (2019). Validity and Reliability of Wearable Sensors for Joint Angle Estimation: A Systematic Review. *Sensors*, 19(7), 1555. doi: [10.3390/s19071555](https://doi.org/10.3390/s19071555)

- Rapp, E., Shin, S., Thomsen, W., Ferber, R., & Halilaj, E. (2021). Estimation of kinematics from inertial measurement units using a combined deep learning and optimization framework. *Journal of Biomechanics*, *116*, 110229. doi: [10.1016/j.jbiomech.2021.110229](https://doi.org/10.1016/j.jbiomech.2021.110229)
- Sharifi-Renani, M., Eustace, A. M., Myers, C. A., & Clary, C. W. (2021). The Use of Synthetic IMU Signals in the Training of Deep Learning Models Significantly Improves the Accuracy of Joint Kinematic Predictions. *Sensors*, *21*(17), 5876. doi: [10.3390/s21175876](https://doi.org/10.3390/s21175876)

BIBLIOGRAPHIE

- Agence de la santé publique du Canada. (2020, 24 décembre). L'arthrose au Canada. *Gouvernement du Canada*. [recherche]. Repéré à <https://www.canada.ca/fr/sante-publique/services/publications/maladies-et-affections/arthrose.html>
- Antoniou, T., & Mamdani, M. (2021). Évaluation des solutions fondées sur l'apprentissage machine en santé. *CMAJ: Canadian Medical Association Journal*, 193(44), E1720-E1724. <https://doi.org/10.1503/cmaj.210036-f>
- Barua, A., Zakia, U., Menon, C., & Jiang, X. (2021). Deep Learning Techniques in Estimating Ankle Joint Power Using Wearable IMUs. *IEEE Access*, 9, 83041-83054. <https://doi.org/10.1109/ACCESS.2021.3085660>
- Bennett, C. L., Odom, C., & Ben-Asher, M. (2013). Knee Angle Estimation based on IMU data and Artificial Neural Networks. Dans *2013 29th Southern Biomedical Engineering Conference* (pp. 111-112). Miami, FL : IEEE. <https://doi.org/10.1109/SBEC.2013.64>
- Clément, J., Dumas, R., Hagemeister, N., & de Guise, J. A. (2017). Can generic knee joint models improve the measurement of osteoarthritic knee kinematics during squatting activity? *Computer Methods in Biomechanics and Biomedical Engineering*, 20(1), 94-103. <https://doi.org/10.1080/10255842.2016.1202935>
- Clément, J., Toliopoulos, P., Hagemeister, N., Desmeules, F., Fuentes, A., & Vendittoli, P.-A. (2018). Healthy 3D knee kinematics during gait: Differences between women and men, and correlation with x-ray alignment. *Gait & Posture*, 64, 198-204. <https://doi.org/10.1016/j.gaitpost.2018.06.024>
- Conte Alcaraz, J., Moghaddamnia, S., & Peissig, J. (2021). Efficiency of deep neural networks for joint angle modeling in digital gait assessment. *EURASIP Journal on Advances in Signal Processing*, 2021(1), 10. <https://doi.org/10.1186/s13634-020-00715-1>
- de Guise, J. A., Mezghani, N., Aissaoui, R., & Hagemeister, N. (2011). New comprehensive methods for the biomechanical analysis of knee osteoarthritis. Dans *Understanding osteoarthritis from bench to bedside* (Vol. 661, pp. 85-102). (S.l.) : Research Signpost.
- di Falco, C., Aissaoui, R., & Hagemeister, N. (2025). Sensitivity analysis of an inertial calibration method: Influence of leg position on 3D knee kinematics. *Gait & Posture*, 115, 51-58. <https://doi.org/10.1016/j.gaitpost.2024.10.021>
- Dorschky, E., Nitschke, M., Martindale, C. F., Van Den Bogert, A. J., Koelewijn, A. D., & Eskofier, B. M. (2020). CNN-Based Estimation of Sagittal Plane Walking and Running Biomechanics From Measured and Simulated Inertial Sensor Data. *Frontiers in Bioengineering and Biotechnology*, 8, 604. <https://doi.org/10.3389/fbioe.2020.00604>

- Dyas, C. (2019). *Analyse de la marche grâce à la caractérisation de courbes de vitesse angulaire du membre inférieur sur une population de sujets sains et arthrosiques* (Mémoire de maîtrise en génie des technologies de la santé). École de technologie supérieure (ÉTS), Montréal (Québec).
- Elsan. (2024). Ostéophyte. Repéré à <https://www.elsan.care/fr/pathologie-et-traitement/glossaire-medical/orthopedie/osteophyte>
- Figueiredo, J., Carvalho, S. P., Vilas-Boas, J. P., Gonçalves, L. M., Moreno, J. C., & Santos, C. P. (2020). Wearable Inertial Sensor System towards Daily Human Kinematic Gait Analysis: Benchmarking Analysis to MVN BIOMECH. *Sensors*, 20(8), 2185. <https://doi.org/10.3390/s20082185>
- Findlow, A., Goulermas, J. Y., Nester, C., Howard, D., & Kenney, L. P. J. (2008). Predicting lower limb joint kinematics using wearable motion sensors. *Gait & Posture*, 28(1), 120-126. <https://doi.org/10.1016/j.gaitpost.2007.11.001>
- Fong, D. T.-P., & Chan, Y.-Y. (2010). The Use of Wearable Inertial Motion Sensors in Human Lower Limb Biomechanics Studies: A Systematic Review. *Sensors*, 10(12), 11556-11565. <https://doi.org/10.3390/s101211556>
- García-de-Villa, S., Casillas-Pérez, D., Jiménez-Martín, A., & García-Domínguez, J. J. (2023). Inertial Sensors for Human Motion Analysis: A Comprehensive Review. *IEEE Transactions on Instrumentation and Measurement*, 72, 4006439. <https://doi.org/10.1109/TIM.2023.3276528>
- Gasparutto, X., Moissenet, F., Lafon, Y., Chèze, L., & Dumas, R. (2017). Kinematics of the Normal Knee during Dynamic Activities: A Synthesis of Data from Intracortical Pins and Biplane Imaging. *Applied Bionics and Biomechanics*, 2017(1), 1908618. <https://doi.org/10.1155/2017/1908618>
- Gaudreault, N., De Guise, J. A., Hagemeister, N., & Poitras, S. (2011). *Analyse cinématique du genou lors de la marche de travailleurs exposés à une surcharge : une étude pilote* (Rapport No. R-702). IRSST; REPAR-FRSQ.
- Gholami, M., Napier, C., & Menon, C. (2020). Estimating Lower Extremity Running Gait Kinematics with a Single Accelerometer: A Deep Learning Approach. *Sensors*, 20(10), 2939. <https://doi.org/10.3390/s20102939>
- Gholami, M., Rezaei, A., Cuthbert, T. J., Napier, C., & Menon, C. (2019). Lower Body Kinematics Monitoring in Running Using Fabric-Based Wearable Sensors and Deep Convolutional Neural Networks. *Sensors*, 19(23), 5325. <https://doi.org/10.3390/s19235325>

- Grood, E. S., & Suntay, W. J. (1983). A Joint Coordinate System for the Clinical Description of Three-Dimensional Motions: Application to the Knee. *Journal of Biomechanical Engineering*, 105(2), 136-144. <https://doi.org/10.1115/1.3138397>
- Hagemeister, N., Parent, G., Van de Putte, M., St-Onge, N., Duval, N., & de Guise, J. (2005). A reproducible method for studying three-dimensional knee kinematics. *Journal of Biomechanics*, 38(9), 1926-1931. <https://doi.org/10.1016/j.jbiomech.2005.05.013>
- Hanna, M. G., Olson, N. H., Zarella, M., Dash, R. C., Herrmann, M. D., Furtado, L. V., ... Seheult, J. N. (2023). Recommendations for Performance Evaluation of Machine Learning in Pathology: A Concept Paper From the College of American Pathologists. *Archives of Pathology & Laboratory Medicine*, 148(10), e335-e361. <https://doi.org/10.5858/arpa.2023-0042-CP>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. Dans *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 770-778). Las Vegas, NV, USA : IEEE. <https://doi.org/10.1109/CVPR.2016.90>
- Hernandez, V., Dadkhah, D., Babakeshizadeh, V., & Kulić, D. (2021). Lower body kinematics estimation from wearable sensors for walking and running: A deep learning approach. *Gait & Posture*, 83, 185-193. <https://doi.org/10.1016/j.gaitpost.2020.10.026>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hossain, M. S. B., Dranetz, J., Choi, H., & Guo, Z. (2022). DeepBBWAE-Net : A CNN-RNN Based Deep SuperLearner for Estimating Lower Extremity Sagittal Plane Joint Kinematics Using Shoe-Mounted IMU Sensors in Daily Living. *IEEE Journal of Biomedical and Health Informatics*, 26(8), 3906-3917. <https://doi.org/10.1109/JBHI.2022.3165383>
- Huang, Y., He, Z., Liu, Y., Yang, R., Zhang, X., Cheng, G., ... Liu, T. (2019). Real-Time Intended Knee Joint Motion Prediction by Deep-Recurrent Neural Networks. *IEEE Sensors Journal*, 19(23), 11503-11509. <https://doi.org/10.1109/JSEN.2019.2933603>
- ICR - Nice. (2024). L'arthrose du genou. *Institut de Chirurgie Réparatrice Locomoteur & Sport*. Repéré à <https://icr-nice.com/les-pathologies/le-genou/larthrose-du-genou/>
- James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. E. (2023). *An introduction to statistical learning: with applications in Python*. Cham : Springer.
- Kellgren, J. H., & Lawrence, J. S. (1957). Radiological Assessment of Osteo-Arthrosis. *Annals of the Rheumatic Diseases*, 16(4), 494. <https://doi.org/10.1136/ard.16.4.494>

- Kohle, M., Merkl, D., & Kastner, J. (1997). Clinical gait analysis by neural networks: issues and experiences. Dans *Proceedings of Computer Based Medical Systems* (pp. 138-143). Maribor, Slovenia : IEEE Comput. Soc. Press. <https://doi.org/10.1109/CBMS.1997.596423>
- Labbe, D. R., Hagemeister, N., Tremblay, M., & de Guise, J. (2008). Reliability of a method for analyzing three-dimensional knee kinematics during gait. *Gait & Posture*, 28(1), 170-174. <https://doi.org/10.1016/j.gaitpost.2007.11.002>
- Lee, M., & Park, S. (2020). Estimation of three-dimensional lower limb kinetics data during walking using machine learning from a single imu attached to the sacrum. *Sensors (Switzerland)*, 20(21), 6277. <https://doi.org/10.3390/s20216277>
- Lee, T., Kim, I., & Lee, S.-H. (2021). Estimation of the Continuous Walking Angle of Knee and Ankle (Talocrural Joint, Subtalar Joint) of a Lower-Limb Exoskeleton Robot Using a Neural Network. *Sensors*, 21(8), 2807. <https://doi.org/10.3390/s21082807>
- Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., & Talwalkar, A. (2018). Hyperband: A Novel Bandit-Based Approach to Hyperparameter Optimization. *Journal of Machine Learning Research*, 18(185), 1-52.
- Liang, F.-Y., Gao, F., & Liao, W.-H. (2021). Synergy-based knee angle estimation using kinematics of thigh. *Gait & Posture*, 89, 25-30. <https://doi.org/10.1016/j.gaitpost.2021.06.015>
- Lim, H., Kim, B., & Park, S. (2020). Prediction of lower limb kinetics and kinematics during walking by a single IMU on the lower back using machine learning. *Sensors (Switzerland)*, 20(1), 130. <https://doi.org/10.3390/s20010130>
- Lustig, S., Magnussen, R. A., Cheze, L., & Neyret, P. (2012). The KneeKG system: a review of the literature. *Knee Surgery, Sports Traumatology, Arthroscopy*, 20(4), 633-638. <https://doi.org/10.1007/s00167-011-1867-4>
- Marieb, E. N. (2005). *Anatomie et physiologie humaines* (3e édition). Montréal, Québec, Canada : ERPI.
- Miller, C., Portlock, T., Nyaga, D. M., & O'Sullivan, J. M. (2024). A review of model evaluation metrics for machine learning in genetics and genomics. *Frontiers in Bioinformatics*, 4, 1457619. <https://doi.org/10.3389/fbinf.2024.1457619>
- Mon Arthrose. (2024). La gonarthrose. Repéré à <http://www.mon-arthrose.com/arthrose-du-genou/la-maladie/>

- Mundt, M., Johnson, W. R., Potthast, W., Markert, B., Mian, A., & Alderson, J. (2021). A comparison of three neural network approaches for estimating joint angles and moments from inertial measurement units. *Sensors*, 21(13), 4535. <https://doi.org/10.3390/s21134535>
- Mundt, M., Koeppe, A., Bamer, F., David, S., & Markert, B. (2020). Artificial Neural Networks in Motion Analysis—Applications of Unsupervised and Heuristic Feature Selection Techniques. *Sensors*, 20(16), 4581. <https://doi.org/10.3390/s20164581>
- Mundt, M., Koeppe, A., David, S., Witter, T., Bamer, F., Potthast, W., & Markert, B. (2020). Estimation of Gait Mechanics Based on Simulated and Measured IMU Data Using an Artificial Neural Network. *Frontiers in Bioengineering and Biotechnology*, 8, 41. <https://doi.org/10.3389/fbioe.2020.00041>
- Mundt, M., Thomsen, W., Witter, T., Koeppe, A., David, S., Bamer, F., ... Markert, B. (2019). Prediction of lower limb joint angles and moments during gait using artificial neural networks. *Medical and Biological Engineering and Computing*, 58(1), 211-225. <https://doi.org/10.1007/s11517-019-02061-3>
- OpenSim. (2024). OpenSense - Kinematics with IMU Data - OpenSim Documentation. *OpenSim*. Repéré à <https://opensimconfluence.atlassian.net/wiki/spaces/OpenSim/pages/53084203/OpenSense+-+Kinematics+with+IMU+Data>
- Ordóñez, F., & Roggen, D. (2016). Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition. *Sensors*, 16(1), 115. <https://doi.org/10.3390/s16010115>
- Organisation mondiale de la santé. (2023, 14 juillet). Arthrose. *Organisation mondiale de la santé*. Repéré à <https://www.who.int/fr/news-room/fact-sheets/detail/osteoarthritis>
- Palermo, E., Rossi, S., Marini, F., Patanè, F., & Cappa, P. (2014). Experimental evaluation of accuracy and repeatability of a novel body-to-sensor calibration procedure for inertial sensor-based gait analysis. *Measurement*, 52, 145-155. <https://doi.org/10.1016/j.measurement.2014.03.004>
- Planckaert, C. (2016). *Analyse clinique et cinématique de la prothèse totale de genou douloureuse* (Mémoire de maîtrise en génie des technologies de la santé). École de technologie supérieure (ÉTS), Montréal (Québec).
- Ponzio, D. Y., Syed, U. A. M., Purcell, K., Cooper, A. M., Maltenfort, M., Shaner, J., & Chen, A. F. (2018). Low Prevalence of Hip and Knee Arthritis in Active Marathon Runners. *The Journal of Bone and Joint Surgery. American Volume*, 100(2), 131-137. <https://doi.org/10.2106/JBJS.16.01071>

- Rapp, E., Shin, S., Thomsen, W., Ferber, R., & Halilaj, E. (2021). Estimation of kinematics from inertial measurement units using a combined deep learning and optimization framework. *Journal of Biomechanics*, 116, 110229. <https://doi.org/10.1016/j.jbiomech.2021.110229>
- Raschka, S. (2020, 11 novembre). Model Evaluation, Model Selection, and Algorithm Selection in Machine Learning. arXiv preprint. <https://doi.org/10.48550/arXiv.1811.12808>
- Robert-Lachaine, X., Parent, G., Fuentes, A., Hagemester, N., & Aissaoui, R. (2020). Inertial motion capture validation of 3D knee kinematics at various gait speed on the treadmill with a double-pose calibration. *Gait & Posture*, 77, 132-137. <https://doi.org/10.1016/j.gaitpost.2020.01.029>
- Rossi, S., Lisini Baldi, T., Aggravi, M., Ulivelli, M., Cioncoloni, D., Niccolini, V., ... Prattichizzo, D. (2020). Wearable haptic anklets for gait and freezing improvement in Parkinson's disease: a proof-of-concept study. *Neurological Sciences*, 41(12), 3643-3651. <https://doi.org/10.1007/s10072-020-04485-4>
- Sati, M., de Guise, J. A., Larouche, S., & Drouin, G. (1996). Improving in vivo knee kinematic measurements: application to prosthetic ligament analysis. *The Knee*, 3(4), 179-190. [https://doi.org/10.1016/S0968-0160\(96\)00209-8](https://doi.org/10.1016/S0968-0160(96)00209-8)
- Sharifi-Renani, M., Eustace, A. M., Myers, C. A., & Clary, C. W. (2021). The Use of Synthetic IMU Signals in the Training of Deep Learning Models Significantly Improves the Accuracy of Joint Kinematic Predictions. *Sensors*, 21(17), 5876. <https://doi.org/10.3390/s21175876>
- Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2019). The Performance of LSTM and BiLSTM in Forecasting Time Series. Dans *2019 IEEE International Conference on Big Data (Big Data) (Big Data)* (pp. 3285-3292). <https://doi.org/10.1109/BigData47090.2019.9005997>
- Simonyan, K., & Zisserman, A. (2014, 1 septembre). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv e-prints*. <https://doi.org/10.48550/arXiv.1409.1556>
- Soins MSQ Champlain. (2019). Anatomie Genou - Conditions du Genou. Repéré à <https://www.champlainmskcare.ca/conditionsdugenou>
- Stetter, B. J., Krafft, F. C., Ringhof, S., Stein, T., & Sell, S. (2020). A Machine Learning and Wearable Sensor Based Approach to Estimate External Knee Flexion and Adduction Moments During Various Locomotion Tasks. *Frontiers in Bioengineering and Biotechnology*, 8, 9. <https://doi.org/10.3389/fbioe.2020.00009>

- Tan, J.-S., Tippaya, S., Binnie, T., Davey, P., Napier, K., Caneiro, J. P., ... Campbell, A. (2022). Predicting Knee Joint Kinematics from Wearable Sensor Data in People with Knee Osteoarthritis and Clinical Considerations for Future Machine Learning Models. *Sensors*, 22(2), 446. <https://doi.org/10.3390/s22020446>
- Terrier, P., & Reynard, F. (2015). Effect of age on the variability and stability of gait: a cross-sectional treadmill study in healthy individuals between 20 and 69 years of age. *Gait & Posture*, 41(1), 170-174. <https://doi.org/10.1016/j.gaitpost.2014.09.024>
- Tsungnan Lin, Horne, B. G., Tino, P., & Giles, C. L. (1996). Learning long-term dependencies in NARX recurrent neural networks. *IEEE Transactions on Neural Networks*, 7(6), 1329-1338. <https://doi.org/10.1109/72.548162>