



HAL
open science

**Analyse de signaux physiologiques pour la prédiction de
l'évolution pathologique par intelligence artificielle.
Application à la maladie de Parkinson et à l'analyse
quantifiée de la marche**

Nawel Ben Chaabane

► **To cite this version:**

Nawel Ben Chaabane. Analyse de signaux physiologiques pour la prédiction de l'évolution pathologique par intelligence artificielle. Application à la maladie de Parkinson et à l'analyse quantifiée de la marche. Intelligence artificielle [cs.AI]. Université de Bretagne occidentale - Brest, 2023. Français. NNT : 2023BRES0085 . tel-04547276

HAL Id: tel-04547276

<https://theses.hal.science/tel-04547276>

Submitted on 15 Apr 2024

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

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

THÈSE DE DOCTORAT DE

L'UNIVERSITÉ DE BRETAGNE OCCIDENTALE

ÉCOLE DOCTORALE N° 637

Sciences de la Vie et de la Santé

Spécialité : *Analyse et Traitement de l'Information et des Images Médicales*

Par

Nawel BEN CHAABANE

Analyse de signaux physiologiques pour la prédiction de l'évolution pathologique par intelligence artificielle. Application à la maladie de Parkinson et à l'analyse quantifiée de la marche

Thèse présentée et soutenue à Brest, le 01/12/2023

Unité de recherche : Laboratoire de Traitement de l'Information Médicale (LaTIM), INSERM UMR 1101

Rapporteurs avant soutenance :

Amine LAZOUNI Maître de conférences HDR, Université de Tlemcen, Algérie
Hassen DRIRA Professeur des universités, Télécom Physique Strasbourg, France

Composition du Jury :

Président : Amine LAZOUNI Maître de conférences HDR, Université de Tlemcen, Algérie

Examineurs : Hassen DRIRA Professeur des universités, Télécom Physique Strasbourg, France
Pierre-Henri CONZE Maître de conférences, IMT atantique, Brest, France
Béatrice COCHENER Professeur des universités et Praticien hospitalier
Université de Bretagne Occidentale, Brest, France

Dir. de thèse : Béatrice COCHENER Professeur des universités et Praticien hospitalier
Université de Bretagne Occidentale, Brest, France

Invités :

Mathieu LAMARD Ingénieur de recherche, Université de Bretagne Occidentale, Brest, France
Mathieu LEMPEREUR Ingénieur de recherche, CHU de Brest, France

*«Les machines un jour pourront
résoudre tous les problèmes, mais
jamais aucune d'entre elles ne pourra
en poser un !»*

Albert Einstein

REMERCIEMENT

De nombreuses personnes ont contribué d'une manière directe ou indirecte au succès de ce travail de thèse de 3 ans. Le chemin du doctorat, parfois laborieux et difficile, est aussi l'occasion de rencontres. J'espère n'oublier personne dans ce remerciement sans tomber dans l'aspect catalogue.

Je pense que je souhaite tout d'abord remercier les rapporteurs de mon jury de thèse, le professeur **Hassen Drira** et le maître de conférences HDR **Amine Lazouni** qui m'ont fait l'honneur de lire, de commenter et de rapporter ce travail.

Je remercie également la professeur et ophtalmologue **Béatrice Cochener** d'avoir examiné ce travail.

Il m'est impossible d'oublier **Mathieu Lempereur** qui a accepté de faire partie de mon jury de thèse. Grâce à nos différentes rencontres pour discuter des données de la marche, j'ai pu profiter de votre expérience et savoir. Vous étiez toujours prêt à répondre à toutes mes questions avec une précision accrue et une grande bienveillance. Merci infiniment pour tous vos efforts.

Merci également aux membres de mon comité de suivi individuel, **Said Andaloussi** et **Pierre Gasnier** pour leurs précieux conseils et leurs encouragements au cours de nos deux rencontres.

Mes remerciements s'adressent particulièrement au brillant duo **Mathieu Lamard** et **Pierre-Henri Conze** qui m'ont encadrée et soutenue tout au long de ma thèse. J'ai énormément apprécié leur grande disponibilité et leur réactivité. Ils ont été à la fois des encadrants idéaux, mais aussi des personnes avec qui on peut discuter sur un pied d'égalité. Merci du fond du cœur de m'avoir donné l'opportunité de réaliser ce projet à vos côtés.

Je tiens à remercier également **Gwenolé Quellec** pour son aide précieuse au cours de

ma thèse et ses suggestions largement pertinentes. Son expérience, ses connaissances et son appétence pour le domaine ont très fortement contribué à la réussite de ce travail.

J'ai une pensée toute particulière pour **Jean-François Clément** qui était toujours là pour me sauver quand un problème technique avec mon matériel informatique survint. Sans toi, j'aurais terriblement galéré.

Je remercie les membres du **CHU de Brest** d'avoir accepté la collaboration nous permettant de disposer des données de la marche essentielles à la réalisation des travaux liés à cette thèse. Les différents échanges que nous avons pu avoir étaient toujours très constructifs et l'intérêt porté à ce projet fut très stimulant.

Je souhaite également exprimer ma reconnaissance aux différents membres de l'**équipe pédagogique de l'UFR de Sciences et Techniques** avec qui j'ai pu avoir l'occasion d'échanger lors des missions d'enseignement. Je pense notamment à **Jérémy Rivière, Damien Massé, Laurence Duval** et **Mickael Kerboeuf**. Cette expérience m'a été largement fructueuse.

De manière générale, je souhaite également saluer toutes les personnes avec qui j'ai pu échanger des pensées, des joies et des peines au LATIM, pendant ces années : **Isabelle Sanchez, Christelle Besnier, Yihao Li, Philippe Zhang, Rachid Zeglache, Maxime Faure, Mostafa El Habib Daho**, etc. Mes pensées vont en particulier aux doctorantes et post-doctorantes : **Fatima-Zahra, Sarah**, et **Ikram**.

Ces remerciements ne seraient pas complets si je ne remerciais pas **mes parents Tahar** et **Najoua**. Ils m'ont donné la force et les moyens de faire ces études. Je leur en suis très reconnaissante. Pour finir, je souhaite témoigner toute ma gratitude et mon amour à mes sœurs **Faten** et **Nour** et mon frère **Mohamed Ali**. Je sais que je peux compter sur vous pour m'accompagner, quelle que soit la voie que je souhaite emprunter.

TABLE DES MATIÈRES

Introduction	17
1 Contexte	21
1.1 Introduction	21
1.2 Projet FollowKnee	21
1.2.1 Contexte du projet	21
1.2.2 Personnalisation pour une prothèse articulaire sur mesure	22
1.2.3 Vers une implantation chirurgicale plus précise	23
1.2.4 Suivi pour une prise en charge individualisée	23
1.3 Objectifs de la thèse	24
1.4 Recherche de bases de données	24
1.5 Conclusion	27
2 Description des bases de données	29
2.1 Introduction	29
2.2 Base de données EMA	29
2.2.1 La maladie de Parkinson	29
2.2.1.1 Symptômes	29
2.2.1.2 Traitements symptomatiques	30
2.2.2 Description de la base de données	31
2.3 Base de données de l'Analyse Quantifiée de la Marche	34
2.3.1 Un examen clinique standardisé : L'analyse quantifiée de la marche	35
2.3.1.1 La marche humaine	35
2.3.1.1.1 Contexte et définition	35
2.3.1.1.2 Le cycle de marche	35
2.3.1.1.3 La marche dite "normale"	36
2.3.1.1.4 La marche dite "pathologique"	37
2.3.1.2 L'analyse quantifiée de la marche en pratique	38
2.3.1.2.1 Le fonctionnement	38

TABLE DES MATIÈRES

2.3.1.2.2	Le matériel	38
2.3.1.2.3	Les données de l'AQM	39
2.3.1.2.3.1	Paramètres spatio-temporaux	39
2.3.1.2.3.2	Paramètres cinématiques	39
2.3.1.2.3.3	Paramètres cinétiques	39
2.3.1.2.3.4	Paramètres électromyographiques	40
2.3.1.2.3.5	Paramètres cliniques	40
2.3.1.2.4	Le déroulement d'un examen	40
2.3.1.2.4.1	Préparation	40
2.3.1.2.4.2	Bilan clinique et mesures anthropométriques	41
2.3.1.2.4.3	Vidéo fonctionnelle	41
2.3.1.2.4.4	Équipement du patient	41
2.3.1.2.4.5	Enregistrement statique et dynamique	41
2.3.1.2.4.6	Traitement/Réduction des données	42
2.3.1.2.4.7	Interprétation des données	42
2.3.1.2.5	Le score de la marche (<i>Gait Profile Score</i> GPS)	42
2.3.1.2.5.1	Définition et formule	42
2.3.1.2.5.2	La variation du GPS	44
2.3.1.2.6	Les utilisations de l'AQM	45
2.3.1.2.6.1	Synthèse des défauts de marche	45
2.3.1.2.6.2	Effet d'un traitement	46
2.3.1.2.6.3	Suivi de l'évolution de la marche	46
2.3.1.2.7	Les limites de l'AQM	46
2.3.1.2.7.1	Liées à l'acquisition	46
2.3.1.2.7.2	Liées aux modèles	46
2.3.1.2.7.3	Liées à l'expérimentateur	47
2.3.1.2.7.4	Liées au patient	47
2.3.1.2.7.5	Liées aux traitements des données	48
2.3.1.2.7.6	Liées à l'interprétation des données	48
2.3.2	La base de données	50
2.3.2.1	Les patients	50
2.3.2.2	Les pathologies	51
2.3.2.3	Les appareillages	52
2.3.2.4	Les sessions de marche	52

2.4	Conclusion	53
3	Aspects théoriques et bibliographie	54
3.1	Introduction	54
3.2	Principes des réseaux de neurones et de l'apprentissage profond	55
3.2.1	Réseaux de neurones	55
3.2.1.1	Réseaux de neurones à couches multiples	55
3.2.1.2	Réseaux de neurones récurrents	56
3.2.1.2.1	Principe	56
3.2.1.2.2	LSTM	58
3.2.1.3	Réseaux de neurones convolutifs	60
3.2.2	Apprentissage	61
3.2.2.1	Préparation des données d'entrées	62
3.2.2.1.1	Répartition des données	62
3.2.2.1.2	Augmentation de données	63
3.2.2.2	Hyper-paramètres des réseaux	63
3.2.2.3	Sur-apprentissage et sous-apprentissage	63
3.2.2.4	Apprentissage par transfert (<i>transfer learning</i>)	64
3.2.3	Modèles discriminatifs et génératifs	64
3.2.3.1	Modèles génératifs	64
3.2.3.2	Modèles discriminatifs	65
3.3	État de l'art	65
3.3.1	Utilisations de la conversion signal/image	66
3.3.1.1	Transformée de Fourier rapide (<i>Fast Fourier Transform</i> , FFT)	67
3.3.1.2	<i>Gramian angular field</i> (GAF)	67
3.3.1.3	<i>Markov transition field</i> (MTF)	68
3.3.2	Apprentissage profond et analyse de signaux physiologiques	68
3.3.2.1	Classification	68
3.3.2.2	Prédiction	70
3.3.3	Apprentissage profond et maladie de Parkinson	71
3.3.4	Apprentissage profond et AQM	72
3.3.4.1	Augmentation des données	73
3.3.4.2	<i>Transfer learning</i>	74

3.3.4.3	Réseaux de neurones	75
3.3.4.3.1	CNN	75
3.3.4.3.2	RNN	75
3.3.4.3.3	Auto-encodeur	76
3.3.4.3.4	Modèle hybride	77
3.4	Conclusion	78
4	Matériels et méthodes	79
4.1	Introduction	79
4.2	Matériels et méthodes pour EMA	79
4.2.1	Étude de Faisabilité des auteurs de l'article [22]	79
4.2.2	Méthode des auteurs sur une base de test différente et LSTM	80
4.2.2.1	Code des auteurs	80
4.2.2.2	LSTM développée	81
4.3	Matériels et méthodes pour AQM	81
4.3.1	Évaluation du GPS	81
4.3.1.1	Préparation des données	81
4.3.1.2	Méthodes développées	83
4.3.1.2.1	MLP	83
4.3.1.2.2	LSTM	83
4.3.1.2.3	1D-CNN	84
4.3.2	Prédiction de la variation du GPS sans Δd	85
4.3.2.1	Approche signal	86
4.3.2.1.1	Augmentation des données	86
4.3.2.1.1.1	Jittering	86
4.3.2.1.1.2	<i>Scaling</i>	86
4.3.2.1.1.3	Permutation	88
4.3.2.1.1.4	<i>Window warping</i>	88
4.3.2.1.1.5	<i>Window slicing</i>	89
4.3.2.1.2	Technique utilisée	89
4.3.2.1.3	Prédiction de la valeur exacte du ΔGPS	90
4.3.2.1.3.1	Préparation des données	90
4.3.2.1.3.2	Méthodes développées	91
4.3.2.1.4	Prédiction de la classe du ΔGPS	91

4.3.2.1.4.1	Préparation des données	92
4.3.2.1.4.2	Méthodes développées	92
4.3.2.2	Approche image pour la prédiction de la classe du ΔGPS	95
4.3.2.2.1	Description du pipeline	95
4.3.2.2.1.1	GAF	96
4.3.2.2.1.2	MTF	98
4.3.2.2.1.3	2D FFT	98
4.3.2.2.2	Architectures utilisées	99
4.3.3	Prédiction de la classe du ΔGPS avec Δd	101
4.3.3.1	Préparation des données	101
4.3.3.1.1	Augmentation des données	101
4.3.3.1.2	Répartition des données	101
4.3.3.2	Δd ajouté au milieu de l'architecture	102
4.3.3.2.1	MLP	103
4.3.3.2.2	LSTM	103
4.3.3.3	<i>Time-modulated</i> LSTM (tLSTM)	104
4.4	Conclusion	104
5	Résultats	105
5.1	Introduction	105
5.2	Résultats et discussion pour EMA	105
5.2.1	Régression logistique avec une base de test différente	105
5.2.2	LSTM	106
5.2.3	Discussion	106
5.3	Résultats et discussion pour AQM	106
5.3.1	Estimation du GPS	106
5.3.1.1	Résultats	107
5.3.1.2	Discussion	107
5.3.2	Prédiction de la variation du GPS sans Δd	108
5.3.2.1	Approche signal	108
5.3.2.1.1	Prédiction de la valeur du ΔGPS	108
5.3.2.1.1.1	Résultats	108
5.3.2.1.1.2	Discussion	109
5.3.2.1.2	Prédiction de la classe du ΔGPS	109

TABLE DES MATIÈRES

5.3.2.1.2.1	Résultats	110
5.3.2.1.2.2	Discussion	112
5.3.2.2	Approche image	113
5.3.2.2.1	Résultats	113
5.3.2.2.2	Discussion	113
5.3.3	Prédiction de la variation du GPS avec Δd	114
5.3.3.1	Résultats	115
5.3.3.1.1	Δd ajouté au milieu de l'architecture	115
5.3.3.1.2	Time-modulated LSTM (tLSTM)	117
5.3.3.2	Discussion	118
5.4	Conclusion	118
Conclusion		123
A Liste des publications		126
Bibliography		126

TABLE DES FIGURES

2.1	Histogramme des questionnaires complétés	32
2.2	Diagramme en barre de <code>sanpar_onoff</code> sur 14 jours pour un patient donné.	33
2.3	Diagrammes circulaires de <code>sanpar_onoff</code> pour deux patients donnés. . .	34
2.4	Illustration des différents niveaux du système locomoteur	36
2.5	Cinématique d'un cycle de marche	44
2.6	50
2.7	Diagramme circulaire du genre	51
2.8	Diagramme circulaire du genre	51
2.9	Diagramme circulaire des origines	52
2.10	Diagramme circulaire des étiologies.	52
3.1	Structure d'un MLP [86].	56
3.2	Représentation dépliée dans le temps et hiérarchisée des RNN [90]. Les boîtes bleues, rouges et vertes représentent la couche d'entrée, la couche cachée récurrente et celle de sortie respectivement. Les hachures permettent de distinguer l'état du réseau à différents instants temporels.	58
3.3	Une cellule LSTM. Les flèches en pointillé représentent les opérandes avec un décalage temporel ($t - 1$). La fonction d'activation α (pour l'entrée et la sortie) est généralement une tangente hyperbolique (<code>tanh</code>) [90].	59
3.4	Documents par année traitants de l'apprentissage profond appliqué à des signaux mono-dimensionnels.	66
4.1	Architecture du LSTM pour la prédiction ON/OFF.	82
4.2	Histogramme du GPS de tous les cycles.	82
4.3	Architecture du MLP.	84
4.4	Architecture du LSTM.	84
4.5	Architecture du 1D-CNN.	85
4.6	<i>Jittering</i> avec l'ajout de bruit gaussien, avec $\sigma = 0.09$	87
4.7	<i>Scaling</i> avec $\alpha = 0.1$	87

TABLE DES FIGURES

4.8	Permutation de 4 segments de taille égale.	88
4.9	<i>Window warping</i> avec sur-échantillonnage d'une fenêtre de longueur 11.	89
4.10	<i>Window slicing</i>	89
4.11	Histogramme du ΔGPS	90
4.12	FCN.	93
4.13	ResNet.	94
4.14	Encoder.	95
4.15	t-Lenet.	95
4.16	Images GADF d'un cycle de marche.	97
4.17	Images GASF d'un cycle de marche.	98
4.18	Images MTF d'un cycle de marche.	99
4.19	(a) Cycle de marche. (b) Amplitude de la 2D FFT. (c) Amplitude centralisée de la 2D FFT.	100
4.20	Histogramme de Δd en jours.	102
4.21	MLP intégrant le Δd	103
4.22	LSTM intégrant le Δd	103
5.1	Courbes ROC des différentes architectures de l'approche signal	111
5.2	Courbes ROC des différentes architectures de l'approche image 2D FFT.	115
5.3	Matrice de confusion [241].	117
5.4	test AUC en fonction du Δd en années pour le MLP.	119
5.5	test AUC en fonction du Δd en années pour le LSTM.	120
5.6	test AUC en fonction du Δd en années pour le tLSTM.	120

LISTE DES TABLEAUX

1.1	Bases de données identifiées.	28
2.1	Aperçu du questionnaire de la base de données EMA.	33
2.2	Les appareillages	53
4.1	Pourcentages de la variable ON.	81
4.2	Répartition des données pour l'évaluation du GPS.	83
4.3	répartition de données entre entraînement, validation et test.	91
4.4	Répartition des données	102
5.1	Résultats du LSTM pour EMA.	106
5.2	Résultats de l'estimation du GPS.	107
5.3	Hyperparamètres utilisés pour l'estimation du GPS.	107
5.4	Résultats de la prédiction de la valeur du ΔGPS	108
5.5	Hyperparamètres utilisés dans la prédiction de la valeur du ΔGPS	108
5.6	Répartition des données des enfants.	109
5.7	Hyperparamètres utilisés la prédiction de la valeur du ΔGPS pour les enfants.	109
5.8	Hyperparamètres utilisés dans la prédiction de la valeur du ΔGPS pour les enfants.	109
5.9	Résultats de la prédiction de la classe du ΔGPS par l'approche signal.	110
5.10	Hyperparamètres du MLP et LSTM utilisés dans la prédiction de la classe du ΔGPS par l'approche signal.	110
5.11	p -values du test statistique de Delong pour tous les patients avec l'approche signal.	110
5.12	Résultats de la prédiction de la classe du ΔGPS pour les enfants avec l'approche signal.	111
5.13	Hyperparamètres utilisés pour les enfants.	112
5.14	Résultats de la prédiction de la classe du ΔGPS à l'échelle de l'examen avec l'approche signal.	112
5.15	Hyperparamètres utilisés dans la prédiction à l'échelle de l'examen.	112

5.16 Résultats de la prédiction de la classe du ΔGPS par l'approche image. . . 113

5.17 Hyperparamètres des 2D-CNN utilisés dans la prédiction de la classe du ΔGPS avec l'approche image. 114

5.18 *p-values* du test Delong obtenues par l'approche image. 114

5.19 Résultats pour le Δd ajouté au milieu de l'architecture. 115

5.20 Hyperparamètres MLP et LSTM - Δd ajouté au milieu de l'architecture. . 116

5.21 Nombre de paramètres MLP et LSTM - Δd ajouté au milieu de l'architecture. 116

5.22 Matrices de confusion - Δd ajouté au milieu de l'architecture. 116

5.23 Résultats du tLSTM. 117

5.24 Hyperparamètres du tLSTM. 117

5.25 Nombre de paramètres du tLSTM. 118

5.26 *p-values* du test Delong comparent les deux approches incluant le Δd 118

5.27 *p-values* du test Delong pour les MLP et LSTM sans et avec Δd 118

5.28 Répartition du Δd en année. 119

INTRODUCTION

L'apprentissage profond est de plus en plus utilisé et l'état de l'art évolue rapidement. Il est basé sur des réseaux de neurones artificiels qui permettent d'extraire les caractéristiques nécessaires à partir de données fournies pour résoudre une tâche spécifique. Il existe de nombreuses utilisations comme la classification, la traduction ou encore la détection d'anomalie. On peut noter, depuis quelques années, la présence d'un engouement de plus en plus important pour l'application de l'apprentissage profond aux signaux physiologiques. Ces derniers sont très répandus dans le domaine médical vu la richesse de l'information qu'ils portent et la standardisation de leurs processus d'acquisition. À titre d'exemple, de nombreuses approches ont été proposées pour la classification des états de sommeil à partir de signaux ECG (électrocardiogramme), enregistrés par des appareils portatifs à domicile. Par ailleurs, certains travaux de la littérature se sont intéressés à la détection de l'arythmie dans des signaux ECG. Un autre cas d'utilisation est la détection de crises d'épilepsie à partir de signaux EEG (électroencéphalogramme).

D'une manière générale, certaines approches de l'apprentissage profond visent à diagnostiquer une anomalie ou une pathologie donnée à partir de signaux physiologiques (tel est le cas des exemples cités précédemment), alors que d'autres se proposent d'aller plus loin en mettant en place un suivi de patients atteints d'une certaine pathologie tout au long de leurs parcours de soin. Ce suivi patient à long terme a pour principaux objectifs de :

- permettre au patient d'accéder à une prise en charge complète, personnalisée et de qualité. Ce dernier se verra bénéficier de soins adéquats au bon moment, et ce dans les structures adaptées. Cela englobe aussi la détection et la gestion des effets indésirables des traitements. L'ajustement dans le temps de l'option de soins s'avère nécessaire des fois,
- gérer les conséquences psychologiques de la maladie sur la vie personnelle, sociale et professionnelle du patient,
- détecter une éventuelle récurrence ou rémission de la maladie,
- prévenir une complication ou une comorbidité éventuelle de celle-ci.

Le suivi des patients et des personnes âgées en utilisant des capteurs portables et/ou des applications mobiles envoyant des notifications invitant à répondre à des questionnaires est

devenu un objet de réelle discussion dans la communauté des chercheurs en informatique et des professionnels de santé. Nous parlons aujourd’hui de maisons intelligentes, c’est-à-dire équipées par des capteurs qui grâce à la technologie de l’information permettent aux personnes qui devraient normalement être placées dans des établissements spécialisés de vivre en autonomie. Les patients portent des capteurs et/ou utilisent des applications mobiles qui surveillent les signes vitaux signalés en temps réel à leur médecin. Cela leur permet d’améliorer la qualité de leurs soins de santé et d’économiser de l’argent. Si la mise en place d’une architecture de télésurveillance n’est pas possible, un suivi régulier dans un cadre hospitalier s’avère nécessaire.

Une partie du financement de cette thèse a été assurée par le projet de l’Agence Nationale de la Recherche (ANR) Followknee (ANR-17-RHUS-0005) qui a pour objectif de concevoir une prothèse de genou totalement connectée et de prédire de la manière la plus précise possible des anomalies éventuelles (une infection par exemple) chez les patients opérés d’une arthroplastie totale de genou. La présente thèse s’intéresse à la prédiction de l’évolution pathologique dans des signaux biomédicaux monodimensionnels par intelligence artificielle dans l’intention de garantir un meilleur suivi du patient. Dans ce cadre, nous avons travaillé sur deux applications différentes : celle de la maladie de Parkinson et celle de l’analyse quantifiée de la marche (AQM). Dans la première, la base de données *Ecological Momentary Assessment* (EMA) a été analysée. Cette dernière comporte une vingtaine de patients ayant porté trois unités de mesure (accéléromètre et gyroscope) sur 14 jours et répondu à des questionnaires journaliers à propos de leur état de santé, leur traitement, ainsi que leur fonction motrice. Notre objectif était de prédire les réponses des patients à une question particulière portant sur leur état de santé global en utilisant les données des capteurs collectées juste avant l’enregistrement des réponses concernées. Pour ce faire, les auteurs de la base de données ont proposé une régression logistique qu’ils ont testée sur un seul patient. Pour aller plus loin, nous avons élargi la base de test considérée et comparé les résultats obtenus à ceux donnés par un *Long Short Term Memory* (LSTM). Les LSTM sont issus des réseaux de neurones récurrents.

La base de données AQM contient les données cinématiques de plus de 600 patients suivis de manière longitudinale. Une AQM est un examen standardisé permettant l’évaluation des difficultés au cours de la marche et fournissant une aide thérapeutiques. Nous nous sommes intéressés au *Gait Profile Score* (GPS) qui est une mesure de la déviation de la marche d’un patient donné par rapport à celle normale d’une population de référence. Par définition, plus il est petit, mieux c’est. L’objectif était de prédire le sens de sa varia-

tion à partir des cinématiques. Dans un premier temps, nous n'avons pas pris en compte l'écart temporel entre les examens. Deux approches ont été considérées : l'approche signal utilisant les données brutes de la cinématique et l'approche image qui repose sur une conversion des signaux en images. Dans un second temps, nous avons pris en compte l'information temporelle de deux manières différentes : la concaténation avec le vecteur de caractéristiques extrait par le modèle et l'utilisation de *time-LSTM*.

CONTEXTE

1.1 Introduction

Dans ce premier chapitre, le projet FollowKnee dans lequel se positionne cette thèse est présenté d'une manière générale ainsi que les objectifs de ce travail qui tournent autour du suivi longitudinal post-opératoire de l'arthroplastie totale de genou. Étant toujours en cours, il n'était pas possible d'en utiliser les données pour mener à bien les travaux de cette thèse. De ce fait, notre premier défi consistait à trouver des bases de données suffisamment représentative et similaire au contexte du projet FollowKnee. Une description concise de chacune des bases de données identifiées est également fournie dans ce qui suit.

1.2 Projet FollowKnee

1.2.1 Contexte du projet

La chirurgie de remplacement de genou (appelée aussi arthroplastie totale du genou) consiste à remplacer les zones d'os et de cartilage usées par des pièces artificielles de même forme (une prothèse). Selon une analyse de l'Agence Nationale de Sécurité du Médicament et des produits de santé (ANSM) exploitant les données de l'assurance maladie, 80 819 prothèses totales de genou ont été posées en France en 2013, soit environ 30% de plus qu'en 2008. Avec 100 000 implantations pour l'année 2019, l'arthroplastie totale du genou est devenue l'une des opérations orthopédiques majeures de nos jours. La croissance projetée pour les prochaines décennies est supérieure à 100% [1]-[4]. Le vieillissement de la population, la montée de l'obésité et une opération de plus en plus jeune sont les causes du caractère explosif de la demande.

L'indication la plus fréquente de la chirurgie de remplacement du genou est l'arthrose (90% des cas). Elle constitue l'une des 10 maladies les plus invalidantes dans les pays développés. Selon l'Organisation Mondiale de la Santé (OMS), 9,6% des hommes et 18%

des femmes de plus de 60 ans en souffrent à l'échelle mondiale. Cette pathologie articulaire engendre la destruction du cartilage. Les ligaments, les os, les muscles ainsi que le liquide synovial sont aussi altérés, entraînant des douleurs et une gêne fonctionnelle. Le but d'une prothèse est de soulager la douleur et de récupérer une bonne mobilité du genou.

C'est dans ce cadre de chirurgie de remplacement de genou que se situe le projet FollowKnee. Doté d'un budget de 24 millions d'euros, dont un tiers apporté par l'État, le projet est porté par un consortium scientifique et industriel, coordonné par l'Inserm (Institut national de la santé et de la recherche médicale) et le LaTIM (Laboratoire de Traitement de l'Information Médicale, UMR 1101, Inserm), et comprenant les partenaires suivants : UBO (Université de Bretagne Occidentale), IMT Atlantique, CHRU de Brest, CEA-Leti, Imascap, SLS France, Immersion, b<>com et Biototech Santé Bretagne.

Prévu sur 5 ans avec l'objectif d'apporter une réponse innovante à la chirurgie de remplacement de genou, FollowKnee s'organise autour de deux étapes clés : conception, fabrication et implantation de prothèses d'une part et réalisation d'un suivi temporel post-opératoire d'autre part, et ce grâce à différents capteurs (pH, température, pression) intégrés aux prothèses. Il s'agit d'abord de proposer une nouvelle prothèse sur mesure. La technologie d'impression 3D est utilisée dans la génération et la fabrication de cette prothèse personnalisée. Le deuxième objectif du projet FollowKnee est l'assistance du chirurgien pendant l'intervention en lui permettant d'avoir directement dans son champ de vision tous les paramètres de pose. Dans cette optique, le développement d'un système de réalité augmentée est planifié. Le dernier volet du projet consiste à proposer un programme de rééducation personnalisé, un suivi post-opératoire adapté et une détection préventive des infections. En somme, personnalisation, précision et suivi sont les trois enjeux de FollowKnee.

1.2.2 Personnalisation pour une prothèse articulaire sur mesure

La prothèse de genou pensée dans le cadre de FollowKnee est personnalisée selon la morphologie du patient, afin d'améliorer la satisfaction post-opératoire. Un logiciel spécialement dédié et utilisant l'intelligence artificielle (IA) est développé pour créer une prothèse entièrement sur mesure et correspondant au genou du patient. À terme, ce logiciel permettra aux chirurgiens de concevoir et de produire automatiquement, à partir d'images tomodensitométriques (TDM) ou par résonance magnétique (IRM) pré-opératoires, une nouvelle génération de prothèses personnalisées et imprimées en 3D. Les fichiers de personnalisation ainsi obtenus seront envoyés à l'industriel pour une fabrication par impression 3D. De nouveaux alliages métalliques plus légers et plus résistants seront utilisés.

1.2.3 Vers une implantation chirurgicale plus précise

Sur le même logiciel de personnalisation, le chirurgien pourra préparer son opération en prenant en considération les paramètres individuels de chaque patient. Après la personnalisation et la préparation, le chirurgien sera en mesure de poser la prothèse sur le patient. Durant cette opération, il aura recours à un nouveau système de guidage développé et conçu dans le cadre du projet. Cet outil s'appuie sur les concepts de la réalité augmentée. Toutes les informations du patient issues de la planification seront superposées sur le genou grâce à un casque de réalité augmentée. Le chirurgien se focalisera ainsi sur la zone opératoire, sans écran annexe à regarder. Un affichage holographique l'informerá de la bonne pose des guides de coupe (pour retirer l'os à couper) et de la prothèse. A l'image d'un pilote d'avion, le chirurgien aura dans son champ visuel à la fois le patient opéré et les paramètres de pose de la prothèse. Ce système est conçu pour s'intégrer à l'environnement hospitalier sans être intrusif au regard des technologies employées actuellement.

1.2.4 Suivi pour une prise en charge individualisée

Cette prothèse de genou nouvelle génération sera connectée. À terme, elle enverra les données collectées de ces capteurs intégrés aux différents utilisateurs (médecins, chercheurs, patients). Elle sera donc capable d'assurer un suivi post-opératoire personnalisé et préventif pour améliorer la rééducation et éviter (ou retarder) la reprise chirurgicale. Sans suivi, le risque d'une reprise chirurgicale n'en sera que plus probable. Cette chirurgie de révision, dont la fréquence augmente rapidement, est iatrogène et d'efficacité fonctionnelle moindre. Les capteurs embarqués viseront à détecter précocement des problèmes :

- de descellement mécanique ou d'usure grâce à des mesures de paramètres physiques (pression, angle),
- d'infection grâce à des mesures de pH et de température.

Avec le temps, le patient peut voir sa qualité de vie se dégrader, étant exposée à un risque accentué de descellement, d'usure prématurée ou d'infection. Les données issues des capteurs seront sécurisées par cryptographie. Une infrastructure de stockage et de partage assurera la traçabilité et la sécurité des données et des échanges. Par ailleurs, elles seront consultables et visualisables par les professionnels et les patients sur une plateforme web dédiée. Des outils d'IA seront mis en œuvre pour l'exploitation, la gestion des données pour l'aide à la décision, la télésurveillance et l'analyse prédictive. L'ensemble des données recueillies par la prothèse intelligente FollowKnee permettront ainsi, lors du

suivi et de la vie de tous les jours post-opératoire du patient :

- au chirurgien, d'identifier précocement les problèmes liés à la prothèse (descellement, usure ou infection), sans forcément réopérer et d'assurer un suivi personnalisé et à distance du patient,
- lors de la rééducation, de proposer des exercices adaptés à la morphologie articulaire des patients, afin d'optimiser la récupération d'une articulation fonctionnelle,
- au patient, de pouvoir suivre l'évolution de sa propre prothèse.

1.3 Objectifs de la thèse

L'analyse des données issues des différents capteurs de la prothèse est un élément clé du projet Followknee. Ces données numériques ont de nombreuses particularités. Elles seront recueillies à un rythme aléatoire et peuvent être incomplètes et bruitées. Le but de cette thèse est de développer des algorithmes exploitant des techniques issues de l'IA permettant de détecter et prédire, avec le plus de précision possible, les éventuelles infections et comportements biomécaniques anormaux à partir des données recueillies. Certains éléments de Followknee sont toujours en cours de développement ou de conception. De ce fait, aucune donnée issue du projet n'était disponible pour cette thèse. Par conséquent, notre premier défi a été de trouver une base de données proche de celle du projet FollowKnee : un ensemble de signaux physiologiques (idéalement issus de capteurs) permettant un suivi longitudinal de façon à rendre une tâche de détection de changement possible. Dans ce qui suit, nous présenterons les principales bases de données *open source* identifiées. Nous avons constaté à travers cette recherche effectuée en début 2021 que les données multi-capteurs et monodimensionnelles (séries temporelles multivariées) sont utilisées dans des domaines variés, avec une prépondérance d'applications liées à la classification d'activités, ce qui ne répond pas à nos besoins. En effet, notre centre d'intérêt est la détection de changement qui consiste à repérer les évolutions d'une donnée en entrée au cours d'un certain laps de temps, tandis que la classification attribue à une donnée figée une classe (catégorie) parmi un ensemble de classes prédéfinies.

1.4 Recherche de bases de données

Cette étape du travail nous a éclairés sur la grande variété des domaines d'application des séries temporelles consacrées à la recherche médicale.

La première est celle des frappes de clavier, ***Tappy Keystroke Data***¹ [5] [6]. 200 utilisateurs ont été recrutés dont des personnes atteintes par la maladie de Parkinson pour enregistrer la frappe de leurs propres claviers (sans aucune supervision humaine) pendant des mois (de 1 à 8), via une application personnalisée nommée *Tappy*. Après son installation, le participant utilise son ordinateur d'une manière ordinaire (consultation du courrier électronique, traitement de texte, recherches sur le web...). *Tappy* génère un fichier d'enregistrement par mois. Le nombre d'entrées (enregistrements) par fichier est très variable (de 9 à 90000 environ). Une entrée contient les champs suivants :

- La date et l'horodatage (*timestamp*) sous la forme HH:MM:SS.SSS.
- Le temps de maintien (*hold time*) : temps entre la pression (*key press*) et le relâchement de la touche actuelle (**release**) en millisecondes.
- Le temps de latence (*latency time*) : temps écoulé entre l'appui sur la touche précédente et l'appui sur la touche actuelle en millisecondes.
- Le temps de vol (*flight time*) : temps écoulé entre le relâchement de la touche précédente et l'appui sur la touche actuelle en millisecondes.

Les données de frappe générées ont été analysées afin de démontrer leur utilité pour détecter les changements dans les caractéristiques du mouvement des doigts des patients atteints de Parkinson dans les premiers stades de la maladie. Le but final était de réaliser une détection précoce de la maladie de Parkinson à l'aide de multiples caractéristiques du mouvement des doigts lors de la frappe.

La deuxième base de données est celle de l'**estimation de la vitesse de la marche**. Elle a été employée dans [7]. Elle utilisait un ensemble d'accéléromètres collés à la peau de sujets sains et atteints de différentes scléroses et ayant été recrutés pour réaliser des activités physiques sur tapis roulant. Les données de capteurs brutes n'étaient pas à disposition, mais plutôt les caractéristiques extraites de celles-ci. Le but de l'étude était de prédire la vitesse de la marche par apprentissage machine.

Concernant la base de données ***Hospital-activity-bosch***² [8][6], 58 patients hospitalisés étaient invités à effectuer des activités physiques en étant équipés d'un certain nombre de capteurs : accéléromètre, gyroscope, capteur de température et d'humidité et capteur de pression atmosphérique. La fréquence d'échantillonnage était de 100Hz pour les capteurs

1. <https://physionet.org/content/tappy/1.0.0/>

2. <https://physionet.org/content/hospital-activity-bosch/>

inertiels et de 1Hz pour le reste des capteurs. L'utilisation de la base de données consistait à prédire la durée d'hospitalisation et le risque de réadmission dans le mois suivant la décharge.

La quatrième base de données *A smartphone enabled wireless and batteryless implantable blood flow sensor for remote monitoring of prosthetic heart valve function*³ [9] utilisait un capteur de débit sanguin embarqué dans un mobile pour la télésurveillance de la fonction de valves cardiaques prothétiques, dans une optique de faciliter la prise en charge des maladies cardio-vasculaires.

La cinquième base de données est *Diabetes Data Set*⁴. Elle comporte des enregistrements appartenant à 70 patients diabétiques et provenant de deux sources différentes : un dispositif d'enregistrement électronique et des dossiers papiers. L'expérience s'est étalée sur des semaines, de 51 à 1 327 jours. L'appareil électronique disposait d'une horloge interne permettant d'horodater les mesures et les événements, tandis que les dossiers papiers ne fournissaient que des "horaires logiques" fixes : petit-déjeuner (8h00), déjeuner (12h00), dîner (18h00), heure du coucher (22h00). Les informations enregistrées étaient : les doses de trois insulines différentes (régulière, NPH (*Neutral Protamine Hagedorn*) et ultra lente), la glycémie à différents moments de la journée (hors repas, avant/après le petit-déjeuner, avant/après le déjeuner et avant/après le dîner), les symptômes d'hypoglycémie, si l'activité physique du patient était plus importante que d'habitude et des informations sur la digestion des repas consommés. Diabetes Data Set met à disposition environ 1 000 enregistrements (mesure ou événement) par patient. Un cas d'utilisation possible de cette base de données est de suivre l'évolution de la glycémie pour mieux adapter le traitement d'insulinothérapie.

Pour la sixième base de données⁵, l'étude menée portait sur **le suivi continu de la mobilité pendant 18 mois après une chirurgie du genou** en réponse à une fracture du plateau tibial [10]. Les patients étaient des hommes de 36 ans. Le capteur utilisé était un accéléromètre de 100 Hz porté à la taille pour une collecte de données sur une période

3. https://figshare.com/articles/dataset/A_smartphone_enabled_wireless_and_batteryless_implantable_blood_flow_sensor_for_remote_monitoring_of_prosthetic_heart_valve_function/11606943

4. <https://archive.ics.uci.edu/ml/datasets/diabetes>

5. https://github.com/Novartis/mueller_et_al_2018

de 553 jours, avec un taux de conformité supérieur à 80 %. Par ailleurs, le suivi reposait sur un journal quotidien avec annotation des événements majeurs (chutes, quasi-chutes, périodes de vélo ou séances de kinésithérapie) et des dates clés du parcours du patient, y compris les interventions médicales, l'abandon des béquilles, le rétablissement et le retour au travail. Le but final de l'étude consistait à montrer l'importance du suivi des patients pour une meilleure prise en charge (adaptation du traitement) et réadaptation.

1.5 Conclusion

Toutes ces bases de données ne pouvaient pas servir dans le cadre de cette thèse, soit parce qu'elles ne modélisaient pas l'évolution d'une pathologie donnée (*Tappy Keystroke Data*, la base de données de l'estimation de la vitesse de la marche ainsi que *Hospital-activity-bosch*), soit parce qu'elles n'utilisaient qu'un seul type de capteurs (les bases de données de l'estimation de la vitesse de la marche et du suivi de la mobilité). Pour la base de données des patients diabétiques (*Diabetes Data Set*), le taux de la glycémie mesuré à différents moments de la journée reflète l'état de santé du patient. Cependant, nous l'avons rejetée, car elle présente de nombreuses données manquantes. À titre d'exemple, la mesure de glycémie après le petit déjeuner est présente dans uniquement 0.11% des enregistrements (tous patients confondus) et celle de l'insuline ultra latente dans 5.7% des cas. Certains événements comme une hypoglycémie ne sont jamais apparus chez 32 patients (soit chez 45.71% des patients). Néanmoins, une étude [11] s'est intéressée à la prédiction du prochain niveau de glycémie avant le petit-déjeuner, indicateur complet à 19.05%, en utilisant les techniques de modélisation paramétrique autorégressive (AR) et autorégressives moyennes mobiles (*AutoRegressive Moving Average*, ARMA).

Pour résumer, nos critères de recherche de bases de données imposent les trois caractéristiques suivantes :

- des données multi-capteurs et mono-dimensionnelles,
- une évolution d'une pathologie donnée pour permettre une tâche de détection de changement,
- des données complètes, exploitables et interprétables.

La Table 1.1 montre la satisfaction des trois critères pré-cités par chacune des bases de données identifiées et décrites précédemment.

	Multi-capteurs, 1-D	Évolution	Exploitabilité
<i>Tappy Keystroke Data</i>	×		×
Estimation de la vitesse de marche			×
<i>Hospital-activity-bosch</i>	×		×
<i>Blood flow sensor</i>		×	×
<i>Diabetes Data Set</i>	×	×	
Suivi de la mobilité		×	×

TABLE 1.1 – Bases de données identifiées.

Cette première recherche de ressources publiquement accessibles n’a pas répondu favorablement aux besoins de ce travail. Cependant, une recherche ultérieure plus avancée a permis d’identifier une base de données de patients atteints de la maladie de Parkinson appelée *Ecological Momentary Assessment (EMA) and wearable sensor monitoring in Parkinson disease*^{6 7}.

EMA propose d’évaluer les pensées et les comportements des individus dans leurs vies quotidiennes. Cela repose sur des recueils répétitifs de données dans l’environnement normal de la personne, et ce à des moments bien précis. Grâce au progrès technologique et numérique, de nouvelles méthodes automatiques de collecte de données, en temps réel parfois, ont émergé : capteurs, applications mobiles, notifications ou questionnaires envoyés à des intervalles prédéfinis. EMA se montre ainsi utile pour comprendre les changements au fil du temps chez un individu, par exemple les changements d’humeur ou de consommation d’alcool au cours du temps.

Quelques mois plus tard, nous avons reçu l’approbation d’utiliser la base de données de l’analyse quantifiée de la marche (AQM) dont nous étions avertis de l’existence au sein du CHRU de Brest. La base de données AQM constituera le cœur des travaux de cette thèse qui consiste principalement en une tâche de prédiction de changement, ravivant ainsi l’objectif de suivi post-opératoire du projet FollowKnee.

6. <https://dataverse.nl/dataset.xhtml?persistentId=doi:10.34894/5HHK8H>

7. https://github.com/jgvhabets/sensor_EMA_PD_monitoring

DESCRIPTION DES BASES DE DONNÉES

2.1 Introduction

Ce deuxième chapitre est consacré à la description des deux bases de données analysées dans le cadre de cette thèse : EMA (*Ecological Momentary Assessment*) et AQM (*Analyse Quantifiée de la Marche*). En ce qui concerne la base de données de la marche, nous commençons par présenter ce qu'est l'AQM avant de donner certaines statistiques parlantes, dont celles des pathologies. Ces dernières relèvent de la paralysie cérébrale principalement.

2.2 Base de données EMA

Dans cette section, nous décrivons la base de données EMA en commençant par l'aspect clinique. Une présentation concise de la maladie de Parkinson est réalisée.

2.2.1 La maladie de Parkinson

2.2.1.1 Symptômes

La maladie de Parkinson (MP) touche majoritairement des patients âgés de plus de 50 ans et sa prévalence augmente d'une manière exponentielle pour atteindre plus de 4% des plus de 80 ans pour l'estimation européenne la plus élevée. Comme dans la plupart des maladies neurodégénératives, l'âge est un important facteur de risque de la MP.

Historiquement, la MP a été décrite comme étant une pathologie à part entière pour la première fois en 1817 [12]. Des symptômes de six patients entre 50 et 65 ans ont été mis en avant : tremblement des membres au repos, perte de force musculaire, posture voûtée et des troubles de la marche [13]. D'une manière globale, ces observations initiales sont toujours d'actualité dans le diagnostic qui passe par la distinction entre la MP et le syndrome parkinsonien [14]. Un certain nombre de maladies et de schémas thérapeutiques (certains médicaments par exemple) peuvent donner naissance au syndrome parkinsonien.

En France, la MP, appelée parfois syndrome parkinsonien idiopathique, représente environ 80% des cas observés selon l'association France Parkinsonien [15]. Un syndrome parkinsonien peut être défini comme étant un ensemble de troubles neurologiques entraînant des symptômes moteurs dits de Parkinson :

- une lenteur et réduction des mouvements (bradykinésie),
- une rigidité (raideur des extrémités ou de la nuque),
- un tremblement de repos.

Le symptôme majeur du syndrome est la bradykinésie et le diagnostic clinique est généralement posé en l'associant à la rigidité ou au tremblement de repos.

Le diagnostic clinique de la MP idiopathique se base sur l'identification d'une pathologie du mouvement ayant principalement les caractéristiques suivantes [16] [17] :

- les manifestations sont celles du syndrome parkinsonien [14],
- les symptômes sont asymétriques,
- l'installation et l'aggravation sont progressives,
- la présence d'une amélioration par la prise de précurseur de la dopamine.

Les symptômes associés à la MP dépassent de loin les troubles moteurs étant donné qu'il est possible d'observer chez certains patients, parfois bien avant le diagnostic de la maladie, une dépression, des troubles du sommeil, une hyposmie, des troubles digestifs, des troubles dysautonomiques (syndrome d'hyperactivité vésicale, hypotension orthostatique...) ou encore des anomalies sensorielles [18] [19]. La batterie thérapeutique à suggérer aux patients est diversifiée, mais les traitements existants restent symptomatiques et ciblent presque exclusivement la voie dopaminergique [20]. Les patients se trouvent alors dans un état de handicap à longue durée où les symptômes non sensibles (symptômes non moteurs) aux traitements dopaminergiques prennent le dessus.

2.2.1.2 Traitements symptomatiques

Deux types de traitements existent actuellement : le traitement chirurgical et les traitements médicamenteux. Le médicament le plus utilisé et le plus efficace, depuis la découverte de la MP, est la L-dopa, ou levodopa. La L-dopa compense le manque de la dopamine en stimulant son action à long terme [21]. Sa dose est augmentée au fil de l'évolution de la maladie. Les agonistes dopaminergiques se rejoignent à ce traitement en réduisant l'effet de certains symptômes non moteur comme la dépression. Dans certains cas, les traitements dopaminergiques provoquent des effets secondaires comme de la dyskinésie, des nausées, des vomissements, des troubles du comportement (l'addiction aux

jeux par exemple).

Face à une réaction sensible du patient aux traitements dopaminergiques, la chirurgie est alors recommandée. Cependant, le recours à cette intervention lourde reste limité en pratique (5 à 10% des patients). La chirurgie consiste en une stimulation cérébrale profonde pendant laquelle une (ou deux) électrode(s) sont implantée(s) dans le cerveau au niveau du noyau sous-thalamique [19].

Les deux types de traitements, la L-dopa et la stimulation cérébrale profonde peuvent être combinés pour des résultats plus satisfaisants [21]. Cependant, le traitement chirurgical a peu d'effet sur les syndromes non-moteurs. Pour remédier à cela, des rééducations physique et orthophonique sont proposées, ce qui contribue à l'amélioration de la qualité de vie des patients malgré l'évolution inéluctable de la maladie au cours du temps.

2.2.2 Description de la base de données

Cette base de données a été référencée et utilisée, entre autres, dans [22]-[24]. 20 patients atteints de la MP ont été recrutés pour porter 3 unités de mesure (UM) ayant un accéléromètre et un gyroscope chacune, et ce sur une période de 14 jours consécutifs. L'une des UM a été placée sur la poitrine et les deux autres aux poignets. La fréquence d'échantillonnage était de 200 Hz. En moyenne, les patients portent les UM pour une durée de 15 heures par jour environ.

Pendant la période de suivi, les patients répondent quotidiennement à sept questionnaires qui portent sur leur état de santé général et l'état de leur fonction motrice. Ces questionnaires sont reçus à des moments semi-aléatoires de la journée (entre 8h et 22h) et sont appelés questionnaires continus. On les distingue du questionnaire journalier du matin (à y répondre au réveil) et de celui du soir (à y répondre au coucher). Ainsi le nombre total de questionnaires continus reçus par chaque patient est égal à 98, contre 14 pour les questionnaires du matin ou du soir. Les patients sont invités à répondre aux maximums de questionnaires sans que cela n'altère, même légèrement, leurs vies quotidiennes. En moyenne, le nombre de questionnaires complétés par patient est de : 77,5 pour les questionnaires continus, 13,6 pour les questionnaires du matin et 13,2 pour les questionnaires du soir. Un total de 1539 questionnaires a été complété. L'histogramme 2.1 montre le nombre de questionnaires complétés par patient le long de la période de suivi. Les réponses aux questionnaires se font via une application mobile facile d'installation et exploitant l'*Experience Sampling Method* (ESM). L'ESM est une méthode de questionnaires digitaux et validés collectant des réponses utilisateurs à des instants précis de la journée

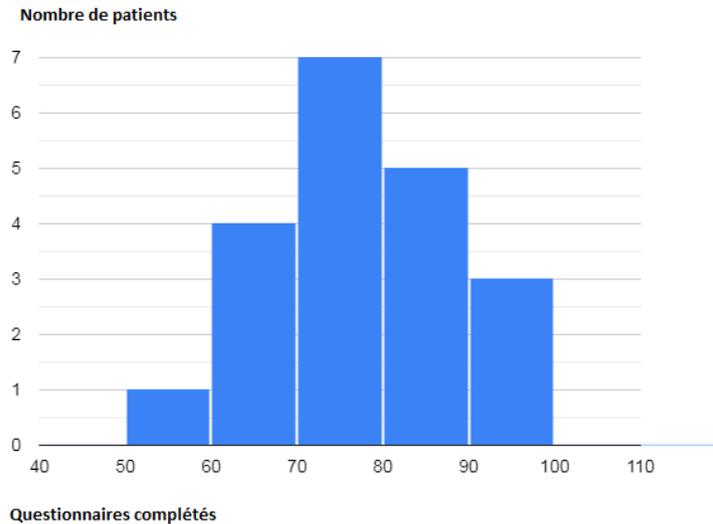


FIGURE 2.1 – Histogramme des questionnaires complétés de la base de données EMA.

[25] [26]. Les questionnaires ESM ont été élaborés en se basant sur la littérature décrivant les symptômes et traits (variables) pertinents de la MP dans un cadre de suivi des patients à domicile. Par ailleurs, des entretiens avec les patients ont contribué à la confection de ces questionnaires [27] [28].

Certains de ces questionnaires sont à choix multiple et leur format ordinaire est organisé en trois colonnes et plusieurs lignes : une ligne par variable d'intérêt surveillée contenant son nom, la question posée la concernant et la réponse subjective du patient (son ressenti) selon l'échelle Likert [29] de 1 à 7 où 1 correspond à "pas du tout dérangement" et 7 à "très dérangement". Dans la Table 2.1, nous présentons un aperçu du contenu de ces questionnaires pour trois variables différentes. La variable `sanpar_onoff` est présente dans un total de 1 360 enregistrements. Elle indique le statut de la médication. L'état 3 (ON) indique que les symptômes de la maladie sont contrôlés grâce au traitement [30]. La Figure 2.2 montre les variations de cette variable pour un patient donné au cours des 14 jours de suivi. Dans 3.89% des cas (3 questionnaires), le patient a répondu par 2 sur l'échelle de Likert contre 96,10% (74 questionnaires) par 3. La figure 2.3 montre la variabilité de cette même variable pour deux autres patients.

Il s'agit de reproduire l'étude de faisabilité mise en avant par les auteurs [22], à savoir la possibilité de prédire de manière fiable et à partir des données des UM les réponses

Le label de la variable	La question/explication	Les codes ou options de la réponse
mood_well	<i>I feel well</i>	Likert 1 – 7
act_problemless	<i>I can do my current activity without hinder</i>	Likert 1 – 7
sanpar_onoff	<i>Currently, I feel...</i>	1 : OFF 2 : Changing from OFF towards ON 3 : ON 4 : Changing from ON to OFF

TABLE 2.1 – Aperçu du questionnaire de la base de données EMA.

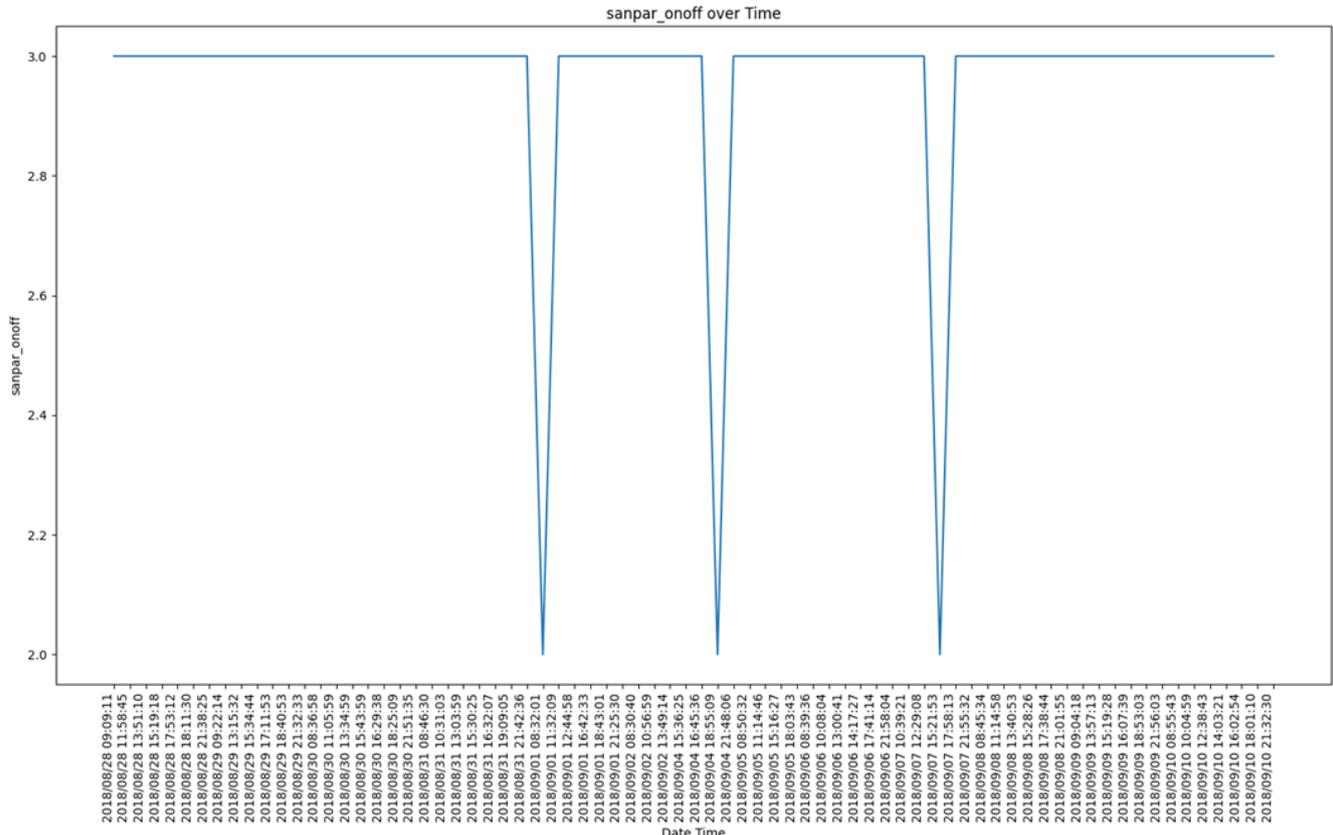


FIGURE 2.2 – Diagramme en barre de sanpar_onoff sur 14 jours pour un patient donné.

rapportées subjectivement par l'un des patients. Cette base de données avait constitué

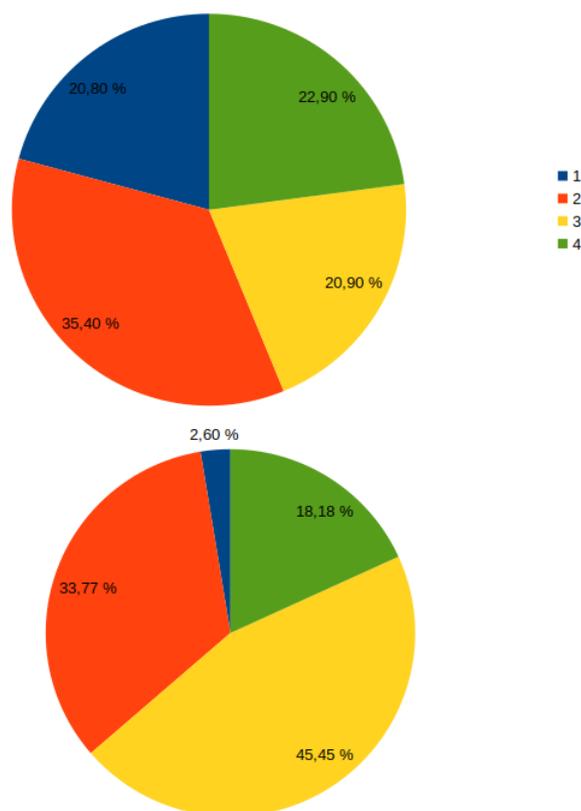


FIGURE 2.3 – Diagrammes circulaires de `sanpar_onoff` pour deux patients donnés.

le premier centre d'intérêt de cette thèse. La fiabilité des vérités terrain (réponses des patients) est cependant problématique au vu de l'aspect personnel et subjectif d'EMA (voir la sous-section 5.2.3).

2.3 Base de données de l'Analyse Quantifiée de la Marche

Les troubles de la marche désignent les anomalies de la marche comme la perte de fluidité, de vitesse, de symétrie ou d'équilibre. Ils constituent un enjeu majeur de santé publique vu les conséquences dramatiques qu'ils induisent surtout chez la personne âgée : risque de chutes avec leurs conséquences traumatiques dans cette population à risque de vulnérabilité [31]. Les causes pouvant entraîner une difficulté à marcher sont très nombreuses et diversifiées. Afin de caractériser les troubles de la marche, un examen clinique appelé Analyse Quantifiée de la Marche (AQM) a été proposé. La spécificité de cet examen est

d'utiliser des paramètres biomécaniques à des fins médicales. Son but est d'identifier, quantifier et comprendre les troubles de la marche rencontrés chez un patient, principalement dans l'optique de choisir le traitement le plus approprié.

2.3.1 Un examen clinique standardisé : L'analyse quantifiée de la marche

2.3.1.1 La marche humaine

2.3.1.1.1 Contexte et définition

La marche humaine est un domaine étudié anciennement en biomécanique. Le développement des techniques de mesure du mouvement en a permis l'expansion des connaissances. En 1836, l'une des premières études biomécaniques a été réalisée par les frères Werber en appliquant les lois de la mécanique newtonienne au mouvement humain [32]. Néanmoins, c'est grâce à l'évolution des techniques photographiques introduites par Marey et Muybridge que les principales connaissances biomécaniques de la marche ont été acquises. Depuis, il existe une quantité importante de publications et d'ouvrages qui y sont consacrés.

Généralement, tous ces travaux concordent avec une définition simple de la marche comme étant un déplacement qui consiste en une translation de l'ensemble du corps, consécutive à des mouvements de rotations [33]. Ce déplacement implique une répétition cyclique de séquences des segments corporels pour faire avancer le corps tout en maintenant l'équilibre [34]. La marche est découpée ainsi en cycles qui commencent par le contact d'un pied au sol et finissent par le contact subséquent de ce même pied.

2.3.1.1.2 Le cycle de marche

La marche est une activité motrice cyclique qui alterne une phase d'appui (pied en contact avec le sol) et une phase oscillante. La phase d'appui constitue 60% du cycle. On distingue l'appui bipodal (les deux membres sont en phase d'appui) de l'appui unipodal (l'un des deux membres est en phase d'appui alors que l'autre est en phase oscillante).

Après avoir défini ce que c'est la marche humaine, il s'avère nécessaire de discerner le normal du pathologique. Une excellente synthèse de la marche dite "normale" et dite "pathologique" a été réalisée dans les ouvrages de Perry [34] et Gage [35].

2.3.1.1.3 La marche dite "normale"

Globalement, la marche dite "normale" repose sur un fonctionnement satisfaisant, sur tous les niveaux, du système locomoteur. La figure 2.4 illustre ces différents niveaux. L'ensemble du mouvement est contrôlé par le cortex moteur et les centres supérieurs. Les

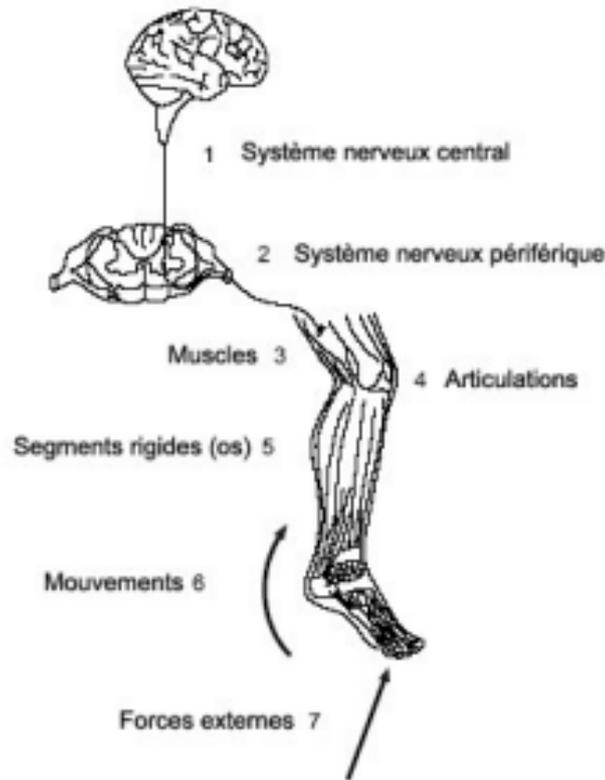


FIGURE 2.4 – Illustration des différents niveaux du système locomoteur [36].

patrons moteurs et la coordination sont gérés par le système extrapyramidal. Une tension appropriée doit être développée par les muscles en réponse à un niveau d'activation neuronale donné. Les articulations doivent bouger avec une amplitude adéquate sans douleur. Les forces nécessaires doivent être retransmises par les os.

La marche dite "normale" a été largement décrite dans la littérature d'un point de vue global initialement. Dans [37] elle a d'abord été définie intégralement comme étant le centre de gravité du corps qui oscille de droite à gauche et de haut en bas, ainsi que les différents paramètres spatio-temporaux liés à un cycle de marche. Ensuite, chaque phase du cycle de marche a été décrite par les déplacements linéaires de chaque segment corporel et les

déplacements angulaires de chaque articulation (cinématique) [34][35][38].

Afin de mieux appréhender la marche dite "normale", il s'est avéré nécessaire de comprendre la fonction de chaque mouvement pendant la marche. Ces muscles sont eux-mêmes commandés et régulés par le système nerveux. Plusieurs approches complémentaires ont été considérées : une globale du rôle de chaque mouvement, une spécifique des fonctions de chaque muscle par rapport aux mouvements et une concernant la commande et la régulation de ces mouvements.

Le rôle de chaque mouvement est défini en mettant en relation les données anatomiques, cinétiques, cinématiques, et énergétiques. D'après [34], les fonctions locomotrices de la marche sont : la propulsion/progression, l'équilibre, l'absorption des chocs et la conservation d'énergie. Chaque mouvement peut ainsi être décrit à travers ces quatre fonctions. Ces mouvements sont contrôlés par des muscles qui assurent des fonctions d'amortissement, de freinage, d'accélération et d'équilibre [39].

Des enregistrements électromyographiques (EMG) ont permis de déterminer le rôle de chaque muscle à chaque instant du cycle de marche. Les muscles permettent d'amortir les contraintes exercées sur le corps lors du contact du pied avec le sol. Nombreux muscles assurent une fonction de freinage de par leur viscoélasticité ou leur capacité à contrôler leur étirement par contraction. Les muscles extenseurs dans le plan sagittal du membre inférieur contribuent à l'accélération des segments et à la propulsion [40] [41]. Plus finement, les muscles contrôlent aussi l'équilibre pendant la marche avec des contractions isométriques [35]. Il est crucial de noter que les rôles des muscles ne sont pas toujours simples à cerner malgré une connaissance assez précise de leur activité.

Malgré ces connaissances sur la marche humaine, de nombreuses zones d'ombre persistent. Les avancées sur la compréhension de la marche dite "normale" ont permis de se pencher sur la marche dite "pathologique" dans l'espoir de la comprendre et de corriger ses causes.

2.3.1.1.4 La marche dite "pathologique"

Une atteinte ou une anomalie à n'importe quel niveau entre le cerveau et les os engendre une marche dite "pathologique" ou une incapacité à marcher. Plus précisément, la marche dite "pathologique" peut être classée en deux catégories selon son origine : neurologique, c'est-à-dire causée par une atteinte du système nerveux ou non neurologique. Les mala-

dies neurologiques (hémiplégié, parésies, paraplégies...) entraînent des paralysies et des troubles du tonus musculaire ou des tremblements. En l'occurrence, une hypertonie musculaire et des tremblements au repos constituent des symptômes majeurs du syndrome parkinsonien. Une maladie du cervelet provoque des problèmes de coordination.

Les causes non neurologiques englobent les maladies ostéo-articulaires (l'arthrose et l'arthrite par exemple), les déformations squelettiques et les maladies qui provoquent une faiblesse générale (maladies fébriles, musculaires, infectieuses, l'obésité. . .). Malgré la grande multitude des pathologies affectant la marche, les altérations et les déficits qu'elles imposent peuvent se décliner en quatre catégories fonctionnelles majeures : déformations, faiblesses musculaires, problèmes de contrôle musculaire et douleur.

La compréhension de la marche a rendu possible à un examen clinique d'investigation de voir le jour : l'analyse quantifiée de la marche (AQM).

2.3.1.2 L'analyse quantifiée de la marche en pratique

L'AQM est un examen simple et relativement courant permet de mieux comprendre comment une personne met en jeu ses articulations et muscles lors de la marche. Toutes les connaissances acquises à travers les travaux de description et de compréhension de la marche ont permis l'interprétation de cet examen standard pertinent dans la prise en charge d'une personne présentant des défauts de la marche. La décision thérapeutique se voit améliorée avec une diminution des gestes chirurgicaux et des coûts associés aux traitements. Les paragraphes suivants décrivent cet examen, ainsi que ces apports et limites.

2.3.1.2.1 Le fonctionnement

En France, tout laboratoire a son propre fonctionnement et dépend d'une structure hospitalière. La réalisation des examens est assurée par une équipe pluridisciplinaire constituée au minimum d'un médecin (responsable de la partie médicale) et d'un ingénieur ou technicien biomédical (responsable de la partie analyse du mouvement). Il est assez courant de trouver des kinésithérapeutes au sein de l'équipe. Le même type de fonctionnement et de matériel est observé aux États-Unis.

2.3.1.2.2 Le matériel

De même, le matériel varie d'un laboratoire à l'autre. Généralement, la salle de l'examen correspond à une pièce assez grande pour que le patient puisse marcher en ligne droite

sur une distance de 10 mètres. D'une manière générale, le système d'acquisition comporte [42] [43] :

- quatre à cinq caméras à éclairage infrarouge,
- un système optoélectronique pour la mesure de la cinématique des segments. Il s'agit de marqueurs rétro-réfléchissants de surface au niveau des différentes articulations ou surfaces osseuses. Ces marqueurs sont détectés par les caméras infrarouges,
- des plates-formes de force au sol pour la dynamique (enregistrement des forces de réaction au sol). Généralement leur nombre est d'un ou deux,
- un système électromyographique pour l'enregistrement de l'activité des muscles,
- du matériel vidéo pour filmer le patient de face et de profil.

Le tout est synchronisé et relié à un système informatique récoltant les différentes données émises et capable de les traiter.

2.3.1.2.3 Les données de l'AQM

2.3.1.2.3.1 Paramètres spatio-temporaux

Ils reflètent un aspect général de la marche d'un patient donné. Les paramètres génériques de la marche sont : la longueur du pas, la cadence, et la vitesse. Quant aux paramètres spécifiques au cycle de marche, ce sont les durées et les pourcentages qui y sont rattachés.

2.3.1.2.3.2 Paramètres cinématiques

Lors du mouvement humain, il est question de se focaliser sur non seulement les coordonnées des marqueurs collés à la peau, mais aussi le mouvement des segments corporels. L'articulation reliant deux segments permet le mouvement de l'un par rapport à l'autre. Un modèle mécanique est nécessaire pour calculer l'angle en question. D'une manière générale, le mouvement dans l'espace des segments corporels est obtenu à partir de trois marqueurs non colinéaires. Cela implique une modélisation des segments en tant que rigides et indéformables. La méthode des angles d'Euler est communément utilisée pour calculer l'angle entre deux segments [44].

2.3.1.2.3.3 Paramètres cinétiques

Les premières données cinétiques analysées dans l'AQM sont les forces de réaction au sol enregistrées directement par les plates-formes de force. Elles permettent de déceler les

phases de freinage et propulsion ainsi que l'appui du pied sur le sol. En plus des forces de réaction, les moments et les puissances articulaires sont des données essentielles de l'AQM. Le moment articulaire permet de déterminer le groupe musculaire principalement responsable du mouvement au niveau de l'articulation selon les trois axes du mouvement. Le type de contraction de ce groupe musculaire est renseigné par la puissance articulaire.

2.3.1.2.3.4 Paramètres électromyographiques

Le signal électromyographique reflète l'activité électrique du muscle en question. Il constitue un complément aux paramètres cinétiques, car il montre si le groupe musculaire est actif ou pas et fait savoir quel muscle est actif dans le groupe [45]. Son *timing* permet de déterminer si l'activité est normale, absente, inversée, prolongée, ou continue. Pour se faire une idée du niveau de contraction d'un muscle, il faut garder à l'esprit que l'intensité du signal EMG n'est pas proportionnelle à la force du muscle. La forme du signal peut révéler des anomalies. Dans certains cas, une comparaison de celle-ci avec celle d'une courbe normale permet de mettre en évidence une activité excessive sur une partie du cycle. Un clonus (une succession de contractions rapides et réflexes suite à l'étirement brusque de certains muscles) dû à de la spasticité se manifestera par des pics d'intensité élevée et à fréquence régulière.

2.3.1.2.3.5 Paramètres cliniques

La première donnée clinique à prendre en considération est le motif de prescription de l'AQM. Ensuite se positionne l'historique médical du patient qui dépend de sa pathologie. Il comprend les principaux problèmes de marche, l'âge des premiers pas, l'utilisation éventuelle d'aides techniques, les douleurs ainsi que les traitements précédents [46]. Dès fois, cet historique est enrichi par des données d'examen complémentaires tels qu'un dosage sanguin, des radiographies, un EMG, une IRM [43].

2.3.1.2.4 Le déroulement d'un examen

2.3.1.2.4.1 Préparation

Il est essentiel de préparer la salle d'examen avant d'accueillir le patient. Cette tâche comprend la mise au point des caméras, le calibrage du système optoélectronique (la préparation des marqueurs) et des plates-formes de force ainsi que la préparation informatique et/ou manuscrite d'une fiche sur le patient.

2.3.1.2.4.2 Bilan clinique et mesures anthropométriques

L'AQM commence ou finit par un bilan clinique réalisé par un médecin spécialisé et s'effectuant sur table clinique. Ce bilan comporte la mesure :

- de la force musculaire,
- de l'amplitude passive du mouvement des articulations,
- des troubles du tonus musculaire : le plus répandu est la spasticité [47].

Certains éléments relatifs à la pathologie du patient sont notés également : une griffe d'orteil, un arrière-pied raide. . .

Les mesures anthropométriques englobent la longueur et la circonférence des membres et la largeur des articulations. . .Généralement, elles permettent d'estimer les paramètres inertiels des segments et les centres articulaires.

2.3.1.2.4.3 Vidéo fonctionnelle

Le film réalisé permet de visualiser la marche au ralenti de face et de profil. Par ailleurs, il constitue un complément fonctionnel au bilan clinique. D'une manière générale, sa durée est de quelques minutes montrant les capacités fonctionnelles du patient. L'enregistrement commence par une prise statique de profil et de face du patient qui s'engage ensuite à marcher sur les talons, à la pointe des pieds, sur une ligne, en arrière, à s'asseoir, à courir, à se relever, à tenir en équilibre sur un pied ou encore à faire de petits sauts.

2.3.1.2.4.4 Équipement du patient

Par la suite, le patient est équipé d'électrodes électromyographiques et de marqueurs réfléchissants. D'abord les électrodes qui serviront à l'enregistrement de l'activité musculaire sont positionnées. Cela passe par le repérage des muscles de surface en invitant le patient à les contracter. Ensuite, les marqueurs réfléchissants sont positionnés sur les points anatomiques définis par le protocole de mesure.

2.3.1.2.4.5 Enregistrement statique et dynamique

L'enregistrement statique du patient équipé permettra par la suite la reconnaissance automatique des marqueurs (*auto-labelling*) lors du traitement des essais dynamiques. Le patient marche sur un chemin de marche. Il est demandé de réaliser un certain nombre de passages jugé suffisant pour le traitement des données. Si les capacités du patient le permettent, il est nécessaire d'avoir un certain nombre minimal de passages considérés comme bons (incluant les appuis entiers sur les plates-formes de force) pour arrêter l'acquisition dynamique.

2.3.1.2.4.6 Traitement/Réduction des données

La première étape consiste à nommer les marqueurs sur la vue en trois dimensions. Ce travail est majoritairement effectué par le processus de reconnaissance. La seconde étape est l'identification sur chaque passage des instants caractéristiques du cycle de marche. Pour ce faire, il est commun d'avoir recours à des algorithmes automatiques. Par la suite, les calculs sont automatisés grâce à des logiciels permettant l'estimation des angles, moments et puissances articulaires. Ces calculs sont normalisés suivant le cycle de marche. Le traitement se termine quand un rapport électronique avec les différentes courbes de l'AQM est prêt à être interprété.

2.3.1.2.4.7 Interprétation des données

L'interprétation ne s'effectue pas d'une façon automatique et peut se décomposer en deux phases. La première phase est réalisée au préalable de l'interprétation proprement dite et elle consiste à identifier les défauts de la marche. Toutes les déviations significatives par rapport à une marche "normale" sont notées. Le score de la marche GPS (*Gait Profile Score*) permet de quantifier ces déviations.

La seconde phase est l'interprétation des déviations initialement observées. Elle est plus délicate puisqu'elle a pour but d'appréhender ces déviations pour en identifier les causes. Pour ce faire, il est indispensable d'aligner les données de l'AQM et les éléments cliniques disponibles en tenant compte de la mécanique des marches dites "normale" et "pathologique" et du processus de collecte et de calcul des données [46]. À ce stade, il est crucial de distinguer les défauts à traiter directement de ceux qui constituent une compensation pour un autre défaut [35]. Une erreur lors de l'interprétation peut engendrer une erreur dans le choix du traitement et par conséquent détériorer la marche d'un patient [48]. L'interprétation est alors une expertise patho-biomécanique complexe et fondamentale puisqu'elle détermine directement le traitement choisi.

2.3.1.2.5 Le score de la marche (*Gait Profile Score* GPS)

2.3.1.2.5.1 Définition et formule

Connu couramment sous le nom du score global de comportement de la marche, il correspond à une mesure de synthèse construite mathématiquement en 2009 [49] en tant qu'un score brut global de la distance entre le sujet et la moyenne des sujets sains [50][51] [52] sur l'ensemble du cycle de marche [50]. Pour le clinicien, l'association des scores avec les neuf angles articulaires est pratique. D'un point de vue mathématique, le GPS n'est autre que

la différence quadratique moyenne entre les données cinématiques pathologiques et le jeu de donnée normative physiologique. De par sa confrontation à la référence de normalité, le GPS se revêtit bel et bien le rôle d'un score du comportement de marche [53].

Il est divisé en neuf domaines jugés pertinents par les auteurs : les sous-scores variables globaux GVS (*Gait Variable Score*), en raison d'un par variable cinématique [52] [54][53]. Les GVS montrent l'ampleur de la déviation d'une variable cinématique simple donnée (angle articulaire) par rapport à la physiologie [51]. Instinctivement, les GVS sont plus simples à interpréter qu'un indice global de déviation ou de comportement de la marche. Ils sont la différence quadratique moyenne entre une variable cinématique n normalisée dans le temps spécifique T et les données moyennes de la population de référence calculées sur le cycle de marche.

$$GVS_n = \sqrt{\frac{1}{T} \sum_{t=1}^T (c_{t,n} - c_{t,n}^{ref})^2} \quad (2.1)$$

- t = le point spécifique (pas temporel) du cycle de marche,
- T = le nombre total de points dans le cycle de marche. L'une des normalisations possibles propose un T de 51. Dans notre cas, c'est égal à 101 [44],
- $c_{t,n}$ = la valeur de la variable de marche n au point t ,
- $c_{t,n}^{ref}$ = la moyenne de la variable de marche n au point t dans la population de référence.

La définition mathématique du GPS découle comme étant la moyenne quadratique des N GVS :

$$GPS = \sqrt{\frac{1}{N} \sum_{n=1}^N GVS_n^2} \quad (2.2)$$

avec N étant le nombre total de variables cinématiques dont nous disposons (égal à 9) :

- Rétroversion du pelvis (*Pelvis Angle X*),
- Inclinaison du pelvis (*Pelvis Angle Y*),
- Rotation du pelvis (*Pelvis Angle Z*),
- Extension de la hanche (*Hip Angle X*),
- Abduction de la hanche (*Hip Angle Y*),
- Rotation de la hanche (*Hip Angle Z*),
- Extension du genou (*Knee Angle X*),

- Extension de la cheville (*Ankle Angle X*),
- Angle de progression (*Progress Angle Z*).

Le GPS englobe les neuf variables de la marche pouvant être visualisées et rapprochées des paramètres de la marche dite normale. Cette mise en face ressortira les anomalies et les déviations par rapport à la normalité. Ces variables pour un cycle de marche donné sont représentées sur la figure 2.5.

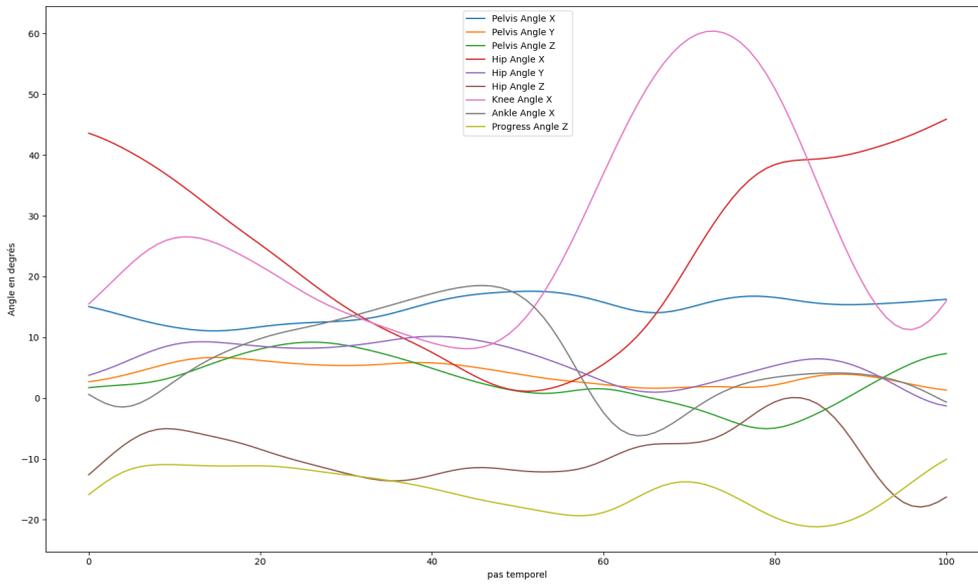


FIGURE 2.5 – Cinématique d'un cycle de marche

2.3.1.2.5.2 La variation du GPS

Nous définissons une session de marche par l'ensemble de pas effectués par le patient dans la salle de l'examen. Grâce à l'étape de traitement/réduction des données, les pas réalisés sont normalisés en cycle de marche. Nous notons une session de marche d'un patient p à une date d par $E_{p,d}$:

$$E_{p,d} = \{C_{E_{p,d}}^1, C_{E_{p,d}}^2, \dots, C_{E_{p,d}}^K\} \quad (2.3)$$

avec $C_{E_{p,d}}^k$ étant le k -ème cycle de marche de $E_{p,d}$ et K étant le nombre total des cycles de marche de la session $E_{p,d}$.

Soit $c_{t,n}^{E_{p,d}^k}$ la valeur du cycle de marche $C_{E_{p,d}}^k$ au pas temporel t et à l'angle articulaire

n. On la note simplement par $c_{t,n}$, dans ce qui suit, pour alléger l'écriture. $C_{E_{p,d}}^k$ se voit instinctivement représenté par une matrice à 101 lignes (pas temporels) et 9 colonnes (angles articulaires).

$$C_{E_{p,d}}^k = \begin{bmatrix} c_{1,1} & c_{1,2} & \dots & c_{1,9} \\ c_{2,1} & c_{2,2} & \dots & c_{2,9} \\ \vdots & & & \\ c_{101,1} & c_{101,2} & \dots & c_{101,9} \end{bmatrix} \quad (2.4)$$

Considérons deux sessions de marche $E_{p,d}$ et $E_{p,d+\Delta d}$ espacées temporellement de Δd (Δd étant la durée écoulée entre les deux). Nous attribuons à chaque cycle de marche $C_{E_{p,d}}^k$ de la session $E_{p,d}$, une variation de GPS notée $\Delta GPS(C_{E_{p,d}}^k)^{\Delta d}$ et calculée simplement comme suit :

$$\Delta GPS(C_{E_{p,d}}^k)^{\Delta d} = GPS_{avg}(E_{p,d+\Delta d}) - GPS(C_{E_{p,d}}^k) \quad (2.5)$$

Avec :

- $GPS_{avg}(E_{p,d+\Delta d})$ est le GPS moyen par cycle de la session $E_{p,d+\Delta d}$,
- $GPS(C_{E_{p,d}}^k)$ est le GPS du cycle en question.

Ce formalisme permet d'opter pour le plus petit Δd pour un cycle de marche donné (i.e prendre la session d'examen qui le suit directement) ou de considérer toute la combinatoire possible (les cycles de marche de la session 1 à associer aux sessions 2,3,4... et ainsi de suite pour les cycles de marche de la session 2...). La deuxième configuration exige la prise en considération du Δd dans la construction des *data-driven* modèles d'IA.

2.3.1.2.6 Les utilisations de l'AQM

Dans un contexte clinique, l'AQM est principalement pratiquée pour trois utilisations :

- faire l'inventaire des défauts de marche,
- apprécier l'effet d'un traitement donné,
- suivre l'évolution de la marche au cours du temps.

2.3.1.2.6.1 Synthèse des défauts de marche

La synthèse des défauts de marche consiste en leur identification et leur quantification. Grâce à l'interprétation patho-biomécanique, les causes cliniques sous-jacentes à ces défauts peuvent souvent être identifiées. Cette synthèse, en plus de la compréhension de la marche, a montré son intérêt pour orienter au mieux le traitement administré [55].

2.3.1.2.6.2 Effet d'un traitement

Afin d'évaluer l'effet d'un traitement donné sur la marche d'un patient, il est judicieux de comparer l'AQM réalisée avant et après son administration. Cela rend possible l'adaptation du schéma thérapeutique. L'AQM permet de juger le résultat d'une chirurgie [56]. En ce qui concerne le traitement à base d'injection de toxine botulinique, une AQM est parfois réalisée juste avant son administration et un mois après [57]. En cas d'utilisation d'orthèses, l'AQM offre l'occasion d'opter pour l'orthèse la plus adaptée ou d'ajuster les réglages de celle choisie [58] [59]. Dans le cadre d'une rééducation, les kinésithérapeutes et plus généralement les thérapeutes utilisent l'AQM pour tracer les progrès accomplis dans la marche du patient.

2.3.1.2.6.3 Suivi de l'évolution de la marche

Dans une certaine mesure, l'AQM constitue un tableau dynamique de la marche à instant défini. La prise de ces tableaux à différents instants permet le suivi de l'évolution de la marche au cours du temps. Un tel suivi est particulièrement pertinent dans la prise en charge des maladies neuromusculaires caractérisées par la dégradation de la marche avec le temps. On connaît l'évolutivité des troubles neuro-orthopédiques à l'âge adulte.

2.3.1.2.7 Les limites de l'AQM

Les limites de l'AQM sont directement liées à celles de l'analyse du mouvement humain. Elles engendrent des erreurs de mesures et d'interprétation des résultats.

2.3.1.2.7.1 Liées à l'acquisition

La première limite à la précision des mesures de l'AQM réside dans le matériel utilisé et la configuration de l'environnement pour l'enregistrement du mouvement. La qualité de l'optique des caméras et la résolution des capteurs entraînent des distorsions. Les erreurs de mesure peuvent être liées au nombre et à la position des caméras, au volume d'acquisition ou encore à la qualité de la calibration [60]. La série d'algorithmes permettant le calcul des coordonnées des marqueurs en trois dimensions peut être à l'origine des erreurs.

2.3.1.2.7.2 Liées aux modèles

L'une des sources d'imprécisions est le modèle calculant les variables de l'AQM à partir des coordonnées des points en trois dimensions. La première limite provient de la modélisation des segments par des corps rigides indéformables, ce qui ignore le mouvement

des parties molles. En l'occurrence, le pied est un segment constitué de plusieurs os et de nombreux degrés de liberté.

L'estimation des centres articulaires des marqueurs externes pose un problème également. Dans [61], Croce et al. estiment une erreur de localisation du centre articulaire par rapport au centre réel de la hanche pouvant atteindre jusqu'à 105 mm.

Une autre limite réside aussi dans la modélisation de ces centres articulaires. L'articulation pivot fait abstraction de l'articulation du genou qui combine un mouvement de rotation et de translation [62].

Par ailleurs, une difficulté majeure du modèle consiste à calculer mathématiquement avec une précision acceptable d'un point de vue clinique les angles articulaires entre les segments.

2.3.1.2.7.3 Liées à l'expérimentateur

L'expérimentateur figure dans les limites de l'AQM de par les marqueurs et les électrodes qu'il place sur le patient. Généralement, la détermination du centre articulaire pour l'emplacement des marqueurs externes manque de précision [61]. Dans [61], l'effet du mauvais placement des marqueurs sur les résultats de l'analyse du mouvement a été synthétisé. Dans [63], une variabilité importante du placement des marqueurs a été démontrée entre des expérimentateurs de 12 centres d'analyse de la marche aux États-Unis. En l'occurrence, cette variabilité est d'une amplitude supérieure à 20° sur le calcul de la flexion et rotation de la hanche.

Les mesures de l'examen clinique réalisées sont une autre source de l'imprécision des variables de l'AQM vu qu'elles présentent une forte variabilité. [64] note une amplitude de mesure pour un même patient évalué dans quatre centres différents variant de 25 à 50° suivant la mesure considérée. De manière générale, chaque laboratoire d'analyse du mouvement comporte un expérimentateur qui reste inchangé lors de chaque examen, diminuant par conséquent les variations inter-examineurs [65].

2.3.1.2.7.4 Liées au patient

La variabilité de la marche d'un patient dépend de ses attributs (âge, pathologie, étiologie, etc.) et des paramètres analysés. Les sujets pathologiques présentent généralement une variabilité de marche inter-essais plus importante que les sujets sains [66]. Chez l'enfant la variabilité est plus importante que chez l'adulte [67]. Plus l'enfant est jeune, plus cette variabilité est élevée [68]. De plus, dans [69], il a été démontré que les sujets 21 à 47 ans

ne présentent pas une variabilité plus faible que ceux âgés de 66 à 84 ans.

Les paramètres temporels montrent une plus grande variabilité que les paramètres spatiaux [67]. Les paramètres cinématiques et cinétiques sont plus variables dans les plans frontaux et horizontaux que dans le plan sagittal [70] [71] [64]. De plus, lors de l'enregistrement en laboratoire, de nombreux patients "s'appliquent" et se "concentrent" durant les essais, ne représentant plus l'exactitude de leur marche au quotidien. D'autres, se "focalisent" sur les plate-formes de force situées au sol et ralentissent ou au contraire accélèrent le pas afin d'avoir un appui unipodal sur l'une d'entre elles. Dans ce cas, l'examineur se doit d'être vigilant afin de ne pas retenir l'enregistrement de cet essai pour éviter de conserver des données inexactes.

2.3.1.2.7.5 Liées aux traitements des données

Il est impératif d'identifier les instants caractéristiques du cycle de marche afin de normaliser les données de l'AQM (voir le paragraphe Traitement/Réduction des données). Cette identification est soit automatique grâce aux appuis sur les plates-formes soit manuelles. Une imprécision dans cette identification risque d'entraîner une erreur d'estimation des données de l'AQM [72].

La création du rapport de l'AQM se termine par une étape de sélection des essais présentés, ce qui est assujéti à la subjectivité de l'expérimentateur.

2.3.1.2.7.6 Liées à l'interprétation des données

L'interprétation des résultats de l'AQM est l'étape la plus difficile, tel est le cas d'autres domaines de l'analyse du mouvement. Elle est aussi particulièrement fondamentale vu qu'elle conditionne explicitement le traitement à administrer au patient. Comme mentionné dans le paragraphe d'interprétation des données, le clinicien commence par identifier les déviations de la marche qu'il juge significatives pour essayer ensuite de remonter à leurs causes. Cette étape exige une bonne compréhension biomécanique de la marche et de ses défauts ainsi que des modèles utilisés pour les calculs des différentes variables de l'AQM [73]. Cinq difficultés majeures peuvent être mises en avant.

La première difficulté dans l'interprétation vient de la grande quantité de données à traiter. De plus, toutes ces données sont corrélées les unes aux autres. Il importe d'effectuer des liens entre l'ensemble des données collectées (données cinématiques, électromyographiques, cinétiques. . .).

La deuxième difficulté est de relier toutes ces informations. Les courbes de marche sont à la base liées entre elles. Une transformation de l'une d'elles (par exemple : une flexion de genou excessive en début d'appui) impacte la majorité des autres courbes (une diminution de la longueur du pas et de la vitesse de marche, etc.). La cohérence de ces modifications devra être vérifiée [73].

La troisième difficulté consiste à déterminer si ces modifications observées sont significatives d'un point de vue clinique. Une méthode statistique permettant de mettre en évidence ces différences par rapport à une marche dite "normale" a été présentée dans [74]. Cette troisième difficulté soulève la question de ce que c'est la normalité de la marche.

La quatrième difficulté consiste à déterminer le type des modifications observées sur les courbes : primaire, secondaire ou tertiaire. Les modifications primaires sont les déviations causées directement par la pathologie (la spasticité par exemple). Les secondaires sont les conséquences "fixées" des primaires (contracture due à la spasticité par exemple). Les tertiaires sont les compensations mises en place par le patient pour marcher avec les anomalies de type primaire et secondaire. Supprimer ces anomalies fait disparaître les compensations. Afin de différencier les types d'anomalies, l'expert doit aligner les données de l'AQM aux données cliniques. D'une manière générale, l'expert part d'un certain nombre d'hypothèses qu'il vérifiera en examinant les données. Ce travail permet d'élucider les causes des anomalies observées.

La dernière difficulté de l'interprétation réside dans le choix du traitement approprié en réponse aux causes des anomalies trouvées.

Compte tenu de l'aspect subjectif de la tâche, il n'est pas surprenant d'aboutir à une grande variabilité des données de l'AQM d'un même patient appréhendées par plusieurs experts de différents laboratoires [75] [64]. Une variabilité importante dans les recommandations des traitements chirurgicaux a été également notée dans ces études. En effet, les experts peuvent avoir des philosophies de traitement différentes [75].

En somme, les principales limites de l'AQM sont la variabilité des données et la difficulté de leur interprétation. Cependant, cet examen reste cliniquement valide et pertinent.

2.3.2 La base de données

La base de données utilisée dans cette étude comporte les données cliniques, fonctionnelles et issues d'AQM de 734 patients ayant au moins une session de marche. Certains reviennent à l'hôpital d'une façon irrégulière, ce qui rend possible leur suivi temporel. Le nombre total de sessions tous patients confondus est de 1459. L'histogramme de la figure 2.6 montre la répartition des examens par patient.

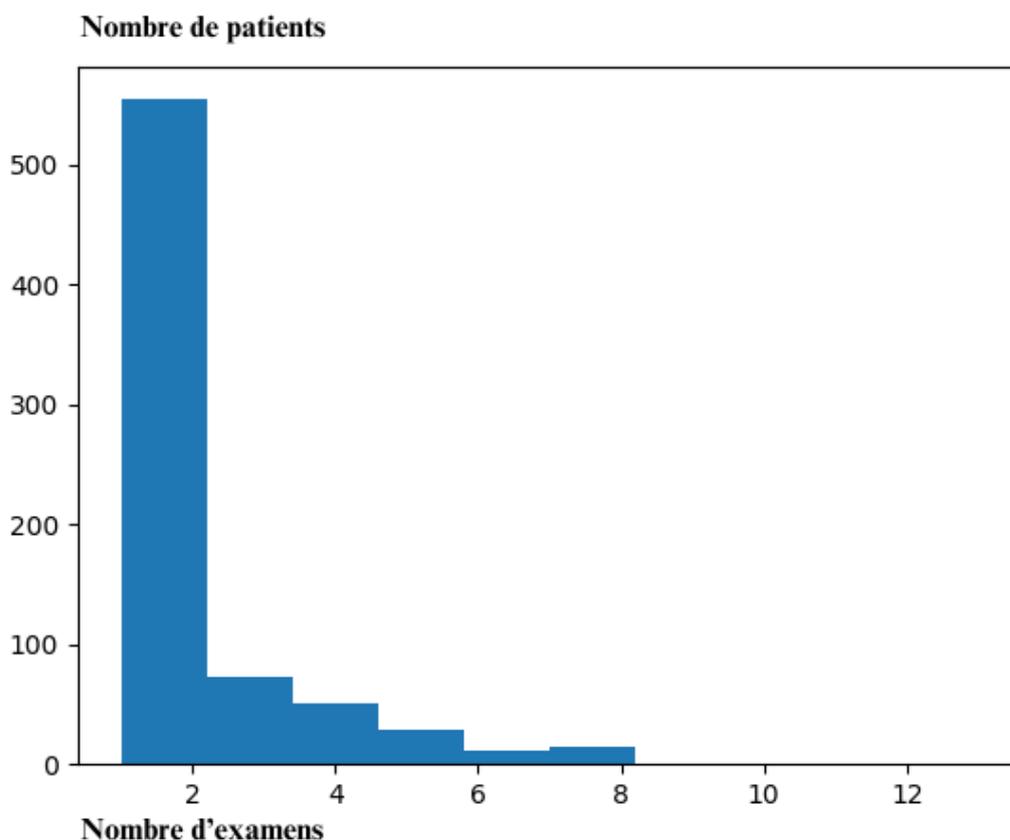


FIGURE 2.6 – Histogramme du nombre d'examens par patient.

2.3.2.1 Les patients

734 patients y compris 619 enfants ont été recrutés au CHRU de Brest entre juin 2006 et juillet 2021. L'âge moyen du patient lors de la première session de marche est de 14 ans, avec un écart type de 16 ans. Les diagrammes circulaires suivants montrent les répartitions du genre et de l'âge dans la base de données.

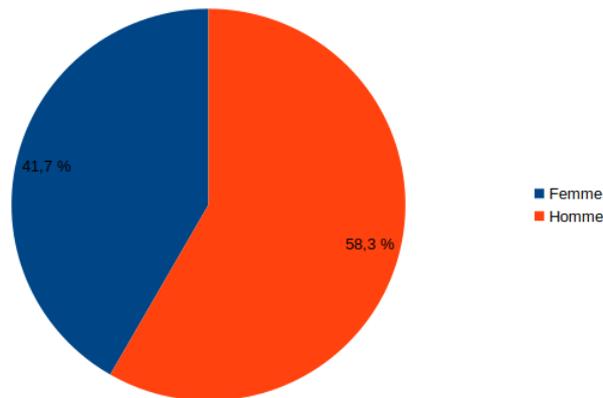


FIGURE 2.7 – Genre des patients.

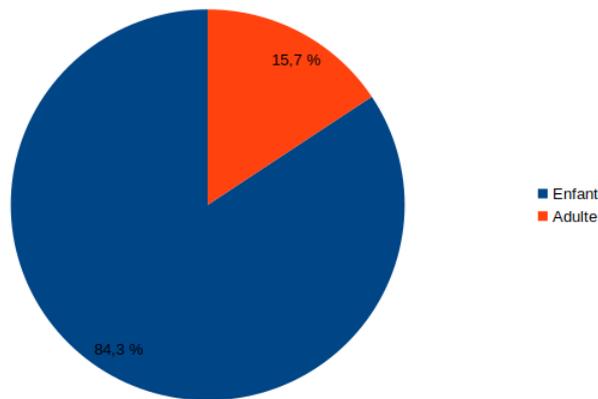


FIGURE 2.8 – Âge des patients.

2.3.2.2 Les pathologies

Les origines des troubles de la marche, si elles sont connues, se déclinent en cinq familles :

- Neurologique,
- Orthopédique,
- Neuromusculaire,
- Psychogène,
- Autre.

Le diagramme circulaire 2.9 montre la répartition des différentes origines précédemment énumérées. La principale étiologie expliquant le trouble de la marche est neurologique et il s'agit plus précisément de la paralysie cérébrale. Le diagramme circulaire 2.10 montre la répartition des différentes étiologies. L'atteinte incomplète signifie que le patient a un problème orthopédique qui n'atteint pas l'ensemble des membres inférieurs. La valeur

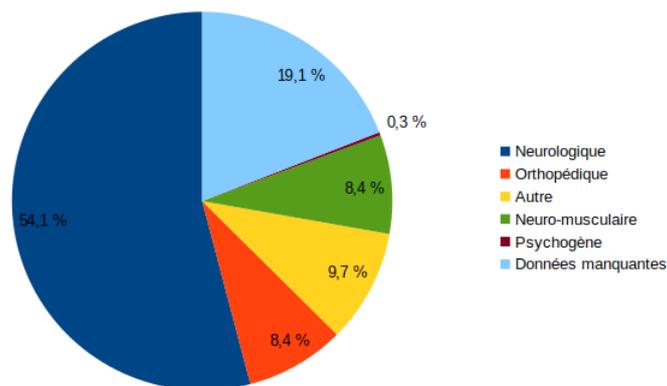


FIGURE 2.9 – Origines des troubles de la marche.

"Aucun" correspond à l'origine psychogène ou à une donnée manquante.

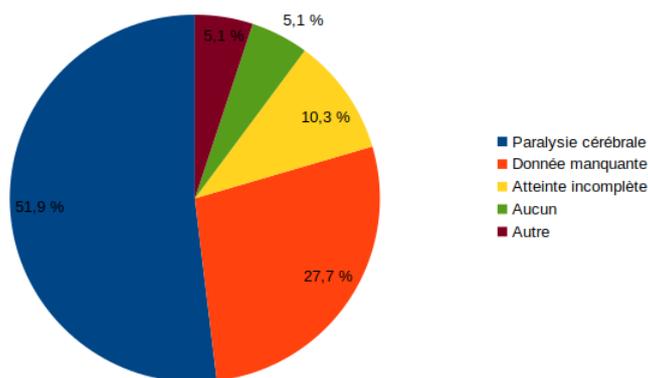


FIGURE 2.10 – Diagramme circulaire des étiologies.

2.3.2.3 Les appareillages

Certaines sessions ont été effectuées sans appareillage et d'autres avec. La table 2.2 dénombre les appareillages dans la base de données.

2.3.2.4 Les sessions de marche

Le nombre moyen de cycles de marche par session est de 18 avec un écart-type de 6. Le nombre moyen de sessions de marche par patient est de 1.988 avec un écart-type de 1.515. Δd moyen entre deux sessions consécutives est presque égal à 740 jours, avec un écart-

Appareillage	Nombre de sessions
Sans appareillage	1239 (84.92%)
Aide	79
Deux cannes simples	31
Déambulateur postérieur	25
Une canne simple	24
Déambulateur antérieur	14
Prothèse	9
Deux cannes tripodes	8
Orthèse	11
Bloc	7
Corset	3
Bande de dérotation	3
Autre	3
Pompe	2
Deux batons	1

TABLE 2.2 – Les appareillages

type de 577 jours. Le plus court Δd est égal à 4 jours tandis que le plus long est égal à 4438 jours (12 ans et 38 jours). Lier chaque session à celle qui la suit directement, si le patient a réalisé plus d'une session de marche dans son parcours de suivi, génère des paires de sessions. Leur total nombre est de 1384 appartenant à 319 patients dont 1152 sans appareillage appartenant à 274 patients.

Le nombre total de cycles, tous patients confondus, des sessions pour lesquelles le calcul d'un ΔGPS est possible est de 53693.

2.4 Conclusion

Nous avons pu voir dans ce chapitre les bases de données explorées dans cette thèse. Quelques statistiques clés ont été notées. Les travaux de cette thèse seront consacrés à la prédiction du ΔGPS . Le chapitre suivant sera focalisé sur l'état de l'art de l'apprentissage profond pour l'analyse de signaux en général et l'analyse de la marche en particulier.

ASPECTS THÉORIQUES ET BIBLIOGRAPHIE

3.1 Introduction

L'apprentissage profond est une branche de l'intelligence artificielle (IA) fondée sur l'utilisation de réseaux de neurones [76]. Issu d'une analogie avec les neurones biologiques du cerveau, le neurone artificiel est apparu vers la fin des années 1940 [77] [78]. L'idée était d'imiter l'intelligence humaine. Dans ses formes les plus primaires, l'apprentissage profond n'a pas atteint les objectifs escomptés. Cela était dû au manque de données et à la limitation des ressources informatiques à disposition. En outre, les premiers algorithmes n'étaient pas assez élaborés. Durant la dernière décennie, la quantité de données disponible a explosé au point de parler de données massives (*big data*) [79]. Parallèlement à cela, les ressources de calcul par l'intermédiaire des *Graphics Processing Unit* (GPU) et grilles de calcul (*clusters*) ont connu un développement considérable. De ce fait, l'apprentissage profond a connu un tournant majeur dans son développement. L'utilisation de ses méthodes et algorithmes sous-jacents a fortement augmenté dans des domaines variés : transport, industrie, santé, robotique, économie, agriculture... Parmi les diverses techniques utilisées, les réseaux de neurones récurrents (*Recurrent Neural Network*, RNN) sont particulièrement adaptés à l'analyse de séries temporelles [80]. Cela justifie leur utilisation historiquement importante pour une telle problématique. Cependant, des études plus récentes sont allées plus loin en comparant les RNN à d'autres techniques : hybrides, réseaux de neurones convolutifs (*Convolutional Neural Network* CNN), *Transformers*... [81] [80]. Tous ces algorithmes ont été appliqués avec succès aux dossiers médicaux partagés (*Electronic Medical Records*, EMR) [82] et plus particulièrement aux signaux physiologiques [83] : électrocardiogramme (ECG), électromyogramme (EMG), électroencéphalogramme (EEG). Les travaux de cette thèse s'intéressent à l'analyse et la prédiction de séries temporelles médicales dans l'optique de suivre l'évolution d'une pathologie. Ce chapitre s'avère

donc indispensable pour appréhender les techniques d'apprentissage profond relativement récentes. Nous commençons par présenter brièvement le principe de l'apprentissage profond et des réseaux de neurones. Ensuite, nous retraçons l'utilisation de l'apprentissage profond pour l'analyse de signaux. Dans ce cadre, nous mettons l'accent sur deux tâches en particulier : la classification et la prédiction. Enfin, nous passons en revue certaines applications de l'apprentissage profond pour l'analyse de la marche et nous détaillons les techniques de son application pour ce cas d'utilisation.

3.2 Principes des réseaux de neurones et de l'apprentissage profond

Nous présentons dans ce qui suit différentes familles de réseaux de neurones.

3.2.1 Réseaux de neurones

3.2.1.1 Réseaux de neurones à couches multiples

Le perceptron (neurone formel) a été inventé en 1957 par Frank Rosenblatt dans les laboratoires du Cornell Aeronautical pour modéliser le fonctionnement d'un neurone humain [84] [85]. Il n'avait qu'une seule sortie à laquelle toutes les entrées étaient connectées. Un réseau de neurones à couches multiples, appelé aussi perceptron multi-couches (*Multi Layer Perceptron*, MLP), est composé de neurones organisés en couches à l'image de la structure neuronale du cerveau comme le montre la figure 3.1. Son nombre de couches n'est théoriquement pas limité : une d'entrée, au moins une cachée et une de sortie. Le nombre de couches cachées dépend de l'application et de la nature et taille des données d'entrées. Chaque couche comprend un certain nombre de neurones formels potentiellement différent d'une couche à une autre. Les neurones sont inter-connectés, un même neurone reçoit donc l'information de plusieurs neurones et la transmet à plusieurs autres. L'information circule de la couche d'entrée, en passant par les éventuelles couches cachées, vers la couche de sortie uniquement : propagation directe (*feedforward*). Les neurones d'une couche reçoivent ainsi des données d'entrée, les traitent, et les transmettent à tous les neurones de la couche suivante. Outre ces réseaux à couches multiples, de nouvelles architectures continuent à émerger. Nous en proposons ci-dessous une énumération non-exhaustive :

- les réseaux de neurones convolutifs,
- les réseaux de neurones récurrents,

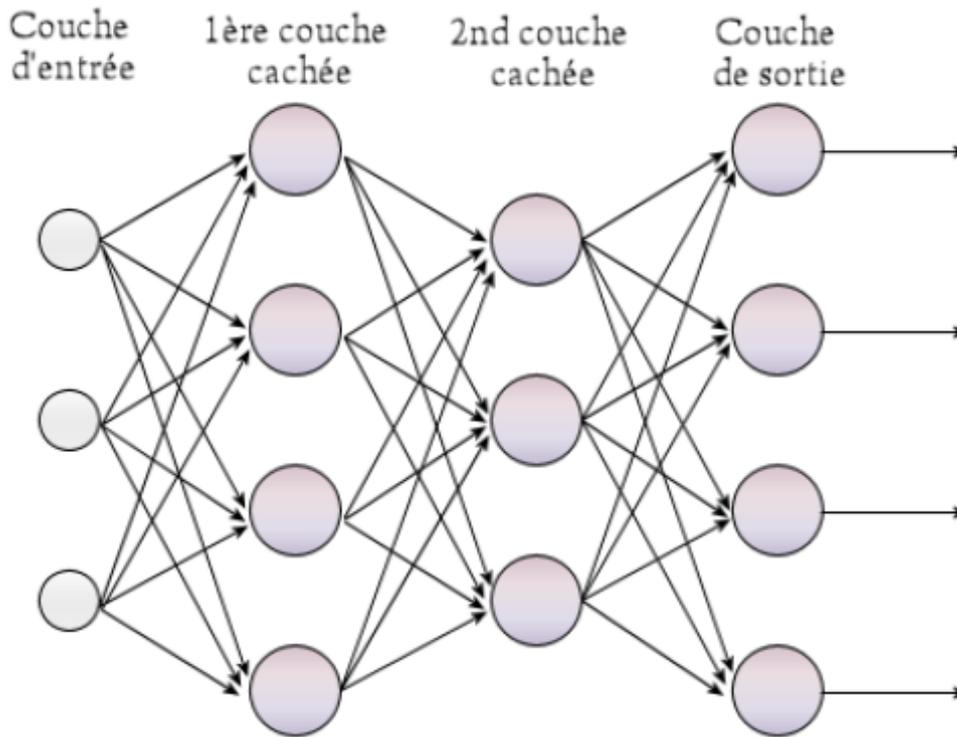


FIGURE 3.1 – Structure d'un MLP [86].

- les réseaux de neurones résiduels,
- les réseaux auto-organisés,
- les réseaux à résonance [87].

Dans ce qui suit, nous présentons brièvement les réseaux de neurones récurrents et convolutifs utilisés dans la suite de ce travail.

3.2.1.2 Réseaux de neurones récurrents

3.2.1.2.1 Principe

Un réseau de neurones récurrent a un graphe de connexion possédant au moins un cycle contrairement aux réseaux à couches multiples (MLP) qui sont acycliques.

Ces connexions cycliques ne sont utiles et de fort impact que lorsque l'entrée du réseau a la forme d'une séquence temporelle (où chaque vecteur de la séquence représente un évènement temporel). La liaison cyclique sert à encoder les dépendances latentes entre les événements temporels d'une séquence de vecteurs d'entrée. Le RNN le plus simple est celui proposé par Jeffrey Elman en 1990 [88] où a été rajouté à un MLP des liens pour :

- donner en entrée d'une couche du réseau sa propre sortie au pas de temps précédent,

— lui donner en plus la sortie courante de la couche précédente.

Le principe du RNN repose sur un mécanisme de mémoire des entrées précédentes à propager à travers les états internes du réseau, de façon à conditionner les futures sorties. Mathématiquement, un RNN reçoit en entrée une séquence de vecteurs $x = (x_1, x_2, \dots, x_T)$ et définit la séquence d'états cachés $h = (h_1, h_2, \dots, h_T)$ pour générer la séquence de vecteurs de sortie $y = (y_1, y_2, \dots, y_T)$ en itérant de $t = 1$ à T :

$$h_t = H(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (3.1)$$

$$y_t = W_{hy}h_t + b_y \quad (3.2)$$

où T est le nombre total de vecteurs d'entrée, $W_{\alpha\beta}$ est la matrice de poids entre les couches α et β , et b_β est le vecteur de biais de la couche β . La fonction H utilisée est généralement la tangente hyperbolique. Un algorithme d'optimisation régule et ajuste les paramètres de poids et de biais des couches d'une manière itérative. Parmi les méthodes d'optimisation les plus répandues ressort la descente de gradient combinée à un algorithme de rétropropagation (*backpropagation*).

Les liaisons temporelles exprimées dans les formules précédentes ne peuvent pas être prises en considération par l'algorithme de rétropropagation du gradient, conçu pour les réseaux non bouclés. De ce fait, une version appelée rétropropagation du gradient à travers le temps (*Backpropagation Through Time*, BPTT) a été élaborée [89]. La schématisation de la figure 3.2 montre que l'échelle temporelle, représentée à travers les arcs diagonaux, porte une signification hiérarchique, les couches cibles étant de plus haut niveau. Les RNN bidirectionnels connectent deux couches cachées de directions opposées à la même sortie de la sorte qu'elle obtienne simultanément des informations sur les états passés (en arrière) et futurs (en avant). Sans précautions particulières, les RNN éprouvent des difficultés à aborder des séquences relativement longues, notamment celles contenant plus de 10 événements [91]. Par ailleurs, ils souffrent de deux problèmes nommés dissipation du gradient (*vanishing gradient*) et explosion du gradient (*exploding gradient*) [91]. En effet, avec des calculs cumulés à la longue, l'erreur obtenue avec la rétropropagation du gradient décroît (dissipation du gradient) ou, moins fréquemment, augmente d'une manière exponentielle au fil du temps (explosion du gradient). Ces limitations se rajoutent à la mémoire relativement réduite des RNN pour donner naissance durant les dernières années à un type particulier de RNN : *Long Short-Term Memory* (LSTM) avec l'objectif de pallier aux problèmes rencontrés par ses précurseurs.

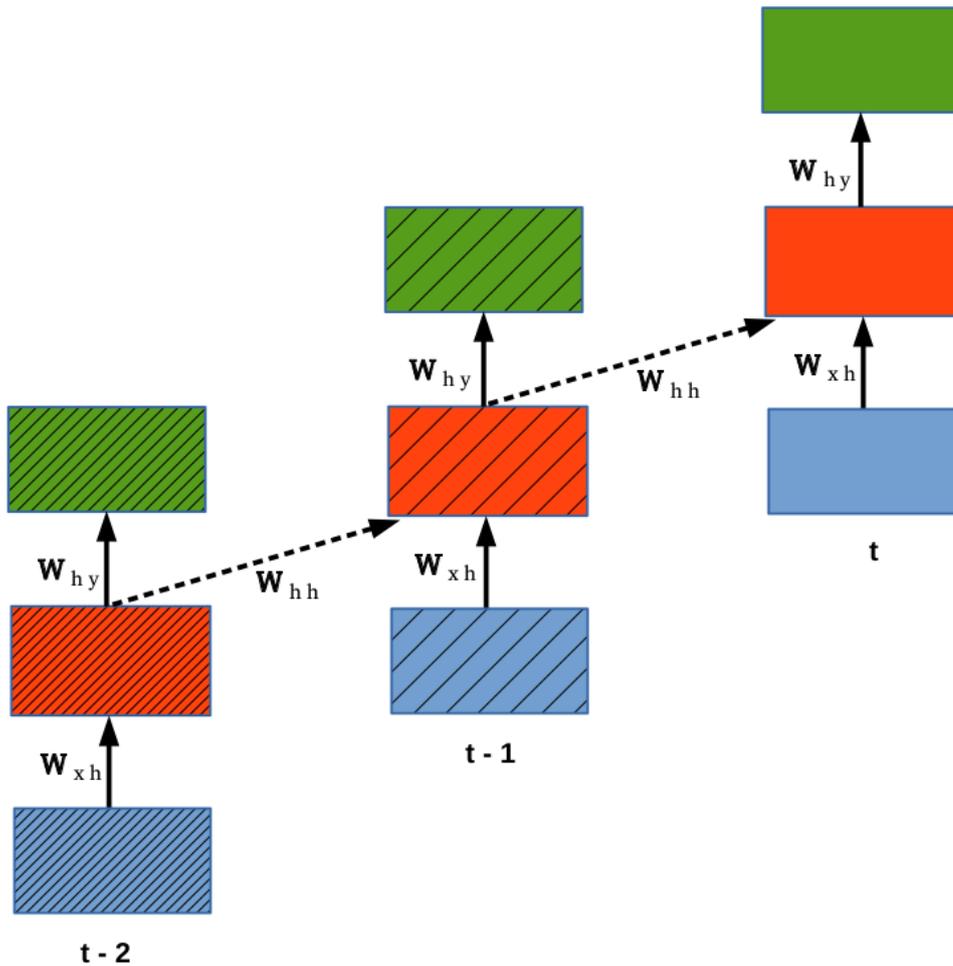


FIGURE 3.2 – Représentation dépliée dans le temps et hiérarchisée des RNN [90]. Les boîtes bleues, rouges et vertes représentent la couche d’entrée, la couche cachée récurrente et celle de sortie respectivement. Les hachures permettent de distinguer l’état du réseau à différents instants temporels.

3.2.1.2.2 LSTM

Le LSTM constitue une extension substantielle du concept des RNN. Il a été développé pour, entre autres, remédier à un contexte passé qui reste très local pour un RNN et donc d’utilisation limitée dans le traitement de l’information courante. Plusieurs études ont eu recours au LSTM comme une *baseline* à des fins de comparaison avec d’autres réseaux vu qu’il était considéré comme une norme à performances prometteuses sur des tâches nombreuses et diversifiées traitant des données séquentielles [92]-[95]. L’architecture de base et les formules mathématiques sont héritées des formulations précédentes, mais c’est

la manière de gérer l'état caché qui diffère.

Une cellule à mémoire est adoptée à la place de la couche cachée du RNN comme le montre la figure 3.3. La cellule LSTM est composée d'un nœud central, contenant son état (ou

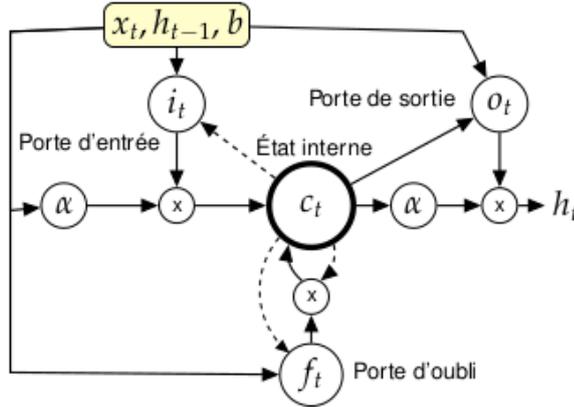


FIGURE 3.3 – Une cellule LSTM. Les flèches en pointillé représentent les opérandes avec un décalage temporel ($t - 1$). La fonction d'activation α (pour l'entrée et la sortie) est généralement une tangente hyperbolique (\tanh) [90].

mémoire) interne, et un nombre de "portes" appartenant à 3 catégories différentes. Les portes d'entrée et d'oubli assurent la tenue en mémoire de l'information séquentielle. En l'occurrence, la porte d'entrée gère l'influence des nouveaux événements sur l'information de la cellule. Sa fermeture détermine que ses évènements auront un impact minime sur la cellule. La porte de sortie définit le rôle de l'état interne dans la production de chacune des sorties. Nous notons que les portes d'entrée et d'oubli sont calculées avant la mise à jour de l'état interne. À l'étape de propagation avant à un instant t , ces portes ont donc recours à l'état interne précédent (celui de l'instant $t - 1$).

Selon cette représentation, H est désormais une fonction composite définie par :

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \tag{3.3}$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \tag{3.4}$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \tag{3.5}$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \tag{3.6}$$

$$h_t = o_t \tanh(c_t) \tag{3.7}$$

où c est le vecteur d'état interne ayant la même taille que celle du vecteur caché h . i , f et o , sont respectivement les portes d'entrée, d'oubli et de sortie. Les matrices W partent de la cellule c vers les portes i , f et o . Les connexions en question sont diagonales et relient ainsi l'élément j dans le vecteur de chaque porte à uniquement l'élément j du vecteur de la cellule. σ est la fonction logistique sigmoïde.

Les LSTM promettent de bonnes performances dans différents domaines d'application. Ils constituent actuellement la méthode phare de traitement des données séquentielles [92]. Leur intérêt est, de plus, marqué face à des séquences d'événement assez longues [96] [97].

3.2.1.3 Réseaux de neurones convolutifs

Les CNN sont une famille des perceptrons multi-couches [98] [99] initialement conçus pour le traitement d'images et la vision par ordinateur. Plus particulièrement, ils ont montré leur intérêt dans plusieurs applications différentes comme des tâches de détection d'objet et de classification d'images [100], [101]. En ce qui concerne l'application d'un réseau de neurones multi-couche à une donnée image, la couche d'entrée comporterait un nombre de perceptrons égal aux nombres de pixels de l'image en entrée (65536 perceptrons pour une image de taille 256×256 pixels par exemple). Compte tenu du nombre de couches cachées qui en découlerait, un nombre trop important de paramètres serait à déterminer. En outre, ce type d'architecture passe à côté de l'information spatiale en étant incapable de localiser un pixel et son voisinage dans une image. Or, cette information est cruciale en traitement d'image et est exploitée à travers des opérations de convolution, ce qui donne libre cours aux analyses locales des caractéristiques de l'image. En pratique, des couches de convolution sont successivement rajoutées aux réseaux de neurones de manière à permettre l'extraction des caractéristiques de l'image à différents niveaux de détails.

Les CNN sont destinés à traiter des données sous la forme de tableau de valeurs en N dimensions. En l'occurrence, une image RGB (*red*, *green*, *blue*) comporte trois tableaux 2D, un par canal de couleur. Ces tableaux contiennent les intensités de pixels comme valeur. Plusieurs autres types de données se présentent sous la forme de tableaux à multiples dimensions :

- 1D pour les signaux et les séquences, y compris le langage naturel,
- 2D pour images ou spectrogrammes audios,
- 3D pour les vidéos ou les images volumétriques.

Le principe d'un CNN se base sur trois idées clés :

- les connexions locales,

- les poids partagés,
- la couche de regroupement (*pooling*).

L'architecture d'un CNN typique est structurée en une série d'étapes. Les premières étapes sont constituées de deux types de couches : les couches convolutives et les couches de pooling. Le CNN peut être utilisé pour extraire des caractéristiques temporelles lorsque le noyau se déplace selon une seule direction (*one dimensional convolutional neural network*, 1D-CNN). Ce réseau est utile pour l'analyse de signaux de longueur fixe. Son avantage est qu'il met en jeu moins de paramètres que les RNN [102].

Nous détaillons dans ce qui suit le déroulement de l'apprentissage d'un réseau profond.

3.2.2 Apprentissage

L'apprentissage profond est au cœur de l'apprentissage automatique (*machine learning*), qui est à son tour une branche de l'IA. Ces techniques permettent d'apporter une réponse à différentes tâches : classification, régression, segmentation, prédiction...

L'apprentissage automatique suppose que les données en entrée sont structurées, alors que l'apprentissage profond extrait automatiquement les caractéristiques discriminantes de ces dernières. Il est utilisé dans le traitement de données complexes et variées (texte, son, image, séries temporelles...). Les méthodes d'apprentissage profond reposent sur des couches de neurones artificiels inter-connectés entre eux de manière à former un graphe orienté. Ces derniers assurent une fonction de calcul. Un nombre de couches très élevé justifie l'aspect profond de cet apprentissage. Une phase d'entraînement permet au réseau d'apprendre à effectuer une tâche, ce qui imite le fonctionnement du cerveau humain. En analogie avec les réseaux biologiques de neurones, les connexions entre les nœuds du graphe symbolisent les synapses.

Les recherches dans ce domaine s'efforcent de construire de meilleures représentations du réel et de créer des modèles capables d'apprendre ses représentations à partir de données. L'apprentissage d'un modèle consiste à déterminer les valeurs de ses poids d'une manière à réduire les écarts entre les prédictions qu'il produit et les vérités terrain espérées et connues au préalable. Il s'agit d'un problème d'optimisation dans un espace multi-dimensionnel. Deux étapes majeures définissent cet apprentissage :

- La phase d'entraînement où les poids du modèle sont mis à jour tout au long de l'apprentissage. Il est courant d'initialiser ses poids aléatoirement. Au fur et à mesure de l'apprentissage, certaines connexions entre neurones vont se renforcer.
- La phase de validation qui compare les prédictions calculées sur de nouvelles don-

nées d'entrées (non rencontrées pendant la phase d'entraînement) aux sorties espérées. Les poids utilisés dans ce calcul sont les derniers mis à jour par l'entraînement.

Cette phase est primordiale pour évaluer la capacité de généralisation du modèle. Durant l'apprentissage, une fonction de perte évalue la précision des prédictions du réseau générées en les comparant aux sorties espérées. Cette fonction génère une erreur qui sera employée pour mettre à jour les poids des neurones par un algorithme de rétropropagation du gradient de l'erreur. L'apprentissage du réseau avec ses deux phases d'entraînement et de validation est un processus itératif étant donné que les mêmes données d'entrées sont balayées plusieurs fois par le réseau (itérations ou *epochs*). Cela simule le fonctionnement du cerveau humain qui assimile par répétition. Le processus d'apprentissage avec ses deux phases prend fin suite à un certain nombre d'itérations et en convergeant vers un modèle adéquat grâce à l'optimisation. Une fois l'entraînement réalisé, ce modèle est prêt à être appliqué sur de nouvelles données de test. Cet apprentissage est supervisé puisque nous disposons de données servant de vérité terrain. Dans l'apprentissage non-supervisé, le réseau assume la détection de similarités ou de différences dans les données, sans disposer de vérité terrain. Il sera alors capable d'identifier les structures inhérentes aux données.

3.2.2.1 Préparation des données d'entrées

L'apprentissage d'un réseau de neurones conditionne son efficacité et ses performances. De ce fait, il est très important que le jeu de données à disposition soit le plus représentatif. Sa variabilité doit être suffisante pour inclure des cas rares et couvrir une large palette d'observation pour une capacité d'apprentissage maximale.

3.2.2.1.1 Répartition des données

Le jeu de données à disposition est généralement divisé en trois sous-ensembles à prodiguer aux différents cas d'utilisation du réseau :

- le jeu d'entraînement employé pour l'apprentissage,
- le jeu de validation permettant de vérifier le bon déroulement de l'apprentissage,
- le jeu de test.

L'apprentissage d'un réseau nécessite une grande quantité de données pour aboutir à un modèle performant et facilement déployable. De ce fait, d'une manière générale, 2/3 des données totales sont généralement consacrées à l'entraînement. Le tiers restant est ainsi suffisant pour effectuer les deux autres cas d'utilisation, et est communément scindé d'une manière équitable entre le jeu de validation et le jeu de test. Cependant, un point

très important à noter est la nécessité à ce que les 3 sous-ensembles soient suffisamment représentatifs des différentes caractéristiques des données présentes à nous. Autrement dit, ces sous-ensembles doivent présenter une variance assez équitable entre les différentes caractéristiques représentant les données.

3.2.2.1.2 Augmentation de données

L'augmentation des données est une technique qui accroît la taille et la diversité des données d'apprentissage en les transformant. Cet enrichissement du jeu d'entraînement l'alimente de données diversifiées, ce qui améliorera les performances du réseau. L'application de l'augmentation des données à l'apprentissage automatique permet d'améliorer la capacité de généralisation des modèles, en particulier dans le cadre de l'apprentissage profond [103]. Les méthodes les plus courantes pour les séries temporelles sont la permutation, la rotation, le *slicing*, le *jittering* et le *scaling* [104].

3.2.2.2 Hyper-paramètres des réseaux

Plusieurs paramètres, outre le choix de la fonction de perte et de l'algorithme d'optimisation, permettent de conditionner le comportement d'un réseau et de son apprentissage. Ces hyper-paramètres impactent significativement les performances et leur optimisation n'est pas toujours instinctive. Généralement, leur sélection pour un problème donné se fait d'une manière heuristique : plusieurs combinaisons d'eux sont testées une à une.

3.2.2.3 Sur-apprentissage et sous-apprentissage

L'apprentissage visé correspond à un modèle capable de généraliser ce qu'il a appris pendant l'entraînement à de nouvelles données. Autrement dit, ses performances, en termes de précision des prédictions, sont comparables entre les deux phases d'entraînement et de validation. Néanmoins, dans certains cas, le modèle peut sous-apprendre (sous-entraînement) ou sur-apprendre (sur-entraînement). Dans le sous-apprentissage, le modèle produit des résultats peu satisfaisants dans les étapes d'entraînement et de validation. Dans le cas de sur-apprentissage, les performances du modèle sont plutôt bonnes dans l'étape d'entraînement, mais médiocres sur les données de validation. Ce phénomène est appelé *over-fitting* en anglais. Il se caractérise par une faible capacité prédictive du modèle vis-à-vis des nouvelles données qu'il rencontre. Afin d'apporter une réponse convenable à ces deux cas de figure, plusieurs possibilités s'offrent à nous. Certaines d'entre elles ciblent directement l'origine du problème si cette dernière est connue. D'une manière générale, il

s'avère judicieux de modifier le modèle et sa complexité, d'optimiser ses hyper-paramètres, d'augmenter les données d'apprentissage et leur hétérogénéité en créant artificiellement des nouveaux patterns.

3.2.2.4 Apprentissage par transfert (*transfer learning*)

Le *transfer learning* est une technique d'apprentissage automatique dans laquelle un modèle exploite les connaissances acquises lors d'une tâche précédente pour améliorer la généralisation sur une autre tâche. En d'autres termes, cet apprentissage peut compenser le manque de données étiquetées par le transfert de connaissances provenant d'autres sources de données étiquetées. Selon [105], plusieurs taxonomies peuvent être utilisées pour catégoriser les méthodes de *transfer learning*. Nous passons ici en revue l'adaptation au domaine, la généralisation du domaine et le transfert des connaissances liées aux paramètres (*transferring knowledge related to the parameters*). L'adaptation au domaine vise à généraliser un modèle entre les domaines source et cible qui suivent des distributions différentes. La généralisation des domaines regroupe les connaissances de plusieurs domaines sources en un seul modèle qui peut être généralisé à de nouveaux domaines cibles [106]. L'apprentissage multi-tâches vise à apprendre simultanément tout en maximisant les performances sur une ou plusieurs tâches. Le transfert de la connaissance des paramètres est une technique qui permet de réutiliser les poids d'une ou plusieurs couches d'un réseau pré-entraîné dans un nouveau modèle et de l'affiner (*fine-tuning*).

3.2.3 Modèles discriminatifs et génératifs

3.2.3.1 Modèles génératifs

D'une manière générale, un modèle génératif comprend une étape d'apprentissage non-supervisée qui précède une phase d'entraînement d'un classifieur ou prédicteur standard [107]. Le but des approches génératives est d'abord de trouver une représentation significative, qui porte en elle des caractéristiques latentes des données considérées et à la transmettre après au modèle à entraîner [107]. À titre d'exemple, un auto-encodeur est un réseau neuronal non-supervisé capable d'apprendre des représentations de données efficaces grâce à ses fonctions de compression et de décompression [108] [109]. Il se compose de trois éléments : l'encodeur, la fonction de perte et le décodeur. Un autre exemple est le réseau antagoniste génératif (Generative Adversarial Network, GAN) développé en 2014 [110]. Il comprend deux réseaux de neurones, un discriminateur et un générateur, s'affron-

tant sous la forme d'un jeu à somme nulle, où le gain d'un agent est la perte d'un autre agent. L'idée centrale d'un GAN est basée sur l'apprentissage indirect via le discriminateur, qui peut indiquer au générateur à quel point l'entrée semble réaliste. Le générateur n'est ainsi pas formé pour minimiser la distance par rapport à une entrée spécifique, mais plutôt pour tromper le discriminateur.

3.2.3.2 Modèles discriminatifs

Le modèle apprend la fonction qui lie les données en entrée à leurs cibles correspondantes en sortie (classes exprimées en termes de probabilité d'appartenance lors de la résolution d'un problème de classification). Les algorithmes discriminatifs peuvent être divisés en deux catégories : ceux travaillant avec des caractéristiques extraites manuellement (*handcrafted features*) et ceux qui sont automatiques de bout en bout (*end-to-end*).

Les méthodes d'extraction de *handcrafted features* les plus utilisées sont inspirées de la vision par ordinateur et englobent les transformations des séries temporelles en images. Ces méthodes dépendent généralement du domaine d'application et nécessitent par conséquent l'apport d'un expert (*feature engineering*). Une fois extraites, les *handcrafted features* sont transmises aux algorithmes d'apprentissage profond sélectionnés pour la tâche en question. Les algorithmes *end-to-end* proposent d'extraire eux même des caractéristiques pertinentes qui sont idéalement représentatives de la forme générale des données. Le processus d'apprentissage des caractéristiques (*feature learning process*) est incorporé dans l'étape d'entraînement et d'optimisation des paramètres du réseau (*fine-tuning*). Dans ce cas, aucune connaissance préalable du domaine d'application n'est requise.

3.3 État de l'art

Tous les exemples de la littérature cités dans cette bibliographie impliquent des données de capteurs capturant la marche humaine ou des données temporelles destinées à une application médicale. Nous nous limitons notre étude bibliographique aux articles publiés après 2019.

Nous avons utilisé Scopus¹ [111] le 31 août 2023 pour dénombrer les articles publiés après 2019 et traitants de l'apprentissage profond sur des signaux mono-dimensionnels : séries temporelles ou données de capteurs.

1. <https://www.scopus.com/>

Nous nous sommes limités aux domaines de l’informatique et de la médecine. La recherche Scopus révèle 16 610 articles répondants à ces critères. Leur nombre par année est indiqué dans la Figure 3.4. Cette première recherche montre que l’apprentissage profond pour

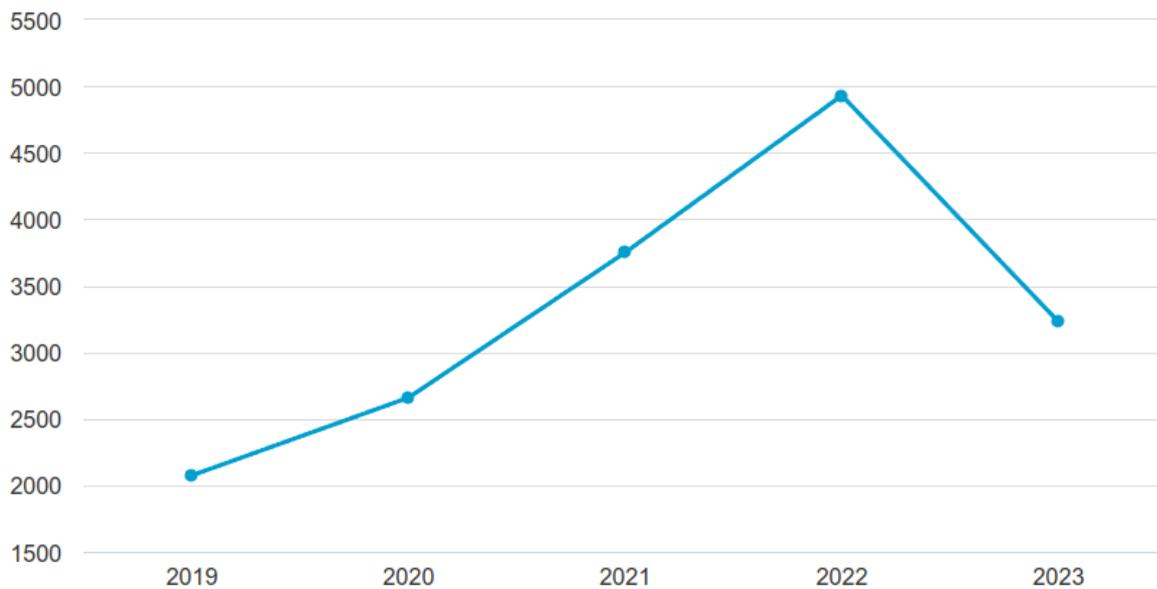


FIGURE 3.4 – Documents par année traitants de l’apprentissage profond appliqué à des signaux mono-dimensionnels.

des signaux mono-dimensionnels est un domaine naissant et sollicitant de plus en plus l’intérêt de la communauté, mais il reste sous-exploité comparé à celui de l’apprentissage profond appliqué au traitement d’images ou à la vision par ordinateur (39 629 articles publiés après 2019).

Afin de tirer profit des modèles de vision par ordinateur, nous avons procédé à un encodage signal/image. Nous citons ci-dessous des exemples de transformations possibles.

3.3.1 Utilisations de la conversion signal/image

Une recherche Scopus des articles publiés après 2019 dans des revues scientifiques ressort 654 articles dont 357 datant de 2019-2021. Nous nous sommes limités aux domaines de la médecine et de l’informatique. Nous énumérons les travaux trouvés par type d’encodage.

3.3.1.1 Transformée de Fourier rapide (*Fast Fourier Transform*, FFT)

[112] a opté pour une architecture qui combine une FFT, un CNN, un LSTM et un mécanisme d'attention pour extraire des caractéristiques spatio-temporelles à partir de signaux EEG, et ce dans l'intention de détecter l'alcoolisme. Les résultats analytiques utilisant l'architecture proposée montrent une précision de 98.83%, ce qui la rend meilleure que la plupart des algorithmes de l'état de l'art. Dans [113], il s'agissait d'introduire la représentation fréquentielle dans les CNN ce qui a donné naissance à un nouveau modèle nommé tKFC-Net. Grâce à la FFT, la représentation fréquentielle a été utilisée dans le *pooling*, le sur-échantillonnage et la convolution sans aucun ajustement de l'architecture du réseau. L'application de cette étude portait sur la segmentation d'images médicales. Le modèle proposé obtient des résultats remarquables : le score F1 est de 0.878 pour la segmentation des lésions cutanées, de 0.8185 pour la segmentation des vaisseaux sanguins, de 0.9830 pour la segmentation des poumons et de 0.8457 pour la segmentation des tumeurs cérébrales. Dans [114], l'objectif était de classifier des signaux EEG issus de patients ayant subi un Accident Vasculaire Cérébral (AVC) en AVC/non AVC. La première étape du traitement des signaux consistait en leur conversion en des images FFT.

3.3.1.2 *Gramian angular field* (GAF)

[115] a proposé une méthode d'estimation de la longueur du pas ou encore la distance entre les points successifs de contact initial d'un même pied (*stride length*) basée sur des images GAF obtenues à partir des données d'un accéléromètre. Les GAF étaient ensuite introduites dans un CNN. Les résultats obtenus montrent que la méthode proposée est supérieure en termes de précision que d'autres méthodes utilisant directement les données de l'accéléromètre. Dans [116], des signaux ECG ont été convertis en des images *Gramian Angular Difference Field* (GADF) pour une tâche de détection d'anomalies dans le cadre d'un suivi du rythme cardiaque (*cardiac monitoring*). La méthode développée donne des performances prometteuses dans la détection de patterns ECG anormaux induits par divers types de maladies cardiaques. Par exemple, un score F de 0.9771 pour la détection de la fibrillation auriculaire, 0.9986 pour la détection du bloc de branche droit et 0.9550 pour la détection de la dépression ST (*ST depression*). [117] s'est intéressé à la détection de l'infarctus du myocarde. Les ECG étaient d'abord transformés en images GADF.

3.3.1.3 *Markov transition field* (MTF)

Dans [118], une méthode efficace a été proposée pour une application au diabète de type 2, et ce en utilisant les ondes de pouls périphériques qui peuvent être mesurées rapidement, simplement et à moindre coût par un capteur de force placé sur le poignet au-dessus de l'artère radiale. Les séries de pouls ont été codées sous forme d'images GAF, MTF et RP (*recurrence plot*). Un CNN de fusion multi-tâches à quatre couches a été développé pour une classification inter-patients pour distinguer les patients sains des diabétiques. Les résultats montrent que la meilleure précision atteint 90.6 %. Dans [119], des signaux ECG ont été convertis en images RP, GAF et MTF. Après cet encodage, une fusion d'images était mise en place pour combiner les trois modalités résultantes, constituant ensuite l'entrée d'un CNN destiné à une classification des battements de cœur. Une précision de classification de 99.7% et de 99.2% a été atteinte pour l'arythmie et l'infarctus du myocarde, respectivement.

3.3.2 Apprentissage profond et analyse de signaux physiologiques

L'objectif de cette section est de comprendre ce que les approches d'apprentissage profond peuvent apporter à des problématiques d'analyse de signaux mono-dimensionnels à travers plusieurs cas d'usage. Nous nous limitons à deux applications à savoir la classification et la prédiction et aux articles de revue (*reviews*) vu le nombre d'articles très important identifiés sur Scopus. Cette recherche ressort 116 articles parmi les 16 610 trouvés précédemment, dont 42 datant de 2019-2021.

3.3.2.1 Classification

La classification de séries temporelles (*Time Series Classification*, TSC) consiste à attribuer à une série temporelle l'une des classes présentes dans un ensemble prédéfini.

Elle constitue un large champ de recherche ambitieux qui a pris de l'ampleur ces dernières années. Des centaines d'algorithmes ont été élaborés pour répondre à un besoin croissant de classer des séquences diversifiées et appartenant à des domaines d'application variés : reconnaissance de l'activité humaine (*human activity recognition*) [120], *electronic health records* [121]... Initialement, une minorité de ces algorithmes ont considéré l'apprentissage profond, bien qu'il se soit brillamment imposé dans le contexte du *data mining* [122]. Cela s'explique par l'intérêt majoritaire que portait, depuis toujours, l'apprentissage profond à la vision par ordinateur. De larges progrès ont vu le jour dans la reconnaissance d'ob-

jets ou la classification d'images par exemple grâce à l'utilisation massive de CNN et de réseaux résiduels. En ce qui concerne la TSC, l'apprentissage profond a montré beaucoup plus tard son efficacité à traiter des séries temporelles et des séquences comme pour la classification de document.

Depuis 2015, avec la croissance prégnante des données temporelles [123], des centaines d'algorithmes d'apprentissage profond dédiés au TSC ont été développés [124] pour répondre à des domaines d'application hétérogènes. Plusieurs parmi ces algorithmes et leurs variantes, ont puisé dans les bases de données variées de l'archive UCR/UEA [125] qui constitue le plus large dépôt de séries temporelles. Même en dehors de cette archive, les algorithmes d'apprentissage profond ont atteint des performances exceptionnelles sur plusieurs bases de données dans différents domaines [107].

Pour la reconnaissance de l'activité humaine à partir de capteurs portables, l'apprentissage profond de bout en bout est entrain de remplacer les algorithmes de *feature engineering*. Nous n'énumérons pas les travaux réalisés pour cette application dans cette thèse. Dans ce qui suit, nous illustrons par des exemples l'utilisation de l'apprentissage profond sur des signaux physiologiques à des fins de classification.

Dans [126], un MLP a été façonné pour apprendre à partir de zéro (*from scratch*) et de bout en bout une tâche de TSC. Nous rappelons que le MLP ne conserve pas l'information temporelle. Les caractéristiques qu'il extrait ne sont pas invariantes dans le temps (*time-invariant*). Néanmoins, dans ce sens, les CNN s'avèrent plus utiles en tant que modèles capables d'apprendre des filtres (ou caractéristiques) invariants dans l'espace (*spatially invariant*) à partir de séries temporelles brutes [127]. Une erreur moyenne par classe (*mean per-class error*) de 0.143 a été obtenue sur la base de données Adiac [128]. Les auteurs dans [122] stipulent que le CNN est l'architecture la plus largement appliquée dans le contexte du TSC, ce qui est probablement dû à sa robustesse et à son temps d'apprentissage relativement faible par rapport aux architectures plus complexes telles que les RNN ou les MLP. Les résultats obtenus montrent l'efficacité des CNN et des réseaux résiduels. Une revue récente sur l'apprentissage profond pour la classification des signaux physiologiques [129] prône le CNN comme l'architecture phare pour la tâche considérée. Dans [130], un certain nombre de caractéristiques, dont la vélocité, ont été extraites des données de capteurs portés par un chirurgien à sa main. L'objectif de cette étude menée de bout en bout était de déterminer le niveau de compétence pendant la formation chirurgicale. L'optimisation du réseau de neurones utilisé a été réalisée après sept essais avec un ensemble de données d'entraînement de 38 chirurgiens. Le taux de

jugement correct atteint était de 0.99. Dans [131], des CNN ont été conçus pour atteindre de hautes performances dans l'identification des compétences chirurgicales. La méthode proposée a été validée sur l'ensemble de données JIGSAWS [132] et a obtenu des résultats très compétitifs avec une précision de 100% pour les tâches de suture et de passage d'aiguille. En 2018, dans [133], l'architecture proposée dans [127] a été modifiée pour tirer parti d'une technique d'initialisation de filtres basée sur les valeurs d'ondelettes de Daubechies 4 (*Daubechies 4 Wavelet*). Dans [8], des enregistrements sonores de battement de cœur recueillis auprès de sujets sains ou malades ont été classifiés en normal ou pathologique. Plusieurs travaux ont été consacrés à la détection des anomalies cardiaques comme l'arythmie à partir de signaux ECG [134] [135]. Dans [134], une précision, une sensibilité et une spécificité de 92.50%, 98.09% et 93.13%, respectivement, ont été obtenues pour deux secondes de segments ECG. Des électroculogrammes (EOG) ont été utilisés pour le diagnostic de pathologies ophtalmologiques [136]. Dans [137], certains modèles avec différents nombres de couches LSTM et de couches entièrement connectées ont été développés pour la détection de la dépression à partir de signaux EEG. Une précision (*Accuracy*) de 99.10% a été atteinte. Dans [138], un LSTM-RNN a été considéré pour l'identification de l'apnée du sommeil et de sa gravité. Il s'agit d'une classification de l'apnée minute par minute à partir de signaux ECG.

3.3.2.2 Prédiction

Dans [139], un récent réseau antagoniste génératif couplé à un CNN a été confronté à des *Electronic Health Records* dans l'intention d'accomplir une prédiction de risque, et ce en se basant sur l'historique des patients. L'apprentissage était réalisé de bout en bout. Dans [8], différents capteurs ont été portés par des patients hospitalisés depuis 48h au moins. Ces derniers étaient invités à réaliser une activité physique durant l'hospitalisation. Les mesures collectées par les capteurs sont : l'accélération, la vitesse angulaire, la lumière, la température, l'humidité et la pression atmosphérique. Le but de l'étude était de prédire la durée de l'hospitalisation et le risque d'une réadmission dans les 30 jours. Dans [140], un CNN a été employé sur des signaux EEG pour la prédiction de crises d'épilepsie. Pour chaque patient, 100% des crises ont été prédites en moyenne 60 minutes avant leur apparition, sans fausse alerte. Dans [141], une prédiction de la mortalité peu après la confirmation de l'infection par le SRAS-CoV-2 dans la population des patients de la Mayo Clinic a été développée. Pour ce faire, des RNN ont été considérés. Dans [142], un RNN a été appliqué à la prédiction des crises d'épilepsie sur des signaux EEG. Une Aire sous la

courbe ROC (*Receiver Operating Characteristic*) AUC (*Area Under Curve*) maximale en validation croisée de 0.938 a été atteinte. Ce même type de signaux a été exploité, à l'aide d'un RNN, dans la prédiction précoce de la maladie d'Alzheimer [143].

Dans ce qui suit, nous déclinons les utilisations de l'apprentissage profond spécifiques à la maladie de Parkinson (MP) et à l'AQM.

3.3.3 Apprentissage profond et maladie de Parkinson

Dans cette section, nous commençons par faire l'inventaire des utilisations de l'apprentissage profond pour EMA. 3 articles parmi les 16 610 trouvés précédemment étaient obtenus. En particulier, [144] propose un LSTM pour prédire les troubles de la mobilité sur la base de l'évaluation WHODAS 2.0 (*World Health Organization Disability Assessment Schedule 2.0*) à partir de biomarqueurs numériques. [145] a utilisé des capteurs de *smartphone* et des modèles d'apprentissage profond personnalisés pour prédire les futurs symptômes d'anxiété parmi un échantillon rapportant des symptômes de troubles anxieux cliniques. Ces modèles étaient capables de prédire la majorité de la variation totale des symptômes d'anxiété ($R^2 = 0.748$) ainsi qu'une grande partie de la variation intra-personnelle heure par heure (R^2 moyen = 0,385). [146] présente les RNN comme une approche d'apprentissage statistique puissante pour l'analyse et la prédiction de séries temporelles collectées à partir de dispositifs portables, tels que les *smartphones*, les *trackers de fitness* ou les *smartwatches*. Dans cette étude, il a été stipulé que les RNN peuvent être entraînés simultanément sur plusieurs modalités de données pour apprendre un modèle dynamique qui pourrait être utilisé pour prévoir les trajectoires individuelles et planifier les interventions médicales de patients souffrant de psychoses.

En ce qui concerne les utilisations de l'apprentissage profond pour la MP, 133 articles ressortent parmi les 16 610 trouvés précédemment, dont 73 publiés avant 2021. Dans [147], le but était de fournir une estimation fiable et continue de la gravité de la MP à domicile. Un LSTM et un LSTM-CNN ont été utilisés pour estimer le *Unified Parkinson Disease Rating Scale-part III* à partir des données de capteurs inertiels portables. L'algorithme a été évalué sur les données gyroscopiques de 24 personnes âgées atteintes de la MP pendant qu'elles effectuaient différentes activités de la vie quotidienne. Les scores UPDRS-III estimés présentaient une corrélation de 0.79 ($p < 0.0001$) et une erreur absolue moyenne de 5.95 avec les scores de l'examen clinique. Dans [148], l'apprentissage profond a été entraîné sur des données de l'accéléromètre et du gyroscope afin de prédire la présence de la MP et la gravité de trois de ses symptômes : tremblements, dyskinésie et bradykinésie.

Quarante équipes du monde entier ont obtenu une performance prédictive de l'état de la MP (meilleur AUROC = 0.87), ainsi que des tremblements (meilleur AUPR = 0.75), de la dyskinésie (meilleur AUPR = 0.48) et de la sévérité de la bradykinésie (meilleur AUPR = 0.95). Dans [149], la détection de la MP passe par une approche multimodale d'apprentissage profond. L'architecture proposée utilise deux modalités de données, acquises à partir de capteurs de vision et d'accéléromètre dans un environnement domestique, pour entraîner des modèles d'auto-encodeur variationnel. Dans [150], un nouveau modèle génératif profond stochastique a été proposé pour la prévision de l'évolution de la maladie à l'aide de données cliniques longitudinales. Dans [151], un CNN de 20 couches a été déployé pour exploiter les caractéristiques extraites de signaux EEG au repos afin de détecter la MP. Dans [152], un CNN-LSTM a été employé pour la classification des stages de sommeil à partir de données de capteur de lit hydraulique. Le but de cette étude étant de diagnostiquer les troubles de sommeil fréquents dans la MP. Les résultats obtenus montraient une précision moyenne d'environ 76% en utilisant la validation LOSO (*leave-one-subject-out*). Dans [153], des données de dessin ont été considérées comme une série temporelle de coordonnées, d'angles et de mesures de pression pour entraîner des LSTM sur une tâche de détection de la MP. Dans [154], un BLSTM a été exploité dans l'analyse de signaux de parole pour la détection de la maladie. Dans [155], les auteurs ont proposé d'évaluer la faisabilité d'un système d'accéléromètre portable au poignet pour détecter les tremblements dans la MP. Dans [156], un ensemble de séries temporelles multimodales a été recueilli : des enregistrements d'écriture manuscrite, des signaux de parole et des mouvements oculaires. Dans ce travail, l'application de diverses architectures d'apprentissage profond, à savoir le CNN et le CNN-BLSTM, à la détection de la MP a été étudiée. Les résultats expérimentaux montraient que la meilleure performance pour la détection précoce de la MP (97.62% de précision) était atteinte par le CNN-BLSTM entraîné sur des données augmentées synthétiquement. Dans [157], l'objectif était de développer un LSTM qui, combiné à des données de gyroscopes portables, permet d'estimer le tremblement parkinsonien total pendant que les patients effectuaient une variété de mouvements corporels libres. [158] a mis en avant une prédiction de la progression des symptômes de la MP à l'aide d'un CNN entraîné sur une série temporelle des caractéristiques de la parole.

3.3.4 Apprentissage profond et AQM

Dans cette section, nous passons en revue les applications de l'apprentissage profond à l'AQM. La recherche Scopus utilisée donne 198 articles parmi les 16 610 identifiés, dont 102

publiés entre 2019 et 2021. L'apprentissage de modèles avec des données limitées entraîne souvent un sur-apprentissage qui les empêche de bien généraliser à des données non vues auparavant. Pour éviter cela, plusieurs études récentes sur l'analyse de la marche ont utilisé de nouvelles techniques comme l'augmentation des données et le *transfer learning*.

3.3.4.1 Augmentation des données

L'augmentation de l'espace des caractéristiques est une méthode efficace d'augmentation des données pour l'analyse de la marche. Par exemple, [159] a appliqué la technique de sur-échantillonnage minoritaire synthétique (*Synthetic Minority Oversampling Technique*, SMOTE) à un ensemble de données du gel de la marche FoG (*Freezing of Gait*) pour générer des données dans la catégorie FoG. Les expériences menées ont montré que l'utilisation de VGG16 et de modèles similaires permet d'obtenir une précision de classification de 89%. Le SMOTE est une méthode d'augmentation qui atténue les problèmes de déséquilibre dans les ensembles de données en créant des instances synthétiques de données sous-représentées [160]. De même, pour les séries temporelles telles que les données inertielles, plusieurs méthodes d'augmentation des données sont disponibles, comme mentionné dans [103]. Parmi celles-ci, les transformations de base dans le domaine temporel, le domaine fréquentiel et le domaine temps-fréquence sont particulièrement populaires. Dans le contexte de l'analyse clinique de la marche, la perturbation de l'amplitude, la perturbation temporelle, la rotation aléatoire et l'injection de bruit ont été utilisées dans [161]-[164]. Les GAN ont été appliqués à la reconnaissance de la marche anormale afin d'étendre leur ensemble de données d'entraînement. [165] a utilisé un GAN conditionnel [166] pour synthétiser les caractéristiques cinématiques des pieds et des chevilles de patients souffrant de lésions du ligament collatéral latéral. [167] a utilisé des GAN conditionnels pour générer un modèle 3D paramétrique du corps avec un squelette intégré et a synthétisé des échantillons de marche asymétrique. Dans [168], un GAN convolutif profond a été utilisé pour générer des images binaires capturant trois patterns de marche anormale telle que la chute. Par la vérification et la comparaison d'allures de marche réelles, une AUC de 88.9% a été obtenue. Le GAN convolutif profond est une version étendue du GAN classique qui utilise le CNN au lieu du MLP afin d'améliorer la capacité de généralisation du générateur.

3.3.4.2 *Transfer learning*

[169]-[171] ont exploité les données de marche de différents sujets pour développer un modèle de prédiction pour un sujet particulier. [169] constitue la première étude visant à explorer les algorithmes d'adaptation de domaine pour prédire les épisodes de FoG chez des patients atteints de la MP. Les résultats obtenus sur un ensemble de 10 patients démontrent le potentiel des algorithmes utilisés à identifier avec précision les épisodes de FoG avant qu'ils ne se produisent. Dans [170], des expériences en conditions réelles avec cinq volontaires ont été réalisées et il a été conclu qu'un modèle personnalisé de détection des chutes est nettement plus performant que les modèles génériques, notamment en termes de précision. [172] a proposé un apprentissage de la représentation multi-modale pour permettre un transfert entre sujets et entre modes. Ces méthodes de transfert ont contribué à résoudre le problème de la disponibilité limitée de données pathologiques précises sur la pose humaine. Grâce à cette approche, l'Accuracy de classification a été significativement améliorée. [173], [174] ont amélioré les performances dans les paires de tâches suivantes en utilisant une quantité limitée de données : évaluation du risque de chute et identification humaine, et évaluation de la gravité du risque de chute et de la MP. Dans [173], lors de l'utilisation de l'apprentissage multi-tâche (*multi-task learning*), avec le sexe et l'âge comme tâches auxiliaires, les modèles d'apprentissage profond étaient plus performants. Par ailleurs, il a été constaté que le prétraitement des données permettait d'obtenir les meilleures performances (AUC = 0.75). Au final, il a été conclu que l'apprentissage profond, et en particulier l'apprentissage multi-tâche, évalue efficacement le risque de chute sur des données de capteurs. Pour remédier au manque de données sur la marche anormale, [175]-[178] ont utilisé différents réseaux neuronaux pré-entraînés sur un ensemble de données à grande échelle, comme ImageNet [179]. [175] présente une nouvelle méthode qui permet de classifier la marche dans différentes pathologies en utilisant des images énergétiques de la marche. Dans ce travail, au lieu d'utiliser le *feature engineering*, l'extraction des caractéristiques est effectuée à l'aide d'un CNN, VGG19, qui est ajusté (*fine-tuned*) par *transfer learning*. Les résultats obtenus montrent que la méthode proposée surpasse celles de l'état de l'art, atteignant une Accuracy de 95% sur un ensemble de données contenant des séquences de marche affectées par la diplégie, l'hémiplégie, la neuropathie et la MP, ainsi que des séquences de marche normales. Dans ce qui suit, nous déclinons les utilisations d'apprentissage profond par type de réseau.

3.3.4.3 Réseaux de neurones

3.3.4.3.1 CNN

Dans [180], un CNN 1D a été appliqué à la détection de la MP et à la prédiction de sa gravité en se basant sur la force de réaction verticale du sol vGRF (*vertical Ground Reaction Force*) des capteurs de pieds. Le nombre total de signaux utilisés pour l'apprentissage du modèle était de 18 : ceux collectés des huit capteurs placés sous chaque pied et deux supplémentaires représentant la somme des huit vGRF pour chaque pied. Le modèle proposé a atteint une précision de 98,7% et 85,3% dans la détection de la MP et l'évaluation de sa gravité, respectivement. Dans [181], un réseau entièrement convolutif (*Fully Convolutional Network*, FCN) et un réseau résiduel (*Residual Network*, ResNet) ont été utilisés pour la prédiction de la *stride length*. Un CNN a été sélectionné comme un modèle de régression pour l'estimation de la cinématique des membres inférieurs pendant la course, et ce avec un seul accéléromètre [182]. [183] a été consacré à la prévision de l'apparition du pic d'impact de la force de réaction au sol (GRF) via un problème de classification binaire. Les données cinématiques ont été utilisées comme entrée de cinq CNN.

3.3.4.3.2 RNN

Ce modèle est souvent utilisé dans l'analyse de la marche basée sur la vision [184]-[188]. Certains travaux ont utilisé les RNN bidirectionnels pour l'analyse de la marche [189]-[192]. [189] a réussi à capturer les relations temporelles passées et futures dans les séries temporelles provenant de capteurs portables. Le modèle proposé est plus performant que les CNN dans la classification d'altérations mineures de la marche. Ces dernières ont été simulées par l'ajout de coussinets sous les chaussures. Bien que ces altérations n'affectent pas beaucoup la pression plantaire du pied, le modèle proposé a été capable de détecter les patterns de marche avec une précision de 82%. Des RNN avec mécanisme d'attention ont été appliqués à l'analyse clinique de la marche dans [193]-[196]. Dans [193], deux types d'attention ont été proposés pour améliorer la classification : temporel et capteur. Le mécanisme d'attention temporel met en évidence la partie importante de la série temporelle, tandis que le mécanisme d'attention capteur pondère l'importance de la modalité du capteur pendant l'apprentissage. Dans le modèle proposé, les deux mécanismes d'attention sont appliqués à un LSTM afin d'améliorer l'extraction des caractéristiques. En conséquence, le modèle proposé est plus performant qu'un LSTM standard, qu'un LSTM avec attention temporel et qu'un LSTM avec attention capteur dans la reconnaissance de l'activité humaine et la détection du gel de la marche. Dans [197], il a été démontré

que le LSTM offre des performances supérieures à celles d'autres approches d'apprentissage automatique dans la modélisation non-linéaire des angles d'articulation des membres inférieurs. Une seule unité de mesure inertielle (*Inertial Measurement Unit*, IMU) a été utilisée. Dans [198], deux LSTM bidirectionnels ont été empilés pour l'estimation de la trajectoire du pied à l'aide de capteurs inertiels. Dans [161], les paramètres spatio-temporels ont été utilisés comme entrée d'un classifieur LSTM pour l'évaluation du risque de la chute (*fall risk assesement*). Le LSTM proposé, entraîné sur un ensemble de données de la marche de 60 patients atteints de troubles neurologiques, atteint une **Accuracy** supérieure de 92.1% sur un ensemble de données de test distinct recueillies auprès de 16 patients. Dans [199], un ConvLSTM a été appliqué à une tâche de prédiction de chutes, avec des résultats plus performants que les modèles LSTM et CNN en termes de précision et de latence. Les résultats de la validation ont montré que le ConvLSTM présentait des sensibilités moyennes de 93.15, et 96,00% respectivement pour la non-chute, et la chute, ce qui est plus élevé que le LSTM (à l'exception de la classe de chute) et le CNN. Le ConvLSTM a également montré des spécificités plus élevées pour les deux classes (96.59 et 98.69%) que le LSTM et le CNN. En outre, le test de latence sur un microcontrôleur a montré que le ConvLSTM avait une latence courte de 1.06 ms, ce qui est bien inférieur au LSTM (3.15 ms) et comparable au CNN (0.77 ms). Dans [200], un ConvLSTM a été utilisé pour la reconnaissance des phases de la marche. ConvLSTM est une variante de LSTM contenant une opération de convolution à l'intérieur de la cellule LSTM.

3.3.4.3.3 Auto-encodeur

Dans l'analyse de la marche, les auto-encodeurs ont été utilisés en tant que méthode de débruitage [201] [202]. Dans [201], un modèle de débruitage a été proposé pour détecter les mouvements anormaux chez les patients atteints de la MP. Les expériences sur trois ensembles de données de référence montrent l'efficacité de la méthode proposée. En outre, certains travaux dans divers domaines ont démontré que l'introduction des caractéristiques reconstruites par les auto-encodeurs dans le modèle en tant qu'entrée permet d'obtenir une plus grande précision que l'introduction des données brutes [203]-[205]. [206] a proposé un modèle hybride RNN auto-encodeur pour reconnaître une marche anormale à partir des données du squelette. La méthode d'extraction automatique des caractéristiques proposée améliore les performances. Un RNN auto-encodeur est un auto-encodeur pour les données séquentielles ayant un encodeur-décodeur à base de RNN.

3.3.4.3.4 Modèle hybride

Un modèle hybride combinant un CNN et un RNN a été appliqué à l'analyse de la marche. Il existe plusieurs façons de combiner les deux modèles. Par exemple, dans [207] et [208], le CNN a été empilé au-dessus du LSTM. D'abord, le CNN du modèle traite les données d'entrée, puis les caractéristiques extraites sont converties en données 1D qui sont ensuite introduites dans le LSTM. Cette structure permet au modèle d'apprendre simultanément les caractéristiques spatiales et temporelles des patterns de la marche. Cependant, avec l'augmentation de la profondeur du réseau, le modèle tend à être sensible au problème de dissipation du gradient. Pour résoudre ce problème, [207] a appliqué la structure de connexion par saut (*skip connection*) et la normalisation par lots (*batch normalization*) au réseau combiné CNN-LSTM proposé, appelé FMS-Net. Ce modèle surpasse un simple réseau combiné CNN-LSTM dans la classification des quatre phases de marche. Dans [209], un réseau à deux canaux tirant parti à la fois du CNN et du LSTM a été appliqué pour la détection de la MP et l'évaluation de sa gravité. Le modèle proposé se compose de deux canaux : un CNN à cinq couches et un LSTM à deux couches, pour extraire les caractéristiques des vGRF. Les mêmes vecteurs de caractéristiques, qui sont les valeurs vGRF mesurées par les capteurs de pieds, sont introduits dans chaque canal en tant que données d'entrée. Les deux réseaux sont connectés en parallèle et entraînés conjointement. La moyenne pondérée de la softmax fournit le résultat final de la classification : la présence d'une MP ou le niveau de sa gravité. La méthode proposée est plus performante que les méthodes existantes en termes d'Accuracy de prédiction du niveau de gravité de la MP. Dans [200], un réseau combiné CNN-LSTM a été mis en œuvre pour effectuer la segmentation des phases de la marche (*gait phase segmentation*) en utilisant les données de 11 IMU attachées au pied, au tibia, à la cuisse, à la hanche et aux deux bras. Les auteurs ont utilisé les données du gyroscope, de l'accéléromètre et du baromètre de tous les capteurs comme entrée de leur réseau de neurones. Le modèle proposé prédit la phase de la marche actuelle avec une Accuracy de plus de 92% sur un sujet non vu, en différenciant cinq phases différentes. Dans une autre étude, un LSTM-DNN (*Deep neural network DNN*) a été entraîné sur des données d'accéléromètre, de gyroscope et de magnétomètre provenant de deux capteurs attachés aux tibias des participants [210]. La tâche en question était l'estimation des phases de la marche (*gait phase estimation*). Un CNN avec une architecture U-Net a été utilisé pour la détection de certains événements de marche comme le contact initial et le contact final [211] [212]. Dans [213], un *Multivariate Long Short-Term Memory Fully Convolutional Network* a été utilisé pour la prédiction de la

stride length.

À la fin de cette bibliographie, nous tenons à souligner que la tâche de prédiction de la variation du GPS (*Gait Profile Score*) n'a pas été étudiée dans la littérature. De ce fait, les méthodes choisies pour accomplir cette tâche sont inspirées de ce qui existe dans l'état de l'art.

3.4 Conclusion

Les progrès techniques, donnant accès à des ressources de calcul toujours plus performantes et l'abondance des données disponibles, ont ouvert les portes aux développements de méthodes d'IA par apprentissage profond. Nous avons pu mesurer dans ce chapitre l'ampleur qu'a pu prendre l'apprentissage profond au sein de l'analyse des signaux en général, de l'AQM et de la MP en particulier. Dans les chapitres suivants, nous tirerons donc parti de la puissance des réseaux de neurones, dont l'efficacité a été prouvée à de nombreuses reprises, pour proposer des méthodes d'investigation d'EMA et de prédiction de la variation du GPS. Le LSTM sera considéré comme méthode de référence pour les deux bases de données dont nous disposons. En ce qui concerne celle de l'AQM, nous allons opter pour les méthodes ayant prouvé leur efficacité sur un nombre important de séries temporelles de l'archive UCR/UEA notamment étant donné que nos variables cinématiques, données d'entrée des méthodes à considérer, sont atypiques. À notre connaissance, celles-ci n'ont pas été explorées en détail dans la littérature.

MATÉRIELS ET MÉTHODES

4.1 Introduction

Dans le chapitre précédent, nous avons présenté les techniques d'IA basées sur des réseaux de neurones. Nous avons pu constater aux travers des différentes utilisations mentionnés précédemment les performances qu'elles proposent, en surpassant régulièrement les méthodes traditionnelles.

Néanmoins, afin d'atteindre des performances optimales, ces réseaux ont besoin d'un nombre conséquent de données d'entraînement variées et représentatives. Il n'y a cependant pas de règles sur la quantité de données requises pour des modèles d'apprentissage profond. Cette quantité dépend de nombreux paramètres, dont, en grande partie, la complexité des données et la complexité des modèles. L'observation des courbes d'apprentissage peut apporter des informations précieuses à ce sujet, indiquant les performances du modèle au fur et à mesure de l'entraînement. Il convient donc de décrire tout d'abord les données mises en jeu pour l'apprentissage des différents réseaux de neurones.

Dans ce chapitre, nous présenterons la préparation de nos données pour l'apprentissage et nous détaillerons les architectures neuronales développées pour traiter les bases de données EMA et AQM.

4.2 Matériels et méthodes pour EMA

4.2.1 Étude de Faisabilité des auteurs de l'article [22]

Dans leur étude de faisabilité, les auteurs ont binarisé la variable `sanpar_onoff` en associant la valeur 1 à l'état ON et la valeur 0 aux trois autres états restants (OFF et changement de ON à OFF et vice versa). Une régression logistique a été employé pour classifier les quinze dernières minutes de données capteurs qui précèdent directement les réponses à la question ON/OFF.

L'apprentissage de la régression logistique a été effectuée sur des caractéristiques extraites manuellement et par fenêtre des données de capteurs. Il est possible de décliner ces caractéristiques en deux groupes : celles associées aux tremblements et celle relatives à la bradykinésie. Celles de tremblement sont relatives à l'énergie du signal logarithmique (*Logarithmic Signal Energy*) entre 3,5 et 7,5 Hz. Leur nombre est de 6 et elles sont calculées à la fois à partir de l'accéléromètre et du gyroscope. Celles de bradykinésie se divisent comme suit :

- la *Logarithmic Signal Energy* de la série temporelle filtrée passe-bas (3 Hz) (3 caractéristiques à partir de l'accéléromètre),
- la moyenne quadratique (*Root Mean Square*) de la série temporelle filtrée passe-bas (3 Hz) (3 caractéristiques à partir de l'accéléromètre),
- la fréquence dominante et rapport énergétique dominant (*dominant energy ratio*) (6 caractéristiques à partir de l'accéléromètre),
- la plage d'amplitude (*Amplitude Range*) de la série temporelle brute (3 caractéristiques à partir de l'accéléromètre),
- la corrélation croisée normalisée maximale (*Maximum Normalized Cross-correlation*) et le décalage temporel (*temporal offset*) correspondant entre tous les canaux de l'accéléromètre et du gyroscope (2 caractéristiques).

Cela fait un total de 23 caractéristiques par fenêtre et par unité de mesure (UM). Un seul patient avec plusieurs fluctuations ON/OFF a été considéré pour le test de la régression logistique. L'aire sous la courbe ROC (*Area under the curve AUC*) obtenue était de 0.73. Ce résultat préliminaire insinuait que les réponses *Experience Sampling Method* (ESM) pourraient constituer une vérité terrain pour les données de capteurs.

4.2.2 Méthode des auteurs sur une base de test différente et LSTM

4.2.2.1 Code des auteurs

L'aboutissement prometteur des auteurs sur un patient nous a amenés à tester leur code ¹ sur plus de patients. Nous avons considéré uniquement les questionnaires pour lesquels les données (celles de l'accéléromètre et du gyroscope) des 3 unités de mesure (UM) étaient disponibles. Leur nombre total étant de 1360 dont 1044 état ON (soit 76.76%). Nous avons réparti les patients entre entraînement, validation et test de manière à obtenir trois

1. https://github.com/jgvhabets/sensor_EMA_PD_monitoring

patients différents pour le test (comprenant le patient réservé au test par les auteurs dans leur étude) et trois autres pour la validation. Le reste des patients étant réservé à l'entraînement. Avec la répartition choisie, nous avons consacré environ 70% des données à l'entraînement (941 questionnaires), 15% (214 questionnaires) au test et 15% (205 questionnaires) à la validation. Le pourcentage de l'état ON pour chaque jeu de données est présenté dans la Table 4.1.

%ON entraînement	%ON validation	%ON test
76.20	79.44	76.59

TABLE 4.1 – Pourcentages de la variable ON.

4.2.2.2 LSTM développée

Nous souhaitons à travers ce test comparer la régression logistique au LSTM. Le principe, à la façon des auteurs, consistait à associer aux m dernières minutes qui précédaient le début du questionnaire la réponse ON/OFF du patient comme vérité terrain. Le nombre de pas temporels dans ces m minutes est égal à $m \times 60 \times$ la fréquence d'échantillonnage. D'un point de vue architectural, nous avons empilé un certain nombre de couches LSTM. La couche de sortie est dense et comporte un seul neurone et une Sigmoid comme fonction d'activation pour la "classification binaire" ON/OFF. L'optimiseur et la fonction perte utilisés sont Adam et la *binary crossentropy* respectivement. La Figure 4.1 montre l'architecture proposée.

4.3 Matériels et méthodes pour AQM

4.3.1 Évaluation du GPS

Dans ce chapitre, nous commençons à explorer la base de données AQM. La première tâche réalisée consiste à évaluer le GPS associé à un cycle de marche donné. Bien que relativement simple, cette tâche permettra de valider quelques-unes de nos méthodes.

4.3.1.1 Préparation des données

Nous rappelons que nous disposons de 734 patients (dont 619 enfants) avec au moins une session de marche pour chacun. Le nombre total de ces sessions, tous patients confondus,

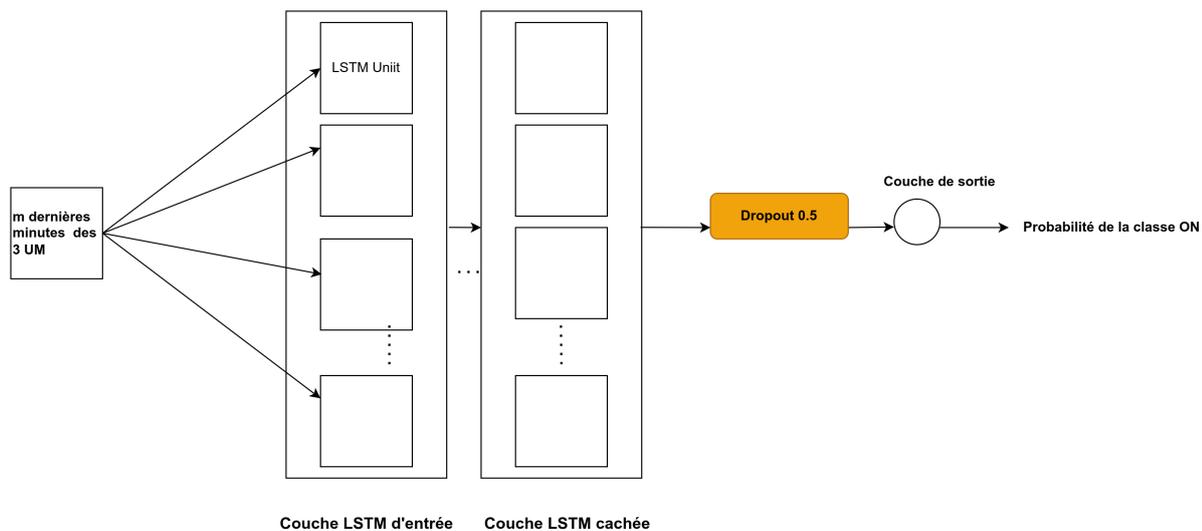


FIGURE 4.1 – Architecture du LSTM pour la prédiction ON/OFF.

est de 1459 et elles regroupent 53693 cycles de marche. Nous montrons sur la Figure 4.2 l’histogramme du GPS de l’ensemble de ces cycles. Voici quelques statistiques clés du GPS

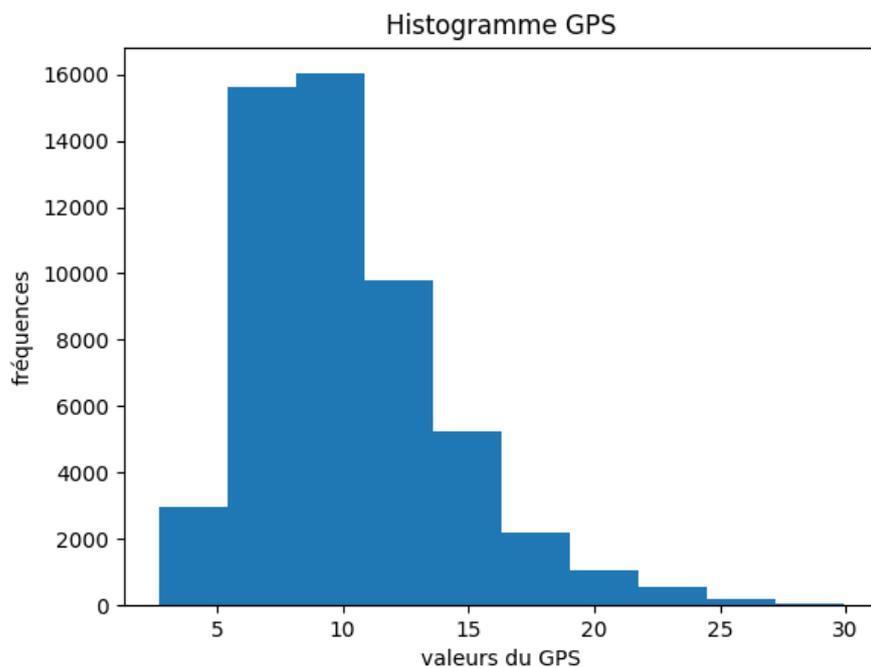


FIGURE 4.2 – Histogramme du GPS de tous les cycles.

sur notre base de données :

- valeur maximale : 29.96,
- valeur minimale : 2.68,
- valeur moyenne : 10.20,
- écart type : 3.9.

Nous répartissons nos patients entre ensemble d’entraînement, validation et test comme le montre la Table 4.2. Nous avons veillé à avoir environ $\frac{2}{3}$ des cycles dans la base d’entraînement. Le $\frac{1}{3}$ restant étant divisé d’une manière équitable entre validation et test.

Entraînement	Validation	Test
85 adultes et 430 enfants	18 adultes et 92 enfants	12 adultes et 97 enfants
37824 cycles (70.44% des cycles)	7689 cycles (14.32%)	8180 cycles (15.23%)

TABLE 4.2 – Répartition des données pour l’évaluation du GPS.

4.3.1.2 Méthodes développées

Comme la tâche cible est relativement simple (les paramètres à estimer sont relatifs à la cinématique de la population de référence), nous avons misé sur les méthodes de base à savoir les MLP, LSTM et 1D-CNN. Une couche dense ayant un seul neurone et une fonction d’activation linéaire était figée comme dernière couche de tous les modèles (semblablement à une tête de classifieur). L’optimiseur et la fonction perte utilisés sont RMSprop et l’erreur quadratique moyenne (*Mean Squared Error* MSE) respectivement. La métrique utilisée était l’erreur absolue moyenne (*Mean Absolute Error* MAE).

4.3.1.2.1 MLP

La couche d’entrée (*input layer*) était une *flatten* [214] afin de formater le cycle de marche d’une matrice 101×9 à un vecteur de 909 valeurs. Un *batch size* de 32 a été utilisé. Nous avons fait varier le nombre de couches cachées ainsi que le nombre de neurones par couche cachée (toutes les couches cachées partageaient cet hyperparamètre). Le pas d’apprentissage (*learning rate*) était un hyperparamètre à optimiser également. L’architecture utilisée est illustrée dans la Figure 4.3.

4.3.1.2.2 LSTM

Dans la même optique que précédemment, nous avons fait varier le nombre de couches

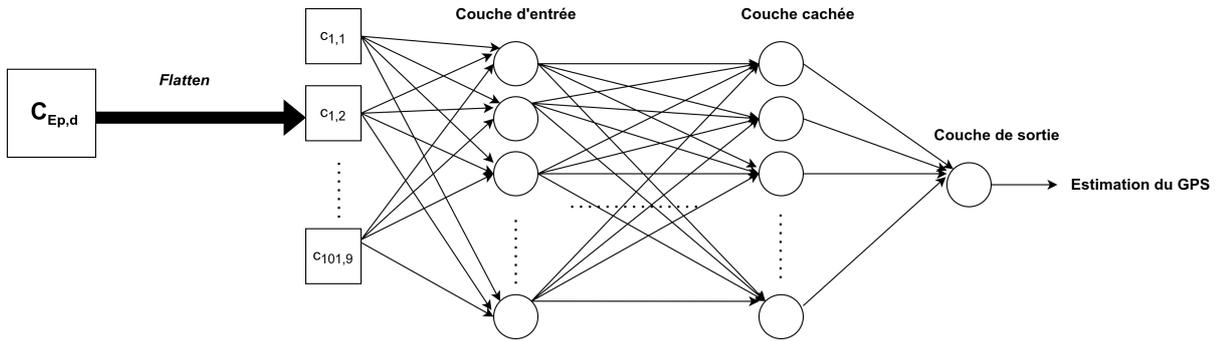


FIGURE 4.3 – Architecture du MLP.

LSTM, le nombre d'unités par couche LSTM (partagé entre toutes les couches LSTM) et le *learning rate*. L'architecture utilisée est illustrée dans la Figure 4.4.

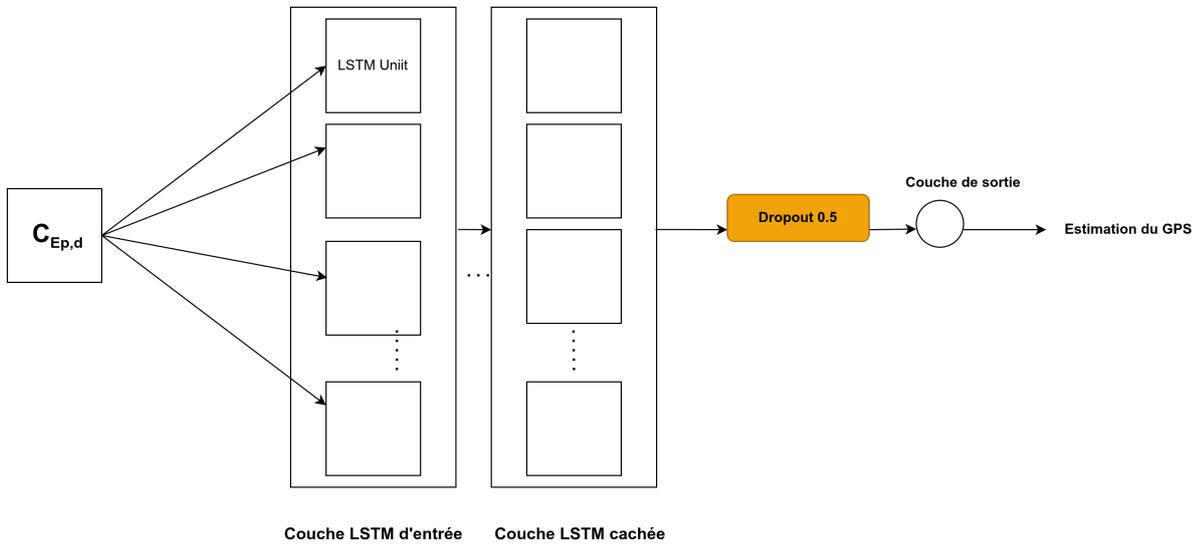


FIGURE 4.4 – Architecture du LSTM.

4.3.1.2.3 1D-CNN

Nous avons testé trois architectures différentes à base de couches de convolution à une dimension (*one dimensional convolutional neural network* 1D-CNN). La première avait une seule couche CNN, la deuxième en avait deux et la troisième en avait trois. Le bloc convolutif a été suivi par une couche dense pour l'interprétation de sa sortie. Nous avons eu recours au *framework* KerasTuner [215] pour optimiser les hyperparamètres de chaque architecture : nombre de filtres de convolution, la taille du noyau (*kernel size*), le coefficient *dropout*, la taille du *pooling* de la couche de *max pooling*, le nombre de neurones

de la couche dense en sortie du bloc convolutif et *le learning rate*. KerasTuner est un framework d'optimisation d'hyperparamètres facile à utiliser et évolutif. Il est livré avec des algorithmes intégrés d'optimisation (bayésienne, de recherche aléatoire *random search...*), et est également conçu pour être facile à étendre par les chercheurs afin d'expérimenter de nouveaux algorithmes de recherche d'hyperparamètres optimaux.

Dans notre cas, les paramètres du *Tuner* utilisés sont les suivants :

- *SEED* = 1 : pour la reproductibilité des expériences.
- *N_EPOCH_SEARCH* = 100 : définit le nombre d'itérations d'apprentissage pour chaque combinaison d'hyperparamètres.
- *MAX_TRIALS* = 100 : représente le nombre de combinaisons d'hyperparamètres qui seront testées par le *Tuner*.
- *EXECUTION_PER_TRIAL* = 2 : c'est le nombre de modèles qui doivent être construits et ajustés pour chaque essai (*trial*) à des fins de robustesse.
- *Random search* : c'est la méthode de *tuning* (l'algorithme de recherche).

Une fois que les hyperparamètres sont optimisés par le *Tuner*, nous les avons considérés pour entraîner le modèle ajusté sur mesure, et ce pour 300 *epochs*. L'architecture utilisée est indiquée dans la Figure 4.5.

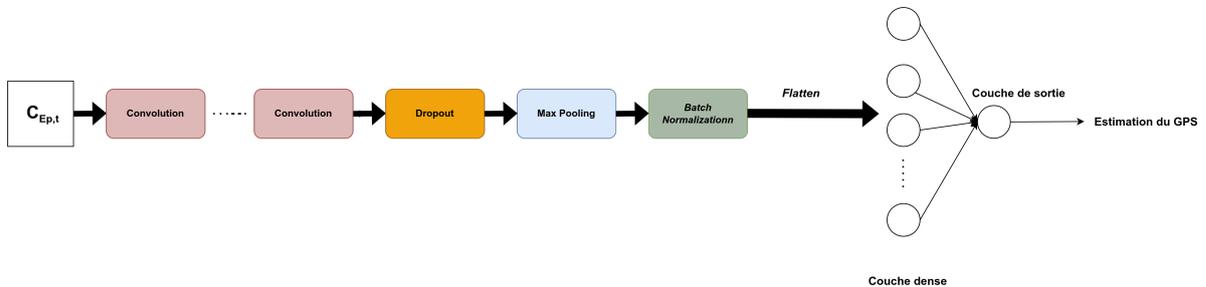


FIGURE 4.5 – Architecture du 1D-CNN.

4.3.2 Prédiction de la variation du GPS sans Δd

Cette section sera consacré à la prédiction du ΔGPS sans prise en compte du Δd . De ce fait, nous nous limitons à la session de marche qui suit directement le cycle en question. Autrement dit, nous prenons le Δd minimal pour chaque cycle de marche d'une session donnée : seules les sessions directement successives ($E_{p,d}, E_{p,d+\Delta d}$) seront incluses. Deux approches ont été considérées : l'approche signal et l'approche image. L'approche signal

traite les cycles dans leur forme brute. L'approche image les convertit en un signal à deux dimensions (une image).

4.3.2.1 Approche signal

Le prétraitement auquel nous avons eu recours est l'augmentation des données (paragraphe 3.2.2.1.2) dans le domaine temporel. Les techniques choisies agissent majoritairement sur l'amplitude du signal et conservent ainsi les dépendances temporelles.

4.3.2.1.1 Augmentation des données

4.3.2.1.1.1 Jittering

C'est une technique d'injection de bruit dans le signal. La puissance du bruit incorporé doit être assez minime de manière à ne pas altérer la classe ou catégorie attribuée au signal original [103]. Le *jittering* ne se limite pas à l'ajout du bruit gaussien, mais englobe aussi le recours aux tendances monotones, linéaires, spirales, en escalier... [103] Soit c_n la variable cinématique n d'un cycle de marche donné. Le *jittering* est défini comme suit :

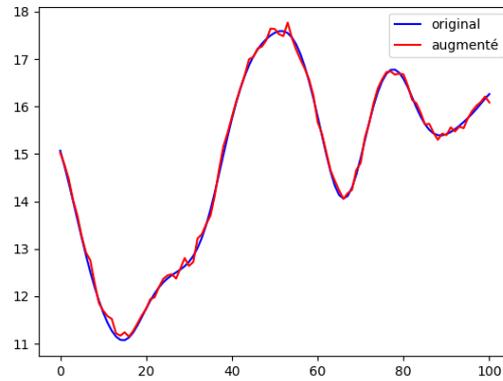
$$c'_n = c_{1,n} + \epsilon_1, \dots, c_{t,n} + \epsilon_t, \dots, c_{T,n} + \epsilon_T \quad (4.1)$$

où ϵ est un bruit gaussien ajouté à chaque pas temporel et $\epsilon \sim \mathcal{N}(0, \sigma^2)$. L'écart type σ est un hyperparamètre ajustable et prédéterminé [216]. Le *jittering* est souvent adopté pour augmenter la capacité de généralisation des modèles vu qu'il crée des nouveaux patterns [217] [218]. Il est commun que les applications utilisant des séries temporelles de données de capteurs puisent dans le *jittering* pour répondre à un problème de sur-apprentissage [219] [220]. La Figure 4.6 montre l'effet du *jittering* par ajout de bruit gaussien sur une variable cinématique donnée, avec σ égal à 0.09.

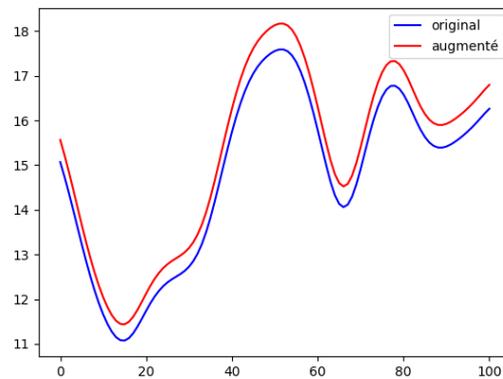
4.3.2.1.1.2 *Scaling*

Le *scaling* est une transformation du domaine de l'amplitude qui modifie l'intensité de l'ensemble de la série temporelle par une valeur scalaire aléatoire [216]. Soit α cette valeur aléatoire, appelée aussi facteur de *scaling*. Le *scaling* d'une variable cinématique n d'un cycle de marche donné peut être défini comme suit :

$$c'_n = \alpha \times c_{1,n}, \dots, \alpha \times c_{t,n}, \dots, \alpha \times c_{T,n} \quad (4.2)$$

FIGURE 4.6 – *Jittering* avec l'ajout de bruit gaussien, avec $\sigma = 0.09$.

Le facteur de *scaling* α est tiré dans une distribution gaussienne : $\alpha \sim \mathcal{N}(0, \sigma^2)$. Il est paramétrable et parfois aléatoirement choisi dans un ensemble prédéfini [219]. Il convient de noter que le *scaling* de séries temporelles est différent de celui utilisé en traitement d'images [216]. Modifier simplement l'ampleur globale d'une série temporelle, qui peut être assimilée à une grille ou matrice, n'a pas d'impact sur sa "résolution" ou "dimension". Le *scaling* est largement utilisé comme prétraitement des données dans des applications de classification de données de capteurs [219]. La Figure 4.7 illustre l'effet du *scaling* sur une variable cinématique donnée avec $\alpha = 0.1$.

FIGURE 4.7 – *Scaling* avec $\alpha = 0.1$.

4.3.2.1.1.3 Permutation

La permutation est une technique du domaine temporel décrite dans [221]. Une nouvelle représentation de la série temporelle est obtenue en réarrangeant les segments qui la constituent. De ce fait, les dépendances temporelles ne seront pas préservées. La permutation se décline en deux types selon la prise en compte de segments de taille variable ou fixe [222]. Une permutation avec segments de taille fixe égale à L divise une série temporelle de taille T en des segments de taille $\frac{T}{L}$ et les permute. Le *Random shuffling* peut être considéré comme une forme de permutation qui réarrange des éléments (pas temporels) individuels plutôt que des segments. L'utilisation de segments de taille variable utilise des segments de taille aléatoire [223]. La Figure 4.8 montre l'effet de la permutation de 4 segments de taille égale sur une variable cinématique donnée.

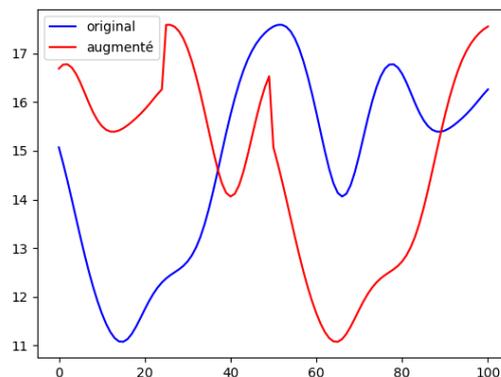


FIGURE 4.8 – Permutation de 4 segments de taille égale.

4.3.2.1.1.4 Window warping

La distorsion de fenêtre est une technique populaire de distorsion temporelle proposée dans [223]. Elle prend une fenêtre aléatoire de la série temporelle et l'étire (dilate) de 2 (sur-échantillonnage) ou la contracte (comprime) de $\frac{1}{2}$ (sous-échantillonnage). Cela permet d'obtenir des séries temporelles de longueurs multiples. Il est possible de conserver la taille initiale de la série temporelle par interpolation. La Figure 4.9 montre l'effet du *window warping* sur une variable cinématique donnée. Il s'agit d'un sur-échantillonnage d'une fenêtre de longueur 11 (10% de la longueur de la variable cinématique).

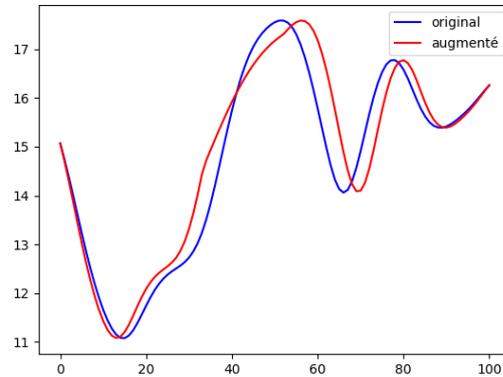


FIGURE 4.9 – *Window warping* avec sur-échantillonnage d'une fenêtre de longueur 11.

4.3.2.1.1.5 *Window slicing*

Le découpage en fenêtres est équivalent au recadrage, une méthode d'augmentation de données d'images. Le concept général consiste à augmenter la série temporelle en découplant ses pas temporels à partir de sa fin, et ce à l'aide d'une fenêtre de taille finie à glisser. La Figure 4.10 illustre l'effet du *window slicing* sur une variable cinématique donnée. La taille de la fenêtre considérée est de 90% de la taille totale de la variable, soit 91 pas temporels. La taille d'entrée (101 pas temporels) est conservée par interpolation).

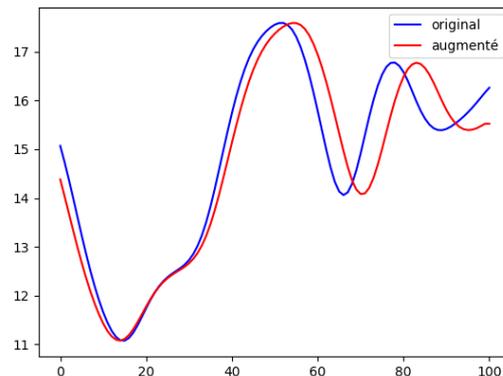


FIGURE 4.10 – *Window slicing*.

4.3.2.1.2 Technique utilisée

Les cinq techniques d'augmentation des données déjà présentées ont été combinées afin

de mitiger un éventuel phénomène de sur-apprentissage. L'ordre de l'application des cinq a été choisi aléatoirement pour chaque *batch*. Les meilleurs paramètres d'augmentation des données ont été trouvés empiriquement pour chaque architecture.

4.3.2.1.3 Prédiction de la valeur exacte du ΔGPS

La figure 4.11 montre l'histogramme du ΔGPS . Indiquons quelques statistiques clés du

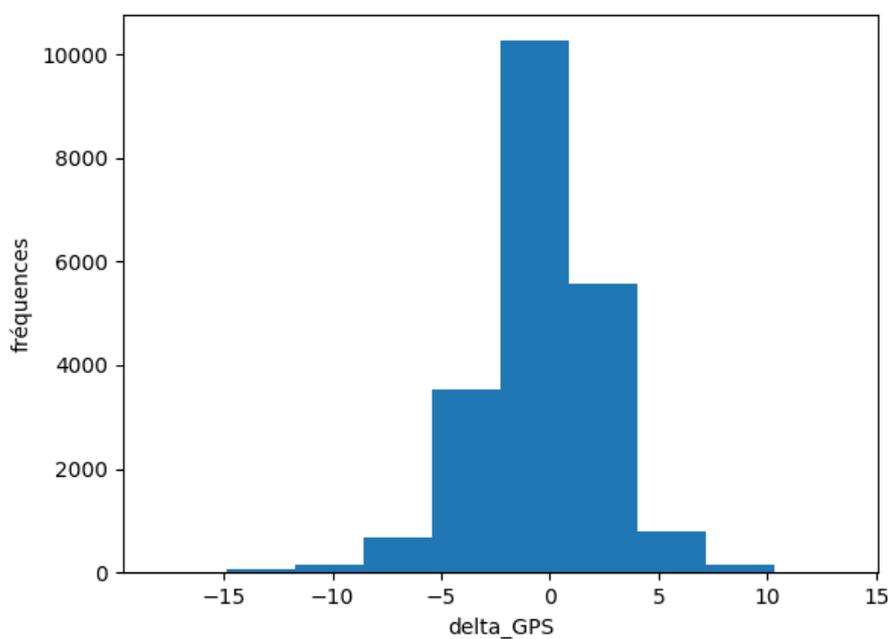


FIGURE 4.11 – Histogramme du ΔGPS .

ΔGPS :

- valeur maximale : 13.50,
- valeur minimale : -18.05,
- valeur moyenne : -0.38,
- écart type : 2.80.

4.3.2.1.3.1 Préparation des données

Les conditions de marche impliquées dans les sessions sont diverses : sans aucun équipement, avec une canne, avec un déambulateur, avec une orthèse, avec une prothèse ...

Seules les paires de sessions sans équipement ont été sélectionnées afin de se mettre dans les mêmes conditions et ainsi ne pas biaiser les résultats (79% des paires disponibles, soit 1152). Les premières sessions de marche de ces paires ont été utilisées pour l’entraînement. Les modèles ont été alimentés par les cycles de marche des premières sessions $E_{p,d}$ (21167 cycles de marche au total). Nous répartissons nos 274 patients entre ensembles d’entraînement (73% du total des cycles), validation (12% des cycles) et test (14% des cycles) comme le montre la Table 4.3.

Train	Validation	Test
193 patients	38 patients	43 patients
15509 cycles	2678 cycles	2980 cycles
844 paires de sessions	142 paires de sessions	166 paires de sessions
54.39 % de classe 1	54.11 % de classe 1	55.60 % de classe 1

TABLE 4.3 – répartition de données entre entraînement, validation et test.

4.3.2.1.3.2 Méthodes développées

MLP

Les matrices cycles de marche ont été aplaties de manière à ce que la longueur d’entrée du modèle soit égale à 909 pas temporels. Le nombre de neurones par couche était partagé par toutes les couches entièrement connectées. De nombreuses valeurs de ce nombre ont été testées manuellement afin de trouver la meilleure structure pour notre tâche. Le nombre de couches denses a été également optimisé. En somme, nous avons deux hyperparamètres à optimiser :

- le nombre de neurones partagé par toutes les couches denses,
- le nombre de couches denses du MLP.

Le modèle a été entraîné pour 3000 epochs avec un *learning rate* égale à 10^{-5} .

LSTM

L’architecture adoptée est classique : des couches LSTM ont été empilées et un *dropout* a été ajouté avant la couche finale à un seul neurone. Pareil au MLP, le modèle a été entraîné pour 3000 epochs avec un *learning rate* égale à 10^{-5} .

4.3.2.1.4 Prédiction de la classe du ΔGPS

4.3.2.1.4.1 Préparation des données

La question la plus pertinente d'un point de vue clinique est la suivante : la marche du patient s'améliora-t-elle à la prochaine visite ? Ce qui intéresse cruciallement les praticiens est la prédiction du sens de l'évolution (amélioration ou dégradation) du trouble de la marche. De ce fait, nous ramenons la prédiction à deux vérités terrain grossières, à la façon d'une "classification binaire" :

- ΔGPS est négatif, auquel cas la marche du patient s'améliore ("classe" 1),
- La "classe" complémentaire 0 correspond alors à une variation positive du GPS et ainsi une dégradation de la qualité de la marche.

Nous avons conservé la même répartition des patients que celle décrit précédemment. Nous disposons de 45.61 %, 45.89 % et 44.4% de "classe" 0 dans l'entraînement, validation et test respectivement.

Pour être assez exhaustifs, un MLP, un LSTM, un encodeur (architecture hybride) et plusieurs CNN (*Fully Convolutional Neural Network* FCN, *Residual Network* ResNet, *time Le-Net* t-LeNet) ont été explorés. MLP et LSTM ont été conçus et développés à partir de zéro. L'optimisation de leurs hyperparamètres était effectuée manuellement. L'optimiseur Adam [224] [225] et la perte logarithmique (*Binary Cross Entropy*) ont été utilisés. Une couche finale dense à un seul neurone et une fonction d'activation Sigmoid est commune à toutes les architectures de cette partie, et ce pour prédire le sens de variation du ΔGPS à la sortie du modèle.

4.3.2.1.4.2 Méthodes développées

MLP

Nous considérons la même configuration que précédemment (dans 4.3.2.1.3.2).

LSTM

De même, nous considérons la même configuration que précédemment (dans 4.3.2.1.3.2).

FCN

L'architecture adoptée est celle proposée dans [122]. Elle est composée de trois blocs convolutifs, où chaque bloc contient trois opérations : une convolution suivie d'une normalisation par lots (*batch normalization*) dont le résultat est transmis à une fonction d'activation de type ReLU. Le résultat du troisième bloc convolutif est moyenné sur l'en-

semble de la dimension temporelle en utilisant une couche (*Global Average Pooling* GAP). Toutes les convolutions ont un *stride* égal à 1, avec une marge de zéro (*zero padding*) pour préserver la longueur exacte de la série temporelle. La première convolution contient 128 filtres d'une longueur égale à 8, suivie d'une deuxième convolution de 256 filtres d'une longueur égale à 5, qui à son tour est envoyée à une troisième et dernière couche convolutive composée de 128 filtres d'une longueur de 3. La Figure 4.12 montre l'architecture utilisée.

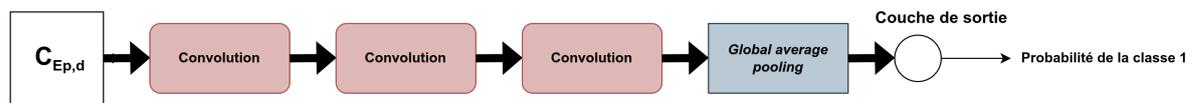


FIGURE 4.12 – FCN.

ResNet

Nous avons utilisé l'architecture présentée dans [122] qui est populaire et largement utilisée dans la classification d'images et la reconnaissance d'objet. Un tel réseau constitue une avancée importante dans l'apprentissage profond grâce à sa théorie, dite optimale, d'entraînement de réseaux de neurones très profonds [226]. La principale caractéristique de ResNet est la connexion résiduelle raccourcie entre les couches convolutives consécutives. Ces connexions linéaires facilitent l'apprentissage du réseau de neurones profond vu qu'elles conditionnent le calcul du gradient [122]. ResNet est composé de trois blocs résiduels suivis d'une couche GAP. Chaque bloc résiduel est d'abord composé de trois convolutions, dont la sortie est ajoutée à l'entrée du bloc résiduel en question, puis transmise à la couche suivante. Le nombre de filtres pour toutes les convolutions est fixé à 64 pour le premier bloc résiduel et à 128 pour le deuxième et le troisième bloc, avec la fonction d'activation ReLU qui est précédée d'une opération de *batch normalisation*. Dans chaque bloc résiduel, la longueur du filtre est fixée à 8, 5 et 3 respectivement pour la première, deuxième et troisième convolution. La Figure 4.13 affiche l'architecture utilisée.

Encoder

Il s'agit de l'architecture décrite dans [122]. Le réseau est inspiré de l'architecture FCN avec quelques changements. La principale différence est que la couche GAP du FCN est remplacée par une couche d'attention. Les trois premières couches sont convolutives : la première est composée de 128 filtres de longueur 5 ; la deuxième est composée de 256 filtres de longueur 11 et la troisième est composée de 512 filtres de longueur 21. Chaque convo-

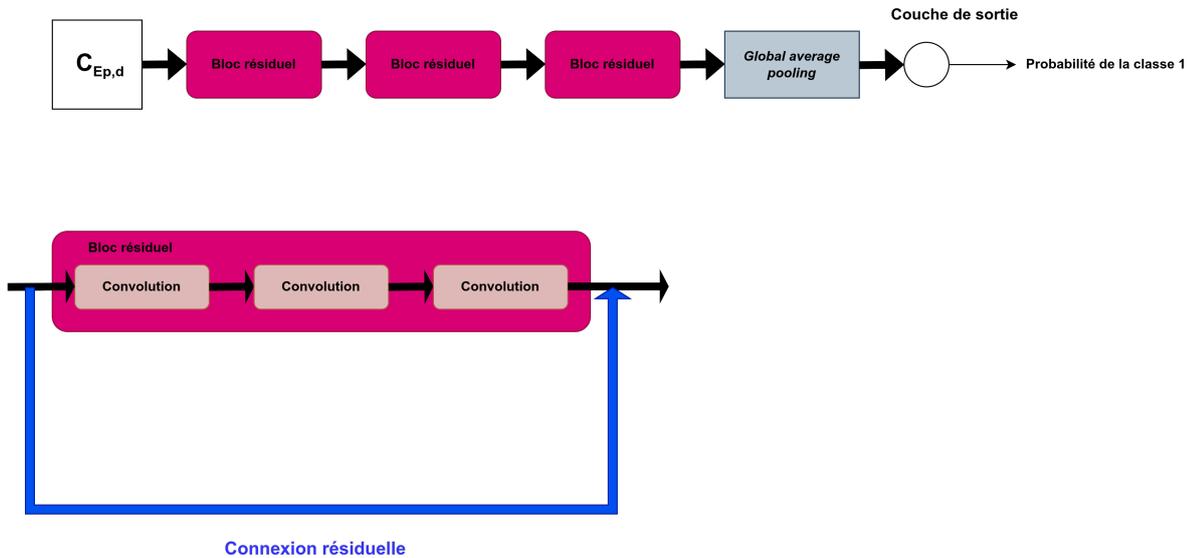


FIGURE 4.13 – ResNet.

lution est suivie d’une opération d’*instance normalization* (normalisation de l’instance) [227] dont la sortie est transmise à la fonction d’activation PReLU (*Parametric Rectified Linear Unit*) [228]. La sortie de PReLU est suivie d’une opération de *dropout* (avec un taux égal à 0.2) et d’un *max pooling* de longueur 2. La troisième couche convolutive est alimentée par un mécanisme d’attention [229] qui permet au réseau d’apprendre quelles parties de la série temporelle (dans le domaine temporel) sont importantes pour une certaine classification. Plus précisément, pour mettre en œuvre cette technique, la série temporelle multivariée d’entrée est multipliée par une seconde série temporelle multivariée de la même longueur et du même nombre de canaux, sauf que cette dernière est traitée par la fonction sigmoïde. Chaque élément de la seconde série temporelle agira comme un poids pour la première série temporelle permettant ainsi au réseau d’apprendre l’importance de chaque pas temporel. La Figure 4.14 illustre l’architecture utilisée. **t-LeNet**

Le t-LeNet a été proposé pour la première fois dans [223]. Cette architecture a été inspirée par les performances exceptionnelles de l’architecture LeNet pour une application de reconnaissance de documents [100]. Ce modèle peut être considéré comme un CNN traditionnel avec deux convolutions suivies d’une couche dense composée de 500 neurones. Il existe deux différences principales avec les FCN : (1) la couche dense et (2) les opérations de *max pooling*. Pour les deux convolutions, la fonction d’activation ReLU est utilisée avec une longueur de filtre égale à 5. Pour la première convolution, 5 filtres sont

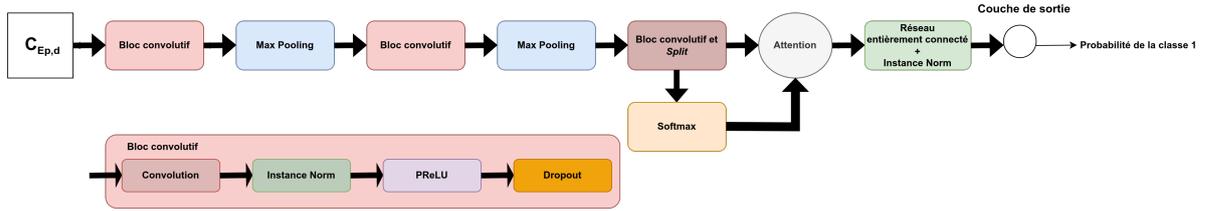


FIGURE 4.14 – Encoder.

utilisés et suivis d'un *max pooling* de longueur égale à 2. La deuxième convolution utilise 20 filtres suivis d'un *max pooling* de longueur égale à 4. Pour s'assurer que des sous-séquences de même longueur soient extraites pour l'entraînement du réseau, le WS est adopté. Par conséquent, une série temporelle en entrée de longueur l est d'abord dilatée ($\times 2$) puis comprimée ($\times \frac{1}{2}$), ce qui donne trois séries temporelles de longueur l , $2l$ et $\frac{1}{2}l$. Des sous-séquences de même longueur sont extraites de ces dernières par WS. La Figure 4.15 montre l'architecture utilisée.

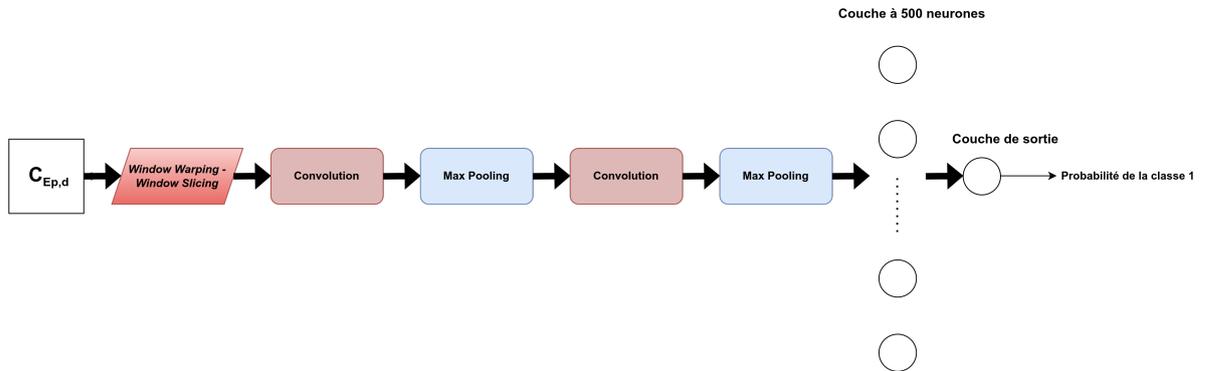


FIGURE 4.15 – t-Lenet.

4.3.2.2 Approche image pour la prédiction de la classe du ΔGPS

Le prétraitement dans l'approche image consiste en la conversion des signaux en des images ce qui permettra l'utilisation des architectures de vision par ordinateur pré-entraînées sur ImageNet.

4.3.2.2.1 Description du pipeline

Chaque cycle est converti en une image GAF (*Gramian Angular Field*) avec ses deux

variantes GADF (*Gramian Difference Angular Field*) et GASF (*Gramian Summation Angular Field*), MTF (*Markov Transition Field*) ou 2D FFT (*two Dimensional Fast Fourier Transform*). Dans [230], les auteurs ont utilisé des *tiled* CNN sur 20 ensembles de données standard pour apprendre des caractéristiques de haut niveau à partir des images GASF-GADF-MTF individuelles et composées. Les résultats obtenus étaient très compétitifs par comparaison à neuf des meilleures approches actuelles de classification des séries temporelles. Dans [231], les images de l'amplitude de la 2D FFT construites à partir des données de capteurs ont alimenté un CNN pré-entraîné pour une tâche de reconnaissance d'activité.

4.3.2.2.1.1 GAF

Ce premier type d'image a été défini dans [230]. La série temporelle est représentée dans le système de coordonnées polaires au lieu du système de coordonnées cartésiennes. Étant donné une série temporelle $X = \{x_1, x_2, \dots, x_n\}$ de n observations à valeurs réelles, nous mettons à l'échelle X de façon à situer toutes ses valeurs dans l'intervalle $[-1, 1]$ ou $[0, 1]$:

$$\tilde{x}_i^{-1} = \frac{(x_i - \max(X)) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (4.3)$$

ou

$$\tilde{x}_i^0 = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (4.4)$$

\tilde{x}_i^{-1} et \tilde{x}_i^0 sont les valeurs mises à l'échelle de x_i dans les intervalles $[-1, 1]$ et $[0, 1]$ respectivement.

Nous pouvons donc représenter la série temporelle mise à l'échelle \tilde{X} dans le système de coordonnées polaires en codant ses valeurs sous forme de cosinus angulaire et ses pas temporels sous forme de rayon, et ce avec les équations ci-dessous :

$$\phi = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \quad (4.5)$$

$$r = \frac{t_i}{N}, t_i \in \mathbb{N} \quad (4.6)$$

t_i étant le pas temporel et N étant une constante utilisée pour régulariser l'étendue du système de coordonnées polaires. Cette représentation basée sur les coordonnées polaires est une nouvelle façon de comprendre les séries temporelles. Au fur et à mesure que le temps passe, les valeurs correspondantes se déforment entre différents points angulaires sur les cercles de recouvrement (*spanning circles*). La carte d'encodage des équations

précédentes possède deux propriétés importantes : cela est bijectif quand $\phi \in [0, \pi]$ et le système de coordonnées polaires conserve les relations temporelles absolues contrairement au système de coordonnées cartésiennes. La série temporelle mise à l'échelle dans différents intervalles a des limites angulaires différentes. $[0, 1]$ correspond à la fonction cosinus dans $[0, \frac{\pi}{2}]$, tandis que les valeurs du cosinus dans l'intervalle $[-1, 1]$ tombent dans les limites angulaires $[0, \pi]$. Après avoir projeté les séries temporelles mises à l'échelle dans le système de coordonnées polaires, nous pouvons facilement exploiter la perspective angulaire en considérant la somme/différence trigonométrique entre chaque pair de points pour identifier la corrélation temporelle dans différents intervalles de temps.

GADF

GADF est défini comme-suit :

$$GADF = [\sin(\phi_i - \phi_j)] = \tilde{x}_i \sqrt{1 - \tilde{x}_j^2} - \sqrt{1 - \tilde{x}_i^2} \tilde{x}_j \quad (4.7)$$

La Figure 4.16 illustre les neuf images GADF d'un cycle de marche donné. Une carte de couleur chaude est utilisée à des fins de visualisation. **GASF**

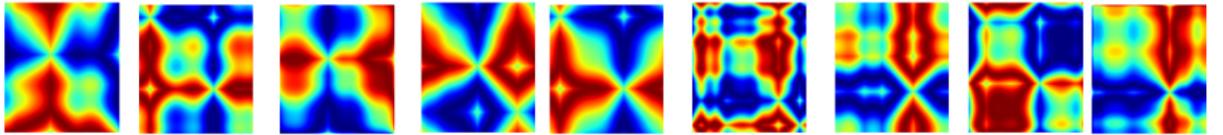


FIGURE 4.16 – Images GADF d'un cycle de marche.

GASF se calcule de la manière suivante :

$$GASF = [\cos(\phi_i + \phi_j)] = \tilde{x}_i \tilde{x}_j - \sqrt{1 - \tilde{x}_i^2} \sqrt{1 - \tilde{x}_j^2} \quad (4.8)$$

La Figure 4.17 permet de visualiser les neuf images GASF d'un cycle de marche donné. Les GAF sont de taille $n \times n$ et ont plusieurs avantages. Ces images fournissent un moyen de préserver les dépendances temporelles. Elles contiennent les corrélations temporelles puisque $GAF_{(i,j||i-j=k)}$, l'élément à la ligne i et la colonne j de la matrice GAF avec $i - j = k$, représente la corrélation relative par superposition/différence de directions par rapport à l'intervalle de temps k . Quand $k = 0$, nous nous retrouvons sur la diagonale GAF_{ii} qui contient l'information angulaire originale. À partir de cette dernière, nous

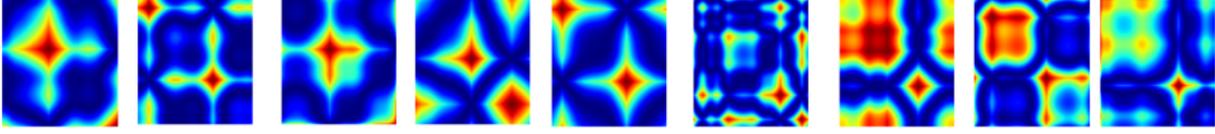


FIGURE 4.17 – Images GASF d’un cycle de marche.

pouvons reconstruire la série temporelle.

4.3.2.2.1.2 MTF

Ce deuxième type d’image a été défini dans [230] également. Étant donné une série temporelle X , nous identifions ses quantiles Q et attribuons à chaque x_i un quantile q_j avec $j \in [1, Q]$. Ainsi nous construisons une matrice d’adjacence pondérée W de taille $Q \times Q$ en comptant les transitions entre les quantiles à la manière d’une chaîne de Markov du premier ordre le long de l’axe temporel. $w_{i,j}$ de W est donné par la fréquence à laquelle un point du quantile q_j est suivi d’un point du quantile q_i . Après normalisation, W est la matrice de transition de Markov. Elle est insensible à la distribution de X et à la dépendance temporelle des pas temporels t_i , ce qui résulte en une perte d’informations. Pour pallier cette limitation, nous définissons la matrice MTF comme suit :

$$MTF = \begin{bmatrix} w_{ij|x_1 \in q_i, x_1 \in q_j} & \cdots & w_{ij|x_1 \in q_i, x_n \in q_j} \\ w_{ij|x_2 \in q_i, x_1 \in q_j} & \cdots & w_{ij|x_2 \in q_i, x_n \in q_j} \\ \vdots & \ddots & \vdots \\ w_{ij|x_n \in q_i, x_1 \in q_j} & \cdots & w_{ij|x_n \in q_i, x_n \in q_j} \end{bmatrix} \quad (4.9)$$

L’élément w_{ij} de MTF désigne la probabilité de transition de q_i à q_j . MTF est obtenu à partir de W en considérant les pas temporels. $w_{i,j||i-j|=k}$, l’élément à la ligne i et la colonne j de la matrice MTF avec $i - j = k$, représente la probabilité de transition pour un écart temporel de k . Pour $k = 0$, nous nous retrouvons sur la diagonale de MTF. w_{ii} capture la probabilité de passer de chaque quantile à lui-même (probabilité d’autotransition) au pas temporel i . La Figure 4.18 montre les neuf images MTF d’un cycle de marche donné. La concaténation de ses images constituera l’entrée des architectures neuronales.

4.3.2.2.1.3 2D FFT

Le signal original peut être décomposé en ses composantes fréquentielles en appliquant

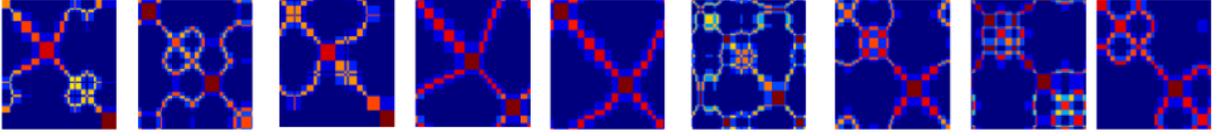


FIGURE 4.18 – Images MTF d’un cycle de marche.

des méthodes d’analyse spectrale. La 2D FFT [232] est la méthode la plus courante pour l’analyse spectrale, où chaque valeur du signal représente un pixel. Elle est rapide et efficace. Elle permet également de réduire efficacement la complexité de la transformée de Fourier discrète. La formule utilisée pour le calcul est la suivante :

$$F(u, v) = \frac{1}{M \cdot N} \sum_{x=0}^M \sum_{y=0}^N f(x, y) e^{-j2\pi(\frac{ux}{M} + \frac{vy}{N})} \quad (4.10)$$

où $f(x, y)$ est la valeur initiale du pixel de l’image, $F(u, v)$ la transformée de Fourier directe de l’image, N et M sa largeur et sa hauteur, respectivement. $F(u, v)$ est une fonction complexe indiquant la phase et l’amplitude du signal dans le domaine fréquentiel. L’amplitude $|F(u, v)|$ est un signal à deux dimensions qui porte l’information fréquentielle et peut être considéré comme une image. La zone blanche de cette dernière indique une énergie élevée dans les basses fréquences. La 2D FFT a des attributs de translation et de rotation. La composante de fréquence zéro peut donc être déplacée vers le centre de $|F(u, v)|$ sans engendrer une perte d’informations. L’image centralisée obtenue est plus visible. Nous montrons dans la Figure 4.19 $|F(u, v)|$ et $|F(u, v)|$ centralisée d’un cycle de marche donnée. Les images $|F(u, v)|$ centralisées des cycles de marche ont été utilisées dans l’entraînement des architectures adoptées.

4.3.2.2.2 Architectures utilisées

Nous nous intéressons au transfert des réseaux convolutifs profonds pré-entraînés (VGG16, ResNet34 et EfficientNet-B0) sur une base large échelle qui est ImageNet [233]. Le *transfer learning* est un moyen pour remédier au manque des données d’entraînement étant donné que le réseau pré-entraîné sera utilisé comme extracteur de caractéristiques. L’étape de *fine-tuning* permet d’adapter le réseau à nos propres données. Le jeu de données ImageNet contient divers types d’images telles que des plantes, des animaux, des ustensiles... Il regroupe plus de 14 millions d’images appartenant à 1000 classes.

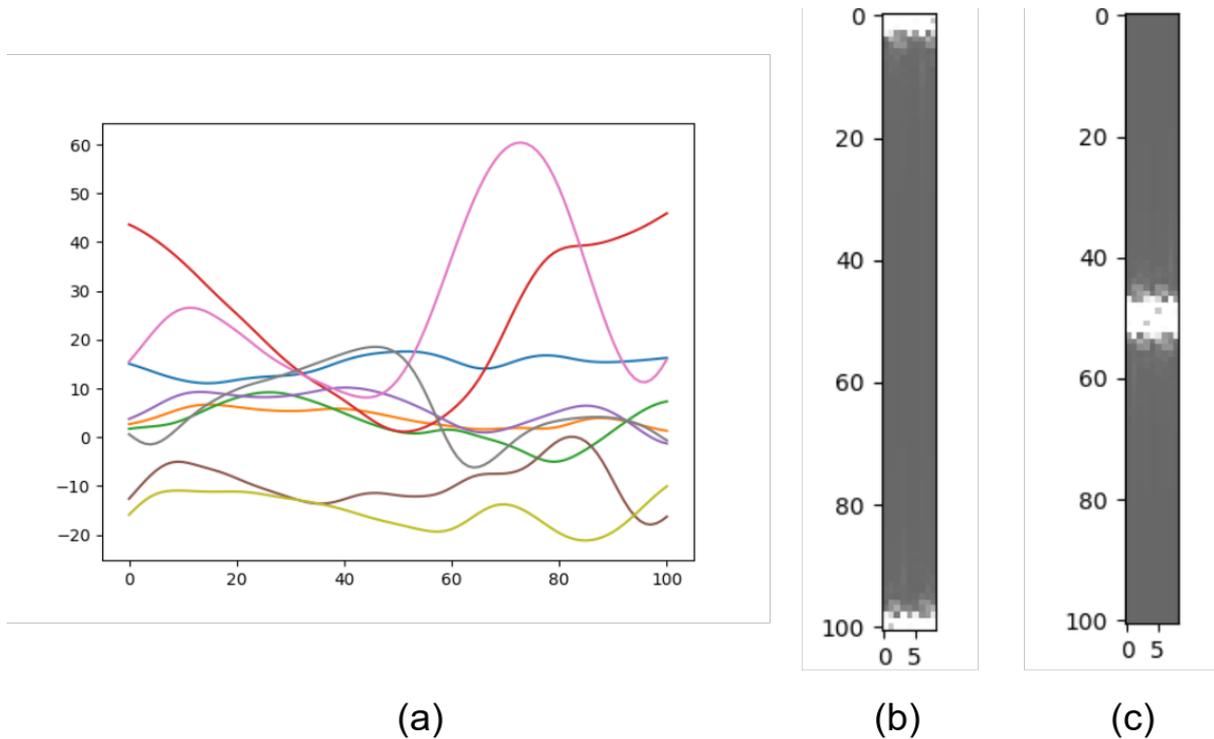


FIGURE 4.19 – (a) Cycle de marche. (b) Amplitude de la 2D FFT. (c) Amplitude centralisée de la 2D FFT.

VGG16 est un modèle de réseau de neurones convolutif à 16 couches profondes conçu par K. Simonyan et A. Zisserman de l’université d’Oxford et qui a acquis une notoriété en gagnant la compétition ILSVRC (*ImageNet Large Scale Visual Recognition Challenge*) en 2014. Ce modèle atteint une précision de test de 92,7% sur ImageNet. Il s’est différencié des modèles précédents en considérant des noyaux de convolution de plus petites dimensions (3×3).

ResNet34 est un réseau convolutif à 34 couches présenté dans [234]. Il possède des liens résiduels qu’il utilise dans les couches connectées suivantes.

EfficientNet-B0 a été présenté dans [235]. EfficientNet est un CNN qui met à l’échelle uniformément toutes les dimensions de profondeur, largeur et résolution à l’aide d’un ensemble de coefficients de *scaling* fixes. EfficientNet-B0 est basé sur les blocs résiduels *bottleneck* inversé, en plus des blocs de compression et d’excitation (*squeeze-and-excitation*).

Pour pouvoir se comparer à l’approche signal ainsi que noter l’effet de la réduction du nombre de paramètres de l’architecture utilisée, nous avons développé quatre **CNN** ayant chacun un nombre de couches convolutives dans $\{1, 2, 3, 4\}$. L’optimisation des hyperparamètres de chacun d’eux a été effectué par KerasTuner. Ces hyperparamètres sont les suivants : nombre de filtres de convolution, la taille du noyau (kernel size), le coefficient dropout, la taille du pooling de la couche de max pooling, le nombre de neurones de la couche dense en sortie du bloc convolutif et le learning rate. Les paramètres du *Tuner* utilisés sont les suivants :

- *SEED* = 1,
- *N_EPOCH_SEARCH* = 100,
- *MAX_TRIALS* = 5,
- *EXECUTION_PER_TRIAL* = 1,
- *Random search*.

4.3.3 Prédiction de la classe du ΔGPS avec Δd

Cette section est consacré à la présentation de la méthodologie de la tâche de prédiction du ΔGPS en intégrant le Δd dans les architectures développées. La prise en compte de cet écart temporel donnera la possibilité de considérer toutes les sessions de marche ayant une session subséquente. Toutes les paires de sessions successives seront considérées (la première session avec la deuxième, la première avec la troisième et ainsi de suite) et non pas juste la session et celle qui la suit directement.

4.3.3.1 Préparation des données

4.3.3.1.1 Augmentation des données

La même technique d’augmentation des données utilisée pour la prédiction du ΔGPS sans Δd a été considérée.

4.3.3.1.2 Répartition des données

Nous avons 277 patients, ayant au moins deux sessions de marche effectuées sans équipement, à répartir entre l’ensemble d’entraînement, validation et test. Le nombre total de sessions éligibles à la tâche (ayant au moins une session subséquente) est égal à 2404 ayant 43979 cycles. La Table 4.4 montre la répartition des données entre entraînement, validation et test. La Figure 4.20 affiche l’histogramme de Δd en jours. Indiquons quelques

Train	Validation	Test
195 patients	42 patients	40 patients
32012 cycles	5577 cycles	6390 cycles
1758 paires de sessions	308 paires de sessions	338 paires de sessions
59.62 % de classe 1	59.26 % de classe 1	52.24 % de classe 1

TABLE 4.4 – Répartition des données

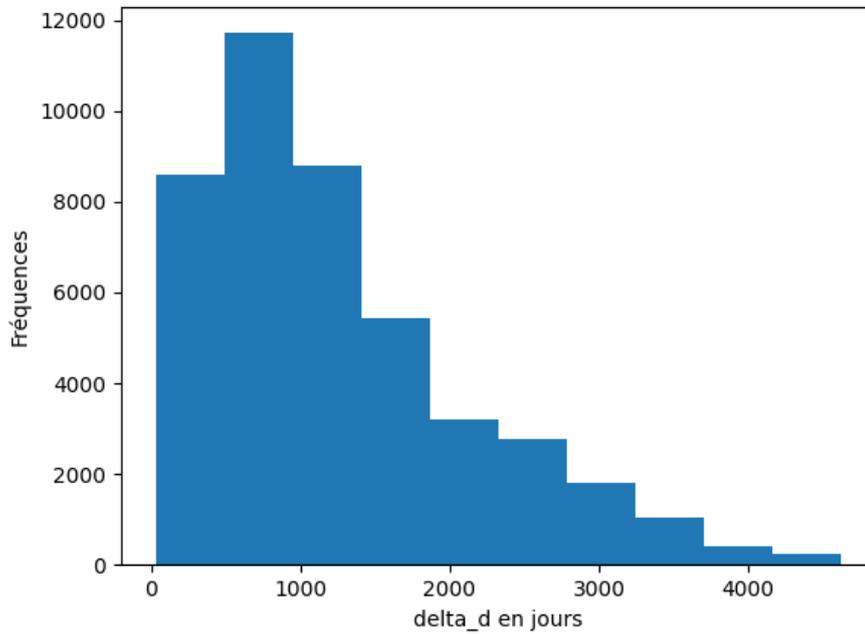


FIGURE 4.20 – Histogramme de Δd en jours.

statistiques clés concernant Δd :

- la valeur moyenne : 1264.95 jours,
- la valeur maximale : 4625 jours,
- la valeur minimale : 30 jours,
- l'écart-type : 891.54 jours.

4.3.3.2 Δd ajouté au milieu de l'architecture

Δd sera ajouté au milieu de l'architecture et non pas en début pour éviter que l'information temporelle ne se noie dans les cinématiques du cycle. Quelques couches denses seront empilées après sa concaténation avec le vecteur de caractéristiques produit par le réseau

afin que celui-ci interprète le nouveau vecteur obtenu.

4.3.3.2.1 MLP

Nous empilons un certain nombre de couches denses à optimiser manuellement. La sortie de ces couches est concaténée avec le Δd . La concaténation obtenue est traitée par un réseau de neurones entièrement connecté. La figure 4.21 montre l'architecture utilisée.

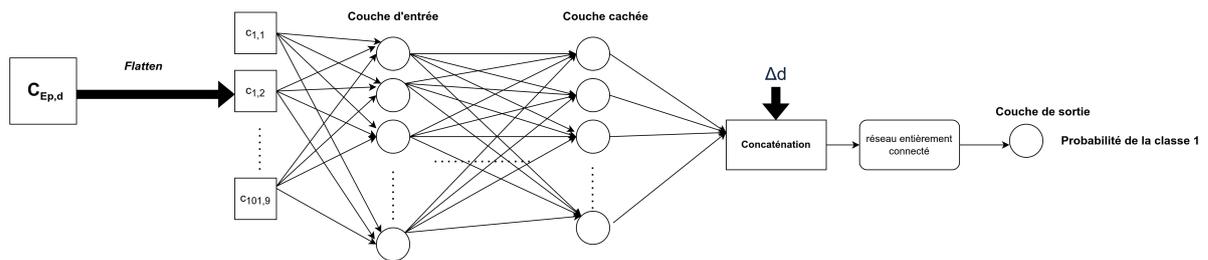


FIGURE 4.21 – MLP intégrant le Δd .

4.3.3.2.2 LSTM

L'architecture utilisée est similaire au MLP. Un certain nombre de couches LSTM, à optimiser d'une manière heuristique, est empilé. Sa sortie est concaténée avec le Δd . La concaténation obtenue est traitée par un réseau de neurones entièrement connecté. La Figure 4.22 montre l'architecture utilisée.

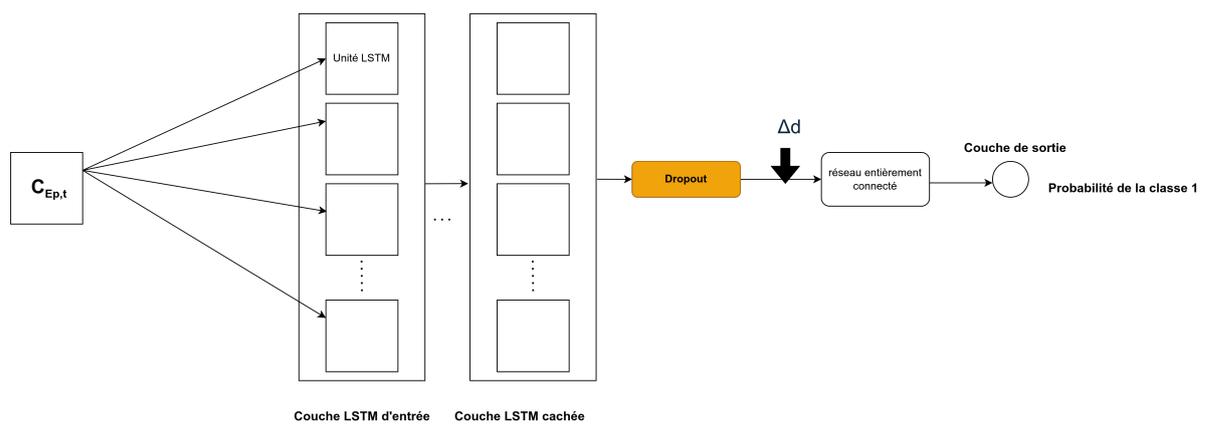


FIGURE 4.22 – LSTM intégrant le Δd .

4.3.3.3 *Time-modulated* LSTM (tLSTM)

Il a été démontré que les LSTM sont peu performants avec des séries temporelles à pas temporel irrégulier [236] [237]. Pour remédier à cela, des modifications ont été apportées à l'architecture standard de LSTM dans [238]. La première version proposée de tLSTM est définie par les équations suivantes :

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + W_{ji}\Delta d + b_i) \quad (4.11)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + W_{jf}\Delta d + b_f) \quad (4.12)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + W_{jc}\Delta d + b_c) \quad (4.13)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + W_{jo}\Delta d + b_o) \quad (4.14)$$

$$h_t = o_t \tanh(c_t) \quad (4.15)$$

Un terme additif fonction du Δd est ajouté aux équations des portes d'entrée, d'oubli et de sortie ainsi qu'à celle de la cellule mémoire. C'est ainsi que le tLSTM incorpore l'information sur le temps écoulé dans l'architecture standard du LSTM ce qui permet de capturer la dynamique temporelle des données séquentielles présentant des irrégularités temporelles.

4.4 Conclusion

Ce chapitre a été l'occasion de dévoiler les détails du pré-traitement des données s'il existe (augmentation des données) et de la distribution de celles-ci entre entraînement, validation et test. Par ailleurs, chacune des architectures développées a été décrite en détail. En cas d'optimisation des hyperparamètres d'une architecture donnée, ces derniers ont été énumérés. Par ailleurs, les paramètres du *Tuner* utilisé ont été évoqués. Après avoir décrit les méthodologies, nous proposons de les évaluer et de noter et interpréter les résultats obtenus. C'est l'objet du dernier Chapitre de la thèse.

RÉSULTATS

5.1 Introduction

Ce chapitre donne et interprète les résultats obtenus sur les données EMA et AQM. Pour EMA, il s'agissait de prédire à partir des données de capteurs les réponses patient à la question ON/OFF du questionnaire. Sur les données AQM, trois tâches ont été réalisées :

- estimation du GPS,
- prédiction du ΔGPS sans prise en compte du Δd ,
- prédiction du ΔGPS avec prise en compte du Δd .

5.2 Résultats et discussion pour EMA

Nous rappelons que les auteurs d'EMA [22]-[24] ont testé une régression logistique sur un seul patient ¹. Quant à nous, le travail que nous avons effectué pour aller plus loin se divise en deux : application de la régression logistique proposée par les auteurs sur tous les patients et développement d'une prédiction à base de LSTM en considérant la même répartition des données que pour la régression logistique.

5.2.1 Régression logistique avec une base de test différente

La nouvelle base de test comprend le patient de test des auteurs. Nous avons obtenu les mêmes résultats que les auteurs sur ce dernier. L'AUC (*Area Under the Curve*) sur les données de validation (`val AUC`) et l'AUC sur les données de test (`test AUC`) obtenues étaient de 0.59 et de 0.53 respectivement.

5.2.2 LSTM

La Table 5.1 résume les résultats obtenus en termes d’AUC sur les données de validation (**val AUC**) et en fonction des hyperparamètres considérés : c le nombre de couches LSTM empilées ayant n unités LSTM chacune et m le nombre de minutes précédant la réponse faite au questionnaire.

c	n	m	val AUC	test AUC
1	3	10	0.59	0.504
2	3	10	0.57	0.404
2	10	10	0.62	0.603
2	10	15	0.57	0.572

TABLE 5.1 – Résultats du LSTM pour EMA.

5.2.3 Discussion

D’une manière générale, les résultats obtenus sont médiocres et soulignent ainsi la difficulté de la mise en place du service de *remote monitoring* (suivi à distance) basé sur EMA. Le LSTM surpasse légèrement la régression logistique proposée par les auteurs. Nous remarquons que les résultats sont légèrement meilleurs en considérant les 10 dernières minutes précédant les réponses aux questionnaires plutôt que les 15 dernières. Une augmentation de c n’a pas résulté en une amélioration des résultats (les deux premières lignes du tableau) tant dis qu’un n plus élevé (deuxième et troisième ligne du tableau) accroît considérablement l’AUC. Une direction d’investigation future pourra se baser sur un nombre de patients plus important. Cependant, nous n’avons pas eu accès à davantage de données durant la thèse. De ce fait, nous sommes passés à la base de données AQM. Des méthodes complémentaires aux LSTM ont été mises en place.

5.3 Résultats et discussion pour AQM

5.3.1 Estimation du GPS

Nous rappelons que l’estimation du GPS est réalisée par cycle.

1. https://github.com/jgvhabets/sensor_EMA_PD_monitoring

5.3.1.1 Résultats

Les performances sont exprimées en termes d'erreur absolue moyenne (*mean absolute error* MAE) sur les données de validation (**val mae**) et les données de test (**test mae**). La Table 5.2 fournit les résultats pour chaque architecture.

Architecture	val mae	test mae
MLP	0.397	0.423
LSTM	0.382	0.418
1D-CNN	0.360	0.379

TABLE 5.2 – Résultats de l'estimation du GPS.

Les hyperparamètres optimisés de chaque architecture sont présentés dans la Table 5.3. Pour le MLP et le LSTM, l'optimisation était empirique. Pour le 1D-CNN, nous avons eu recours à KerasTuner.

Architecture	Hyperparamètres
MLP	Nombre de couches denses : 5
	Nombre de neurones par couches : 1000
	<i>Learning rate</i> : 10^{-5}
LSTM	Nombre de couches LSTM : 1
	Nombre d'unités par couche : 1000
	<i>Learning rate</i> : 10^{-3}
1D-CNN	Nombre de couches de convolution : 3
	Nombre de filtres : 32
	Taille du noyau : 4
	Coefficient <i>dropout</i> : 0
	Taille de <i>pooling</i> : 2
	Nombre de neurones de la couche dense : 300
	<i>Learning rate</i> : 0.0031

TABLE 5.3 – Hyperparamètres utilisés pour l'estimation du GPS.

5.3.1.2 Discussion

Indépendamment de la méthode utilisée entre MLP, LSTM et 1D-CNN, la performance obtenue en terme de **test mae** est aux alentours de 0.4. Une telle incertitude peut être expliquée par les erreurs d'acquisition, les erreurs de sauvegarde dans la base de données... Ces résultats sont satisfaisants compte tenu de l'étendue du GPS (comme indiqué dans

le Chapitre 5). Cela est prévisible vu la simplicité de la tâche en question (le nombre de paramètres à estimer est limité). Complexifier l’architecture en augmentant le nombre de couches et/ou le nombre de neurones par couche n’améliore pas forcément les performances. Le *learning rate* est un hyperparamètre déterminant, d’où l’importance de son optimisation. Par ailleurs, il influe sur la rapidité de la convergence donnée par le nombre d’itérations nécessaire pour l’atteindre.

5.3.2 Prédiction de la variation du GPS sans Δd

5.3.2.1 Approche signal

5.3.2.1.1 Prédiction de la valeur du ΔGPS

Les résultats de cette partie sont présentés pour tous les patients ainsi que pour les enfants uniquement. Les performances sont exprimées en termes de `val mae` et de `test mae`.

5.3.2.1.1.1 Résultats

La Table 5.4 montre les résultats obtenus pour chaque architecture.

Architecture	Nombre de paramètres	val mae	test mae
MLP	48 101	2.006	2.267
LSTM	12 051	1.991	2.155

TABLE 5.4 – Résultats de la prédiction de la valeur du ΔGPS .

Les hyperparamètres optimisés de chaque architecture sont présentés dans la Table 5.5.

Architecture	Hyperparamètres
MLP	Nombre de couches denses : 2
	Nombre de neurones par couches : 50
LSTM	Nombre de couches LSTM : 2
	Nombre d’unités par couche : 100

TABLE 5.5 – Hyperparamètres utilisés dans la prédiction de la valeur du ΔGPS .

Par ailleurs, nous nous sommes limités aux enfants pour voir si cela change l’ordre de grandeur des résultats. La Table 5.6 montre la quantité de données dans chaque sous-ensemble de données.

Les résultats obtenus pour chaque architecture sont résumés dans la Table 5.7.

Les hyperparamètres utilisés sont indiqués dans la Table 5.8.

Train	Validation	Test
182 enfants	39 enfants	38 enfants
14266 cycles	3011 cycles	3046 cycles
776 paires d'examens	174 paires d'examens	158 paires d'examens
55.64 % de classe 1	53.37% de classe 1	51.71% de classe 1

TABLE 5.6 – Répartition des données des enfants.

Architecture	Nombre de paramètres	val mae	test mae
MLP	455 501	2.047	1.969
LSTM	1 020 501	1.832	1.772

TABLE 5.7 – Hyperparamètres utilisés la prédiction de la valeur du ΔGPS pour les enfants.

Architecture	Hyperparamètres
MLP	Nombre de couches denses : 1
	Nombre de neurones par couches : 500
	<i>Learning rate</i> : 10^{-5}
LSTM	Nombre de couches LSTM : 1
	Nombre d'unités par couche : 500
	<i>Learning rate</i> : 10^{-5}

TABLE 5.8 – Hyperparamètres utilisés dans la prédiction de la valeur du ΔGPS pour les enfants.

5.3.2.1.1.2 Discussion

Compte tenu de la dynamique du ΔGPS présentée dans le chapitre précédent (valeur moyenne autour de 0), les résultats ne sont pas très bons, ce qui souligne la difficulté de la tâche de prédiction. La prise en compte des enfants uniquement améliore légèrement les résultats, ce qui s'explique en partie par le phénomène de croissance qui ne concerne plus les adultes. Dans les deux cas de figure, ce sont les LSTM qui donnent la meilleure performance indépendamment si leur nombre de paramètres dépasse celui des MLP ou non. Afin de simplifier la tâche de prédiction, nous nous sommes ramenés à deux "classes" selon le sens de variation du ΔGPS .

5.3.2.1.2 Prédiction de la classe du ΔGPS

Les résultats de cette partie sont présentés pour tous les patients ainsi que pour les enfants uniquement. Les performances sont exprimées en termes d'AUC sur les données de validation (**val AUC**) et les données de test (**test AUC**).

5.3.2.1.2.1 Résultats

La Table 5.9 montre les résultats obtenus pour chaque architecture. À ce stade, tous les patients ont été inclus.

Architecture	Nombre de paramètres	val AUC	test AUC
MLP	302 801	0.667	0.667
LSTM	7 026 501	0.712	0.710
FCN	274 049	0.723	0.717
ResNet	511 297	0.719	0.719
Encoder	3 195 009	0.640	0.632
t-LeNet	111 751	0.625	0.665

TABLE 5.9 – Résultats de la prédiction de la classe du ΔGPS par l’approche signal.

Les hyperparamètres optimisés de MLP et LSTM sont présentés dans la Table 5.10.

Architecture	Hyperparamètres
MLP	Nombre de couches denses : 4
	Nombre de neurones par couche : 200
LSTM	Nombre de couches LSTM : 4
	Nombre d’unités par couche : 500

TABLE 5.10 – Hyperparamètres du MLP et LSTM utilisés dans la prédiction de la classe du ΔGPS par l’approche signal.

La figure 5.1 montre les courbes ROC (*Receiver Operating Characteristic*) obtenues pour les différentes architectures.

Nous comparons ces courbes ROC deux à deux en utilisant le test statistique de DeLong [239]. La Table 5.11 montre les résultats de ces comparaisons (*p-values*).

	MLP	LSTM	FCN	ResNet	Encoder	t-LeNet
MLP	-	1.256×10^{-14}	7.116×10^{-16}	1.558×10^{-10}	1.009×10^{-4}	0.768
LSTM	-	-	0.1001	0.2181	$< 2.2 \times 10^{-16}$	5.543×10^{-5}
FCN	-	-	-	0.824	$< 2.2 \times 10^{-16}$	2.033×10^{-6}
ResNet	-	-	-	-	4.813×10^{-15}	7.688×10^{-7}
Encoder	-	-	-	-	-	5.263×10^{-4}

TABLE 5.11 – *p-values* du test statistique de DeLong pour tous les patients avec l’approche signal.

Les résultats obtenus pour les enfants sont présentés dans la Table 5.12.

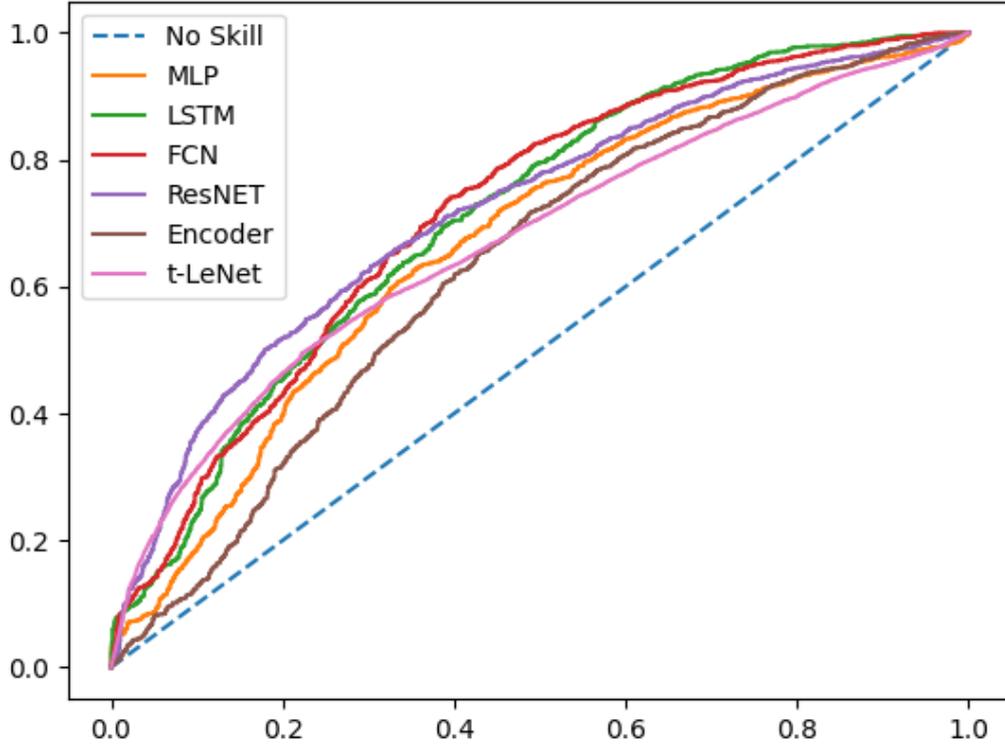


FIGURE 5.1 – Courbes ROC des différentes architectures de l’approche signal

Architecture	val AUC	test AUC
MLP	0.733	0.764
LSTM	0.754	0.717
FCN	0.722	0.725
ResNet	0.7	0.7
Encoder	0.666	0.692
t-LeNet	0.676	0.69

TABLE 5.12 – Résultats de la prédiction de la classe du ΔGPS pour les enfants avec l’approche signal.

Les hyperparamètres optimisés de MLP et LSTM sont présentés dans la Table 5.13.

Si l’on s’intéresse à une prédiction à l’échelle de l’examen, un ΔGPS peut être associé à chaque examen $E_{p,d}$ à considérer, comme-suit :

$$\Delta GPS(E_{p,d})^{\Delta d} = GPS_{avg}(E_{p,d+\Delta d}) - GPS_{avg}(E_{p,d}) \quad (5.1)$$

Architecture	Hyperparamètres	Nombre de paramètres
MLP	Nombre de couches denses : 4	1 207 001
	Nombre de neurones par couche : 500	
LSTM	Nombre de couches LSTM : 1	4 041 001
	Nombre d'unités par couche : 1000	

TABLE 5.13 – Hyperparamètres utilisés pour les enfants.

On rappelle que $GPS_{avg}(E_{p,d})$ est le GPS moyen par cycle de la session $E_{p,d}$. Le plus petit Δd est retenu pour chaque examen pour ne prendre que des paires d'examens directement consécutifs. Le ΔGPS est binarisé tel que nous l'avons fait à l'échelle des cycle. Les *ragged tensors* [240] ont été utilisés comme structure de données pour stocker des examens de longueur (nombre de cycles) variable. Les résultats obtenus sont indiqués dans la Table 5.14.

Architecture	Nombre de paramètres	val AUC	test AUC
ConvLSTM	406 281	0.685	0.680

TABLE 5.14 – Résultats de la prédiction de la classe du ΔGPS à l'échelle de l'examen avec l'approche signal.

Les hyperparamètres utilisés sont résumés dans la Table 5.15.

Hyperparamètres	valeurs
Nombre de couches ConvLSTM	3
Nombre de filtres	40
Taille du noyau	12

TABLE 5.15 – Hyperparamètres utilisés dans la prédiction à l'échelle de l'examen.

5.3.2.1.2.2 Discussion

Le test DeLong considère qu'un modèle A est significativement différent d'un modèle B si la *p-value* des deux courbes ROC en question est strictement inférieur à 0.05. Selon ce test, pour la prédiction incluant tous les patients (Table 5.11), FCN, LSTM et ResNet fonctionnent similairement bien avec une AUC dépassant les 0.7. t-LeNet et MLP viennent en deuxième lieu avec des performances semblables supplantant l'Encoder. La *p-value* entre le FCN utilisé dans la prédiction incluant tous les patients et le LSTM de la prédiction

sur des enfants uniquement est égale à 0.9918, ce qui signifie que les deux prédictions sont similairement performantes (pas de différence statistique significative). De ce fait, nous ne ferons plus cette séparation selon l'âge dans tout ce qui suit. Par ailleurs, nous avons comparé par test Delong le FCN de la prédiction à l'échelle du cycle au ConvLstm de la prédiction à l'échelle de l'examen. La *p-value* retournée est égale à 0.3927, ce qui souligne l'inexistence d'une différence significative entre les deux. La variabilité inter-cycles au sein d'un même examen est limitée. Dans ce qui suit, nous ne considérerons que les cycles de marche et non les examens, ce qui peut être perçu comme une manière de réaliser de l'augmentation de données.

Une AUC supérieure à 0.7 est satisfaisante pour une prédiction sur des données présentant une grande hétérogénéité.

5.3.2.2 Approche image

5.3.2.2.1 Résultats

Les résultats obtenus sont présentés dans la Table 5.16.

	VGG16		ResNet34		EfficientNetb0		2D-CNN	
	val AUC	test AUC	val AUC	test AUC	val AUC	test AUC	val AUC	test AUC
GASF	0.549	0.543	0.543	0.509	0.535	0.498	0.565	0.544
GADF	0.567	0.533	0.539	0.524	0.543	0.525	0.584	0.482
MTF	0.539	0.520	0.540	0.488	0.527	0.487	0.563	0.549
2D FFT	0.650	0.642	0.653	0.679	0.637	0.628	0.726	0.693

TABLE 5.16 – Résultats de la prédiction de la classe du ΔGPS par l'approche image.

Les hyperparamètres des 2D-CNN pour chaque image sont présentés dans la Table 5.17. Nous montrons sur la figure 5.2 les courbes ROC pour les 2D FFT.

Nous calculons, comme le montre la Table 5.18, les *p-values* deux à deux pour les images 2D FFT.

5.3.2.2.2 Discussion

Les images GAF et MTF n'ont pas donné des résultats satisfaisants et ce quelque soit l'architecture utilisée. Cela s'explique par la perte d'information qu'engendrent ces transformations du signal vers l'image. Les 2D FFT permettent d'obtenir une AUC supérieure

	Hyperparamètres						Nombre de paramètres
	Nombre de couches de convolution	Nombre de filtres	Taille du noyau	Coefficient <i>dropout</i>	Taille de <i>pooling</i>	Nombre de neurones de la couche dense	
GASF	2	16	4	0.5	4	600	5 086 033
GADF	3	12	8	0.3	2	600	11 546 581
MTF	3	16	4	0.5	6	600	5 090 145
2D FFT	2	4	32	0	8	300	35 505

TABLE 5.17 – Hyperparamètres des 2D-CNN utilisés dans la prédiction de la classe du ΔGPS avec l’approche image.

	VGG16	ResNet34	EfficientNet_b0	2D-CNN
VGG16	-	0.01995	0.4522	0.0002799
ResNet34	-	-	0.002084	0.1921
EfficientNet_b0	-	-	-	1.167e-05

TABLE 5.18 – *p-values* du test Delong obtenues par l’approche image.

à 0.6, indépendamment de l’architecture utilisée. Le test Delong montre que le 2D-CNN et le ResNet produisent des performances similaires. VGG16 et EfficientNet_b0 fonctionnent similairement bien, mais ils sont dépassés par le 2D-CNN et le ResNet. Un autre test Delong pour comparer le FCN (meilleure architecture de l’approche signal) au 2D-CNN donne une *p-value* de $2.316 * 10^{-4}$, ce qui souligne que la différence entre les deux approches est statistiquement significative. Ce résultat prouve que l’extraction d’informations est plus efficace sur les signaux bruts que par l’intermédiaire d’images synthétiques.

5.3.3 Prédiction de la variation du GPS avec Δd

Deux manières différentes ont été considérées pour la prise en compte du Δd dans les prédictions : sa concaténation au vecteur de caractéristique généré par un MLP et un LSTM ainsi que le développement d’un tLSTM.

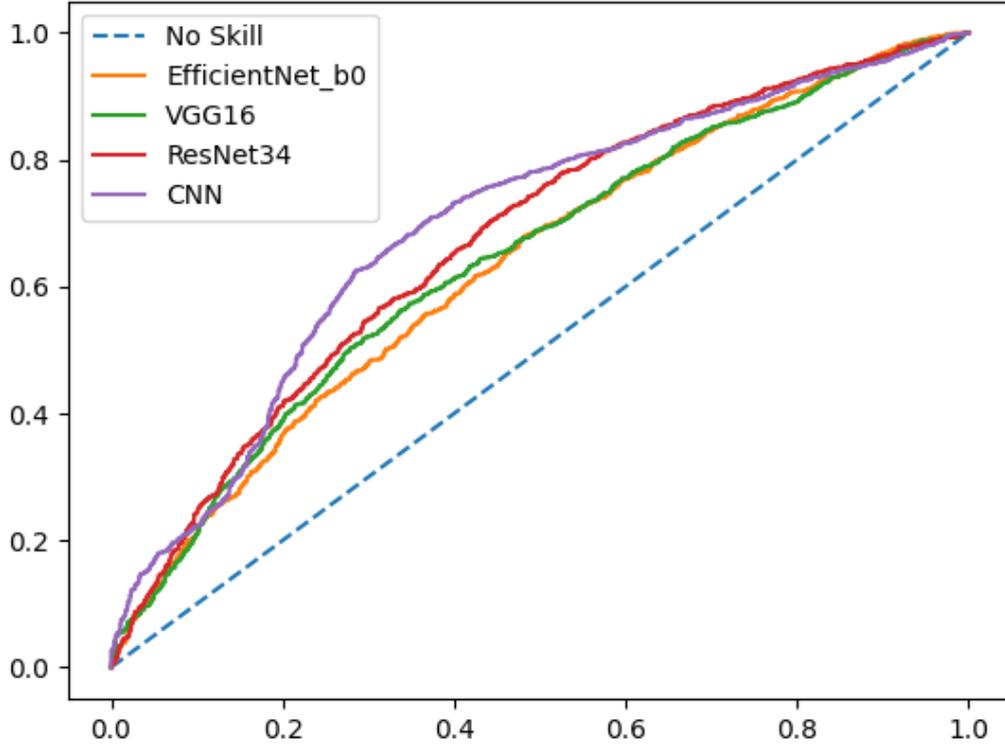


FIGURE 5.2 – Courbes ROC des différentes architectures de l’approche image 2D FFT.

5.3.3.1 Résultats

5.3.3.1.1 Δd ajouté au milieu de l’architecture

La Table 5.19 montre les résultats obtenus. Les hyperparamètres optimisés de MLP et

	Δd exprimée en jours		Δd exprimée en mois		Δd exprimée en années	
	val AUC	test AUC	val AUC	test AUC	val AUC	test AUC
MLP	0.736	0.725	0.721	0.74	0.735	0.702
LSTM	0.744	0.73	0.733	0.753	0.738	0.758

TABLE 5.19 – Résultats pour le Δd ajouté au milieu de l’architecture.

LSTM sont présentés dans la Table 5.20. Leurs nombres de paramètres sont indiqués sur la Table 5.21.

La matrice de confusion permet de connaître les différents types d’erreurs commis par un

Architecture	Hyperparamètres	Δd en jours	Δd exprimée en mois	Δd exprimée en années
MLP	Nombre de couches denses	8	1	2
	Nombre de neurones par couche	500	100	1000
LSTM	Nombre de couches LSTM	1	1	1
	Nombre d'unités par couche	1000	1000	500

TABLE 5.20 – Hyperparamètres MLP et LSTM - Δd ajouté au milieu de l'architecture.

Architecture	Nombre de paramètres		
	Δd en jours	Δd en mois	Δd en années
MLP	3 336 501	819 001	3 539 001
LSTM	5 668 001	5 668 001	2 148 001

TABLE 5.21 – Nombre de paramètres MLP et LSTM - Δd ajouté au milieu de l'architecture.

algorithme de classification. Un de ses intérêts est de montrer rapidement si ce dernier parvient à classifier correctement. Elle se montre comme l'illustre la figure 5.3. Dans un test de classification binaire, un résultat est dit vrai positif lorsqu'un item est correctement détecté par le test. Nous l'opposons aux notions :

- de faux positif : item déclaré positif alors qu'il ne l'était pas),
- de faux négatif : item déclaré négatif alors qu'il était en réalité positif), et
- de vrai négatif : item correctement déclaré comme négatif.

Les matrices de confusion pour le Δd exprimé en jours sont présentées dans la Table 5.22.

Architecture	Matrice de confusion
MLP	$\begin{pmatrix} 955 & 2097 \\ 395 & 2943 \end{pmatrix}$
LSTM	$\begin{pmatrix} 2050 & 1002 \\ 1116 & 2222 \end{pmatrix}$

TABLE 5.22 – Matrices de confusion - Δd ajouté au milieu de l'architecture.

		Classe réelle	
		-	+
Classe prédite	-	True Negatives <i>(vrais négatifs)</i>	False Negatives <i>(faux négatifs)</i>
	+	False Positives <i>(faux positifs)</i>	True Positives <i>(vrais positifs)</i>

FIGURE 5.3 – Matrice de confusion [241].

5.3.3.1.2 Time-modulated LSTM (tLSTM)

La Table 5.23 montre les résultats. Les hyperparamètres pour chaque cas de figure sont

Δd exprimée en jours		Δd exprimée en mois		Δd exprimée en année	
val AUC	test AUC	val AUC	test AUC	val AUC	test AUC
0.696	0.691	0.711	0.737	0.715	0.701

TABLE 5.23 – Résultats du tLSTM.

présentés dans la Table 5.24. La Table 5.25 montre les nombres de paramètres pour chaque cas de figure.

La matrice de confusion pour le Δd exprimé en jours est la suivante : $\begin{pmatrix} 1412 & 1640 \\ 717 & 2621 \end{pmatrix}$. Nous calculons les p -value du test DeLong pour les trois architectures. La Table 5.26 montre les résultats obtenus.

Et si maintenant nous comparons les MLP et LSTM sans et avec Δd . Les résultats du test DeLong sont montrés dans la Table 5.27.

Hyperparamètres	Δd en jours	Δd en mois	Δd en années
Nombre de couches tLSTM	1	1	1
Nombre d'unités par couche	500	500	500

TABLE 5.24 – Hyperparamètres du tLSTM.

	Δd en jours	Δd en mois	Δd en années
Nombre de paramètres	1 273 001	1 273 001	1 273 001

TABLE 5.25 – Nombre de paramètres du tLSTM.

	MLP	LSTM	tLSTM
MLP	-	0.1891	$1.323 * 10^{-05}$
LSTM	-	-	$1.468 * 10^{-08}$

 TABLE 5.26 – p -values du test Delong comparant les deux approches incluant le Δd .

5.3.3.2 Discussion

Pour le LSTM et le MLP, Δd exprimé en jours résultent en de meilleures AUC tant dis que pour le tLSTM c'est le Δd exprimé en années qui l'emporte. Le MLP et le LSTM avec Δd fonctionnent pareillement bien et surpassent le tLSTM.

La répartition du Δd en année est montrée sur la Table 5.28.

Les diagrammes en bar 5.4, 5.5 et 5.6 montrent la **test AUC** en fonction du Δd en années pour le MLP, le LSTM et le tLSTM respectivement. Nous remarquons une diminution substantielle du **test AUC** pour un Δd supérieur à 9 ans, ce qui n'est pas étonnant. Le pic est atteint pour un Δd compris entre 4 et 5 ans, ce qui souligne qu'un écart temporel suffisant doit s'écouler entre deux visites à l'hôpital pour une meilleure prédiction.

5.4 Conclusion

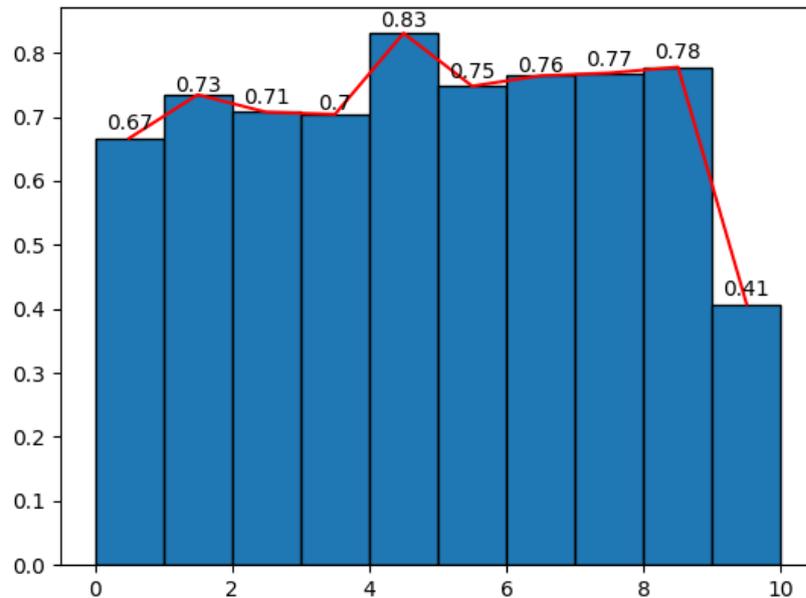
Ce dernier chapitre était consacré à la présentation et à l'interprétation des résultats obtenus. Les principales conclusions tirées sont les suivantes :

- Les résultats de prédiction sur EMA sont médiocres, ce qui souligne la difficulté d'une telle tâche,
- les résultats de la prédiction du ΔGPS à partir des signaux bruts de la cinématique sont honorables malgré la complexité de cette tâche et la faible quantité de données à disposition : FCN, LSTM et ResNet atteignent une AUC dépassant les 0.7,

	MLP sans Δd	LSTM sans Δd	MLP avec Δd	LSTM avec Δd
MLP sans Δd	-	-	$1.027 * 10^{-06}$	$8.657 * 10^{-08}$
LSTM sans Δd	-	-	0.1986	0.07815

 TABLE 5.27 – p -values du test Delong pour les MLP et LSTM sans et avec Δd .

Δd en années]0, 1]]1, 2]]2, 3]]3, 4]]4, 5]]5, 6]]6, 7]]7, 8]]8, 9]]9, 10]
Nombre d'échantillons	840	1470	1192	1028	555	507	309	143	222	124

TABLE 5.28 – Répartition du Δd en année.FIGURE 5.4 – test AUC en fonction du Δd en années pour le MLP.

- se limiter à la population en bas âge n'impacte pas les résultats obtenus, ce qui est dû à sa prédominance dans la cohorte (96 % des cycles appartiennent à des enfants),
- des performances similaires sont obtenues en se mettant à l'échelle de l'examen,
- les conversions GAF et MTF engendrent une perte d'informations conséquente ce qui explique la médiocrité des résultats obtenus,
- le passage au domaine fréquentiel conserve les caractéristiques pertinentes des variables cinématiques et résulte en des scores *AUC* comparables à ceux obtenus par l'approche signal,
- Le LSTM sans et avec Δd donnent des performances similaires avec une *AUC* supérieure à 0.71. Les performances de LSTM sont alors insensibles à l'ajout du Δd . Cela peut être expliqué par le nombre limité de patients ayant plus de deux sessions (voir 2.3.2 du Chapitre 2). Pour cette configuration incorporant le Δd , le

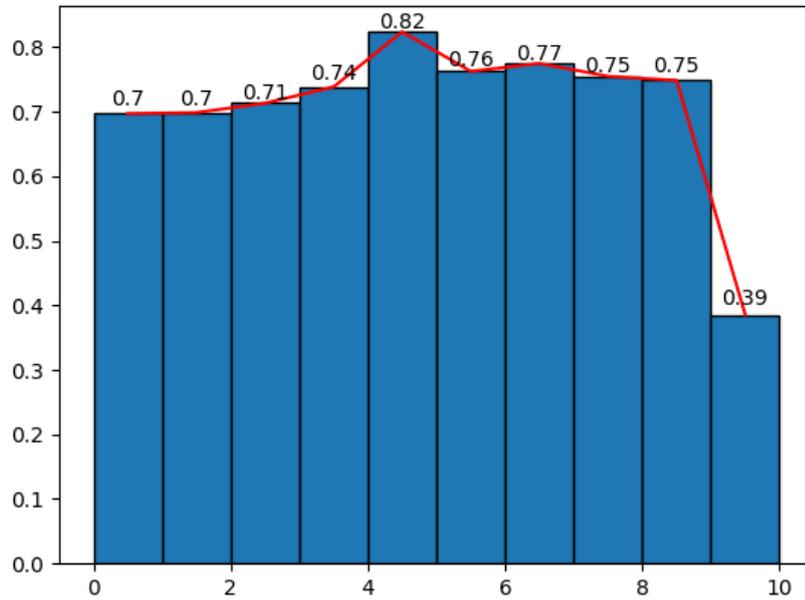


FIGURE 5.5 – test AUC en fonction du Δd en années pour le LSTM.

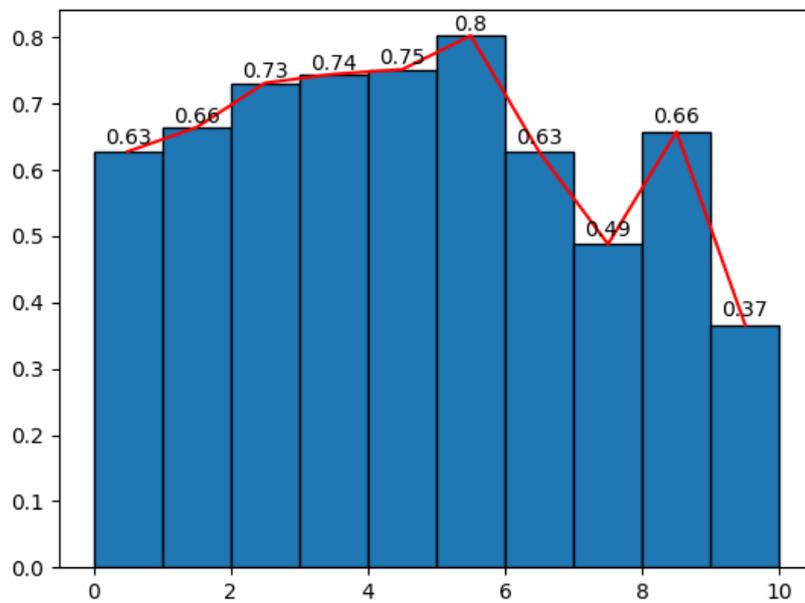


FIGURE 5.6 – test AUC en fonction du Δd en années pour le tLSTM.

MLP fonctionne aussi bien que le LSTM et tous les deux surpassent le MLP sans Δd et le tLSTM. En somme, le LSTM sans ou avec Δd , FCN, et ResNet sont les architectures les plus efficaces.

CONCLUSION

La prédiction de l'évolution pathologique joue un rôle important dans le suivi de patients étant donné qu'elle permet de mieux orienter le traitement et de réduire les actes médicaux comme les interventions chirurgicales. Un tel suivi peut prendre différentes formes comme l'*Ecological Momentary Assessment* (EMA) ou la longitudinalité par des visites médicales répétées et constitue un des défis majeurs du projet Followknee présenté dans le Chapitre 1. Par ailleurs, nous avons pu voir brièvement dans ce chapitre ce qu'est l'EMA ainsi que sa place dans le *remote monitoring*.

Deux bases de données ont été analysées pour le développement d'une prédiction de l'évolution pathologique : EMA pour la maladie de Parkinson et AQM pour l'analyse quantifiée de la marche de patients souffrant de troubles locomoteurs. Le Chapitre 2 a été consacré à leur description. Pour EMA, la maladie de Parkinson a été décrite d'une manière succincte. Par la suite, de nombreux chiffres clés de la base de données ont été évoqués : nombre de patients recrutés, période de port des unités de mesure, nombre de questionnaires complétés, etc. Nous nous sommes intéressés à une variable particulière appelée `sanpar_onoff` et indiquant l'état de santé global noté par le patient parmi 4 valeurs possibles, et ce plusieurs fois par jour. Nous avons pu cerner que `sanpar_onoff` présente une variabilité inter et intra-patients importante. Pour AQM, nous avons commencé par présenter l'analyse quantifiée de la marche en passant par une définition de la marche normale et de la marche pathologique. Par ailleurs, le déroulement de cet examen, ses utilisations et ses limites ont été abordés. Le *Gait Profile Score* (GPS) a été présenté et une formule de calcul de sa variation ΔGPS pour un cycle de marche quelconque à l'issue d'un écart temporel Δd a été donnée. Nous avons clôturé le Chapitre 2 par une étude statistique de la base de données AQM : les patients, les différentes pathologies, les différents appareillages et les sessions de marche ont été dénombrés.

Dans le Chapitre 3, nous avons commencé par présenter les aspects théoriques de l'apprentissage profond. Dans ce sens, 3 types de réseaux de neurones ont été présentés : ceux à couches multiples (*Multi Layer Perceptron* MLP), les réseaux récurrents y compris les *Long Short-Term Memory* (LSTM) et les réseaux convolutifs (*Convolutional Neural Network* CNN). Par la suite, des notions de base de l'apprentissage profond ont été ex-

posées : déroulement entre phase d’entraînement et phase de validation, préparation et augmentation des données, hyper-paramètres, sur et sous-apprentissage, apprentissage par transfert, modèles génératifs et discriminatifs. Uniquement les modèles discriminatifs ont été explorés dans le cadre de cette thèse. La deuxième partie du Chapitre 3 a été destinée à l’étude bibliographique de notre sujet. Nous avons organisé ce travail en 4 sous-parties : utilisation de la conversion signal/image, apprentissage profond et analyse de signaux physiologiques, apprentissage profond et maladie de Parkinson, apprentissage profond et AQM.

Le Chapitre 4 a été réservé à la description des matériels et méthodes pour EMA et AQM. Nous rappelons que pour EMA, le travail réalisé consistait dans le test de la méthode des auteurs (régression logistique ayant résulté en une `test AUC` supérieure à 0.7 pour un patient donné) sur un nouveau set et à la comparaison de cette méthode à un LSTM développé. Pour AQM, la première tâche effectuée s’agissait de l’estimation du GPS par cycle de marche. Celle-ci, bien que relativement simple, nous a permis de valider chaque famille de réseaux de neurones : MLP, LSTM et CNN. Le travail restant était réservé à la prédiction du ΔGPS . Pour ce faire, deux cas de figure ont été pris en compte : sans et avec écart temporel entre les examens Δd . Dans le premier cas, uniquement des paires constituées d’examens directement consécutifs ont été considérées. Cela est fidèle à la réalité clinique étant donné que le clinicien regarde surtout le dernier examen pour prévoir le sens de l’évolution pathologique. Le deuxième cas utilise toute la combinatoire possible, ce qui augmente le nombre de paires disponibles. Cela couvre alors les visites énormément espacées, ce qui prépare le terrain pour une prédiction prenant en considération tout l’historique du patient. Pour la prédiction sans Δd , deux approches ont été proposées : signal et image. Nous avons essayé de couvrir une large palette d’architectures pour l’approche signal : MLP, LSTM, des CNN (FCN, ResNet et t-LeNet) et une méthode hybride (Encodeur). Pour l’approche image, des architectures pré-entraînées ont été considérées pour l’apprentissage par transfert (VGG16, ResNet34 et EfficientNet-B0) à partir des images GAF, MTF et 2D FFT. La prise en compte du Δd pour le deuxième cas de figure a été réalisée de deux différentes manières : injection intuitive au milieu de l’architecture du MLP et LSTM par concaténation avec le vecteur de caractéristiques et développement d’un tLSTM.

Le Chapitre 5 donne et discute les résultats obtenus pour EMA et AQM.

Pour EMA, le LSTM développé surpasse légèrement la régression logistique des auteurs. D’une manière générale, les résultats obtenus étaient médiocres avec une `AUC` maximale

de 0.6 environ. Pour AQM, les meilleures architectures de l'approche signal étaient le LSTM, FCN et ResNet avec une AUC supérieure à 0.71. La conversion en images GAF ou MTF a détérioré les performances vu la perte d'information qu'elle engendre. Cependant, le passage au domaine fréquentiel par 2D FFT a donné de bonnes performances avec une AUC voisinant les 0.7, mais cela fonctionne moins bien que l'approche signal. Avec les 2D FFT, un CNN développé de zéro a eu le dessus sur les modèles pré-entraînés ayant beaucoup plus de paramètres. Nous avons réussi à retrouver la même efficacité atteinte dans l'approche signal en incorporant le Δd au milieu de l'architecture. Le LSTM et MLP utilisés fonctionnent similairement bien et surpassent le t-LSTM.

En guise de perspectives pour EMA, il est possible d'explorer davantage la taille de la fenêtre des données des capteurs à utiliser. Par ailleurs, l'augmentation de la cohorte recrutée serait avantageuse.

Pour AQM, nous proposons d'inclure tout l'historique patient pour la prédiction. Dans ce cas, l'entrée des nouvelles architectures à développer sera l'ensemble des sessions du patient. En outre, il est judicieux de penser à une manière d'exploiter les patients ayant une seule session surtout qu'ils sont prédominants dans la base de données (un pré-entraînement par l'intermédiaire d'une tâche prétexte par exemple). Une autre ouverture sera d'incorporer l'information traitement disponible pour certains patients. Les traitements administrés n'ont pas forcément eu lieu à la même date qu'une session de marche. Une dernière perspective sera d'appliquer les architectures développées au projet Followknee.

LISTE DES PUBLICATIONS

Ben Chaabane, N., Conze, P., Quellec, G., Lempereur M., Rémy-Néris O., Cochener B., Lamard M. (2022). Quantification de la qualité de la marche par intelligence artificielle. RITS, Brest, France.

Ben Chaabane, N., Conze, P., Quellec, G., Lempereur M., Rémy-Néris O., Cochener B., Lamard M. (2023). Gait deviation change prediction for patients with gait disorders using artificial intelligence. IEEE Engineering in Medicine and Biology Conference, Sydney, Australie.

Ben Chaabane, N., Conze, P., Quellec, G., Lempereur M., Rémy-Néris O., Cochener B., Lamard M. (2023). Quantitative gait analysis and prediction using artificial intelligence for patients with gait disorders. Soumis à *Scientific Reports* en juillet.

BIBLIOGRAPHIE

- [1] M. SLOAN, A. PREMKUMAR et N. P. SHETH, « Projected volume of primary total joint arthroplasty in the US, 2014 to 2030 », *JBJS*, t. 100, 17, p. 1455-1460, 2018.
- [2] E. ROMANINI, F. DECAROLIS, I. LUZI et al., « Total knee arthroplasty in Italy : reflections from the last fifteen years and projections for the next thirty », *International orthopaedics*, t. 43, p. 133-138, 2019.
- [3] M. C. INACIO, S. E. GRAVES, N. L. PRATT, E. E. ROUGHEAD et S. NEMES, « Increase in total joint arthroplasty projected from 2014 to 2046 in Australia : a conservative local model with international implications », *Clinical Orthopaedics and Related Research®*, t. 475, p. 2130-2137, 2017.
- [4] A. PATEL, G. PAVLOU, R. MÚJICA-MOTA et A. TOMS, « The epidemiology of revision total knee and hip arthroplasty in England and Wales : a comparative analysis with projections for the United States. A study using the National Joint Registry dataset », *The bone & joint journal*, t. 97, 8, p. 1076-1081, 2015.
- [5] W. R. ADAMS, « High-accuracy detection of early Parkinson's Disease using multiple characteristics of finger movement while typing », *PloS one*, t. 12, 11, e0188226, 2017.
- [6] A. L. GOLDBERGER, L. A. AMARAL, L. GLASS et al., « PhysioBank, PhysioToolkit, and PhysioNet : components of a new research resource for complex physiologic signals », *circulation*, t. 101, 23, e215-e220, 2000.
- [7] R. S. MCGINNIS, N. MAHADEVAN, Y. MOON et al., « A machine learning approach for gait speed estimation using skin-mounted wearable sensors : From healthy controls to individuals with multiple sclerosis », *PloS one*, t. 12, 6, e0178366, 2017.
- [8] S. SCHRICKER, N. SCHMID, M. SCHANZ, M. KIMMEL et M. D. ALSCHER, *In-hospital physical activity measured with a new Bosch accelerometer sensor system*, 2020.

-
- [9] B. VENNEMANN, D. OBRIST et T. RÖSGEN, « A smartphone-enabled wireless and batteryless implantable blood flow sensor for remote monitoring of prosthetic heart valve function », *PLoS One*, t. 15, 1, e0227372, 2020.
- [10] A. MUELLER, H. HOEFLING, T. NURITDINOW et al., « Continuous monitoring of patient mobility for 18 months using inertial sensors following traumatic knee injury : a case study », *Digital biomarkers*, t. 2, 2, p. 79-89, 2018.
- [11] A. AIBINU, M. SALAMI et A. SHAFIE, « Blood glucose level prediction using intelligent based modeling techniques », *Inst Electrical Electron Eng*, t. 4, 2, p. 1734-7, 2010.
- [12] J. PARKINSON, « An essay on the shaking palsy.(Republished in 2002) », *J Neuropsychiatry Clin Neurosci*, t. 14, p. 223-36, 1817.
- [13] A. LEES, « An essay on the shaking palsy », *Brain*, t. 140, 3, p. 843-848, 2017.
- [14] A. ATTYE, F. RENARD, P. COUPÉ et al., « Détection de la maladie de parkinson précoce à l'aide d'une technique d'intelligence artificielle explicable », *Journal of Neuroradiology*, t. 49, 2, p. 141-142, 2022.
- [15] Adresse : <https://www.franceparkinson.fr/>.
- [16] W. GIBB et A. LEES, « The relevance of the Lewy body to the pathogenesis of idiopathic Parkinson's disease. », *Journal of Neurology, Neurosurgery & Psychiatry*, t. 51, 6, p. 745-752, 1988.
- [17] R. B. POSTUMA, W. POEWE, I. LITVAN et al., « Validation of the MDS clinical diagnostic criteria for Parkinson's disease », *Movement Disorders*, t. 33, 10, p. 1601-1608, 2018.
- [18] J. W. LANGSTON, « The Parkinson's complex : parkinsonism is just the tip of the iceberg », *Annals of Neurology : Official Journal of the American Neurological Association and the Child Neurology Society*, t. 59, 4, p. 591-596, 2006.
- [19] D. MILENKOVIC, B. JUDE et C. MORAND, « miRNA as molecular target of polyphenols underlying their biological effects », *Free Radical Biology and Medicine*, t. 64, p. 40-51, 2013.
- [20] B. R. BLOEM, M. S. OKUN et C. KLEIN, « Parkinson's disease », *The Lancet*, t. 397, 10291, p. 2284-2303, 2021.

-
- [21] M. MUTHURAMAN, N. KOIRALA, D. CIOLAC et al., « Deep brain stimulation and L-DOPA therapy : concepts of action and clinical applications in Parkinson's disease », *Frontiers in neurology*, t. 9, p. 711, 2018.
- [22] M. HEIJMANS, J. G. HABETS, C. HERFF et al., « Monitoring Parkinson's disease symptoms during daily life : a feasibility study », *npj Parkinson's Disease*, t. 5, 1, p. 21, 2019.
- [23] J. HABETS, M. HEIJMANS, C. HERFF et al., « Mobile health daily life monitoring for Parkinson disease : development and validation of ecological momentary assessments », *JMIR mHealth and uHealth*, t. 8, 5, e15628, 2020.
- [24] J. G. HABETS, M. HEIJMANS, A. F. LEENTJENS et al., « A long-term, real-life Parkinson monitoring database combining unscripted objective and subjective recordings », *Data*, t. 6, 2, p. 22, 2021.
- [25] M. CSIKSZENTMIHALYI, M. CSIKSZENTMIHALYI et R. LARSON, « Validity and reliability of the experience-sampling method », *Flow and the foundations of positive psychology : The collected works of Mihaly Csikszentmihalyi*, p. 35-54, 2014.
- [26] I. MYIN-GERMEYS, M. OORSCHOT, D. COLLIP, J. LATASTER, P. DELESPAUL et J. VAN OS, « Experience sampling research in psychopathology : opening the black box of daily life », *Psychological medicine*, t. 39, 9, p. 1533-1547, 2009.
- [27] J. J. FERREIRA, A. T. SANTOS, J. DOMINGOS et al., « Clinical parameters and tools for home-based assessment of Parkinson's disease : results from a Delphi study », *Journal of Parkinson's disease*, t. 5, 2, p. 281-290, 2015.
- [28] J. A. SERRANO, F. LARSEN, T. ISAACS et al., « Participatory design in Parkinson's research with focus on the symptomatic domains to be measured », *Journal of Parkinson's disease*, t. 5, 1, p. 187-196, 2015.
- [29] *Likert scale - Wikipedia* — *en.wikipedia.org*, https://en.wikipedia.org/wiki/Likert_scale, [Accessed 17-Jun-2023].
- [30] M. D. HSSAYENI, J. L. ADAMS et B. GHORAANI, « Deep learning for medication assessment of individuals with Parkinson's disease using wearable sensors », in *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, 2018, p. 1-4.
- [31] D. A. GANZ, Y. BAO, P. G. SHEKELLE et L. Z. RUBENSTEIN, « Will my patient fall? », *Jama*, t. 297, 1, p. 77-86, 2007.

-
- [32] P. ALLARD, A. CAPPOZZO, A. LUNDBERG et C. VAUGHAN, *Three-dimensional analysis of human locomotion*. John Wiley & Sons, Inc., 1998.
- [33] B. BOUISSET et B. MATON, « Muscles et mouvement : base et applications de méthode électromyographique », *Paris, Hermann : VII, 735ill*, 1995.
- [34] J. PERRY, J. R. DAVIDS et al., « Gait analysis : normal and pathological function », *Journal of Pediatric Orthopaedics*, t. 12, 6, p. 815, 1992.
- [35] J. R. GAGE, « Gait analysis in cerebral palsy », *Clinics in developmental medicine*, t. 121, 1991.
- [36] C. L. VAUGHAN, B. L. DAVIS et J. C. O'CONNOR, « Dynamics of human gait », (*No Title*), 1992.
- [37] V. T. INMAN, H. J. RALSTON et F. TODD, *Human walking*. Williams & Wilkins, 1981.
- [38] D. H. SUTHERLAND, R. OLSHEN, L. COOPER et S. L. WOO, « The development of mature gait. », *Jbjs*, t. 62, 3, p. 336-353, 1980.
- [39] E. VIEL, G. ASENCIO, J. CASILLAS et al., « Activités des muscles pendant le cycle de marche », *La marche humaine, la course et le saut*, p. 25-46, 2000.
- [40] C. GILLET, J. DUBOY, F. BARBIER et al., « Contribution of accelerated body masses to able-bodied gait », *American journal of physical medicine & rehabilitation*, t. 82, 2, p. 101-109, 2003.
- [41] R. NEPTUNE, F. ZAJAC et S. KAUTZ, « Muscle force redistributes segmental power for body progression during walking », *Gait & posture*, t. 19, 2, p. 194-205, 2004.
- [42] J. PÉLISSIER, E. LAASEL et C. GUIBAL, « Analyse métrologique de la marche et pratique de rééducation », *Cahiers de kinésithérapie*, t. 208, 2, p. 7-10, 2001.
- [43] M. W. WHITTLE, « Clinical gait analysis : A review », *Human movement science*, t. 15, 3, p. 369-387, 1996.
- [44] D. A. WINTER, *Biomechanics and motor control of human gait : normal, elderly and pathological*. 1991.
- [45] D. H. SUTHERLAND, « The evolution of clinical gait analysis part I : kinesiological EMG », *Gait & posture*, t. 14, 1, p. 61-70, 2001.
- [46] R. DAVIS, « Gait Data Reporting, Archiving and Sharing », *Three Dimensional Analysis of Human Locomotion*, p. 173-189, 1997.

-
- [47] J. MILLIGAN, K. RYAN et J. LEE, « Démythifier la spasticité en première ligne », *Canadian Family Physician*, t. 65, 10, e422-e428, 2019.
- [48] J. R. GAGE et T. F. NOVACHECK, « An update on the treatment of gait problems in cerebral palsy », *Journal of Pediatric Orthopaedics B*, t. 10, 4, p. 265-274, 2001.
- [49] R. BAKER, J. L. MCGINLEY, M. H. SCHWARTZ et al., « The gait profile score and movement analysis profile », *Gait & posture*, t. 30, 3, p. 265-269, 2009.
- [50] G. J. BARTON, M. B. HAWKEN, M. A. SCOTT et M. H. SCHWARTZ, « Movement Deviation Profile : A measure of distance from normality using a self-organizing neural network », *Human movement science*, t. 31, 2, p. 284-294, 2012.
- [51] S. J. HOLMES, A. J. MUDGE, E. A. WOJCIECHOWSKI, M. W. AXT et J. BURNS, « Impact of multilevel joint contractures of the hips, knees and ankles on the Gait Profile score in children with cerebral palsy », *Clinical Biomechanics*, t. 59, p. 8-14, 2018.
- [52] S. BEYNON, J. MCGINLEY, F. DOBSON et R. BAKER, « Correlations of the Gait Profile Score (GPS) and the Movement Analysis Profile (MAP) relative to clinical judgments », *Gait & Posture*, 30, S58-S59, 2009.
- [53] J. CHRISTIAN, J. KRÖLL et H. SCHWAMEDER, « Comparison of the Classifier Oriented Gait Score and the Gait Profile Score based on imitated gait impairments », *Gait & Posture*, t. 55, p. 49-54, 2017.
- [54] L. ROBINSON, N. CLEMENT, M. FULLARTON et al., « The relationship between the edinburgh visual gait score, the gait profile score and gmfcs levels i-iii », *Gait & posture*, t. 41, 2, p. 741-743, 2015.
- [55] P. A. DELUCA, R. B. DAVIS, S. ÖUNPUU, S. ROSE et R. SIRKIN, « Alterations in surgical decision making in patients with cerebral palsy based on three-dimensional gait analysis », *Journal of Pediatric Orthopaedics*, t. 17, 5, p. 608-614, 1997.
- [56] G. PENNEÇOT, « Apport de l'analyse quantifiée de la marche à la prise de décision chirurgicale », *La marche humaine, la course et le saut. Biomécanique, explorations, normes et dysfonctionnements. Paris : Masson*, p. 193-212, 2000.
- [57] D. H. SUTHERLAND, K. R. KAUFMAN, M. P. WYATT, H. G. CHAMBERS et S. J. MUBARAK, « Double-blind study of botulinum A toxin injections into the gastrocnemius muscle in patients with cerebral palsy », *Gait & posture*, t. 10, 1, p. 1-9, 1999.

-
- [58] W. E. CARLSON, C. L. VAUGHAN, D. L. DAMIANO et M. F. ABEL, « Orthotic management of gait in spastic diplegia », *American journal of physical medicine & rehabilitation*, t. 76, 3, p. 219-225, 1997.
- [59] S. SPAULDING, L. LIVINGSTON et H. HARTSELL, « The influence of external orthotic support on the adaptive gait characteristics of individuals with chronically unstable ankles », *Gait & posture*, t. 17, 2, p. 152-158, 2003.
- [60] L. CHEN, C. W. ARMSTRONG et D. D. RAFTOPOULOS, « An investigation on the accuracy of three-dimensional space reconstruction using the direct linear transformation technique », *Journal of biomechanics*, t. 27, 4, p. 493-500, 1994.
- [61] U. DELLA CROCE, A. LEARDINI, L. CHIARI et A. CAPPOZZO, « Human movement analysis using stereophotogrammetry : Part 4 : assessment of anatomical landmark misplacement and its effects on joint kinematics », *Gait & posture*, t. 21, 2, p. 226-237, 2005.
- [62] R. D. KOMISTEK, D. A. DENNIS et M. MAHFOUZ, « In vivo fluoroscopic analysis of the normal human knee. », *Clinical Orthopaedics and Related Research (1976-2007)*, t. 410, p. 69-81, 2003.
- [63] G. GORTON, D. HEBERT et B. GOODE, « Assessment of the kinematic variability between 12 Shriners motion analysis laboratories », in *6th Annual Meeting of the Gait and Clinical Movement Analysis Society, Sacramento, California, Gait and Posture*, 2001.
- [64] K. J. NOONAN, S. HALLIDAY, R. BROWNE, S. O'BRIEN, K. KAYES et J. FEINBERG, « Interobserver variability of gait analysis in patients with cerebral palsy », *Journal of Pediatric Orthopaedics*, t. 23, 3, p. 279-287, 2003.
- [65] J. L. MCGINLEY, R. BAKER, R. WOLFE et M. E. MORRIS, « The reliability of three-dimensional kinematic gait measurements : a systematic review », *Gait & posture*, t. 29, 3, p. 360-369, 2009.
- [66] G. STEINWENDER, V. SARAPH, S. SCHEIBER, E. B. ZWICK, C. UITZ et K. HACKL, « Intrasubject repeatability of gait analysis data in normal and spastic children », *Clinical biomechanics*, t. 15, 2, p. 134-139, 2000.
- [67] H. STOLZE, J. KUHTZ-BUSCHBECK, C. MONDWURF, K. JÖHNK et L. FRIEGE, « Retest reliability of spatiotemporal gait parameters in children and adults », *Gait & posture*, t. 7, 2, p. 125-130, 1998.

-
- [68] J. HAUSDORFF, L. ZEMANY, C.-K. PENG et A. GOLDBERGER, « Maturation of gait dynamics : stride-to-stride variability and its temporal organization in children », *Journal of applied physiology*, t. 86, 3, p. 1040-1047, 1999.
- [69] A. GABELL et U. NAYAK, « The effect of age on variability in gait », *Journal of gerontology*, t. 39, 6, p. 662-666, 1984.
- [70] M. KADABA, H. RAMAKRISHNAN, M. WOOTTEN, J. GAINEY, G. GORTON et G. COCHRAN, « Repeatability of kinematic, kinetic, and electromyographic data in normal adult gait », *Journal of orthopaedic research*, t. 7, 6, p. 849-860, 1989.
- [71] R. WHITE, I. AGOURIS, R. SELBIE et M. KIRKPATRICK, « The variability of force platform data in normal and cerebral palsy gait », *Clinical biomechanics*, t. 14, 3, p. 185-192, 1999.
- [72] E. WATELAIN, « PROPOSITION D'UNE METHODOLOGIE D'ANALYSE DU MOUVEMENT :-APPLICATION A LA MARCHE DU SUJET HEMIPLEGIQUE- », thèse de doct., Université de Valenciennes et du Hainaut-Cambresis, 1999.
- [73] R. B. DAVIS, « Reflections on clinical gait analysis », *Journal of Electromyography and Kinesiology*, t. 7, 4, p. 251-257, 1997.
- [74] M. H. SCHWARTZ, J. P. TROST et R. A. WERVEY, « Measurement and management of errors in quantitative gait data », *Gait & posture*, t. 20, 2, p. 196-203, 2004.
- [75] D. L. SKAGGS, S. A. RETHLEFSEN, R. M. KAY, S. W. DENNIS, R. A. REYNOLDS et V. T. TOLO, « Variability in gait analysis interpretation », *Journal of Pediatric Orthopaedics*, t. 20, 6, p. 759-764, 2000.
- [76] J. KUFEL, K. BARGIEL-ŁĄCZEK, S. KOCOT et al., « What Is Machine Learning, Artificial Neural Networks and Deep Learning?—Examples of Practical Applications in Medicine », *Diagnostics*, t. 13, 15, p. 2582, 2023.
- [77] W. S. MCCULLOCH et W. PITTS, « A logical calculus of the ideas immanent in nervous activity », *The bulletin of mathematical biophysics*, t. 5, p. 115-133, 1943.
- [78] D. O. HEBB, « Organization of behavior. new york : Wiley », *J. Clin. Psychol*, t. 6, 3, p. 335-307, 1949.
- [79] G. PRESS, « A very short history of big data », *Forbes Tech Magazine*, May, t. 9, 2013.

-
- [80] R. KHALDI, A. EL AFIA, R. CHIHEB et S. TABIK, « What is the best RNN-cell structure to forecast each time series behavior ? », *Expert Systems with Applications*, t. 215, p. 119-140, 2023.
- [81] C. YANG, W. JIANG et Z. GUO, « Time series data classification based on dual path CNN-RNN cascade network », *IEEE Access*, t. 7, p. 155 304-155 312, 2019.
- [82] K. MANIMALA, E. F. I. RAJ et S. JAGATHESWARI, « Advancements in Deep Learning Techniques for Analyzing Electronic Medical Records », in *Deep Learning for Healthcare Decision Making*, River Publishers, 2023, p. 133-158.
- [83] R. K. TRIPATHY, M. A. PATERNINA et J. A. de la O SERNA, « Machine Learning and Deep Learning for Physiological Signal Analysis », *Frontiers in Physiology*, t. 13, p. 611, 2022.
- [84] F. ROSENBLATT, *The perceptron, a perceiving and recognizing automaton Project Para*. Cornell Aeronautical Laboratory, 1957.
- [85] F. ROSENBLATT, « The perceptron : a probabilistic model for information storage and organization in the brain. », *Psychological review*, t. 65, 6, p. 386, 1958.
- [86] *Perceptron multicouche — Wikipédia — fr.wikipedia.org*, https://fr.wikipedia.org/wiki/Perceptron_multicouche, [Accessed 06-09-2023].
- [87] S. GROSSBERG, « Adaptive Resonance Theory : How a brain learns to consciously attend, learn, and recognize a changing world », *Neural networks*, t. 37, p. 1-47, 2013.
- [88] J. L. ELMAN, « Finding structure in time », *Cognitive science*, t. 14, 2, p. 179-211, 1990.
- [89] D. E. RUMELHART, G. E. HINTON et R. J. WILLIAMS, « Learning internal representations by error propagation », California Univ San Diego La Jolla Inst for Cognitive Science, rapp. tech., 1985.
- [90] M. BOUAZIZ, « Réseaux de neurones récurrents pour la classification de séquences dans des flux audiovisuels parallèles », thèse de doct., Université d'Avignon, 2017.
- [91] S. HOCHREITER, Y. BENGIO, P. FRASCONI, J. SCHMIDHUBER et al., *Gradient flow in recurrent nets : the difficulty of learning long-term dependencies*, 2001.

-
- [92] H. SAK, A. SENIOR et F. BEAUFAYS, « Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition », *arXiv preprint arXiv :1402.1128*, 2014.
- [93] K. YAO, B. PENG, Y. ZHANG, D. YU, G. ZWEIG et Y. SHI, « Spoken language understanding using long short-term memory neural networks », in *2014 IEEE Spoken Language Technology Workshop (SLT)*, IEEE, 2014, p. 189-194.
- [94] J. CHENG, L. DONG et M. LAPATA, « Long short-term memory-networks for machine reading », *arXiv preprint arXiv :1601.06733*, 2016.
- [95] T. FISCHER et C. KRAUSS, « Deep learning with long short-term memory networks for financial market predictions », *European journal of operational research*, t. 270, 2, p. 654-669, 2018.
- [96] X. MA, Z. TAO, Y. WANG, H. YU et Y. WANG, « Long short-term memory neural network for traffic speed prediction using remote microwave sensor data », *Transportation Research Part C : Emerging Technologies*, t. 54, p. 187-197, 2015.
- [97] D. LI et J. QIAN, « Text sentiment analysis based on long short-term memory », in *2016 First IEEE International Conference on Computer Communication and the Internet (ICCCI)*, IEEE, 2016, p. 471-475.
- [98] E. J. HERAVI, H. H. AGHDAM et D. PUIG, « Classification of Foods Using Spatial Pyramid Convolutional Neural Network. », in *CCIA*, 2016, p. 163-168.
- [99] Y. BENGIO, Y. LECUN et al., « Scaling learning algorithms towards AI », *Large-scale kernel machines*, t. 34, 5, p. 1-41, 2007.
- [100] Y. LECUN, L. BOTTOU, Y. BENGIO et P. HAFFNER, « Gradient-based learning applied to document recognition », *Proceedings of the IEEE*, t. 86, 11, p. 2278-2324, 1998.
- [101] R. GIRSHICK, J. DONAHUE, T. DARRELL et J. MALIK, « Rich feature hierarchies for accurate object detection and semantic segmentation », in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2014, p. 580-587.
- [102] M. G. RAGAB, S. J. ABDULKADIR, N. AZIZ et al., « A Novel One-Dimensional CNN with Exponential Adaptive Gradients for Air Pollution Index Prediction », *Sustainability*, t. 12, 23, 2020, ISSN : 2071-1050. DOI : 10 . 3390 / su122310090. adresse : <https://www.mdpi.com/2071-1050/12/23/10090>.

-
- [103] Q. WEN, L. SUN, F. YANG et al., « Time series data augmentation for deep learning : A survey », *arXiv preprint arXiv :2002.12478*, 2020.
- [104] G. IGLESIAS, E. TALAVERA, Á. GONZÁLEZ-PRIETO, A. MOZO et S. GÓMEZ-CANAVAL, « Data Augmentation techniques in time series domain : a survey and taxonomy », *Neural Computing and Applications*, t. 35, 14, p. 10 123-10 145, 2023.
- [105] S. J. PAN et Q. YANG, « A survey on transfer learning », *IEEE Transactions on knowledge and data engineering*, t. 22, 10, p. 1345-1359, 2009.
- [106] S. HU, K. ZHANG, Z. CHEN et L. CHAN, « Domain generalization via multidomain discriminant analysis », in *Uncertainty in Artificial Intelligence*, PMLR, 2020, p. 292-302.
- [107] M. LÄNGKVIST, L. KARLSSON et A. LOUTFI, « A review of unsupervised feature learning and deep learning for time-series modeling », *Pattern recognition letters*, t. 42, p. 11-24, 2014.
- [108] P. BALDI, « Autoencoders, unsupervised learning, and deep architectures », in *Proceedings of ICML workshop on unsupervised and transfer learning*, JMLR Workshop et Conference Proceedings, 2012, p. 37-49.
- [109] G. E. HINTON et R. R. SALAKHUTDINOV, « Reducing the dimensionality of data with neural networks », *science*, t. 313, 5786, p. 504-507, 2006.
- [110] I. GOODFELLOW, J. POUGET-ABADIE, M. MIRZA et al., « Generative adversarial nets », *Advances in neural information processing systems*, t. 27, 2014.
- [111] J. F. BURNHAM, « Scopus database : a review », *Biomedical digital libraries*, t. 3, 1, p. 1-8, 2006.
- [112] V. SINGHAL, J. MATHEW, R. K. BEHERA et al., « Detection of alcoholism using EEG signals and a CNN-LSTM-ATTN network », *Computers in biology and medicine*, t. 138, p. 104 940, 2021.
- [113] X. TANG, J. PENG, B. ZHONG, J. LI et Z. YAN, « Introducing frequency representation into convolution neural networks for medical image segmentation via twin-Kernel Fourier convolution », *Computer Methods and Programs in Biomedicine*, t. 205, p. 106 110, 2021.
- [114] S. FAWAZ, K. S. SIM et S. C. TAN, « Encoding rich frequencies for classification of stroke patients EEG signals », *IEEE Access*, t. 8, p. 135 811-135 820, 2020.

-
- [115] P. D. TINH, H. H. BUI et D. C. NGUYEN, « Image-based gramian angular field processing for pedestrian stride-length estimation using convolutional neural network », *IAES International Journal of Artificial Intelligence*, t. 10, 4, p. 997, 2021.
- [116] H. ZHOU et C. KAN, « Tensor-based ECG anomaly detection toward cardiac monitoring in the internet of health things », *Sensors*, t. 21, 12, p. 4173, 2021.
- [117] G. ZHANG, Y. SI, D. WANG, W. YANG et Y. SUN, « Automated detection of myocardial infarction using a gramian angular field and principal component analysis network », *IEEE Access*, t. 7, p. 171 570-171 583, 2019.
- [118] C. OUYANG, Z. GAN, J. ZHEN, Y. GUAN, X. ZHU et P. ZHOU, « Inter-patient classification with encoded peripheral pulse series and multi-task fusion cnn : application in type 2 diabetes », *IEEE Journal of Biomedical and Health Informatics*, t. 25, 8, p. 3130-3140, 2021.
- [119] Z. AHMAD, A. TABASSUM, L. GUAN et N. M. KHAN, « ECG heartbeat classification using multimodal fusion », *IEEE Access*, t. 9, p. 100 615-100 626, 2021.
- [120] M. N. MEQDAD, A. H. HUSSEIN, S. O. HUSAIN, A. M. JAWAD et S. KADRY, « Human activity recognition method using joint deep learning and acceleration signal », *Int J Artif Intell*, t. 12, 3, p. 1459-1467, 2023.
- [121] J. PARK, M. G. ARTIN, K. E. LEE et al., « Deep learning on time series laboratory test results from electronic health records for early detection of pancreatic cancer », *Journal of biomedical informatics*, t. 131, p. 104 095, 2022.
- [122] H. ISMAIL FAWAZ, G. FORESTIER, J. WEBER, L. IDOUMGHAR et P.-A. MULLER, « Deep learning for time series classification : a review », *Data mining and knowledge discovery*, t. 33, 4, p. 917-963, 2019.
- [123] D. F. SILVA, R. GIUSTI, E. KEOGH et G. E. BATISTA, « Speeding up similarity search under dynamic time warping by pruning unpromising alignments », *Data Mining and Knowledge Discovery*, t. 32, p. 988-1016, 2018.
- [124] A. BAGNALL, J. LINES, A. BOSTROM, J. LARGE et E. KEOGH, « The great time series classification bake off : a review and experimental evaluation of recent algorithmic advances », *Data mining and knowledge discovery*, t. 31, p. 606-660, 2017.
- [125] H. A. DAU, E. KEOGH, K. KAMGAR et al., *The UCR Time Series Classification Archive*, https://www.cs.ucr.edu/~eamonn/time_series_data_2018/, oct. 2018.

-
- [126] S. WANG, G. HUA, G. HAO et C. XIE, « A cycle deep belief network model for multivariate time series classification », *Mathematical Problems in Engineering*, t. 2017, 2017.
- [127] Z. WANG, W. YAN et T. OATES, « Time series classification from scratch with deep neural networks : A strong baseline », in *2017 International joint conference on neural networks (IJCNN)*, IEEE, 2017, p. 1578-1585.
- [128] *Time Series Classification Website — timeseriesclassification.com*, <http://www.timeseriesclassification.com/description.php?Dataset=Adiac>, [Accessed 09-10-2023].
- [129] O. FAUST, Y. HAGIWARA, T. J. HONG, O. S. LIH et U. R. ACHARYA, « Deep learning for healthcare applications based on physiological signals : A review », *Computer methods and programs in biomedicine*, t. 161, p. 1-13, 2018.
- [130] M. UEMURA, M. TOMIKAWA, T. MIAO et al., « Feasibility of an AI-based measure of the hand motions of expert and novice surgeons », *Computational and mathematical methods in medicine*, t. 2018, 2018.
- [131] H. ISMAIL FAWAZ, G. FORESTIER, J. WEBER, L. IDOUMGHAR et P.-A. MULLER, « Evaluating surgical skills from kinematic data using convolutional neural networks », in *Medical Image Computing and Computer Assisted Intervention—MICCAI 2018 : 21st International Conference, Granada, Spain, September 16-20, 2018, Proceedings, Part IV 11*, Springer, 2018, p. 214-221.
- [132] Y. GAO, S. S. VEDULA, C. E. REILEY et al., « Jhu-isi gesture and skill assessment working set (jigsaws) : A surgical activity dataset for human motion modeling », in *MICCAI workshop : M2cai*, t. 3, 2014.
- [133] J. WANG, Z. WANG, J. LI et J. WU, « Multilevel wavelet decomposition network for interpretable time series analysis », in *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2018, p. 2437-2446.
- [134] U. R. ACHARYA, H. FUJITA, O. S. LIH, Y. HAGIWARA, J. H. TAN et M. ADAM, « Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network », *Information sciences*, t. 405, p. 81-90, 2017.

-
- [135] K. LUO, J. LI, Z. WANG, A. CUSCHIERI et al., « Patient-specific deep architectural model for ECG classification », *Journal of healthcare engineering*, t. 2017, 2017.
- [136] R. BAREA, L. BOQUETE, M. MAZO et E. LÓPEZ, « System for assisted mobility using eye movements based on electrooculography », *IEEE transactions on neural systems and rehabilitation engineering*, t. 10, 4, p. 209-218, 2002.
- [137] G. SHARMA, A. PARASHAR et A. M. JOSHI, « DepHNN : a novel hybrid neural network for electroencephalogram (EEG)-based screening of depression », *Biomedical signal processing and control*, t. 66, p. 102-113, 2021.
- [138] A. RAMACHANDRAN et A. KARUPPIAH, « A survey on recent advances in machine learning based sleep apnea detection systems », in *Healthcare*, MDPI, t. 9, 2021, p. 914.
- [139] Z. CHE, Y. CHENG, S. ZHAI, Z. SUN et Y. LIU, « Boosting deep learning risk prediction with generative adversarial networks for electronic health records », in *2017 IEEE International Conference on Data Mining (ICDM)*, IEEE, 2017, p. 787-792.
- [140] P. W. MIROWSKI, Y. LECUN, D. MADHAVAN et R. KUZNIECKY, « Comparing SVM and convolutional networks for epileptic seizure prediction from intracranial EEG », in *2008 IEEE workshop on machine learning for signal processing*, IEEE, 2008, p. 244-249.
- [141] S. SANKARANARAYANAN, J. BALAN, J. R. WALSH et al., « Covid-19 mortality prediction from deep learning in a large multistate electronic health record and laboratory information system data set : Algorithm development and validation », *Journal of medical Internet research*, t. 23, 9, e30157, 2021.
- [142] A. PETROSIAN, D. PROKHOROV, R. HOMAN, R. DASHEIFF et D. WUNSCH II, « Recurrent neural network based prediction of epileptic seizures in intra-and extracranial EEG », *Neurocomputing*, t. 30, 1-4, p. 201-218, 2000.
- [143] A. PETROSIAN, D. PROKHOROV, W. LAJARA-NANSON et R. SCHIFFER, « Recurrent neural network-based approach for early recognition of Alzheimer's disease in EEG », *Clinical Neurophysiology*, t. 112, 8, p. 1378-1387, 2001.
- [144] E. SÜKEI, S. de LEON-MARTINEZ, P. M. OLMOS et A. ARTÉS, « Automatic patient functionality assessment from multimodal data using deep learning techniques—Development and feasibility evaluation », *Internet Interventions*, p. 100657, 2023.

-
- [145] N. C. JACOBSON et S. BHATTACHARYA, « Digital biomarkers of anxiety disorder symptom changes : Personalized deep learning models using smartphone sensors accurately predict anxiety symptoms from ecological momentary assessments », *Behaviour Research and Therapy*, t. 149, p. 104013, 2022.
- [146] G. KOPPE, S. GULOXSUZ, U. REININGHAUS et D. DURSTEWITZ, « Recurrent neural networks in mobile sampling and intervention », *Schizophrenia bulletin*, t. 45, 2, p. 272-276, 2019.
- [147] M. D. HSSAYENI, J. JIMENEZ-SHAHED, M. A. BURACK et B. GHORAANI, « Ensemble deep model for continuous estimation of Unified Parkinson's Disease Rating Scale III », *Biomedical engineering online*, t. 20, p. 1-20, 2021.
- [148] S. K. SIEBERTS, J. SCHAFF, M. DUDA et al., « Crowdsourcing digital health measures to predict Parkinson's disease severity : the Parkinson's Disease Digital Biomarker DREAM Challenge », *NPJ digital medicine*, t. 4, 1, p. 53, 2021.
- [149] F. HEIDARIVINCHEH, R. MCCONVILLE, C. MORGAN et al., « Multimodal classification of parkinson's disease in home environments with resiliency to missing modalities », *Sensors*, t. 21, 12, p. 4133, 2021.
- [150] X. TENG, S. PEI et Y.-R. LIN, « Stocast : Stochastic disease forecasting with progression uncertainty », *IEEE Journal of Biomedical and Health Informatics*, t. 25, 3, p. 850-861, 2020.
- [151] M. SHABAN, S. CAHOON, F. KHAN et M. POLK, « Exploiting the Differential Wavelet Domain of Resting-State EEG Using a Deep-CNN for Screening Parkinson's Disease », in *2021 IEEE Symposium Series on Computational Intelligence (SSCI)*, IEEE, 2021, p. 1-5.
- [152] N. VYAS, K. RYOO, H. TESFAYE, R. YI et M. SKUBIC, « Sleep Stage Classification Using Non-Invasive Bed Sensing and Deep Learning », in *2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, IEEE, 2021, p. 3232-3238.
- [153] A. S. AV, M. A. LONES, S. L. SMITH et M. VALLEJO, « Evaluation of Recurrent Neural Network Models for Parkinson's Disease Classification Using Drawing Data », in *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, IEEE, 2021, p. 1702-1706.

-
- [154] C. QUAN, K. REN et Z. LUO, « A deep learning based method for Parkinson's disease detection using dynamic features of speech », *IEEE Access*, t. 9, p. 10 239-10 252, 2021.
- [155] R. SAN-SEGUNDO, A. ZHANG, A. CEBULLA et al., « Parkinson's disease tremor detection in the wild using wearable accelerometers », *Sensors*, t. 20, 20, p. 5817, 2020.
- [156] C. TALEB, L. LIKFORMAN-SULEM, C. MOKBEL et M. KHACHAB, « Detection of Parkinson's disease from handwriting using deep learning : a comparative study », *Evolutionary Intelligence*, p. 1-12, 2020.
- [157] M. D. HSSAYENI, J. JIMENEZ-SHAHED, M. A. BURACK et B. GHORAANI, « Wearable sensors for estimation of parkinsonian tremor severity during free body movements », *Sensors*, t. 19, 19, p. 4215, 2019.
- [158] N. H. ISMAIL, M. DU, D. MARTINEZ et Z. HE, « Multivariate multi-step deep learning time series approach in forecasting Parkinson's disease future severity progression », in *Proceedings of the 10th acm international conference on bioinformatics, computational biology and health informatics*, 2019, p. 383-389.
- [159] S. ZHANG, S. K. POON, K. VUONG, A. SNEDDON et C. T. LOY, « A deep learning-based approach for gait analysis in Huntington disease », in *MEDINFO 2019 : Health and Wellbeing e-Networks for All*, IOS Press, 2019, p. 477-481.
- [160] T. ZHU, Y. LIN et Y. LIU, « Synthetic minority oversampling technique for multi-class imbalance problems », *Pattern Recognition*, t. 72, p. 327-340, 2017.
- [161] C. TUNCA, G. SALUR et C. ERSOY, « Deep learning for fall risk assessment with inertial sensors : Utilizing domain knowledge in spatio-temporal gait parameters », *IEEE journal of biomedical and health informatics*, t. 24, 7, p. 1994-2005, 2019.
- [162] I. KIPRIJANOVSKA, H. GJORESKI et M. GAMS, « Detection of gait abnormalities for fall risk assessment using wrist-worn inertial sensors and deep learning », *Sensors*, t. 20, 18, p. 5373, 2020.
- [163] E. G. GONZÁLEZ, J. R. VILLAR et E. de la CAL, « Time series data augmentation and dropout roles in deep learning applied to fall detection », in *15th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2020) 15*, Springer, 2021, p. 563-570.

-
- [164] G. PARAGLIOLA et A. CORONATO, « A deep learning-based approach for the classification of gait dynamics in subjects with a neurodegenerative disease », in *Intelligent Systems and Applications : Proceedings of the 2020 Intelligent Systems Conference (IntelliSys) Volume 3*, Springer, 2021, p. 452-468.
- [165] X. LIU, C. ZHAO, B. ZHENG et al., « Synthesizing foot and ankle kinematic characteristics for lateral collateral ligament injuries detection », *IEEE Access*, t. 8, p. 188 429-188 440, 2020.
- [166] M. MIRZA et S. OSINDERO, « Conditional generative adversarial nets », *arXiv preprint arXiv :1411.1784*, 2014.
- [167] J. LUO et T. TJAHJADI, « Multi-set canonical correlation analysis for 3d abnormal gait behaviour recognition based on virtual sample generation », *IEEE Access*, t. 8, p. 32 485-32 501, 2020.
- [168] Z. SONG, S. WANG, J. YANG et D. BAI, « A novel approach to abnormal gait recognition based on generative adversarial networks », in *Robotics and Rehabilitation Intelligence : First International Conference, ICRRRI 2020, Fushun, China, September 9–11, 2020, Proceedings, Part I 1*, Springer, 2020, p. 3-15.
- [169] V. G. TORVI, A. BHATTACHARYA et S. CHAKRABORTY, « Deep domain adaptation to predict freezing of gait in patients with Parkinson’s disease », in *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, IEEE, 2018, p. 1001-1006.
- [170] A. H. NGU, V. METSIS, S. COYNE, B. CHUNG, R. PAI et J. CHANG, « Personalized fall detection system », in *2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, IEEE, 2020, p. 1-7.
- [171] I. KANG, P. KUNAPULI et A. J. YOUNG, « Real-time neural network-based gait phase estimation using a robotic hip exoskeleton », *IEEE Transactions on Medical Robotics and Bionics*, t. 2, 1, p. 28-37, 2019.
- [172] X. GU, Y. GUO, F. DELIGIANNI, B. LO et G.-Z. YANG, « Cross-subject and cross-modal transfer for generalized abnormal gait pattern recognition », *IEEE Transactions on Neural Networks and Learning Systems*, t. 32, 2, p. 546-560, 2020.

-
- [173] A. NAIT AICHA, G. ENGLEBIENNE, K. S. VAN SCHOOTEN, M. PIJNAPPELS et B. KRÖSE, « Deep learning to predict falls in older adults based on daily-life trunk accelerometry », *Sensors*, t. 18, 5, p. 1654, 2018.
- [174] S. YU, H. CHEN, R. BROWN et S. SHERMAN, « Motion sensor-based assessment on fall risk and Parkinson’s disease severity : A deep multi-source multi-task learning (DMML) Approach », in *2018 IEEE International Conference on Healthcare Informatics (ICHI)*, IEEE, 2018, p. 174-179.
- [175] T. T. VERLEKAR, P. L. CORREIA et L. D. SOARES, « Using transfer learning for classification of gait pathologies », in *2018 IEEE international conference on bioinformatics and biomedicine (BIBM)*, IEEE, 2018, p. 2376-2381.
- [176] T. PANDIT, H. NAHANE, D. LADE et V. RAO, « Abnormal gait detection by classifying inertial sensor data using transfer learning », in *2019 18th IEEE International Conference on Machine Learning and Applications (ICMLA)*, IEEE, 2019, p. 1444-1447.
- [177] M. MARTINEZ et P. L. DE LEON, « Falls risk classification of older adults using deep neural networks and transfer learning », *IEEE journal of biomedical and health informatics*, t. 24, 1, p. 144-150, 2019.
- [178] Y. ZHANG, S. LI, Y. ZHOU et J. LIU, « Lower limb motor function assessment based on tensorflow convolutional neural network and kernel entropy component analysis–local tangent space alignment », *Advances in Mechanical Engineering*, t. 12, 7, p. 1 687 814 020 942 650, 2020.
- [179] J. DENG, W. DONG, R. SOCHER, L.-J. LI, K. LI et L. FEI-FEI, « Imagenet : A large-scale hierarchical image database », in *2009 IEEE conference on computer vision and pattern recognition*, Ieee, 2009, p. 248-255.
- [180] I. MAACHI, G.-A. BILODEAU et W. BOUACHIR, « Deep 1D-Convnet for accurate Parkinson disease detection and severity prediction from gait », *Expert Systems with Applications*, t. 143, p. 113 075, nov. 2019. DOI : 10 . 1016 / j . eswa . 2019 . 113075.
- [181] M. R. PATTERSON, W. JOHNSTON, N. O’MAHONY, S. O’MAHONY, E. NOLAN et B. CAULFIELD, « Validation of temporal gait metrics from three IMU locations to the gold standard force plate », in *2016 38th Annual International Conference*

-
- of the *IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, 2016, p. 667-671.
- [182] M. GHOLAMI, C. NAPIER et C. MENON, « Estimating lower extremity running gait kinematics with a single accelerometer : A deep learning approach », *Sensors*, t. 20, 10, p. 2939, 2020.
- [183] A. GIRKA, J.-P. KULMALA et S. ÄYRÄMÖ, « Deep learning approach for prediction of impact peak appearance at ground reaction force signal of running activity », *Computer Methods in Biomechanics and Biomedical Engineering*, t. 23, 14, p. 1052-1059, 2020.
- [184] A. FERRARI, L. BERGAMINI, G. GUERZONI et al., « Gait-Based Diplegia Classification Using LSMT Networks », *Journal of Healthcare Engineering*, t. 2019, p. 1-8, jan. 2019. DOI : 10.1155/2019/3796898.
- [185] Ł. KIDZIŃSKI, S. DELP et M. SCHWARTZ, « Automatic real-time gait event detection in children using deep neural networks », *PLOS ONE*, t. 14, e0211466, jan. 2019. DOI : 10.1371/journal.pone.0211466.
- [186] D.-W. LEE, K. JUN, S. LEE, J.-K. KO et M. S. KIM, « Abnormal gait recognition using 3D joint information of multiple Kinects system and RNN-LSTM », in *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, 2019, p. 542-545.
- [187] K. JUN, Y. LEE, S. LEE, D.-W. LEE et M. S. KIM, « Pathological gait classification using kinect v2 and gated recurrent neural networks », *IEEE Access*, t. 8, p. 139 881-139 891, 2020.
- [188] C. G. PACHÓN-SUESCÚN, J. O. PINZÓN-ARENAS et R. JIMÉNEZ-MORENO, « Abnormal gait detection by means of LSTM. », *International Journal of Electrical & Computer Engineering (2088-8708)*, t. 10, 2, 2020.
- [189] A. TURNER et S. HAYES, « The classification of minor gait alterations using wearable sensors and deep learning », *IEEE Transactions on Biomedical Engineering*, t. 66, 11, p. 3136-3145, 2019.
- [190] A. H. BUTT, F. CAVALLO, C. MAREMMANI et E. ROVINI, « Biomechanical parameters assessment for the classification of Parkinson disease using bidirectional long short-term memory », in *2020 42nd Annual International Conference of the*

-
- IEEE Engineering in Medicine & Biology Society (EMBC)*, IEEE, 2020, p. 5761-5764.
- [191] Y. GUO, R. GRAVINA, X. GU, G. FORTINO et G.-Z. YANG, « EMG-based abnormal gait detection and recognition », in *2020 IEEE International Conference on Human-Machine Systems (ICHMS)*, IEEE, 2020, p. 1-6.
- [192] M. LEMPEREUR, F. ROUSSEAU, O. RÉMY-NÉRIS et al., « A new deep learning-based method for the detection of gait events in children with gait disorders : Proof-of-concept and concurrent validity », *Journal of biomechanics*, t. 98, p. 109490, 2020.
- [193] M. ZENG, H. GAO, T. YU et al., « Understanding and improving recurrent networks for human activity recognition by continuous attention », in *Proceedings of the 2018 ACM international symposium on wearable computers*, 2018, p. 56-63.
- [194] D. AHMEDT-ARISTIZABAL, M. A. ARMIN, S. DENMAN, C. FOOKES et L. PETERSSON, « Attention networks for multi-task signal analysis », in *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, IEEE, 2020, p. 184-187.
- [195] Y. XIA, Z. YAO, Q. YE et N. CHENG, « A dual-modal attention-enhanced deep learning network for quantification of Parkinson's disease characteristics », *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, t. 28, 1, p. 42-51, 2019.
- [196] C. FLAGG, O. FRIEDER, S. MACAVANEY et G. MOTAMEDI, « Streaming Gait Assessment for Parkinson's Disease. », in *HSDM@ WSDM*, 2020, p. 34-42.
- [197] J. CONTE ALCARAZ, S. MOGHADDAMNIA et J. PEISSIG, « Efficiency of deep neural networks for joint angle modeling in digital gait assessment », *EURASIP Journal on Advances in Signal Processing*, t. 2021, 1, p. 1-20, 2021.
- [198] V. GUIMARÃES, I. SOUSA et M. V. CORREIA, « A deep learning approach for foot trajectory estimation in gait analysis using inertial sensors », *Sensors*, t. 21, 22, p. 7517, 2021.
- [199] X. YU, H. QIU et S. XIONG, « A novel hybrid deep neural network to predict pre-impact fall for older people based on wearable inertial sensors », *Frontiers in bioengineering and biotechnology*, t. 8, p. 63, 2020.

-
- [200] D. KREUZER et M. MUNZ, « Deep convolutional and LSTM networks on multi-channel time series data for gait phase recognition », *Sensors*, t. 21, 3, p. 789, 2021.
- [201] N. MOHAMMADIAN RAD, T. VAN LAARHOVEN, C. FURLANELLO et E. MARCHIORI, « Novelty detection using deep normative modeling for imu-based abnormal movement monitoring in parkinson's disease and autism spectrum disorders », *Sensors*, t. 18, 10, p. 3533, 2018.
- [202] A. ELKHOLY, Y. MAKIHARA, W. GOMAA, M. A. R. AHAD et Y. YAGI, « Unsupervised GEI-based gait disorders detection from different views », in *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, 2019, p. 5423-5426.
- [203] E. MARCHI, F. VESPERINI, F. EYBEN, S. SQUARTINI et B. SCHULLER, « A novel approach for automatic acoustic novelty detection using a denoising autoencoder with bidirectional LSTM neural networks », in *2015 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, IEEE, 2015, p. 1996-2000.
- [204] F. ZHAO, J. FENG, J. ZHAO, W. YANG et S. YAN, « Robust LSTM-autoencoders for face de-occlusion in the wild », *IEEE Transactions on Image Processing*, t. 27, 2, p. 778-790, 2017.
- [205] J. TU, H. LIU, F. MENG, M. LIU et R. DING, « Spatial-temporal data augmentation based on LSTM autoencoder network for skeleton-based human action recognition », in *2018 25th IEEE International Conference on Image Processing (ICIP)*, IEEE, 2018, p. 3478-3482.
- [206] K. JUN, D.-W. LEE, K. LEE, S. LEE et M. S. KIM, « Feature extraction using an RNN autoencoder for skeleton-based abnormal gait recognition », *IEEE Access*, t. 8, p. 19 196-19 207, 2020.
- [207] T. ZHEN, L. YAN et J.-l. KONG, « An acceleration based fusion of multiple spatiotemporal networks for gait phase detection », *International journal of environmental research and public health*, t. 17, 16, p. 5633, 2020.
- [208] J. F. REYES, J. S. MONTEALEGRE, Y. J. CASTANO, C. URCUQUI et A. NAVARRO, « LSTM and Convolution Networks exploration for Parkinson's Diagnosis », in *2019 IEEE Colombian Conference on Communications and Computing (COLCOM)*, IEEE, 2019, p. 1-4.

-
- [209] A. ZHAO, L. QI, J. LI, J. DONG et H. YU, « A hybrid spatio-temporal model for detection and severity rating of Parkinson’s disease from gait data », *Neurocomputing*, t. 315, p. 1-8, 2018.
- [210] M. SARSHAR, S. POLTURI et L. SCHEGA, « Gait phase estimation by using LSTM in IMU-based gait analysis—Proof of concept », *Sensors*, t. 21, 17, p. 5749, 2021.
- [211] O. RONNEBERGER, P. FISCHER et T. BROX, « U-net : Convolutional networks for biomedical image segmentation », in *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015 : 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18*, Springer, 2015, p. 234-241.
- [212] L. R. PERAZA, K. M. KINNUNEN, R. MCNANEY et al., « An automatic gait analysis pipeline for wearable sensors : A pilot study in Parkinson’s disease », *Sensors*, t. 21, 24, p. 8286, 2021.
- [213] L. S. VARGAS-VALENCIA, A. ELIAS, E. ROCON, T. BASTOS-FILHO et A. FRIZERA, « An IMU-to-body alignment method applied to human gait analysis », *Sensors*, t. 16, 12, p. 2090, 2016.
- [214] *tf.keras.layers.Flatten* / *TensorFlow v2.12.0* — *tensorflow.org*, https://www.tensorflow.org/api_docs/python/tf/keras/layers/Flatten, [Accessed 18-Jun-2023].
- [215] K. TEAM, *Keras documentation : KerasTuner* — *keras.io*, https://keras.io/keras_tuner/, [Accessed 08-09-2023].
- [216] B. K. IWANA et S. UCHIDA, « An empirical survey of data augmentation for time series classification with neural networks », *Plos one*, t. 16, 7, e0254841, 2021.
- [217] C. M. BISHOP, « Training with noise is equivalent to Tikhonov regularization », *Neural computation*, t. 7, 1, p. 108-116, 1995.
- [218] G. AN, « The effects of adding noise during backpropagation training on a generalization performance », *Neural computation*, t. 8, 3, p. 643-674, 1996.
- [219] K. M. RASHID et J. LOUIS, « Window-warping : a time series data augmentation of IMU data for construction equipment activity identification », in *ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction*, IAARC Publications, t. 36, 2019, p. 651-657.

-
- [220] N. V. CHAWLA, K. W. BOWYER, L. O. HALL et W. P. KEGELMEYER, « SMOTE : synthetic minority over-sampling technique », *Journal of artificial intelligence research*, t. 16, p. 321-357, 2002.
- [221] T. T. UM, F. M. PFISTER, D. PICHLER et al., « Data augmentation of wearable sensor data for parkinson’s disease monitoring using convolutional neural networks », in *Proceedings of the 19th ACM international conference on multimodal interaction*, 2017, p. 216-220.
- [222] Q. PAN, X. LI et L. FANG, « Data augmentation for deep learning-based ECG analysis », *Feature engineering and computational intelligence in ECG monitoring*, p. 91-111, 2020.
- [223] A. LE GUENNEC, S. MALINOWSKI et R. TAVENARD, « Data augmentation for time series classification using convolutional neural networks », in *ECML/PKDD workshop on advanced analytics and learning on temporal data*, 2016.
- [224] D. P. KINGMA et J. BA, « Adam : A method for stochastic optimization », *arXiv preprint arXiv :1412.6980*, 2014.
- [225] U. RUBY et V. YENDAPALLI, « Binary cross entropy with deep learning technique for image classification », *Int. J. Adv. Trends Comput. Sci. Eng*, t. 9, 10, 2020.
- [226] Z. LU, Y. BAI, Y. CHEN et al., « The classification of gliomas based on a pyramid dilated convolution resnet model », *Pattern Recognition Letters*, t. 133, p. 173-179, 2020.
- [227] D. ULYANOV, A. VEDALDI et V. LEMPITSKY, « Instance normalization : The missing ingredient for fast stylization », *arXiv preprint arXiv :1607.08022*, 2016.
- [228] K. HE, X. ZHANG, S. REN et J. SUN, « Delving deep into rectifiers : Surpassing human-level performance on imagenet classification », in *Proceedings of the IEEE international conference on computer vision*, 2015, p. 1026-1034.
- [229] A. VASWANI, N. SHAZEER, N. PARMAR et al., « Attention is all you need », *Advances in neural information processing systems*, t. 30, 2017.
- [230] Z. WANG et T. OATES, « Imaging time-series to improve classification and imputation », *arXiv preprint arXiv :1506.00327*, 2015.
- [231] S. ZEBHI, « Human activity recognition using wearable sensors based on image classification », *IEEE Sensors Journal*, t. 22, 12, p. 12 117-12 126, 2022.

-
- [232] E. O. BRIGHAM, *The fast Fourier transform and its applications*. Prentice-Hall, Inc., 1988.
- [233] *ImageNet* — *image-net.org*, <https://www.image-net.org/>, [Accessed 03-10-2023].
- [234] K. HE, X. ZHANG, S. REN et J. SUN, « Deep residual learning for image recognition », in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, p. 770-778.
- [235] M. TAN et Q. LE, « Efficientnet : Rethinking model scaling for convolutional neural networks », in *International conference on machine learning*, PMLR, 2019, p. 6105-6114.
- [236] D. NEIL, M. PFEIFFER et S.-C. LIU, « Phased lstm : Accelerating recurrent network training for long or event-based sequences », *Advances in neural information processing systems*, t. 29, 2016.
- [237] Z. CHE, S. PURUSHOTHAM, K. CHO, D. SONTAG et Y. LIU, « Recurrent neural networks for multivariate time series with missing values », *Scientific reports*, t. 8, 1, p. 6085, 2018.
- [238] R. SANTERAMO, S. WITHEY et G. MONTANA, « Longitudinal detection of radiological abnormalities with time-modulated LSTM », in *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support : 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4*, Springer, 2018, p. 326-333.
- [239] E. R. DELONG, D. M. DELONG et D. L. CLARKE-PEARSON, « Comparing the areas under two or more correlated receiver operating characteristic curves : a nonparametric approach », *Biometrics*, p. 837-845, 1988.
- [240] *Tenseurs en lambeaux | TensorFlow Core* — *tensorflow.org*, https://www.tensorflow.org/guide/ragged_tensor?hl=fr, [Accessed 18-09-2023].
- [241] *Évaluez un algorithme de classification qui retourne des valeurs binaires* — *openclassrooms.com*, <https://openclassrooms.com/fr/courses/4297211-evaluez-les-performances-dun-modele-de-machine-learning/4308256-evaluez-un-algorithme-de-classification-qui-retourne-des-valeurs-binaires>, [Accessed 06-10-2023].

-
- [242] J. R. MENDELL et J. FLORENCE, « Manual muscle testing », *Muscle & Nerve : Official Journal of the American Association of Electrodiagnostic Medicine*, t. 13, S1, S16-S20, 1990.
- [243] R. W. BOHANNON et M. B. SMITH, « Interrater reliability of a modified Ashworth scale of muscle spasticity », *Physical therapy*, t. 67, 2, p. 206-207, 1987.
- [244] Y. ADBEL-AZIZ, « Direct linear transformation from comparator coordinates into object space in close-range photogrammetry », in *ASP Symp. Proc. on Close-Range Photogrammetry*, American Society of Photogrammetry, Falls Church, 1971, 1971, p. 1-18.
- [245] A. JOBBAGY et E. FURNÉE, « Marker centre estimation algorithms in CCD camera-based motion analysis », *Medical and Biological Engineering and Computing*, t. 32, p. 85-91, 1994.
- [246] A. LEARDINI, L. CHIARI, U. DELLA CROCE et A. CAPPOZZO, « Human movement analysis using stereophotogrammetry : Part 3. Soft tissue artifact assessment and compensation », *Gait & posture*, t. 21, 2, p. 212-225, 2005.
- [247] A. CAPPOZZO, U. DELLA CROCE, A. LEARDINI et L. CHIARI, « Human movement analysis using stereophotogrammetry : Part 1 : theoretical background », *Gait & posture*, t. 21, 2, p. 186-196, 2005.
- [248] D. PEARSALL et P. COSTIGAN, « The effect of segment parameter error on gait analysis results », *Gait & Posture*, t. 9, 3, p. 173-183, 1999.
- [249] W. T. DEMPSTER, « Space requirements of the seated operator, geometrical, kinematic, and mechanical aspects of the body with special reference to the limbs », Michigan State Univ East Lansing, rapp. tech., 1955.
- [250] U. DELLA CROCE, A. CAPPOZZO et D. C. KERRIGAN, « Pelvis and lower limb anatomical landmark calibration precision and its propagation to bone geometry and joint angles », *Medical & biological engineering & computing*, t. 37, p. 155-161, 1999.
- [251] M. RABUFFETTI, G. BARONI, M. FERRARIN, G. FERRIGNO et A. PEDOTTI, « Self-marking of anatomical landmarks for on-orbit experimental motion analysis compared to expert direct-marking », *Human movement science*, t. 21, 4, p. 439-455, 2002.

-
- [252] F. DANION, E. VARRAINE, M. BONNARD et J. PAILHOUS, « Stride variability in human gait : the effect of stride frequency and stride length », *Gait & posture*, t. 18, 1, p. 69-77, 2003.
- [253] M. KADABA, M. WOOTTEN, J. GAINEY et G. COCHRAN, « Repeatability of phasic muscle activity : performance of surface and intramuscular wire electrodes in gait analysis », *Journal of Orthopaedic Research*, t. 3, 3, p. 350-359, 1985.
- [254] D. A. WINTER, *Biomechanics and motor control of human movement*. John Wiley & Sons, 2009.
- [255] V. ZATSIORSKY et V. SELUYANOV, « The mass and inertia characteristics of the main segments of the human body, International Series on Biomechanics », *Human Kinetics Publ Inc., Nagoya, Japan*, 1983.
- [256] R. K. JENSEN, « Body segment mass, radius and radius of gyration proportions of children », *Journal of biomechanics*, t. 19, 5, p. 359-368, 1986.
- [257] E. HANAVAN, « A mathematical model of the human body. Wright-Patterson Air Force Base, OH : US Air Force, 1964 », *AMRL-TR*, t. 64, p. 102,
- [258] M. R. YEADON, « The simulation of aerial movement—II. A mathematical inertia model of the human body », *Journal of biomechanics*, t. 23, 1, p. 67-74, 1990.
- [259] C. E. CLAUSER, J. T. MCCONVILLE et J. W. YOUNG, « Weight, volume, and center of mass of segments of the human body », Antioch Coll Yellow Springs OH, rapp. tech., 1969.
- [260] P. DE LEVA, « Adjustments to Zatsiorsky-Seluyanov's segment inertia parameters », *Journal of biomechanics*, t. 29, 9, p. 1223-1230, 1996.
- [261] A. GEFEN, M. MEGIDO-RAVID, Y. ITZCHAK et M. ARCAN, « Analysis of muscular fatigue and foot stability during high-heeled gait », *Gait & posture*, t. 15, 1, p. 56-63, 2002.
- [262] K. YOSHINO, T. MOTOSHIGE, T. ARAKI et K. MATSUOKA, « Effect of prolonged free-walking fatigue on gait and physiological rhythm », *Journal of biomechanics*, t. 37, 8, p. 1271-1280, 2004.
- [263] S. BOUISSET, B. MATON et B. POGGI, « Muscles, posture et mouvement Bases et applications de la methode electromyographique », *Lyon Pharmaceutique*, t. 5, 47, p. 272, 1996.

-
- [264] P. W. HODGES et B. H. BUI, « A comparison of computer-based methods for the determination of onset of muscle contraction using electromyography », *Electroencephalography and Clinical Neurophysiology/Electromyography and Motor Control*, t. 101, 6, p. 511-519, 1996.
- [265] M. I. JORDAN, « Serial order : A parallel distributed processing approach », in *Advances in psychology*, t. 121, Elsevier, 1997, p. 471-495.
- [266] H. JAEGER et H. HAAS, « Harnessing nonlinearity : Predicting chaotic systems and saving energy in wireless communication », *science*, t. 304, 5667, p. 78-80, 2004.
- [267] B. HAMMER, « On the approximation capability of recurrent neural networks », *Neurocomputing*, t. 31, 1-4, p. 107-123, 2000.
- [268] G. FÉLIX, « Long short-term memory in recurrent neural networks », *Unpublished PhD dissertation, Ecole Polytechnique Fédérale de Lausanne, Lausanne, Switzerland*, 2001.
- [269] W. MCCELLOCH et W. PITTS, « A logical calculus of the idea immanent in neural nets », *Bulletin of Mathematical Biophysics*, t. 5, p. 115-133, 1943.
- [270] Y. LECUN, B. BOSER, J. DENKER et al., « Backpropagation applied to handwritten zip code recognition [J] », *Neural Computation*, t. 1, 4, p. 541-551, 1989.
- [271] D. H. HUBEL et T. N. WIESEL, « Receptive fields and functional architecture of monkey striate cortex », *The Journal of physiology*, t. 195, 1, p. 215-243, 1968.
- [272] Y. LECUN, B. BOSER, J. S. DENKER et al., « Advances in neural information processing systems », *San Francisco, CA, USA : Morgan Kaufmann Publishers Inc*, p. 396-404, 1990.
- [273] Y. LECUN, Y. BENGIO et G. HINTON, « Deep learning », *nature*, t. 521, 7553, p. 436-444, 2015.
- [274] A. KRIZHEVSKY, I. SUTSKEVER et G. E. HINTON, « ImageNet Classification with Deep Convolutional Neural Networks (AlexNet) ImageNet Classification with Deep Convolutional Neural Networks (AlexNet) ImageNet Classification with Deep Convolutional Neural Networks », 2015.
- [275] K. CHELLAPILLA, S. PURI et P. SIMARD, « High performance convolutional neural networks for document processing », in *Tenth international workshop on frontiers in handwriting recognition*, Suvisoft, 2006.

-
- [276] S. HAN, Z. MENG, Z. LI et al., « Optimizing filter size in convolutional neural networks for facial action unit recognition », in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, p. 5070-5078.
- [277] N. SRIVASTAVA, G. HINTON, A. KRIZHEVSKY, I. SUTSKEVER et R. SALAKHUTDINOV, « Dropout : a simple way to prevent neural networks from overfitting », *The journal of machine learning research*, t. 15, 1, p. 1929-1958, 2014.
- [278] A. IGNATOV, « Real-time human activity recognition from accelerometer data using Convolutional Neural Networks », *Applied Soft Computing*, t. 62, p. 915-922, 2018.
- [279] H. F. NWEKE, Y. W. TEH, M. A. AL-GARADI et U. R. ALO, « Deep learning algorithms for human activity recognition using mobile and wearable sensor networks : State of the art and research challenges », *Expert Systems with Applications*, t. 105, p. 233-261, 2018.
- [280] A. ZIAT, E. DELASALLES, L. DENOYER et P. GALLINARI, « Spatio-temporal neural networks for space-time series forecasting and relations discovery », in *2017 IEEE International Conference on Data Mining (ICDM)*, IEEE, 2017, p. 705-714.
- [281] N. STRODTHOFF et C. STRODTHOFF, « Detecting and interpreting myocardial infarction using fully convolutional neural networks », *Physiological measurement*, t. 40, 1, p. 015 001, 2019.
- [282] S. LIN et G. C. RUNGER, « GCRNN : Group-constrained convolutional recurrent neural network », *IEEE transactions on neural networks and learning systems*, t. 29, 10, p. 4709-4718, 2017.
- [283] J. SERRÀ, S. PASCUAL et A. KARATZOGLOU, « Towards a Universal Neural Network Encoder for Time Series. », in *CCIA*, 2018, p. 120-129.
- [284] Y. BENGIO, L. YAO, G. ALAIN et P. VINCENT, « Generalized denoising autoencoders as generative models », *Advances in neural information processing systems*, t. 26, 2013.
- [285] D. BANERJEE, K. ISLAM, K. XUE et al., « A deep transfer learning approach for improved post-traumatic stress disorder diagnosis », *Knowledge and Information Systems*, t. 60, p. 1693-1724, 2019.

-
- [286] N. MEHDIYEV, J. LAHANN, A. EMRICH, D. ENKE, P. FETTKE et P. LOOS, « Time series classification using deep learning for process planning : A case from the process industry », *Procedia Computer Science*, t. 114, p. 242-249, 2017.
- [287] P. MALHOTRA, V. TV, L. VIG, P. AGARWAL et G. SHROFF, « TimeNet : Pre-trained deep recurrent neural network for time series classification », *arXiv preprint arXiv :1706.08838*, 2017.
- [288] D. RAJAN et J. J. THIAGARAJAN, « A generative modeling approach to limited channel ECG classification », in *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, 2018, p. 2571-2574.
- [289] T. LE NGUYEN, S. GSPONER et G. IFRIM, « Time series classification by sequence learning in all-subsequence space », in *2017 IEEE 33rd international conference on data engineering (ICDE)*, IEEE, 2017, p. 947-958.
- [290] Z. GONG, H. CHEN, B. YUAN et X. YAO, « Multiobjective learning in the model space for time series classification », *IEEE transactions on cybernetics*, t. 49, 3, p. 918-932, 2018.
- [291] N. CHOUIKHI, B. AMMAR et A. M. ALIM, « Genesis of basic and multi-layer echo state network recurrent autoencoders for efficient data representations », *arXiv preprint arXiv :1804.08996*, 2018.
- [292] F. J. ORDÓÑEZ et D. ROGGEN, « Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition », *Sensors*, t. 16, 1, p. 115, 2016.
- [293] R. M. van der VELDEN, A. E. MULDER, M. DRUKKER, M. L. KUIJF et A. F. LEENTJENS, « Network analysis of symptoms in a Parkinson patient using experience sampling data : An n= 1 study », *Movement Disorders*, t. 33, 12, p. 1938-1944, 2018.
- [294] P. ROSENBAUM, N. PANETH, A. LEVITON et al., « A report : the definition and classification of cerebral palsy April 2006 », *Dev Med Child Neurol Suppl*, t. 109, suppl 109, p. 8-14, 2007.
- [295] P. ULDALL, « Everyday life and social consequences of cerebral palsy », *Handbook of clinical neurology*, t. 111, p. 203-207, 2013.

-
- [296] C. CANS, « Epidémiologie de la paralysie cérébrale («Cerebral Palsy» ou CP) », *Motricité Cérébrale : Réadaptation, Neurologie du Développement*, t. 26, 2, p. 51-58, 2005.
- [297] C. CHERRIÈRE, « Effets moteurs et cognitifs de la danse pour des jeunes ayant une paralysie cérébrale », thèse de doct., Université Paul Sabatier-Toulouse III, 2020.
- [298] Y. MATSUSHITA, D. T. TRAN, H. YAMAZOE et J.-H. LEE, « Recent use of deep learning techniques in clinical applications based on gait : a survey », *Journal of Computational Design and Engineering*, t. 8, 6, p. 1499-1532, 2021.
- [299] C. ETIENNE, « Apprentissage profond appliqué à la reconnaissance des émotions dans la voix », thèse de doct., Université Paris Saclay (COmUE), 2019.
- [300] A. ESQUENAZI, S. LEE, A. T. PACKEL et L. BRAITMAN, « A randomized comparative study of manually assisted versus robotic-assisted body weight supported treadmill training in persons with a traumatic brain injury », *PM&R*, t. 5, 4, p. 280-290, 2013.
- [301] C. BUCKLEY, M. E. MICÓ-AMIGO, M. DUNNE-WILLOWS et al., « Gait asymmetry post-stroke : Determining valid and reliable methods using a single accelerometer located on the trunk », *Sensors*, t. 20, 1, p. 37, 2019.
- [302] S. H. COLLINS, M. B. WIGGIN et G. S. SAWICKI, « Reducing the energy cost of human walking using an unpowered exoskeleton », *Nature*, t. 522, 7555, p. 212-215, 2015.
- [303] H. F. MAQBOOL, M. A. B. HUSMAN, M. I. AWAD, A. ABOUHOSSEIN, N. IQBAL et A. A. DEHGHANI-SANIJ, « A real-time gait event detection for lower limb prosthesis control and evaluation », *IEEE transactions on neural systems and rehabilitation engineering*, t. 25, 9, p. 1500-1509, 2016.
- [304] J. D. FARAH, N. BADDOUR et E. D. LEMAIRE, « Design, development, and evaluation of a local sensor-based gait phase recognition system using a logistic model decision tree for orthosis-control », *Journal of neuroengineering and rehabilitation*, t. 16, 1, p. 1-11, 2019.
- [305] L. C. GUAYACÁN, E. RANGEL et F. MARTINEZ, « Towards understanding spatio-temporal parkinsonian patterns from salient regions of a 3D convolutional network », in *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, IEEE, 2020, p. 3688-3691.

-
- [306] H. EL-ZIAAT, N. EL-BENDARY et R. MOAWAD, « Using Multi-Feature Fusion for Detecting Freezing of Gait Episodes in Patients with Parkinson's Disease », in *2020 International Conference on Innovative Trends in Communication and Computer Engineering (ITCE)*, IEEE, 2020, p. 92-97.
- [307] L. GONG, J. LI, M. YU, M. ZHU et R. CLIFFORD, « A novel computer vision based gait analysis technique for normal and Parkinson's gaits classification », in *2020 IEEE Intl Conf on Dependable, Autonomic and Secure Computing, Intl Conf on Pervasive Intelligence and Computing, Intl Conf on Cloud and Big Data Computing, Intl Conf on Cyber Science and Technology Congress (DASC/PiCom/CBDCCom/CyberSciTech)*, IEEE, 2020, p. 209-215.
- [308] G. SHALIN, S. PARDOEL, J. NANTEL, E. LEMAIRE et J. KOFMAN, « Prediction of Freezing of Gait in Parkinson's Disease from Foot Plantar-Pressure Arrays using a Convolutional Neural Network », t. 2020, juill. 2020, p. 244-247. DOI : 10.1109/EMBC44109.2020.9176382.
- [309] S.-H. WANG, Y. ZHANG, X. CHENG, X. ZHANG et Y.-D. ZHANG, « PSSPNN : PatchShuffle stochastic pooling neural network for an explainable diagnosis of COVID-19 with multiple-way data augmentation », *Computational and Mathematical Methods in Medicine*, t. 2021, p. 1-18, 2021.
- [310] J.-C. HUANG, S.-J. RUAN, W.-C. HSU, Y.-T. LIU et C.-H. HSU, « 3D-CLDNN : An effective architecture on deep neural network for sEMG-based lower limb abnormal recognition », in *2019 IEEE 8th Global Conference on Consumer Electronics (GCCE)*, IEEE, 2019, p. 906-907.
- [311] Z.-H. ZHOU, « A brief introduction to weakly supervised learning », *National science review*, t. 5, 1, p. 44-53, 2018.
- [312] B. SETTLES, « Active learning literature survey », 2009.
- [313] J. E. VAN ENGELEN et H. H. HOOS, « A survey on semi-supervised learning », *Machine learning*, t. 109, 2, p. 373-440, 2020.
- [314] A. VAITH, B. TAETZ et G. BLESER, « Uncertainty based active learning with deep neural networks for inertial gait analysis », in *2020 IEEE 23rd International Conference on Information Fusion (FUSION)*, IEEE, 2020, p. 1-8.
- [315] S. S. TALATHI, « Deep recurrent neural networks for seizure detection and early seizure detection systems », *arXiv preprint arXiv :1706.03283*, 2017.

-
- [316] C. TUNCA, N. PEHLIVAN, N. AK, B. ARNRICH, G. SALUR et C. ERSOY, « Inertial sensor-based robust gait analysis in non-hospital settings for neurological disorders », *Sensors*, t. 17, 4, p. 825, 2017.

Titre : Analyse de signaux physiologiques pour la prédiction de l'évolution pathologique par intelligence artificielle. Application à la maladie de Parkinson et à l'analyse quantifiée de la marche.

Mot clés : Intelligence artificielle, apprentissage profond, signaux physiologiques, analyse quantifiée de la marche, troubles de la marche, maladie de Parkinson

Résumé : Cette thèse s'intéresse à la prédiction de l'évolution pathologique dans des signaux biomédicaux monodimensionnels par intelligence artificielle. Nous avons utilisé deux bases de données : EMA (*Ecological Momentary Assessment*) et AQM (*Analyse Quantifiée de la Marche*). Pour EMA, les réponses de patients atteints de la maladie de Parkinson à une question posée plusieurs fois par jour et portant sur leur état de santé global ont été prédites à partir des données de capteurs portables (accéléromètre et gyroscope). La base de données AQM comporte les cinématiques d'un certain nombre de patients présentant des troubles de la marche et suivis d'une manière longitudinale. La prédiction du sens de la variation du GPS (*Gait Profile Score*), un indicateur clé de l'AQM indiquant

la déviation par rapport à une marche normale, est le centre de nos travaux. Deux approches ont été considérées : image et signal. L'approche image consiste à convertir les signaux des cinématiques en des images GAF (*Gramian Angular Field*), MTF (*Markov Transition Field*) ou 2 D FFT (*Two Dimensional Fast Fourier Transform*). Cela permettra d'exploiter les réseaux pré-entraînés de vision par ordinateur. Pour l'approche signal, plusieurs réseaux de neurones, comme les LSTM (*Long Short Term Memory*) et les time-LSTM, ont été développés pour cette prédiction résumée à deux cas de figure : une variation positive ou négative du GPS. Les performances en termes d'AUC (*Area Under the Curve*) dépassent les 0.7 pour les deux approches, ce qui est prometteur.

Title: Analysis of physiological signals for the prediction of pathological evolution by artificial intelligence. Application to Parkinson's disease and quantified gait analysis.

Keywords: Artificial intelligence, deep learning, physiological signals, quantified gait analysis, gait disorders, Parkinson's disease

Abstract: This thesis focuses on the prediction of pathological evolution in one-dimensional biomedical signals using artificial intelligence. We used two databases: EMA (*Ecological Momentary Assessment*) and AQM (*Analyse Quantifiée de la Marche*). For EMA, the responses of Parkinson's patients to a question asked several times a day about their overall health were predicted from wearable sensor data (accelerometer and gyroscope). The AQM database includes the kinematics of a number of patients with gait disorders followed longitudinally. Predicting the direction of variation of the GPS (*Gait Profile Score*), a key AQM indicator of deviation from normal gait, is the focus of our work.

Two approaches were considered: image and signal. The image approach involves converting kinematic signals into GAF (*Gramian Angular Field*), MTF (*Markov Transition Field*) or 2 D FFT (*Two Dimensional Fast Fourier Transform*) images. This will make it possible to exploit pre-trained computer vision networks. For the signal approach, several neural networks, such as LSTM (*Long Short Term Memory*) and time-LSTM, have been developed for this two-case prediction: positive or negative GPS variation. Performance in terms of AUC (*Area Under the Curve*) exceeds 0.7 for both approaches, which is promising.