

**Titre:** Quantification de la fatigue physique lors d'activités multitâches  
Title: dans un environnement non contrôlé

**Auteur:** Mathilde Hochedel  
Author:

**Date:** 2022

**Type:** Mémoire ou thèse / Dissertation or Thesis

**Référence:** Hochedel, M. (2022). Quantification de la fatigue physique lors d'activités multitâches dans un environnement non contrôlé [Mémoire de maîtrise, Polytechnique Montréal]. PolyPublie. <https://publications.polymtl.ca/10170/>  
Citation:

 **Document en libre accès dans PolyPublie**  
Open Access document in PolyPublie

**URL de PolyPublie:** <https://publications.polymtl.ca/10170/>  
PolyPublie URL:

**Directeurs de recherche:** Maxime Raison, & Sofiane Achiche  
Advisors:

**Programme:** Génie biomédical  
Program:

**POLYTECHNIQUE MONTRÉAL**

affiliée à l'Université de Montréal

**Quantification de la fatigue physique lors d'activités multitâches dans un  
environnement non contrôlé**

**MATHILDE HOCHEDÉL**

Institut de génie biomédical

Mémoire présenté en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

Génie biomédical

Janvier 2022

# **POLYTECHNIQUE MONTRÉAL**

affiliée à l'Université de Montréal

Ce mémoire intitulé :

## **Quantification de la fatigue physique lors d'activités multitâches dans un environnement non contrôlé**

présenté par **Mathilde HOCHEDÉL**

en vue de l'obtention du diplôme de *Maîtrise ès sciences appliquées*

a été dûment accepté par le jury d'examen constitué de :

**Frédéric LESAGE**, président

**Maxime RAISON**, membre et directeur de recherche

**Sofiane ACHICHE**, membre et codirecteur de recherche

**Daniel SPOONER**, membre

## REMERCIEMENTS

Je tiens à remercier Polytechnique Montréal, la startup Technologies Biolift Inc. et toutes les personnes qui m'ont permis de réaliser cet ambitieux projet.

Je tiens tout d'abord à remercier les membres de mon comité d'encadrement qui ont su m'accompagner et me guider tout au long de ce projet. Une attention particulière à mon directeur de recherche Maxime Raison, professeur au Département de Génie mécanique à l'École de Polytechnique de Montréal et titulaire de la Chaire en génie de la réadaptation appliqué en pédiatrie. Sa confiance et son dévouement pédagogique m'ont donné goût à la recherche et m'ont permis la réalisation de ce projet passionnant. Je remercie également mon codirecteur de recherche Sofiane Achiche, aussi professeur au Département de Génie mécanique, qui a pris le temps de m'écouter et de me soutenir à chaque fois que j'en ai ressenti le besoin. Vous formez un duo dynamique et stimulant au sein duquel il est très agréable de travailler. Par votre passion pour votre travail, vous avez su m'encadrer adéquatement du début à la fin, en me laissant jouir d'une grande autonomie.

Un énorme merci à toute l'équipe de l'entreprise Biolift sans qui ce projet n'aurait pas pu avoir lieu. Vous m'avez rapidement intégrée à votre équipe grâce à votre ouverture et votre générosité. Travailler avec vous a été très enrichissant. Votre contribution au résultat est inestimable.

Je tiens également à remercier mes collègues et amis du laboratoire CoSim. J'ai passé une année inoubliable en votre compagnie. Il est vraiment facile de se motiver chaque jour pour travailler à vos côtés.

Une pensée toute particulière à ma famille et mes amis en France qui m'ont incitée à faire une maîtrise à Montréal et qui m'ont apporté un soutien inconditionnel malgré la distance. Vous êtes pour moi le plus bel exemple de persévérance, et vous m'avez toujours poussé à donner le meilleur de moi-même.

Merci.

## RÉSUMÉ

Chaque année, 1.7 % des travailleurs de la construction subissent une blessure suffisamment grave pour s'absenter du travail. L'une des principales raisons à cela est la fatigue induite par la nature très exigeante physiquement des tâches de la construction. Pour surveiller la fatigue physique en temps réel, des capteurs portables tels que des moniteurs de fréquence cardiaque et des unités de mesures inertielles (IMUs) ont été utilisés dans l'athlétisme et dans l'industrie des transports. Cependant, dans le domaine de la construction, leur utilisation reste généralement limitée au suivi de la fatigue physique sur une seule tâche ou lors d'une activité multitâche mais en laboratoire. Cette étude vise à quantifier la fatigue physique lors d'activités multitâches dans un environnement non-contrôlé, en combinant un capteur IMU et un moniteur de fréquence cardiaque. Le système de capteurs ainsi que la méthode d'analyse et de traitement des données développés ont été testés sur quatre applications réalisées chronologiquement : 1) sur des données extraites d'une tâche répétitive réalisée par quinze sujets en laboratoire, 2) sur des données extraites de deux tâches répétitives réalisées par quinze sujets en laboratoire, 3) sur une activité multitâche réalisée par trois sujets dans un environnement non-contrôlé et 4) sur trois travailleurs de la construction lors de trois demi-journées consécutives de travail. Dans tous les cas, l'échelle de Borg a été utilisée comme échelle subjective pour obtenir le niveau de fatigue ressenti par les participants. Trois modèles de classificateur, à savoir la régression logistique, le *Random Forest* et le *Bagged Trees*, ont été testés pour la quantification de la fatigue physique. Les principaux résultats ont montré que la méthode proposée permet de quantifier la fatigue physique pendant une demi-journée d'activités multitâches dans un environnement non-contrôlé avec une précision de 78.6% par un modèle de *Random Forest* utilisant un maximum de 18 caractéristiques. Les résultats ont également montré que la méthode proposée dans cette étude n'est pas encore directement applicable pour la quantification de la fatigue physique des travailleurs de la construction lors de leur journée de travail. En effet, l'hostilité des conditions climatiques des chantiers de la construction a entraîné un dysfonctionnement du moniteur de fréquence cardiaque et les travailleurs ont systématiquement évalué leur niveau de fatigue à faible, ce qui a entraîné des difficultés pour l'étiquetage des données.

## ABSTRACT

Each year, 1.7% of construction workers sustain an injury serious enough to take time off work. One of the major reasons for this, is the fatigue induced by the highly physically demanding nature of construction tasks. To monitor physical fatigue in real-time, wearable sensors such as heart rate monitors and inertial measurement units (IMUs) have been recognized in professional athletics and in the transportation industry. However, in the construction field, their use generally remains limited to either solely one task or to multitasking activity within laboratory settings. This study aims to quantify the physical fatigue during multitasking activities in a non-controlled environment by combining an IMU and a heart rate monitor. The proposed sensor system as well as the data processing method were tested on four case studies chronologically: 1) on data extracted from a repetitive task performed by fifteen subjects with laboratory settings, 2) on data extracted from two repetitive tasks performed by fifteen subjects with laboratory settings, 3) for a multitasking activity performed by three subjects in a non-controlled environment and 4) on three construction workers during three consecutive half-days of work. In all cases, Borg's Rating of Perceived Exertion was used as a subjective scale to obtain the fatigue level experienced by the participants. Three classifier models, namely the logistic regression, the random forest, and the bagged trees, were tested for physical fatigue quantification. The main results showed that the proposed method allows to quantify the physical fatigue during a half day of multitasking activities in a non-controlled environment with an accuracy of 78.6% using a random forest model using a maximum of 18 features. The results also showed that the method proposed in this study is not, at this stage, directly applicable for the quantification of the physical fatigue of construction workers during their working day. Indeed, the hostile climatic conditions of the construction sites resulted in the heart rate monitor malfunctioning and construction workers systematically rated their fatigue level as low, which created difficulties in labelling the data.

## TABLE DES MATIÈRES

REMERCIEMENTS .....	III
RÉSUMÉ.....	IV
ABSTRACT .....	V
TABLE DES MATIÈRES .....	VI
LISTE DES TABLEAUX.....	X
LISTE DES FIGURES.....	XII
LISTE DES SIGLES ET ABRÉVIATIONS .....	XV
LISTE DES ANNEXES.....	XVI
CHAPITRE 1 INTRODUCTION.....	1
CHAPITRE 2 REVUE DE LA LITTÉRATURE.....	5
2.1 Définition de la fatigue.....	5
2.2 Méthodes de suivi de la fatigue physique .....	7
2.2.1. Méthodes subjectives .....	7
2.2.2. Méthodes objectives.....	10
2.3. Méthodes en apprentissage automatique.....	21
2.3.1. Définition de l'apprentissage automatique.....	21
2.3.2. Données brutes .....	23
2.3.3. Prétraitement des données .....	24
2.3.4. Génération des descripteurs .....	24
2.3.5. Réduction de la dimensionnalité .....	25
2.3.6. Normalisation des descripteurs .....	27
2.3.7. Cas d'un ensemble de données déséquilibrées.....	28
CHAPITRE 3 PROBLÉMATIQUE ET OBJECTIFS.....	30

3.1	Résumé de la problématique .....	30
3.2	Objectifs et hypothèses.....	31
3.2.1.	Objectif général .....	31
3.2.2.	Objectifs spécifiques .....	31
3.2.3.	Hypothèses de recherche .....	31
CHAPITRE 4	MÉTHODE GÉNÉRALE .....	33
4.1	Partie n°1 : Conception du système de capteurs .....	34
4.1.1.	Choix des capteurs .....	34
4.1.2.	Cahier des charges.....	35
4.1.3.	Placement des capteurs.....	35
4.1.4.	Choix des composants et des capteurs .....	36
4.1.5.	Principe de fonctionnement.....	41
4.2	Partie n°2 : Analyse et traitement des données .....	43
4.2.1.	Préparation des données .....	43
4.2.2.	Construction et validation du modèle.....	49
4.2.3.	Optimisation et performance .....	51
4.3	Application .....	53
4.3.1.	Mise en application n°1 : Réalisation d'une tâche répétitive dans un environnement contrôlé (en laboratoire) .....	55
4.3.2.	Mise en application n°2 : Réalisation de deux tâches répétitives dans un environnement contrôlé (en laboratoire) .....	57
4.3.3.	Mise en application n°3 : Activité multitâche d'aménagement paysager (environnement non-contrôlé) .....	57
4.3.4.	Mise en application n°4 : Sur un chantier professionnel.....	58



CHAPITRE 5 ARTICLE 1: QUANTIFICATION OF PHYSICAL FATIGUE BY  
COMBINING AN IMU AND A HEART RATE MONITOR: PROOF OF CONCEPT IN A NON-  
CONTROLLED ENVIRONMENT..... 60

5.1	Introduction .....	61
5.1.1.	Fatigue at work.....	61
5.1.2.	Monitoring physical fatigue in workers .....	62
5.1.3.	Objective of the study .....	65
5.2.	Methods .....	66
5.2.1.	Data acquisition.....	67
5.2.2.	Data cleaning and variable extraction .....	68
5.2.3.	Data pre-processing.....	69
5.2.4.	Model construction and validation.....	71
5.2.5.	Optimization.....	73
5.3.	Case studies .....	73
5.3.1.	Case study n°1: one repetitive task performed in a controlled environment .....	74
5.3.2.	Case study n°2: Two repetitive tasks performed in a controlled environment .....	77
5.3.3.	Case study n°3: Multitasking activity performed in a non-controlled environment ..	78
5.4.	Results .....	79
5.4.1.	Physical fatigue quantification for one repetitive task in a controlled environment (SO1).....	80
5.4.2.	Physical fatigue quantification for two repetitive tasks in a controlled environment (SO2).....	80
5.4.3.	Physical fatigue quantification for multitasking activity in a non-controlled environment (SO3).....	82
5.5.	Discussion .....	83

5.5.1 Quantifying physical fatigue during one repetitive task performed in a controlled environment (SO1).....	83
5.5.2. Quantifying physical fatigue during two repetitive tasks performed in a controlled environment (SO2).....	84
5.5.3 Quantifying physical fatigue during a multitasking activity performed in a non-controlled environment (SO3).....	84
5.5.4. Discussion on the usefulness of combining both sensors .....	85
5.5.5. Limitations .....	87
5.6. Conclusion.....	87
5.7. Funding resources .....	88
CHAPITRE 6 RÉSULTATS COMPLÉMENTAIRES .....	89
6.1 Difficultés rencontrées .....	89
6.2 Solution proposée pour le traitement des données .....	90
6.3 Résultats .....	91
CHAPITRE 7 DISCUSSION GÉNÉRALE .....	93
7.1 Synthèse de l'article .....	93
7.2 Analyse des résultats complémentaires.....	94
7.3 Limites et perspectives .....	95
CHAPITRE 8 CONCLUSION .....	97
RÉFÉRENCES .....	99
ANNEXES .....	103

## LISTE DES TABLEAUX

Tableau 2.1.1 Facteurs pouvant influencer l'occurrence et le développement de la fatigue d'un travailleur de la construction. ....	6
Tableau 2.2.1 Exemple de l'échelle de Borg. ....	8
Tableau 2.2.2 Exemple de l'échelle CR10 de Borg. ....	8
Tableau 2.2.3 Exemple de l'échelle sur le besoin de récupération. ....	9
Tableau 2.2.4 Exemple du FASCW. ....	9
Tableau 2.2.5 Résumé des méthodes de classification et des résultats pour la détection de fatigue. ....	15
Tableau 2.3.1 Données d'entrées adaptées à un modèle d'apprentissage supervisé. ....	24
Tableau 2.3.2 Série temporelle. ....	24
Tableau 4.2.1 Récapitulatif des chaînes de transformation créées. ....	53
Tableau 4.3.1 Caractéristiques pertinentes des sujets qui ont réalisé la première mise en application. ....	55
Tableau 4.3.2 Caractéristiques pertinentes des sujets qui ont réalisé la mise en application sur le chantier non professionnel. ....	57
Tableau 4.3.3 Caractéristiques pertinentes des travailleurs de la construction, suivis pour la 4ème mise en application. ....	58
Table 5.1.1 Physical fatigue indicators, direction of change with fatigue development and related studies. ....	63
Table 5.2.1 Sets of features generated from the raw data for each participant. ....	70
Table 5.2.2 Pipelines created by associating a sampling method and a model. ....	73
Table 5.3.1 Relevant characteristics of the participants for the application in controlled environment. ....	75

Table 5.3.2 Relevant characteristics of the participants for the application in non-controlled environment.....	78
Table 5.4.1 Mean performance and the corresponding standard deviation of the classification methods for fatigue quantification for the tasks performed in controlled environment.....	81
Table 5.4.2 Mean values for the F1 score of the ROS-RF model when inputs are the data from both tasks.....	81
Table 5.4.3 Average values for the F1 score: with all features, with only HR-based features and with only IMU-based features.....	83
Table 5.5.1 Description of the characteristics of the three behaviors observed among the 15 participants performing a multitasking activity in a controlled environment. ....	85
Tableau 6.3.1 Performances d'une classification binaire avec un modèle de forêt aléatoire obtenue pour chacun des travailleurs de la construction, en prenant en entrée les données issues des 3 demi-journées de tests. ....	91

## LISTE DES FIGURES

Figure 2.1.1 Échelle de Borg avec les 4 niveaux de fatigue correspondant.....	3
Figure 2.2.1 A : Système LifeMonitor EQ02 porté. B : Montre PPG. Images directement extraites de (Anwer, S. et al., 2020).....	13
Figure 2.2.2 Modèle de classification binaire avec un classificateur de type SVM proposé par (Karvekar et al., 2019).....	16
Figure 2.2.3 Modèle de classification multi-classes avec un classificateur de type SVM proposé par (Karvekar et al., 2019). ....	17
Figure 2.2.4 Tâche de manutention manuelle (Maman et al. (2017)).....	18
Figure 2.2.5 Tâche de ramassage et d'insertion (Maman et al. (2017)).....	18
Figure 2.2.6 Tâche d'assemblage (Maman et al. (2017)).....	18
Figure 2.2.7 Placement des capteurs dans l'étude (Aryal et al., 2017).....	20
Figure 2.3.1 Schéma représentatif des étapes d'un problème d'apprentissage automatique supervisé .....	23
Figure 2.3.2 Exemple de génération du descripteur mean_grav.z à partir de la série temporelle grav.z. La statistique récapitulative utilisée est la moyenne, sur des fenêtres glissantes avec un chevauchement de 50%. ....	25
Figure 4.1.1 BNO055 Adafruit 9-DOF Absolute Orientation IMU.....	36
Figure 4.1.2 Montre Coospo HW706 utilisée pour la mesure de la fréquence cardiaque. ....	36
Figure 4.1.3 Microcontrôleur ESP32 HUZZAH (Adafruit).....	35
Figure 4.1.4 Module de carte SD (Adafruit) .....	38
Figure 4.1.5 Schéma Fritzing de l'équipement de capteurs.....	37
Figure 4.1.6 Positionnement du système de capteurs.....	40
Figure 4.1.7 Principe de fonctionnement de l'algorithme du microcontrôleur.....	42
Figure 4.2.1 Plan de la méthode proposée pour l'analyse et le traitement des données.....	43

Figure 4.2.2 Exemple de l'application di filtre de Butterworth sur l'accélération en z et le tangage. .....	42
Figure 4.2.3 Orientation de l'IMU en fonction des 3 angles d'Euler, illustré par VPython.. .....	43
Figure 4.2.4 Génération du descripteur « moyenne du tangage » à partir de la série temporelle du tangage, selon les 4 niveaux de fatigue donnés par le sujet (vert = 1(faible), bleu=2(moyenne), orange=3(élevé), rouge=4(très élevé). a) Tangage en fonction du temps. b) Moyenne du tangage calculé sur des fenêtres temporelles glissantes de 30s avec 50% de chevauchement.. .....	45
Figure 4.2.5 Proportion de chacune des classes pour le premier ensemble de données, pour 5 participants (capture d'écran d'un code Python).....	46
Figure 4.2.6 Description du principe de la validation croisée.....	47
Figure 4.3.1 Description des 4 mises en application réalisées pour valider l'équipement de capteurs et la méthode de traitement des données. ....	54
Figure 4.3.2 Photos prises pendant la réalisation de la tâche de levage.....	56
Figure 4.3.3 Aplatir le sol avec une machine .....	59
Figure 4.3.4 Aplatissage du sol à la main. ....	59
Figure 4.3.5 Poser les nouveaux pavés. ....	59
Figure 5.1.1 Borg's RPE scale with the four levels of fatigue.....	66
Figure 5.2.1 Proposed framework for physical fatigue quantification.....	66
Figure 5.2.2 a) Central unit. b) Sensors' localization: heart rate armband and IMU in the back. c) Heart rate armband.Central unit (IMU).....	68
Figure 5.3.1 Description of the three case studies.....	74
Figure 5.3.2 Lifting task. a) Lift to the second floor. b) Box on the ground. c) Complete description. .....	76
Figure 5.3.3 Tiling task complete description.....	72

Figure 5.3.4 Feature extraction of the pitch of participant P1 according to the four levels of fatigue (green = 1, blue = 2, orange = 3 and red = 4). a) Monitored pitch. b) Mean of the pitch calculated on 30s sliding windows with 50% overlapping. ....	77
Figure 5.3.5 Landscaping work. a) Dig the hole. b) Global view of the work.. ....	74
Figure 5.4.1 Feature Importance rates of HR-based features and IMU-based features calculated for each participant for a single model which took as inputs data extracted from combined tasks performed in the controlled environment. ....	77
Figure 5.4.2 Feature Importance rates of HR-based features and IMU-based features calculated for each participant for the multitasking activity performed in non-controlled environment.. ...	78
Figure 6.2.1 Étiquetage des données : premières 20 minutes à non-fatigué (en vert) et 20 dernières à fatigué (en rouge). Les données entre ces deux périodes (en bleu) n'étant pas prises en compte pour le modèle. a) Étiquetage du tangage. b) Étiquetage de la résultante de l'accélération. c) Étiquetage de la secousse. ....	90
Figure A.1 Description du principe du modèle de Random Forest.....	103
Figure A.2 Description du principe de l'algorithme du Boosted Trees.. ....	105
Figure A.3 Description du principe de l'algorithme du Bagged Trees.. ....	105
Figure B.1 Exemple de fichier .csv enregistré sur la carte SD.....	106
Figure B.2 Principe de fonctionnement et de calibration de l'équipement de capteurs.....	107
Figure C.1 Exemple de la fonction dtypes().... ....	108
Figure C.2 Exemple des fonctions isnan() et sum()..... ....	109
Figure C.3 Exemple de la fonction heatmap()..... ....	109
Figure C.4 Exemple de la fonction describe()..... ....	110
Figure C.5 Exemple de la fonction clustermap()..... ....	111
Figure D.1 $\phi$ (roulis), $\theta$ (tangage) et $\psi$ (lacet). L'axe N représente l'axe x intermédiaire autour duquel se produit la rotation du roulis.....	113

## LISTE DES SIGLES ET ABRÉVIATIONS

CV	Coefficient de variation
EEG	Electroencéphalogramme
FC	Fréquence cardiaque
FR	Fréquence de respiration
HRR	<i>Heart rate reserve</i>
IMU	<i>Inertial Measurement Unit</i>
LED	<i>Light Emitting Diode</i>
LIPO	<i>Lithium-ion Polymer</i>
LR	<i>Logistic Regression</i>
MMH	<i>Manual Material Handling</i>
PA	<i>Parts Assembly</i>
PPG	Photopléthysmographie
RF	<i>Random Forest</i>
ROS	<i>Random Over Sampling</i>
RPE	<i>Rating of Perceived Exertion</i>
RUS	<i>Random Under Sampling</i>
SD	<i>Secure Digital</i>
SMOTE	<i>Synthetic Minority Over-sampling Technique</i>
SPI	<i>Supply Pickup and Insertion</i>
SVM	<i>Support Vector Machine</i>



## LISTE DES ANNEXES

Annexe A Description des algorithmes de classification utilisés .....	103
Annexe B Détails concernant l'équipement de capteurs.....	105
Annexe C Détails des fonctions de visualisation des données en Python.....	107
Annexe D Quaternions .....	111

## CHAPITRE 1 INTRODUCTION

Chaque année, 1.7% des travailleurs de la construction, milieu de travail non-contrôlé, subissent une blessure suffisamment grave pour s'absenter au travail (Statistics, 2021). Une des principales raisons à ces problèmes de santé et de sécurité auxquels sont confrontés les travailleurs de la construction est l'exigence physique des tâches de la construction (Yu et al., 2019). En effet, ces tâches impliquent généralement des activités répétitives et souvent exécutées dans des conditions climatiques difficiles et/ou dans des espaces de travail confinés pendant de longues périodes (Aryal et al., 2017; Yu et al., 2019). Les travailleurs de la construction sont fréquemment exposés à de lourdes charges de travail et à de longs horaires sans pauses suffisantes pour récupérer (Aryal et al., 2017; Yu et al., 2019; Zhang, M. et al., 2015). De telles circonstances exposent ces travailleurs au risque du développement de la fatigue (Yu et al., 2019).

Le Bureau des Statistiques du Travail américain a indiqué que 33% de toutes les blessures et troubles musculosquelettiques liés au travail dans le domaine de la construction aux États Unis sont causés par la fatigue et le surmenage (Statistics., 2016). La fatigue est un facteur de risque au travail car elle peut entraîner une diminution de la motivation et de la vigilance ainsi que des accidents et des blessures (Zhang, M. et al., 2015). La fatigue a d'ailleurs été identifiée comme un facteur potentiel des chutes, l'une des quatre causes mortelles dans l'industrie de la construction selon l'OSHA (Aryal et al., 2017).

En fonction de la gravité des blessures, elles peuvent se traduire par une absence au travail variant de quelques semaines à plusieurs mois, voire conduire à l'invalidité du travailleur. Ceci se traduit par des coûts conséquents, autant pour l'employeur que la société (Huysamen et al., 2018). Notamment, le coût annuel total de ces blessures aux États Unis est de plus de 11.5 milliards de dollars (Statistics, 2019).

Ces chiffres montrent la nécessité de développer des techniques permettant de suivre les signaux physiologiques indicateurs de fatigue physique en temps réel dans le but de prévenir des blessures et/ou d'organiser au mieux les périodes de travail des travailleurs de la construction. Grâce au développement continu des technologies portables et à la diminution de leurs coûts, les capteurs portables sont largement considérés pour les systèmes de suivi de la fatigue. Les avantages à utiliser ce type de capteurs englobent la portabilité, l'aspect non-invasif, l'accessibilité, la multifonctionnalité et la fiabilité (Baghdadi et al., 2021). De plus en plus d'études utilisent ces

technologies portables dans le but de surveiller divers signaux physiologiques et biomécaniques afin de modéliser la fatigue physique des travailleurs de la construction (Anwer, Shahnawaz et al., 2021). Même si les résultats présentés par ces études sont prometteurs, ils sont obtenus lors d'expériences réalisées en laboratoire. En effet, de nombreuses études se concentrent uniquement sur l'identification et/ou la quantification de la fatigue physique lors de tâches répétitives indépendantes (Sedighi Maman et al., 2017; Sedighi Maman et al., 2020; Valero et al., 2016) ou lors de séquences de tâches contrôlées (Zhang, L. et al., 2019). Pourtant, le milieu de la construction est un environnement dynamique, diversifié et transitoire (Techera et al., 2018). Pour que les techniques et méthodes développées en laboratoires soient applicables sur les chantiers de la construction, elles doivent prendre en compte ces trois aspects :

- Le dynamisme : la cadence des travailleurs n'est pas imposée pour la réalisation d'une tâche. Les travailleurs disposent d'un laps de temps pour réaliser leur travail (une journée, une semaine, un mois) et sont ainsi libres de ralentir leur cadence lorsqu'ils se sentent fatigués, ou d'accélérer quand ils se sentent assez reposés.
- La diversité des activités : les travaux de construction englobent généralement des tâches qui peuvent être très différentes (de conduire un camion à creuser un sol par exemple).
- L'aspect transitoire : les travailleurs sont libres de passer d'une sous tâche à une autre.

L'objectif principal de l'étude présentée dans ce mémoire est de développer un système de capteurs et une méthode d'analyse et de traitement des données permettant la quantification de la fatigue physique par la combinaison d'une centrale inertielle et d'un capteur de fréquence cardiaque lors d'activités multitâches dans un environnement non-contrôlé. Il s'agit en effet d'une étape intermédiaire primordiale afin de vérifier que les techniques et résultats présentés dans la littérature (et obtenus lors de sessions de tests avec des paramètres de laboratoires) sont applicables sur des chantiers de la construction.

Pour atteindre cet objectif principal, un système basé sur des capteurs composé d'une unité de mesure inertielle (IMU) et d'un moniteur de fréquence cardiaque, ainsi qu'une méthode d'analyse et de traitement des données par apprentissage supervisé ont été développés. Plus précisément, le traitement des données vise à quantifier la fatigue physique d'un individu à travers la classification

des données en 4 niveaux de fatigue : faible, moyen, élevé et très élevé, sur la base de l'échelle RPE de Borg, comme le montre la Figure 2.1.1.

RPE	Level of exertion	Verbal anchors	Fatigue level
6	No exertion	I am not tired; this is similar to resting	1- Low
7			
7.5	Extremely Light		
8		I am not tired; this is similar to walking	
9	Very Light		
10			
11	Light	I feel fine to continue	2- Medium
12			
13	Somewhat hard		
14		I am getting tired, but I can continue	3- High
15	Hard (heavy)		
16			
17	Very hard	I am very tired; I have to push myself to continue	4- Very High
18			
19	Extremely hard	This is one of the hardest things I have done	
20	Maximal exertion		

Figure 2.1.1 Échelle de Borg avec les 4 niveaux de fatigue correspondant.

La méthode proposée a été testée lors de 4 applications :

1. Sur 15 sujets réalisant une tâche répétitive en laboratoire,
2. Sur les mêmes 15 sujets réalisant deux tâches répétitives en laboratoire,
3. Sur 3 sujets réalisant une activité d'aménagement paysager (non professionnel) dans un environnement non-contrôlé durant une demi-journée.
4. Sur 3 travailleurs de la construction lors de trois demi-journées consécutives de travail.

Le Chapitre 2 présente le contexte théorique de l'étude, à savoir la définition de la fatigue physique dans le domaine de la construction ainsi que ses principaux facteurs. De plus, les différentes méthodes de suivi de la fatigue, à savoir les méthodes subjectives et objectives, sont présentées. Puis, une description des études les plus récentes est réalisée. Cette description a permis d'identifier les signaux physiologiques indicateurs de fatigue, les capteurs portables qui permettent de les suivre et les techniques de traitement des données utilisées. Enfin, la dernière partie reprend les grandes définitions et méthodologies des problèmes d'apprentissage supervisé. La problématique et les objectifs sont présentés au Chapitre 3. Le Chapitre 4 détaille la méthodologie générale de

l'étude. Ce chapitre inclut la conception de l'équipement de capteurs, la méthode d'analyse et de traitement des données par apprentissage supervisé et les 4 mises en application de cette méthode. Le Chapitre 5 est constitué d'un article qui vient d'être soumis pour publication. Les résultats portant sur les trois premières applications, en laboratoire et sur l'activité d'aménagement paysager y sont présentés. Le Chapitre 6 présente les résultats de l'application avec les travailleurs de la construction, qui n'ont pas été présentés dans l'article. Une discussion générale de l'étude est abordée au Chapitre 7. Les perspectives et limites de cette étude seront également proposées dans ce chapitre. Le Chapitre 8 conclut le mémoire.

## CHAPITRE 2 REVUE DE LA LITTÉRATURE

Dans un premier temps, une définition de la fatigue physique dans le domaine de la construction ainsi que ses principaux facteurs sont présentés. Les différentes méthodes de suivi de la fatigue, à savoir les méthodes subjectives et objectives, seront ensuite détaillées. Puis, une description des études les plus récentes est réalisée. Cette description a permis d'identifier les signaux physiologiques indicateurs de fatigue, les capteurs portables qui permettent de les suivre et les techniques de traitement des données utilisées par la littérature. Enfin, la dernière partie reprend les grandes définitions et méthodologies des problèmes d'apprentissage supervisé.

### 2.1 Définition de la fatigue

Les chercheurs ont longtemps tenté de définir succinctement la fatigue, mais il n'existe pas toujours de définition simple ou standard (Cavuoto & Megahed, 2016). En effet, la fatigue au travail est un problème multidimensionnel car elle peut être aiguë ou chronique, toucher le corps entier ou être localisée au niveau des muscles, elle peut être physique ou mentale et centrale ou périphérique (Cavuoto & Megahed, 2016).

La définition choisie pour cette étude est une définition assez large, englobant de nombreux facteurs et proposée par (Caldwell et al., 2019). Ils décrivent la fatigue comme étant « *l'état de se sentir très fatigué, las ou somnolent résultant d'un sommeil insuffisant, d'un travail mental ou physique prolongé, ou de périodes prolongées de stress ou d'anxiété* ». Ils ajoutent que les tâches ennuyeuses ou répétitives peuvent intensifier les sensations de fatigue (Caldwell et al., 2019). Ainsi, une personne fatiguée reçoit un signal de son corps indiquant que l'activité en cours, qu'il s'agisse d'une activité physique ou mentale, doit être interrompue (Sadeghniiat-Haghighi & Yazdi, 2015). Cette définition montre que la fatigue est un phénomène complexe qui peut être attribué à de nombreux facteurs.

Ces facteurs peuvent être classés en trois catégories comprenant la charge physique, la charge environnementale et la charge mentale (Sadeghniiat-Haghighi & Yazdi, 2015) décrits dans le tableau ci-dessous (Tableau 2.1.1). La fatigue peut également être induite par une combinaison de ces facteurs (Sadeghniiat-Haghighi & Yazdi, 2015).

Tableau 2.1.1 Facteurs pouvant influencer l'occurrence et le développement de la fatigue d'un travailleur de la construction.

Charge physique	Charge environnementale	Charge mentale
Efforts intenses, Postures inconfortables, Charges statiques, Mouvements répétitifs.	Température, Bruit, Niveau de luminosité, Vibration, Humidité.	Horaires de travail irréguliers, Exigences du travail, Stress au travail, Relation avec les collègues, Autonomie de décisions.

Étant donné que les facteurs environnementaux (tels que le niveau de luminosité, ou de pollution dans l'air) peuvent être difficiles à mesurer – cela nécessite un grand nombre de capteurs, répartis sur l'ensemble du lieu de travail – et qu'il existe des corrélations entre eux (Cavuoto & Megahed, 2016), ces facteurs ne seront pas mesurés ni pris en compte dans cette étude. De même, les facteurs mentaux sont difficiles à mesurer – cela nécessite de nombreux questionnaires et une étude approfondie de l'environnement social du lieu de travail – et ne seront donc pas non plus pris en compte. Enfin, étant donné que la plupart des travailleurs de la construction (tels que les travailleurs manuels) ne nécessitent pas nécessairement d'un niveau élevé de vigilance mentale, cette étude se concentre uniquement sur le suivi et la quantification de la fatigue physique chez les travailleurs de la construction (Aryal et al., 2017). Ainsi, à partir de ce point et pour le reste de l'étude, le terme *fatigue* fera référence à la fatigue physique.

La fatigue au travail aboutit à une diminution des performances des travailleurs. À court terme, elle peut entraîner de l'inconfort, une diminution du contrôle de la motricité et une réduction de la capacité de résistance (Cavuoto & Megahed, 2016). À plus long terme, la fatigue peut conduire à une réduction de la performance, à une baisse de la productivité, à une mauvaise qualité de travail et à l'augmentation des accidents et des erreurs humaines. La fatigue peut également être considérée comme un précurseur aux troubles musculosquelettiques liés au travail (Cavuoto & Megahed, 2016).

Pour surmonter ces défis dans l'industrie de la construction, il est essentiel de surveiller et de gérer efficacement la fatigue des travailleurs de la construction afin d'assurer une main-d'œuvre plus durable et plus productive pour l'industrie à venir (Anwer, Shahnawaz et al., 2021).

## 2.2 Méthodes de suivi de la fatigue physique

Les méthodes traditionnelles utilisées pour mesurer la fatigue physique peuvent être classées entre les méthodes subjectives et objectives (Anwer, Shahnawaz et al., 2021), qui sont détaillées dans les paragraphes suivants.

### 2.2.1. Méthodes subjectives

Ces méthodes se basent sur la perception de la fatigue physique des travailleurs.

En raison de la composante subjective de la perception des travailleurs, les mesures de la fatigue sont adaptées à la situation dans laquelle la fatigue est étudiée (Anwer, Shahnawaz et al., 2021; Aryal et al., 2017; Zhang, M. et al., 2015). Ainsi, différentes échelles ont été créées. Par exemple, l'échelle d'évaluation de l'effort perçu (*Rating of Perceived Exertion* (RPE)) de Borg est utilisée pour recueillir l'effort perçu par le travailleur (Borg, 1998). L'échelle de Borg est une échelle linéaire, de 6 à 20 et a été proposée par G. Borg comme une tentative de quantification des symptômes subjectifs de la manière dont les sujets perçoivent le niveau d'effort de leur travail. Pour cette échelle, un score de 6 correspond à une fréquence cardiaque de 60 battements/min chez un adulte en bonne santé, de 7 à 70 battements/min et ainsi de suite. Comme cette échelle est utilisée pour mesurer l'effort, l'essoufflement et la fatigue d'un individu lors d'un travail physique, l'échelle de Borg est très pertinente pour l'étude de la santé et de la sécurité au travail (Williams, 2017). Un exemple de cette échelle est donné ci-dessous (Tableau 2.2.1).



Tableau 2.2.1 Exemple de l'échelle de Borg.

Comment décrieriez-vous votre effort ?	Évaluation de Borg de l'effort	Exemples (pour la majorité des adultes <65ans)
Aucun	6	Lire un livre, regarder la télévision.
Très, très léger	6 à 8	Attacher ses chaussures.
Très léger	9 à 10	Des corvées – comme plier des vêtements – qui semblent demander un peu d'effort.
Un peu difficile	13 à 14	Marche rapide ou autres activités qui nécessitent un effort modéré et accélèrent les battements du cœur et la respiration, mais qui n'essoufflent pas.
Difficile	15 à 16	Faire du vélo, de la natation, ou d'autres activités qui demandent des efforts vigoureux, font battre le cœur et accélèrent la respiration.
Très difficile	17 à 18	Le plus haut niveau d'activité qu'il est possible de maintenir.
Très, très difficile	19 à 20	Un coup de pied final dans une course ou une autre activité qu'il n'est pas possible de maintenir longtemps.

Borg a également développé une échelle *Category Ratio-10* (CR-10, Tableau 2.2.2). Il s'agit d'une échelle basée sur la précédente, mais contenant seulement 10 niveaux. Le 10<sup>e</sup> représente une intensité d'activité extrême (Williams, 2017).

Tableau 2.2.2 Exemple de l'échelle CR10 de Borg.

Score	Niveau d'effort
0	Pas d'effort du tout
0.5	Très, très léger (juste perceptible)
1	Très léger
2	Léger
3	Modéré
4	Un peu sévère
5	Sévère
6	
7	Très sévère
8	
9	Très, très sévère (presque maximal)
10	Maximal

Un autre exemple est l'échelle sur le besoin de récupération qui pose 11 questions pour évaluer le besoin de repos des travailleurs (van Veldhoven & Broersen, 2003). Cette échelle a pour but d'identifier les premiers symptômes de fatigue au travail en suivant le besoin de récupération au

cours des dernières heures de travail ou immédiatement après le travail. Un exemple de cette échelle est donné ci-dessous (Tableau 2.2.3).

Tableau 2.2.3 Exemple de l'échelle sur le besoin de récupération.

# items	Définition
1	J'ai du mal à me détendre à la fin d'une journée de travail.
2	À la fin de la journée de travail, je me sens vraiment épuisé.
3	À cause de mon travail, à la fin de la journée de travail, je me suis plutôt épuisé.
4	Après le repas du soir, je me sens globalement en forme.
5	En général, je ne commence à me sentir détendu que le deuxième jour de repos.
6	J'ai du mal à me concentrer sur mon temps libre après le travail.
7	Je ne peux pas vraiment montrer d'intérêt pour les autres quand je viens moi-même de rentrer à la maison.
8	En général, j'ai besoin de plus d'une heure avant de me sentir complètement récupéré après le travail.
9	Quand je rentre du travail, j'ai besoin d'être tranquille pendant un moment.
10	Souvent, après une journée de travail, je me sens si fatigué que je ne peux pas m'impliquer dans d'autres activités.
11	Une sensation de fatigue m'empêche de faire mon travail aussi bien que je le ferais normalement pendant la dernière partie de ma journée de travail.

Enfin, (Zhang, M. et al., 2015) ont développé et validé une échelle d'évaluation de la fatigue pour les travailleurs de la construction (*Fatigue Assessment Scale for U.S. Construction Workers* (FASCW)) en examinant les échelles existantes dans la littérature scientifique. Ils ont développé une approche en deux étapes afin d'identifier les 10 éléments qui représentent le mieux les symptômes de fatigue les plus typiques ressentis par les travailleurs de la construction (Tableau 2.2.4).

Tableau 2.2.4 Exemple du FASCW.

Items	Type de fatigue
Je manque d'énergie	Fatigue mentale
J'ai moins de force musculaire	Fatigue physique
Mes jambes sont fatiguées/lourdes	Fatigue physique
Le mouvement de mon corps ralentit	Fatigue physique
Mes pensées vagabondent facilement	Fatigue mentale
Mes bras/jambes sont engourdis	Fatigue physique
Mes épaules sont raides/me font mal	Fatigue physique
Mes articulations (ex. genou, coude) me font mal.	Fatigue physique
Mes yeux sont tendus	Fatigue mentale
Je ressens des crampes dans les muscles	Fatigue physique

Parmi les 10 items, 7 sont associés à la fatigue physique du travailleur et 3 à la fatigue mentale. Cette échelle permet donc d'évaluer les deux types de fatigue et leurs corrélations. Les sujets

doivent évaluer les items sur une échelle de 1 à 5. L'étude des réponses permet de quantifier le niveau de fatigue – physique et mentale – du sujet.

Les méthodes subjectives sont faciles à mettre en œuvre mais ne conviennent pas pour le suivi en temps réel de la fatigue physique des travailleurs de la construction (Yu et al., 2019). Les raisons sont les suivantes : a) Le processus de questionnement verbal peut interrompre l'activité du travailleur (Anwer, Shahnawaz et al., 2021; Sedighi Maman et al., 2020). b) L'auto-évaluation ne fournit que l'état final de fatigue, ce qui limite l'utilisation de ces données dans l'étude du développement de la fatigue (Yu et al., 2019). Ces méthodes sont donc peu pratiques pour la surveillance continue de la fatigue (Anwer, Shahnawaz et al., 2021; Yu et al., 2019).

Dans cette étude, l'échelle de Borg a été utilisée pour recueillir le niveau de fatigue subjectif ressenti par les participants en raison de sa simplicité et de sa large utilisation dans la littérature ergonomique (Sedighi Maman et al., 2017). Cette perception subjective a été utilisée pour étiqueter les données enregistrées en temps réel par les capteurs.

### **2.2.2. Méthodes objectives**

Ces méthodes reposent sur l'utilisation d'une ou plusieurs technologies de capteurs pour surveiller des signaux physiologiques et/ou des changements biomécaniques du corps humain (Sedighi Maman et al., 2020).

Afin de surmonter les limites des méthodes subjectives, plusieurs chercheurs ont tenté de surveiller diverses métriques physiologiques à l'aide de capteurs portables. La portabilité des capteurs permet l'évaluation de la fatigue physique en temps réel avec une interférence minimale avec les travailleurs de la construction (Anwer, Shahnawaz et al., 2021). En effet, avec les progrès continus des technologies portables et la diminution de leurs coûts, les capteurs portables sont de très bons candidats pour les systèmes de surveillance de la fatigue. Les avantages de ces technologies incluent la portabilité, le caractère non invasif, le faible prix, la multifonctionnalité et la fiabilité (Sedighi Maman et al., 2020).

Ces dernières années, de plus en plus d'études ont utilisé ce type de technologie dans le but de surveiller diverses métriques physiologiques et biomécaniques. Les études les plus récentes de la

littérature peuvent être classées en deux groupes, les études descriptives et les études prédictives, comme détaillées ci-dessous.

### 1) Études descriptives :

L'objectif principal des études descriptives est d'identifier les corrélations entre les signaux physiologiques choisis et l'occurrence et/ou le développement de la fatigue physique. En effet, le but de ces études est d'identifier les signaux physiologiques qui sont les plus pertinents pour le suivi de la fatigue. Pour cela, les chercheurs comparent généralement l'évolution de ces signaux avec la perception de fatigue ressentie par les participants (obtenue par les méthodes subjectives présentées plus tôt) et les facteurs environnants (comme les lourdes charges de travail). Certaines de ces études, étudiant respectivement les signaux cardiovasculaires, de thermorégulation et inertiels sont détaillées ci-dessous.

L'étude de (Hwang & Lee, 2017) s'est concentrée sur la fréquence cardiaque. En effet, la fréquence cardiaque est la métrique physiologique la plus couramment utilisée pour surveiller l'effort physique chez les travailleurs de la construction (Anwer, S. et al., 2020; Aryal et al., 2017; Sedighi Maman et al., 2017; Sedighi Maman et al., 2020; Umer et al., 2020). Physiquement, la charge cardiovasculaire augmente à mesure que la contraction musculaire augmente. Le cœur a besoin de pomper plus de sang dans tout le corps. La métrique étudiée par (Hwang & Lee, 2017) correspond au pourcentage de la capacité de fréquence cardiaque utilisée par un individu (% *Heart Rate Reserve* (%HRR)). Ce pourcentage est explicité par l'Équation 1, dans laquelle  $HR_{courant}$  est la fréquence cardiaque mesurée par le capteur en temps réel,  $HR_{max}$  correspond à la fréquence cardiaque maximale que peut atteindre un individu et est définie par  $HR_{max} = 220 - age$ .  $HR_{repos}$  représente le rythme cardiaque au repos de l'individu. .

$$\%HRR = \frac{HR_{courant} - HR_{repos}}{HR_{max} - HR_{repos}} \quad (1)$$

L'objectif principal de cette étude était d'examiner le potentiel de cette mesure continue pour capturer toute variation significative de la demande physique, en étudiant en profondeur les facteurs affectant ces demandes physiques (comme les tâches réalisées, et les facteurs individuels et environnementaux). Pour cela, les chercheurs ont collecté les données cardiovasculaires des sujets à l'aide d'un capteur utilisant une technique de photopléthysmographie (PPG) qui détecte les débits

sanguins contrôlés par l'action de pompage du cœur en capturant l'intensité lumineuse réfléchie par la peau, sur la base d'une LED et d'un photodétecteur. Les mesures de fréquence cardiaque ont ainsi été réalisées auprès de 19 travailleurs, dont 14 travailleurs de la construction travaillant sur leur propre site (menuisiers, maçons, électriciens et ouvriers) et 5 travaillant hors site, dans un atelier de fabrication de tôle. Pour chaque participant, les mesures ont été prises durant une journée entière ou une demi-journée. Les résultats de leur recherche montrent que la mesure continue du %HRR à l'aide d'un bracelet PPG fournit de riches informations pour comprendre, gérer et concevoir les exigences physiques des travaux de construction.

Dans la même perspective, l'étude de (Anwer, S. et al., 2020) a cherché à étudier la combinaison des mesures cardiovasculaires et thermorégulatrices pour le suivi de la fatigue physique des travailleurs de la construction. En effet, pendant une activité physique, la température corporelle centrale augmente et le corps tente de maintenir cette température centrale dans une limite physiologique normale grâce à la thermorégulation. En particulier, la peau joue son rôle en aidant le transfert de chaleur du corps vers l'atmosphère. Ainsi, la température de la peau augmente pendant la réalisation d'activité physiquement exigeante. (Anwer, S. et al., 2020) ont cherché à montrer si ces variations étaient significatives et si, corrélées à des mesures cardiovasculaires, permettaient effectivement d'identifier la fatigue physique. Pour cela, les chercheurs ont simulé de manière contrôlée une série d'activités inspirées de celles du domaine de la construction. Ces tâches ont été réalisées par 25 participants jusqu'à ce qu'ils ressentent une fatigue physique très forte (niveau de fatigue > 15 sur l'échelle de Borg). Afin d'obtenir la fréquence cardiaque, la fréquence respiratoire et la température de la peau des participants, le système LifeMonitor EQ02 (Equivital™, Cambridge, UK) a été utilisé. Ce système se compose d'un gilet textile incrusté de nombreux capteurs. Il a été conçu pour mesurer en temps réel l'électrocardiographie et la température cutanée locale (Figure 2.2.1 A).



Figure 2.2.1 A : Système LifeMonitor EQ02 porté. B : Montre PPG. Images directement extraites de (Anwer, S. et al., 2020).

Une montre-bracelet PPG placée au poignet droit a été choisie pour évaluer l'activité électrodermale (Figure 2.2.1 B) et apporter une deuxième mesure de la fréquence cardiaque. Enfin, pour obtenir une évaluation subjective de la fatigue physique, l'échelle de Borg a été utilisée. En étudiant les corrélations entre l'évolution des signaux cardiovasculaires et de thermorégulation et le score de fatigue subjectif donné par les participants, l'étude a montré que les paramètres cardiorespiratoires et la température cutanée locale étaient de bons substituts pour mesurer la fatigue physique, mais qu'inversement, l'activité électrodermale au poignet droit ne l'était pas.

Enfin, (Zhang, L. et al., 2019) ont basé leur étude sur le suivi des métriques liées aux mouvements et accélérations du corps ou d'une partie du corps, et plus spécifiquement la secousse (*jerk*). La secousse est la dérivée temporelle de l'accélération comme définie dans l'Équation 2.

$$Secousse = \frac{da}{dt} \quad (2)$$

Où  $a = \sqrt{a_x^2 + a_y^2 + a_z^2}$

Puisque la fatigue physique affecte négativement le contrôle et la qualité des mouvements, les travailleurs fatigués devraient hypothétiquement présenter des valeurs de secousses accrues. Les unités de mesures inertielles (*Inertial Measurement Units* (IMUs)) sont des capteurs peu coûteux et fiables qui sont utilisés pour capturer les données d'accélération et de mouvement d'une personne (Sedighi Maman et al., 2020). Ils sont composés d'un accéléromètre, d'un gyroscope et d'un magnétomètre. (Zhang, L. et al., 2019) ont évalué la faisabilité de l'utilisation de la secousse comme indicateur du développement de la fatigue physique au cours de la réalisation d'une tâche physiquement exigeante. Pour cela, ils ont recruté 32 individus de différents niveaux d'expérience en maçonnerie et ont, pour chacun, comparé les valeurs de secousse prises à 7 endroits du corps à

l'aide de capteurs IMUs, à l'état de repos et à l'état de fatigue. Leur étude a permis de montrer que la secousse est effectivement un bon indicateur de fatigue physique.

## 2) Études prédictives.

L'objectif principal des études prédictives est de réaliser une prédiction de l'occurrence et/ou du développement la fatigue à l'aide de techniques d'apprentissage supervisé, prenant en entrée des variables spécifiques issues des signaux physiologiques mesurés. Le Tableau 2.2.5 répertorie les grandes caractéristiques d'une partie des études prédictives les plus récentes sur le sujet.

Tableau 2.2.5 Résumé des méthodes de classification et des résultats pour la détection de fatigue.

	Protocole d'induction de la fatigue	Métriques physiologiques	Capteurs utilisés	Méthode de classification	Résultats
(Sedighi Maman et al., 2017)	MMH SPI PA (8 participants)	FC (poitrine) Mouvements & accélérations (poignet, hanche, cheville et torse)	Sangle pectorale optique (Polar CR800X) IMU (Shimmer3)	Régression logistique pénalisée (binaire : fatigue vs non fatigué)	Plus haute sensibilité : <b>1</b> Plus haute spécificité : <b>0.79</b>
(Baghdadi et al., 2018)	MMH (20 participants)	Mouvements & accélérations (cheville)	IMU (Shimmer3)	SVM (binaire : fatigue vs non fatigué)	Précision : <b>90%</b>
(Karvekar et al., 2019)	Squats (24 participants)	Mouvements & accélérations (mollet)	Téléphone portable	SVM binaire (fatigué vs non-fatigué) SVM Multi-classes (4 niveaux de fatigue)	Précision modèle binaire : <b>94%</b> Précision modèle multi-classes : <b>61%</b>
(Sedighi Maman et al., 2020)	MMH (24 participants) SPI (13 participants)	FC (poitrine) Mouvements & accélérations (poignet, hanche, cheville et torse)	Sangle pectorale optique (Polar CR800X) IMU (Shimmer3)	Classificateur <i>Random Forest</i> (binaire : fatigue vs non fatigué)	Précision (MMH): <b>87.9%</b> Précision (SPI): <b>89.7%</b>
(Aryal et al., 2017)	Tâche de construction en laboratoire (12 participants)	FC (poitrine) Thermorégulation (temple, joue, front, oreilles) EEG (front)	Garmin vivofit, Neurosky Mindware, Capteur de température (MLX90614)	Classificateur <i>Boosted Trees</i> - Multi-classes (4 niveaux de fatigue)	Précision modèle juste FC : <b>59%</b> Précision modèle FC et température : <b>82.60%</b>
(Umer et al., 2020)	MMH (10 participants)	Cardiorespiratoires (FC, FB, ECG) Thermorégulation (torse)	Veste pectorale EQ02 LifeMonitor	Classificateur <i>Bagged Trees</i> - Multi-classes (6-20 Echelle de Borg)	Précision 1 modèle pour tous : <b>95.3 %</b> Précision 1 modèle/participant : <b>96.7%</b>



Les études présentées dans le Tableau 2.2.5 peuvent être séparées en deux groupes en fonction des métriques physiologiques utilisées pour la prédiction, à savoir les métriques inertielles et les métriques cardiovasculaires et thermorégulatrices.

*Métriques inertielles* - Ce sous-groupe est composé des études de (Sedighi Maman et al., 2017), (Baghdadi et al., 2018), (Karvekar et al., 2019) et (Sedighi Maman et al., 2020).

L'étude de (Karvekar et al., 2019) avait un double objectif : être capable de détecter l'occurrence de la fatigue et être capable de suivre son développement en utilisant les capteurs d'un téléphone portable. Pour cela, 24 participants, tous équipés d'un téléphone portable au mollet, ont réalisé des squats. Les sujets renseignaient leurs niveaux de fatigue via l'échelle de Borg toutes les deux minutes. Afin de prédire l'occurrence et le développement de la fatigue physique des participants pendant la réalisation de leur exercice physique, deux modèles de classification ont été développés. La prédiction de l'occurrence de la fatigue physique revient à classer les données entre deux états : fatigué ou non fatigué (Figure 2.2.2). La prédiction du développement de la fatigue revient quant à elle, à classer les données entre 4 niveaux de fatigue : faible, moyen, élevé et très élevé (Figure 2.2.3). Dans les deux cas, un modèle de machine à vecteur de support (*Support Vector Machine* (SVM)) a été choisi. La motivation principale d'un modèle SVM est de séparer plusieurs classes dans l'ensemble des données d'apprentissage avec une surface (hyperplan) qui maximise la marge entre elles (Awad & Khanna, 2015).




Figure 2.2.2 Modèle de classification binaire avec un classificateur de type SVM proposé par (Karvekar et al., 2019).

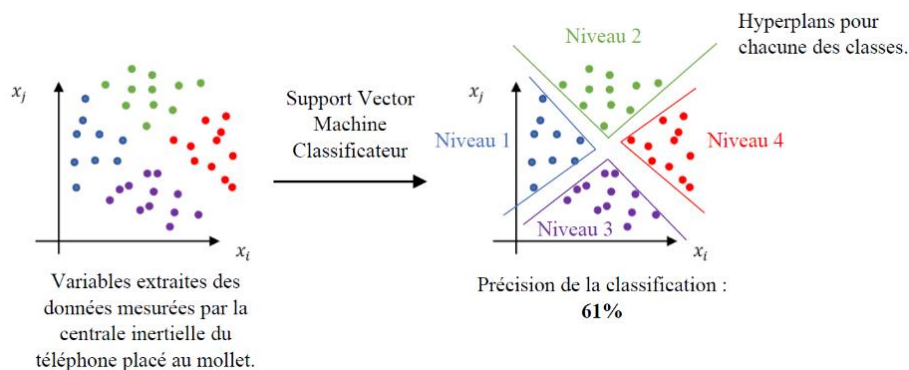


Figure 2.2.3 Modèle de classification multi-classes avec un classificateur de type SVM proposé par (Karvekar et al., 2019).

Leurs résultats ont montré qu'ils étaient capables de prédire l'occurrence de la fatigue avec une précision de 91%, et de prédire le niveau de fatigue (entre 1 et 4) avec une précision de 61%.

De leur côté, les études de (Sedighi Maman et al., 2017), (Baghdadi et al., 2018) et (Sedighi Maman et al., 2020) utilisent toutes des capteurs IMUs de type Shimmer3 (Shimmer, Dublin, Ireland, <https://shimmersensing.com/product/shimmer3-imu-unit/>).

L'étude de (Baghdadi et al., 2018) s'est concentrée sur la détection de fatigue à travers le suivi des patrons de marche. Pour cela, ils ont d'abord utilisé un algorithme de segmentation de la marche, permettant l'extraction de caractéristiques pertinentes (comme la longueur d'un pas) et ont ensuite entraîné un modèle de classification permettant de classer les états de fatigue (fatigué/non-fatigué), à partir de ces caractéristiques. Étant donné que leur modélisation se concentrait uniquement sur les paramètres de la marche, ils n'ont utilisé qu'un capteur IMU positionné au niveau de la cheville. Afin de valider leur méthode, ils ont équipé 20 sujets qui ont réalisé une activité de manutention manuelle en laboratoire. Leur approche, basée également sur un modèle SVM binaire, leur a permis de prédire l'état de fatigue des participants avec une précision de 90%.

Les études de (Sedighi Maman et al., 2017) et de (Sedighi Maman et al., 2020) ont été réalisées par le même groupe de recherche et sont à considérer de manière chronologique.

(Sedighi Maman et al., 2017) ont défini 3 tâches répétitives et physiquement exigeantes à savoir une tâche de manutention manuelle (*Manual Material Handling* (MMH), Figure 2.2.4), une tâche d'insertion et de ramassage de fournitures (*Supply Pickup and Insertion* (SPI), Figure 2.2.5) et une tâche d'assemblage de pièces (*Parts Assembly* (PA), Figure 2.2.6).



Figure 2.2.4 Tâche de manutention manuelle (Maman et al. (2017))



Figure 2.2.5 Tâche de ramassage et d'insertion (Maman et al. (2017))



Figure 2.2.6 Tâche d'assemblage (Maman et al. (2017))

Huit participants ont réalisé ces 3 tâches en étant équipés de cinq capteurs : 1 capteur de fréquence cardiaque de type Polar CR800X (Polar) (sous les vêtements, au niveau de la poitrine) et 4 capteurs IMUs positionnés au niveau du poignet, de la hanche, de la cheville et du torse.

Un des objectifs de l'étude était de prédire l'occurrence de la fatigue des participants (fatigué ou non fatigué) en utilisant un classificateur prenant en entrée les données issues de tous les sujets et de toutes les tâches. (Sedighi Maman et al., 2017) ont choisi de classifier leurs données à l'aide d'une régression logistique pénalisée. La régression logistique est une méthode de classification linéaire dont la fonction prédictive consiste en une combinaison linéaire des variables d'entrées. L'utilisation de la régression logistique sans aucune régularisation supplémentaire garantit rarement de bons résultats, en raison d'un possible surapprentissage. Ce surapprentissage se produit généralement lorsque le nombre d'observations ou d'exemples d'apprentissage n'est pas assez grand par rapport au nombre de variables caractéristiques. Il est donc nécessaire d'ajouter une régularisation afin d'obtenir un classificateur stable. Une régularisation possible est la pénalisation. Il existe 3 types de pénalisation possibles : *LASSO*, *ridge regression* et *elastic-net*. (Sedighi Maman et al., 2017) ont testé les trois types de pénalisation et ont obtenu les meilleurs résultats avec une

régression logistique pénalisée par LASSO. En effet, leur approche permet de prédire l'occurrence de la fatigue (fatigué/non fatigué) avec une sensibilité maximale de 0.95 et une spécificité maximale de 0.89.

L'étude de (Sedighi Maman et al., 2020) vient compléter l'étude précédente. En effet, un de leurs principaux objectifs était de prédire l'occurrence de la fatigue des participants, comme l'étude précédente, mais en essayant de réduire au maximum le nombre de capteurs utilisés. Pour cela, ils ont équipé 37 participants de cinq capteurs (les mêmes que pour l'étude de 2017). 24 sujets ont réalisé la tâche MMH et 13 la tâche SPI. La tâche PA n'a pas été reprise car elle ne provoquait pas suffisamment de fatigue. À partir des données obtenues, ils ont entraîné un classificateur de type forêts d'arbres aléatoires (*Random Forest* (RF)) prenant en entrée les informations issues de tous les capteurs, puis seulement du moniteur de fréquence cardiaque et de 3 IMUs, puis seulement du moniteur de fréquence cardiaque et de 2 IMUS, etc. Les modèles de *Random Forest* sont des modèles qui combinent un ensemble d'arbres décisionnels en parallèle. Pour les tâches de classification, la sortie du modèle est la classe sélectionnée par la majorité des arbres. Les résultats de (Sedighi Maman et al., 2020) montrent qu'un capteur IMU placé sur le torse est suffisant pour la détection de l'occurrence de la fatigue (classification entre les états fatigué et non fatigué) avec une précision moyenne de 85%.

*Métriques cardiovasculaires et de thermorégulation* – Les études de (Umer et al., 2020), (Aryal et al., 2017) et (Garimella Surya et al., 2020) ont exploré l'utilisation des signaux cardiovasculaires et thermorégulateurs pour la prédiction de l'occurrence et du développement de la fatigue.

(Aryal et al., 2017) ont développé un modèle de prédiction de la fatigue basé sur la fréquence cardiaque et la température de la peau. Les chercheurs de l'étude avaient un double objectif. Le premier était de présenter une approche en temps réel permettant la prédiction du développement de la fatigue physique par le suivi de métriques cardiovasculaires et thermorégulatrices. Le deuxième était d'analyser l'utilité de chacun des capteurs utilisés. Pour répondre à leurs objectifs, 12 participants équipés d'un ensemble de capteurs ont réalisé une tâche de construction simulée en laboratoire. En effet, chaque participant était équipé de deux moniteurs de fréquence cardiaque (au niveau de la poitrine et du poignet), d'un capteur électroencéphalographique (EEG) au niveau du front (sous le casque de sécurité) et de 4 capteurs de température infrarouges placés sur le casque

de sécurité et prenant les mesures au niveau du front, de la tempe, des oreilles et des joues (Figure 2.2.7).




Figure 2.2.7 Placement des capteurs dans l'étude (Aryal et al., 2017)

À partir de ces données, ils ont entraîné un modèle d'arbres à gradient amélioré (*Boosted Trees*) permettant de classifier les données selon 4 niveaux de fatigue : faible, moyen, élevé et très élevé. Tout comme le modèle du *Random Forest*, le modèle du *Boosted Trees* est un modèle qui regroupe un ensemble d'arbres décisionnels en série et où chaque arbre tente de minimiser les erreurs de l'arbre précédent. Le modèle final agrège les résultats de chacune des étapes.

Leurs résultats ont montré que l'information combinée du moniteur de fréquence cardiaque et des capteurs de température permet de prédire le développement de la fatigue physique avec une précision de 82%. Un autre résultat majeur est que cette précision de prédiction diminue respectivement à 79% et 59%, si seulement la température de la peau à la tempe ou la fréquence cardiaque sont considérées.

(Umer et al., 2020) ont proposé une étude assez similaire à la précédente. En effet, leur objectif était de prédire le développement de la fatigue en suivant les métriques de fréquence cardiaque et thermorégulatrices. Les deux grandes différences résident dans les capteurs utilisés et le type de classification réalisée. En effet, (Umer et al., 2020) ont utilisé le LifeMonitor EQ02 qui permet de prendre le rythme cardiaque, la température de la peau et le rythme de respiration. Pour la classification, ils ont ajouté de la granularité à leur modèle en tentant de prédire le développement de la fatigue selon les items de Borg, de 6 à 20. Afin de répondre à leur objectif, ils ont équipé 10 participants réalisant une tâche de manutention manuelle en laboratoire. À l'aide des données obtenues, ils ont testé plusieurs algorithmes de classification et obtiennent les meilleures performances avec un modèle d'ensachage d'arbres (*Bagged Trees*). Ce modèle est très proche du

modèle du *Random Forest*. La principale différence est que pour ce modèle, toutes les caractéristiques d'entrées sont utilisées pour chacun des arbres décisionnels.

Leur étude a montré qu'il était possible de quantifier la fatigue physique d'un sujet à partir des données cardiovasculaires et de température, avec une précision de 95.3%. (Umer et al., 2020) ont réussi à augmenter cette précision à 96.7% en réalisant un modèle de quantification de la fatigue par sujet.

Ces études ont montré que les signaux suivants :

- la fréquence cardiaque,
- la respiration,
- la température de parties spécifiques du corps (joues, oreille, front et tempe),
- la secousse,

sont des signaux indicateurs de fatigue.

Une description du principe de chacun des modèles de classification présentés dans la section ci-dessus est donnée dans l'Annexe A.

## **2.3. Méthodes en apprentissage automatique**

L'étude qui est présentée dans ce mémoire vise à quantifier la fatigue physique par la combinaison d'une centrale inertielle et d'un moniteur de fréquence cardiaque lors d'activités multitâches dans un environnement non-contrôlé. Il s'agit donc d'une étude prédictive. Ainsi, des méthodes d'apprentissage automatique vont être utilisées. Dans cette section, les diverses étapes d'un problème général d'apprentissage automatique sont détaillées.

### **2.3.1. Définition de l'apprentissage automatique**

L'apprentissage automatique est une technologie d'intelligence artificielle permettant aux ordinateurs d'apprendre sans avoir été programmés explicitement à cet effet. Il existe deux types d'apprentissage automatique, l'apprentissage supervisé et l'apprentissage non supervisé. Les algorithmes d'apprentissage supervisés sont les plus couramment utilisés. Avec ce type de modèle, l'ingénieur sert de guide et enseigne à l'algorithme les conclusions qu'il doit tirer (Amini, 2020). Les algorithmes de régressions linéaire et logistique, la classification en plusieurs catégories et les

machines à vecteurs de support sont des exemples d'apprentissage automatique supervisé. L'autre type de modèle est l'apprentissage non supervisé. Ce type de modèle utilise une approche plus indépendante dans laquelle une machine apprend à identifier des processus, relations et schémas complexes sans guidage humain (Fard, 2020). Ainsi, l'apprentissage automatique non supervisé nécessite une base de données sans étiquette ni résultat spécifique défini.

Étant donné que pour cette étude, les données sont étiquetées à partir des perceptions subjectives de fatigue des sujets, c'est un modèle d'apprentissage supervisé qui a été choisi.

Parmi les problèmes d'apprentissage supervisé, il est possible de distinguer ceux de régression et ceux de classification. Le but de la régression est d'estimer une valeur numérique de sortie à partir des valeurs d'un ensemble de caractéristiques en entrée (Géron, 2019). Ce type de modèle est par exemple utilisé pour la prédiction de la valeur des biens immobiliers, en fonction de la superficie du bien ou du nombre de chambres par exemple (Géron, 2019). La classification quant à elle, réside dans l'identification de la classe à laquelle un nouvel élément appartient, sur la base d'un jeu de données d'entraînement contenant des exemples dont les classes sont connues (Géron, 2019).

Il existe plusieurs types de classification :

1. Les classifications binaires : Ce type de classification fait référence aux tâches pour lesquelles les exemples d'entrée doivent être attribués à 2 classes. Un exemple courant de ce type de classification est la détection de spams dans les courriels (deux types de classes : *spam* ou *non spam*).
2. Les classifications multi-classes : Ce type de classification fait référence aux tâches qui doivent attribuer aux exemples d'entrée plus de 2 classes. Un exemple courant est la classification des espèces de fleurs d'iris (par exemple *Setosa*, *Versicolour*, *Virginica*...).
3. Les classifications multi-étiquettes : Ce type de classification fait référence aux tâches de classification qui ont deux ou plusieurs classes mais pour lesquelles un exemple d'entrée peut être attribué à une ou plusieurs de ces classes. Un exemple de cette classification est la détection d'objets sur une photo. En effet, sur une photo il est possible d'identifier plusieurs objets comme une pomme, une chaise etc. Chacun de ces objets correspondant à une classe de prédiction distincte.

4. Les classifications déséquilibrées : Ce type de classification fait référence aux tâches de classification pour lesquelles le nombre d'exemples dans chacune des classes est inégalement réparti. Les classifications binaires ainsi que les classifications multi-classes peuvent être déséquilibrées.

D'après les études citées dans la section précédente (section 2.2.2), ce sont en général les modèles de classification qui sont choisis pour classer les données d'entrée selon les états fatigués ou non fatigués, ou selon des états plus précis (faible, moyen, élevé, très élevé). Cette étude se concentre donc sur les modèles de classification. Le schéma suivant (Figure 2.3.1) explicite les différentes étapes suivies lors d'un problème d'apprentissage automatique supervisé de classification :

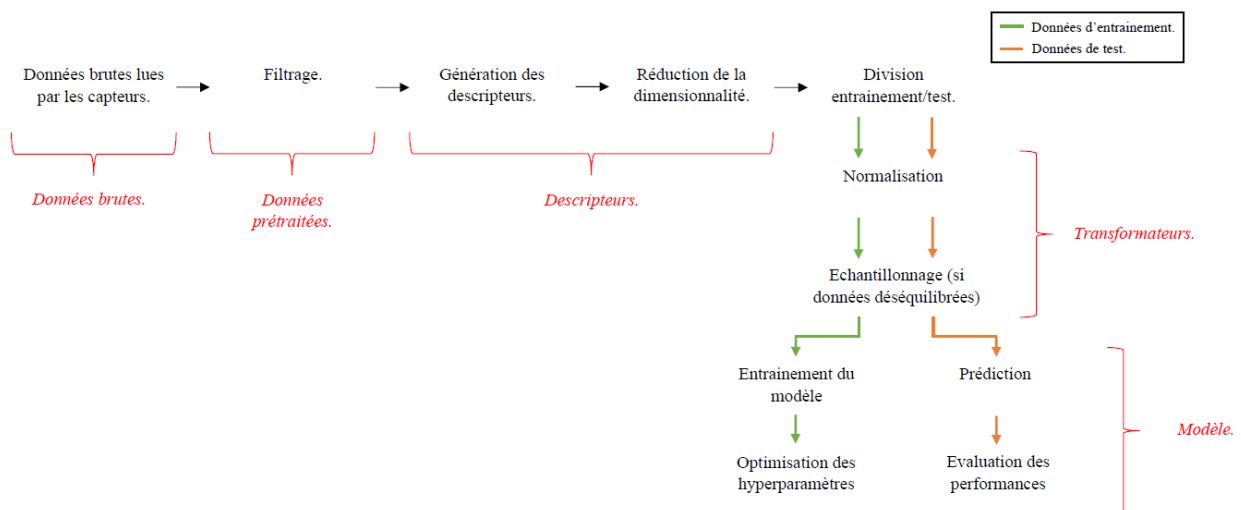


Figure 2.3.1 Schéma représentatif des étapes d'un problème d'apprentissage automatique supervisé

Les différentes étapes présentées dans ce schéma sont détaillées dans les paragraphes suivants.

### 2.3.2. Données brutes

Tout problème d'apprentissage automatique supervisé repose sur des données. Ces données se présentent par paires, composées des données qui serviront d'entrée au modèle et des sorties, appelées étiquettes, qui correspondent à la solution que le modèle doit apprendre (Tableau 2.3.1).



Tableau 2.3.1 Données d'entrées adaptées à un modèle d'apprentissage supervisé.

Entrée 1	Sortie 1
Entrée 2	Sortie 2

La capacité d'apprentissage du modèle repose essentiellement sur la qualité de ces données. En effet, si l'ensemble des données de départ n'a pas été créé de manière standardisé, ou qu'il possède de nombreuses données manquantes ou approximatives, le modèle aura du mal à généraliser. Afin d'obtenir les données les plus pertinentes, il est nécessaire de les prétraiter.

### 2.3.3. Prétraitement des données

La première étape du prétraitement des données consiste en l'exploration de celles-ci. Cela signifie les observer et identifier les données manquantes. En fonction de l'outil de traitement utilisé (Python, Matlab, R), diverses fonctions sont proposées. Puis, une fois les données manquantes et/ou aberrantes retirées de l'ensemble des données, il est nécessaire de filtrer les données. L'étape de filtrage est primordiale car sans cela, il est possible que le modèle prenne en compte le bruit dans son apprentissage. Le choix du type de filtre utilisé dépend du problème et du type de données.

### 2.3.4. Génération des descripteurs

Une fois que les données d'entrées ont été visualisées, nettoyées et filtrées, il est nécessaire de les adapter afin qu'elles puissent être comprises par le modèle. En effet, dans les études mentionnées dans la partie précédente et dans cette étude, les données d'entrées correspondent aux données lues par les capteurs en temps réel. Il s'agit donc de séquences de valeurs numériques indexées dans le temps, avec un temps de pas constant séparant deux observations successives. Ce sont des séries temporelles (Tableau 2.3.2) (Géron, 2019).

Tableau 2.3.2 Série temporelle.

Temps 1	Valeur 1
Temps 2	Valeur 2

Afin que ces données puissent être comprises par un modèle d'apprentissage supervisé, elles doivent être transformées sous forme de paires (entrée/sortie) comme illustré dans le tableau Tableau 2.3.1.

Les « entrées » du Tableau 2.3.1 sont appelées descripteurs dans le domaine de l'apprentissage automatique. La transformation qui permet de passer de la configuration du Tableau 2.3.2 à celle du Tableau 2.3.1 revient à créer ou inventer de nouvelles entités d'entrées (= descripteurs) à partir des séries temporelles. Pour cela, la méthode la plus couramment utilisée dans la littérature, est la méthode des fenêtre temporelles glissantes statistiques (Dietterich, 2002). Cela revient à construire un ensemble de descripteurs en résumant les valeurs des données temporelles aux pas de temps précédents. Pour cela, des statistiques récapitulatives (comme la moyenne) sont calculées sur les valeurs d'une fenêtre temporelle glissante. Ces statistiques sont ensuite incluses en tant que descripteurs. Ce processus est résumé par la Figure 2.3.2.




Figure 2.3.2 Exemple de génération du descripteur mean\_grav.z à partir de la série temporelle grav.z. La statistique récapitulative utilisée est la moyenne, sur des fenêtres glissantes avec un chevauchement de 50%.

La performance de cette technique repose sur la taille des fenêtres temporelles, le possible chevauchement entre les fenêtres et l'information statistique extraite de celles-ci (Dietterich, 2002).

### 2.3.5. Réduction de la dimensionnalité

Seul un petit sous-ensemble de tous les descripteurs calculés est pertinent pour la quantification de la fatigue physique (Mustaqeem, Anwar, Majid et Khan, 2017). La réduction de la dimensionnalité

permet de projeter des données issues d'un espace de grande dimension dans un espace de plus petite dimension. Il s'agit d'une opération cruciale en apprentissage automatique pour lutter contre le fléau des grandes dimensions (*c-à-d* le fait que les grandes dimensions altèrent l'efficacité des méthodes). En effet, l'utilisation de tous les descripteurs peut entraîner une mauvaise généralisation du modèle, car le modèle peut reproduire du bruit dans les descripteurs, ce qui entraîne de mauvais résultats de classification (Drover, Howcroft, Kofman et Lemaire, 2017). La réduction de la dimensionnalité est considérée comme une étape de prétraitement bien connue dans l'exploration de données, la modélisation, la visualisation et l'analyse de données (Mustaqeem et al., 2017). Les avantages à réduire la dimensionnalité de l'espace d'entrée sont que l'algorithme d'apprentissage s'entraîne plus rapidement, la complexité du modèle est réduite, le modèle devient plus facile à interpréter, la précision du modèle est améliorée si le bon sous-ensemble est choisi et enfin, cela permet de réduire le surapprentissage.

Il existe plusieurs méthodes de réduction de la dimensionnalité comme sélectionner un sous-ensemble de descripteur, ou recréer totalement de nouveaux descripteurs dans un espace plus limité. Dans la littérature, la technique de sélection d'un sous ensemble est la plus couramment utilisée (Sedighi Maman et al., 2020). Il existe 3 méthodes permettant de trouver le meilleur sous-ensemble :

1. La méthode de filtrage : Pour cette méthode, les descripteurs sont sélectionnés sur la base de leur score dans divers tests statistiques pour leur corrélation avec la classe cible.
2. La méthode d'emballage: Pour ce genre de méthode, un sous ensemble de descripteurs est choisi et le modèle est entraîné avec celui-ci. Sur la base des inférences tirées de ce modèle, certains descripteurs sont ajoutés ou supprimés et le processus est relancé. Il s'agit donc essentiellement d'un problème de recherche. Cette méthode est très coûteuse en temps de calcul.
3. Les méthodes intégrées : Les méthodes intégrées combinent les qualités des méthodes de filtre et d'emballage. Elles sont implémentées par des algorithmes qui ont leur propre méthode de sélection. Les exemples les plus courants sont la régression LASSO et Ridge qui ont des fonctions de pénalisation intégrées pour réduire le surapprentissage.

### 2.3.6. Normalisation des descripteurs

L'apprentissage automatique, c'est un peu comme un jus de fruits. Afin d'obtenir le meilleur jus, il est nécessaire de mélanger les fruits dans les bonnes proportions et pas en fonction de leur taille. Il est donc nécessaire de se rappeler que même si une pomme est plus grosse qu'une fraise, une plus grosse quantité de pomme que de fraise ne donnera pas un meilleur jus. Il en va de même pour de nombreux algorithmes d'apprentissage automatique. Afin que tous les descripteurs soient représentés dans la même proportion, il est nécessaire de commencer par les mettre tous à la même échelle afin de s'assurer qu'un descripteur « trop gros » n'affecte pas le modèle. La méthode qui permet de mettre tous les descripteurs à la même échelle est la normalisation.

La normalisation est une méthode de pré-traitement des données qui permet de réduire la complexité des modèles (Siddiqi & Pak, 2021). C'est un préalable important aux algorithmes de regroupement car elle égalise les poids de chaque dimension, c'est-à-dire de chaque descripteur. À l'inverse, elle n'a pas d'utilité sur certains algorithmes basés sur des seuils comme les arbres de décision (Siddiqi & Pak, 2021).

Il existe un grand nombre de normalisation possibles. Parmi elles, les plus courantes sont la normalisation standard et la normalisation robuste (Géron, 2019).:

1. Normalisation standard : Cette technique normalise le descripteur en supprimant sa moyenne et en le normalisant à l'aide de sa variance. Soit  $x$  un descripteur, alors la normalisation standard appliquera la transformation suivante :

$$x_{normalisé} = \frac{x - \mu_{entraînement}}{\sigma_{entraînement}} \quad (3)$$

Où  $\mu_{entraînement}$  et  $\sigma_{entraînement}$  sont respectivement la moyenne et l'écart type du descripteur  $x$  sur tous les exemples d'entraînement.

2. Normalisation robuste : Pour ce type de normalisation, chaque descripteur se voit soustraire sa médiane et est divisé par l'intervalle interquartile (IQR) qui correspond à la différence entre le 75<sup>e</sup> et le 25<sup>e</sup> percentile.

$$x_{normalisé} = \frac{x - p50}{p75 - p25} \quad (4)$$

Où  $p_{50}$  correspond à la médiane,  $p_{75}$  au 75<sup>e</sup> percentile et  $p_{25}$  au 25<sup>e</sup> percentile du descripteur  $x$  sur tous les exemples d'entraînement.

Ce type de normalisation est généralement plus robuste aux valeurs aberrantes, car ces dernières influent sur la moyenne et l'écart type, mais pas les percentiles (Géron, 2019).

### 2.3.7. Cas d'un ensemble de données déséquilibrées

Cette situation fait référence aux tâches de classification pour lesquelles le nombre d'exemples dans chacune des classes est inégalement réparti. Ce genre de situation est problématique en apprentissage machine, car la performance des algorithmes de classification s'évalue principalement par la métrique d'exactitude. Or, voyant que la grande majorité des observations appartient à la même catégorie, il est probable d'obtenir un modèle peu intelligent qui va toujours prédire la classe dominante et pourtant donner de bonnes valeurs d'exactitude. Plusieurs méthodes ont été développées pour faire face à ce genre de situation. Les trois plus courantes sont :

1. Les méthodes de rééchantillonnage : Ces méthodes consistent à rééquilibrer le jeu de données soit par suréchantillonnage soit par sous-échantillonnage. Parmi elles, il existe deux approches principales basées sur le rééchantillonnage aléatoire. Le suréchantillonnage aléatoire consiste à sélectionner au hasard des exemples de la classe minoritaire, avec remplacement, et à les ajouter à l'ensemble de données d'entraînement. Le sous-échantillonnage aléatoire consiste à sélectionner au hasard des exemples de la classe majoritaire et à les supprimer de l'ensemble de données d'entraînement (Brownlee, 2018).
2. Les méthodes de génération d'exemples synthétiques : Ces méthodes reposent sur la création d'exemples synthétiques à partir de la classe minoritaire au lieu de créer de simples copies. La plus courante de ces méthodes est la technique de suréchantillonnage synthétique des minorités (*Synthetic Minority Over-sampling Technique (SMOTE)*). Cette technique fonctionne en sélectionnant les exemples les plus proches de l'exemple considéré et à tracer une ligne entre ces deux exemples. Le nouvel exemple créé se situe alors le long de cette ligne (Hadi Mansourifar, 2020).
3. Les méthodes algorithmiques : Ces méthodes reposent sur l'utilisation d'un modèle pénalisé. La classification pénalisée permet d'imposer des coûts supplémentaires au modèle

pour les erreurs de classification commises sur la classe minoritaire pendant la phase d'entraînement (Brownlee, 2018).

## CHAPITRE 3 PROBLÉMATIQUE ET OBJECTIFS

### 3.1 Résumé de la problématique

Le suivi et la quantification de la fatigue physique chez les travailleurs de la construction sont complexes en raison de la diversité des facteurs de celle-ci et de la diversité des tâches accomplies par ces travailleurs (section 2.1). À ce jour, plusieurs études ont proposé de nouvelles méthodes d'analyse de signaux indicateurs de fatigue physique suivis par des technologies portables. Cependant, une problématique majeure persiste. En effet, les recherches existantes obtiennent leurs résultats sur des données obtenues sur des tâches indépendantes réalisées en laboratoire ou lors d'activités totalement contrôlées (Aryal et al., 2017; Baghdadi et al., 2018; Karvekar et al., 2019; Sedighi Maman et al., 2020; Umer et al., 2020). Ainsi, il n'est pas encore possible, avec la revue de littérature actuelle, de confirmer que les méthodes innovantes proposées par celles-ci soient capables de quantifier la fatigue des travailleurs de la construction sur leur lieu de travail. En effet, ces études ne prennent pas en compte :

- Que les capteurs comme le LifeMonitor EQ02 qui se place sous les vêtements (Anwer, S. et al., 2020), ou les capteurs infrarouges qui se placent sur le casque de sécurité (Aryal et al., 2017) ne sont pas adaptés pour une utilisation quotidienne sur un chantier de la construction,
- Que les méthodes d'analyse et de traitement des données ne prennent pas en compte l'aspect transitoire, diversifié et dynamique d'un chantier de la construction (Techera et al., 2018). En effet, les travailleurs réalisent des tâches diversifiées, avec des cadences qui ne sont pas fixes, prennent des pauses, etc. Ces particularités ne se retrouvent pas lors des tests en laboratoire.

Il apparaît donc comme important de développer un système de capteurs ainsi qu'une méthode d'analyse et de traitement des données adaptés aux aspects diverse, transitoire et dynamique des chantiers de la construction. C'est pourquoi cette étude vise à concevoir et tester des solutions dont le but est de quantifier la fatigue physique par la combinaison d'une centrale inertielle et d'un moniteur de fréquence cardiaque lors d'activités multitâches dans un environnement non contrôlé. Il s'agit en effet d'une étape intermédiaire primordiale afin de vérifier que les techniques et résultats présentés dans la littérature sont applicables sur des chantiers de la construction.

## 3.2 Objectifs et hypothèses

### 3.2.1. Objectif général

L'objectif principal de l'étude présentée dans ce mémoire est de quantifier la fatigue physique en combinant une centrale inertielle et un moniteur de fréquence cardiaque lors d'activités multitâches dans un environnement non contrôlé.

### 3.2.2. Objectifs spécifiques

L'objectif général peut être divisé en 4 sous objectifs (SO):

**SO 1 :** Identifier les signaux physiologiques indicateurs de fatigue.

**SO 2 :** Concevoir un système de capteurs portables pour le suivi des signaux physiologiques indicateurs de fatigue.

**SO 3 :** Développer un protocole d'analyse et de traitement des données de quantification de la fatigue physique à partir des signaux physiologiques.

**SO 4 :** Valider le protocole par sa mise en application dans des situations distinctes, en laboratoire, dans un environnement non-contrôlé et sur un chantier professionnel de construction.

### 3.2.3. Hypothèses de recherche

Afin de répondre à ces objectifs, 4 hypothèses de recherche (HR) ont été posées :

**HR 1 :** L'équipement de capteurs développé ainsi que la méthode d'analyse et de traitement des données permettent de quantifier la fatigue physique sur une tâche répétitive, réalisée en laboratoire (*c-à-d* dans un environnement contrôlé).

**HR 2 :** Un modèle d'apprentissage supervisé permet de quantifier la fatigue physique d'un sujet à partir de données cardiaques et inertielles enregistrées lors de deux tâches répétitives distinctes réalisées en laboratoire.

**HR 3 :** L'équipement de capteurs développé ainsi que la méthode d'analyse et de traitement des données permettent de quantifier la fatigue physique lors d'une activité multitâche (composée de 4 tâches distinctes ou plus) réalisée dans un environnement non-contrôlé.



**HR 4 :** Le système de capteurs développé ainsi que la méthode d'analyse et de traitement des données permettent de quantifier la fatigue physique d'un travailleur de la construction lors de plusieurs demi-journées de travail consécutives.

## CHAPITRE 4 MÉTHODE GÉNÉRALE

La revue des connaissances a permis d'identifier les signaux physiologiques indicateurs de fatigue et de dresser une première liste des capteurs portables permettant leur suivi. À partir de ces informations, une méthode permettant de répondre aux 3 sous objectifs suivants à savoir, la conception de l'équipement des capteurs (SO2), le développement de l'analyse et du traitement des données (SO3) et les mises en application (SO4), a été suivie.

La première partie consiste à réaliser l'équipement de capteurs (SO2). Ensuite, l'analyse et le traitement des données ont été construits à partir d'un premier ensemble de données obtenu par la réalisation par 5 sujets d'une tâche physiquement exigeante en laboratoire (SO3). Enfin, 4 mises en application ont été organisées afin de collecter un grand nombre de données et de valider l'équipement de capteurs ainsi que la méthode d'analyse et de traitement des données dans diverses situations (SO4):

1. Lors de la réalisation d'une tâche répétitive physiquement exigeante réalisée en laboratoire (pendant 1 heure) par 15 sujets.
2. Lors de la réalisation de deux tâches répétitives physiquement exigeantes réalisées en laboratoire (2\*1 heure) par 15 sujets.
3. Lors d'une activité multitâche d'aménagement paysager réalisée dans un environnement non-contrôlé (pendant 5 heures) par 3 sujets.
4. Sur un chantier avec 3 travailleurs professionnels de la construction pendant 3 demi-journées consécutives de travail (3\*5 heures).

Le chapitre s'organise de la manière suivante. La section 4.1 se consacre à la conception de l'équipement de capteurs. La méthode d'analyse et de traitement des données est détaillée dans la section 4.2. Enfin, la description des mises en application est donnée dans la section 4.3.

## **4.1 Partie n°1 : Conception du système de capteurs**

### **4.1.1. Choix des capteurs**

La revue de la littérature a permis de dresser une première liste des signaux physiologiques potentiels et de capteurs permettant le suivi de la fatigue.

Afin de choisir les capteurs les plus adaptés aux travailleurs de la construction, une première rencontre a été réalisée avec des travailleurs de la construction. En effet, cette étude a été supportée par l'entreprise Technologies Biolift Inc. (<https://biolift.co/>), qui conçoit des exosquelettes d'assistance du tronc et des épaules pour les travailleurs de la construction. Étant donné qu'un système de suivi de la fatigue des travailleurs leur serait d'une grande aide pour la conception de leurs produits, les membres de l'entreprise ont accepté de me faire participer à leurs rencontres avec des travailleurs de la construction (de leurs entreprises partenaires). Lors de ces rencontres, j'ai pu échanger avec les travailleurs sur le type d'équipements qu'ils seraient prêts à porter quotidiennement. À l'aide de questionnaires, ces derniers m'ont rapporté qu'il serait impossible de leur demander de se déshabiller pour mettre un capteur sous leurs vêtements (perte de temps et problème d'intimité), et qu'installer des capteurs sur leur casque serait peu pratique puisqu'ils le retirent régulièrement (en été) pour s'éponger le front quand ils ont trop chaud ou mettent un bonnet dessous (en hiver) lorsqu'ils ont froid.

Ainsi, en regardant les avantages et inconvénients de chacun des signaux et des capteurs qui leur sont liés et à la suite de mon échange avec les travailleurs de la construction, les signaux de température (suivis par des capteurs infrarouges au niveau du casque, (Aryal et al., 2017)) et de respiration (suivis par un gilet qui se porte sous les vêtements, (Anwer, S. et al., 2020)) ont été éliminés. De plus, comme la revue de connaissance a montré que combiner au moins deux types de signaux permettait d'obtenir de meilleures performances, la fréquence cardiaque et les données inertielles ont été choisies. La fréquence cardiaque sera suivie par une montre utilisant une technique PPG (Biswas et al., 2019) et les données inertielles en utilisant un capteur IMU. En effet, même si le téléphone portable paraissait être une solution plus simple, ils sont souvent interdits sur les lieux de travail et posent le problème des données privées (difficile de montrer que seules les données inertielles sont suivies et pas les données GPS par exemple).

### 4.1.2. Cahier des charges

Deux aspects ont été pris en compte dans la conception de l'équipement de capteurs :

- L'aspect fonctionnel,
- L'aspect pratique.

*Aspect fonctionnel* : Le principal objectif de l'équipement de capteurs est d'être capable d'enregistrer en temps réel et de manière continue les informations collectées par les deux capteurs : le capteur IMU et le moniteur de fréquence cardiaque, et cela quel que soit l'environnement dans lequel l'expérience se déroule.

*Aspect pratique* : Étant donné que le système de capteurs est voué à être utilisé sur des chantiers professionnels de la construction, il est nécessaire de prendre en compte l'aspect pratique dans sa conception. L'objectif étant de limiter la perte du temps des travailleurs et de favoriser son acceptation par ces derniers.

Ainsi, les fonctions du système à développer sont :

- Lire les données de deux capteurs en temps réel, à une fréquence constante,
- Stocker sans connexion particulière un grand volume de données,
- Mettre en marche et calibrer rapidement et facilement le système.

Certaines contraintes sur la solution doivent être considérées, soit :

- Être léger et non invasif.
- Avoir une autonomie de plusieurs heures.

### 4.1.3. Placement des capteurs

(Sedighi Maman et al., 2017; Sedighi Maman et al., 2020) ont positionné l'IMU au niveau du torse. Cependant, selon les travailleurs de la construction interrogés, le torse est une position encombrante pour placer un capteur. Ainsi, l'IMU a été placé au milieu du dos.

Le moniteur de fréquence cardiaque a été placé sur le bras car le poignet (Sedighi Maman et al., 2017; Sedighi Maman et al., 2020) n'était pas un choix viable. En effet, sur des chantiers de

construction, les travailleurs ne sont pas toujours autorisés à porter des montres et/ou des bracelets pour des raisons de sécurité.

#### 4.1.4. Choix des composants et des capteurs

Les différents composants du système de capteurs ont été choisis à partir du cahier des charges et de leur placement. Le système peut être décomposé en 4 sous-ensembles :

1. Les capteurs,
2. Le système de contrôle et de stockage,
3. Le système d'alimentation,
4. L'interface d'utilisation.

##### 1) Les capteurs :

Le capteur IMU choisi est le BNO055 Adafruit 9-DOF Absolute Orientation IMU (Figure 4.1.1). Le principal avantage de ce capteur est qu'il est équipé d'un algorithme de fusion de l'accéléromètre, du gyroscope et du magnétomètre, qui fonctionne en temps réel. Cela signifie qu'en plus d'avoir accès aux données brutes des 3 capteurs, il est également possible d'avoir accès à d'autres données comme les quaternions, sans programmation supplémentaire. Le rôle des quaternions sera expliqué dans la partie suivante.

Étant donné que l'IMU et le moniteur de fréquence cardiaque sont placés à des endroits différents du corps et que le système ne doit pas être invasif, il était nécessaire de trouver un moniteur de



Figure 4.1.1 BNO055  
Adafruit 9-DOF Absolute  
Orientation IMU



Figure 4.1.2 Montre Coospo  
HW706 utilisée pour la mesure de  
la fréquence cardiaque.

fréquence cardiaque fonctionnant en Bluetooth. Le capteur choisi est le CooSpo HW706 (Figure 4.1.2).

Il s'agit d'un capteur sous forme de bracelet, utilisant une technique PPG et qui peut se positionner au niveau du poignet, du bras ou de l'avant-bras. Ce capteur envoie les valeurs de rythme cardiaque lues en temps réel par Bluetooth.

Les avantages de ce capteur sont :

- Sa longue autonomie (une vingtaine d'heures),
- Sa communication Bluetooth aisée,
- L'accès aisé aux données brutes (pas besoin d'interface ou de logiciel particulier).

Malheureusement, ce capteur est moins précis que la plupart des montres connectées commerciales et s'est révélé être sensible à la transpiration et à la couleur de la peau. Pour la suite, il serait nécessaire de s'orienter vers des capteurs plus fiables comme ceux de la marque POLAR (Sedighi Maman et al., 2017; Sedighi Maman et al., 2020), ou des montres connectées comme celles proposées par les marques GARMIN ou SAMSUNG. Ces capteurs n'ont pas été choisis pour cette étude car ils sont très chers et l'accès aux données brutes est souvent plus difficile (nécessité d'installation d'applications particulières, de créer un compte, de payer un abonnement, etc). Une solution à long terme serait d'envisager un partenariat avec une de ces marques.

## 2) Le système de contrôle et de stockage :

Le système de contrôle se résume à un microcontrôleur. Le microcontrôleur choisi est une carte ESP32 HUZZAH Feather proposée par Adafruit (Figure 4.1.3). Celle-ci a été choisie car elle est peu friande en énergie et possède un système Bluetooth fonctionnant à faible énergie (*Bluetooth Low Energy* (BLE)).

Un port de carte SD a été ajouté au système pour le stockage des données (Figure 4.1.4). Ce module, également proposé par Adafruit, se branche directement sur le microcontrôleur et permet de porter




Figure 4.1.3  
Microcontrôleur ESP32  
HUZZAH (Adafruit)




Figure 4.1.4 Module de carte  
SD (Adafruit)

des cartes SD d'un espace de stockage allant jusqu'à 32Gb. La solution de stockage des données en interne sur une carte SD est une solution simple. L'avantage est que cela permet un fonctionnement du système quel que soit l'environnement de tests, par exemple sur un chantier où l'accès au réseau n'est pas forcément possible. À plus long terme, cette solution pourrait toutefois être remplacée par un système de stockage sur un nuage externe, accessible en Wifi. Cela pourrait permettre un stockage d'un plus grand volume de données, et sans interactions avec le système.

### 3) Le système d'alimentation :

Le système doit être autonome et doit donc être alimenté par une batterie portable. Le microcontrôleur est alimenté en 3.7V et délivre une tension de 3.3V aux composants qui lui sont liés. Le système complet est donc alimenté par une batterie *Lithium Ion Polymer* (LIPO) de 3.7V et 2.5A (il est possible d'utiliser une autre valeur de courant, plus faible, mais pas en deçà de 1000mA). Les batteries LIPO ont l'avantage d'être très légères, peu encombrantes et puissantes. Ce type de batterie se recharge à l'aide d'un chargeur à 3 ports : un port pour l'alimentation (ordinateur, prise), un port pour la batterie et un port pour la charge (*c-à-d* le reste du système). Ce chargeur permet de ne pas avoir à débrancher la batterie pour son chargement.

### 4) L'interface d'utilisation :

Un interrupteur a été ajouté entre le chargeur et le reste du système afin d'isoler ce dernier et donc d'éviter que la batterie ne se décharge lorsque le système n'est pas utilisé (pendant les explications de l'expérience par exemple). Cet interrupteur sera par la suite appelé bouton « POWER ». Un

deuxième interrupteur a été ajouté afin de contrôler la prise des mesures. Cet interrupteur sera par la suite appelé bouton « ON/OFF ». Enfin, deux LED ont été ajoutées au circuit. La première s'allume lorsque l'équipement est mis sous tension, la deuxième s'allume lorsque le système est en train de prendre des mesures.

Un schéma du système complet est présenté dans la Figure 4.1.5. Sur ce schéma, il est possible d'identifier de gauche à droite : le module de carte SD, le microcontrôleur, les interrupteurs et LED permettant une interface aisée avec l'utilisateur, l'IMU, le chargeur de la batterie, et la batterie.






Figure 4.1.5 Schéma Fritzing de l'équipement de capteurs.

La Figure 4.1.6 montre comment sont placés les différentes parties du système, à savoir la partie principale composée de l'IMU et des différents composants électroniques, et la moniteur de fréquence cardiaque sur un sujet.




Figure 4.1.6 Positionnement du système de capteurs.

### 4.1.5. Principe de fonctionnement

Le fonctionnement de l'équipement de capteurs a été programmé via l'application ARDUINO, qui utilise un langage de programmation C/C++. L'architecture du code peut être décomposée en 3 parties :

1. La première étape consiste à appeler les différentes bibliothèques qui sont nécessaires au fonctionnement du programme. Puis, les variables globales sont définies ainsi que les sous-fonctions qui vont être appelées par la suite du programme.
2. La deuxième partie comporte la fonction *setup()*. Il s'agit d'une fonction d'initialisation qui n'est traversée que lorsque le microcontrôleur est mis sous tension. Cette fonction est donc traversée à chaque fois que le bouton POWER est actionné. Dans cette fonction, les communications avec le module SD, l'IMU et le moniteur de fréquence cardiaque en Bluetooth sont initialisées. De plus, un dossier est créé sur la carte SD et dans ce dossier, un fichier en format .csv est ouvert pour écriture.
3. La troisième partie est la fonction *loop()*, qui est la fonction principale du programme. Elle est répétée tant que le microcontrôleur est sous tension, c'est-à-dire, dans le cas de notre système, tant que le bouton POWER est enfoncé. La lecture des capteurs et l'écriture sur les fichiers .csv se fait de manière continue tant que le bouton ON/OFF est allumé.

Un schéma récapitulatif du fonctionnement du code et de la fonction principale est donné à la Figure 4.1.7.

Un exemple d'un fichier .csv enregistré sur la carte SD pendant une session de test, ainsi qu'un schéma explicatif du fonctionnement du système global et de sa calibration sont donnés dans l'Annexe B.

**Phase 1 : Appel des bibliothèques et définition des sous fonctions utilisées par le programme.**

Bibliothèques Bluetooth et sous fonction de lectures d'adresse.

Définition des interruptions du programme.

Bibliothèques et variables liées à l'IMU.

Bibliothèques et variables liées à l'écriture sur la carte SD.

**Phase 2 : Initialisation du programme, fonction *setup()*.**

Initialisation de la communication Bluetooth,

Initialisation du temps pour les interruptions,

Initialisation de l'IMU,

Initialisation de la carte SD,

Ouverture d'un dossier,

Ouverture d'un fichier .csv dans ce dossier.

**Phase 3 : Programme principal, fonction *loop()*.**

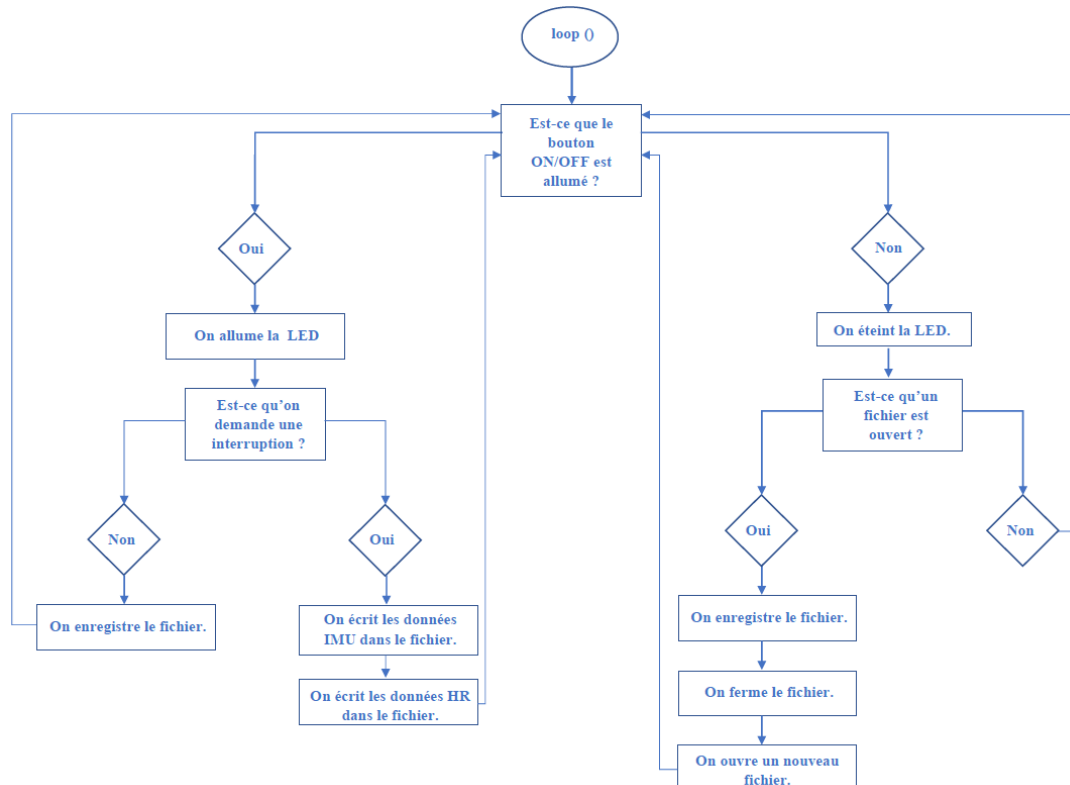


Figure 4.1.7 Principe de fonctionnement de l'algorithme du microcontrôleur.

## 4.2 Partie n°2 : Analyse et traitement des données

La Figure 4.2.1 présente les 4 grandes étapes de la méthode proposée pour l'analyse et le traitement des données, à savoir la définition de la tâche, la préparation des données, la construction et validation du modèle et l'optimisation et l'évaluation de la performance du modèle. Ces 4 grandes étapes sont détaillées dans les paragraphes suivants. Les étapes 2, 3 et 4 ont été réalisées sur Python.




Figure 4.2.1 Plan de la méthode proposée pour l'analyse et le traitement des données.

### 4.2.1. Préparation des données

Avant de construire la méthode d'analyse des données, il est nécessaire de définir la tâche à laquelle devra répondre le modèle. La définition de cette tâche permet également de choisir vers quel type de modèle s'orienter par exemple un modèle de régression ou de classification ainsi que de choisir les métriques pertinentes pour évaluer sa performance.

Dans cette étude, la tâche du modèle est la suivante : « *Quantifier la fatigue physique du sujet selon 4 niveaux : faible (1), moyen (2), élevé (3), très élevé (4)* ».

Étant donné que cette tâche vise à attribuer les données du problème à l'une des 4 classes possibles, il s'agit d'une tâche de classification multi-classes.

### *Visualisation et nettoyage des données :*

Avant d'entamer toute transformation des données, il est nécessaire de les visualiser afin d'identifier les données manquantes et/ou aberrantes qui pourraient influencer voire fausser la prédiction. Ce « premier contact » avec les données se réalise en trois étapes :

1. Identification des données quantitatives et qualitatives : Cette étape est importante puisque ces deux types de données ne se traitent pas de la même manière (notamment au niveau de la normalisation). La fonction *dtypes* de la librairie Panda renvoie le type de chacune des colonnes du tableau voulu.
2. Identification des données manquantes : Cela revient à les compter, puis à visualiser leur répartition. En effet, si par exemple une colonne entière des données brutes possède plus de 50% de données manquantes, alors il est plus judicieux de la supprimer. Les fonctions *isna()* et *sum()* de la bibliothèque Panda renvoient le nombre de valeurs manquantes par colonne du tableau. La fonction *heatmap()* de la bibliothèque Seaborn permet de représenter les valeurs manquantes d'un tableau en affichant d'une certaine couleur les valeurs renseignées et d'une autre les valeurs manquantes.
3. Identification des variables aberrantes : Cette étape est cruciale étant donné que des valeurs aberrantes (comme des erreurs de mesure) peuvent fausser le modèle. La fonction *describe()* de la bibliothèque Panda permet d'afficher les caractéristiques statistiques (moyenne, écart type, min, max...) de chaque colonne d'un tableau de données. Il est ainsi plus facile d'identifier des valeurs aberrantes
4. Identification des corrélations entre les variables : Cette étape est réalisée plusieurs fois au cours de la phase de traitement des données. Elle permet d'identifier les corrélations entre les différentes colonnes du tableau. La fonction *clustermap()* de la bibliothèque Seaborn permet d'afficher la matrice de corrélation de toutes les colonnes du tableau qui lui est donné en argument.

Un exemple de chacune des fonctions mentionnées ci-dessus est donné dans l'Annexe C.

### Filtrage des données :

Les données lues par les capteurs sont bruitées. Il est donc nécessaire de les filtrer pour ne garder que le signal utile. Plusieurs filtres sont utilisés en traitement des données, parmi eux, on peut citer le filtre de Kalman, les filtres de Chebychev ou encore les filtres de Butterworth. (Sedighi Maman et al., 2017), (Sedighi Maman et al., 2020) et (Baghdadi et al., 2018) ont utilisé un filtre de Kalman pour filtrer leurs données. Un filtre de Kalman estime les paramètres d'un système évoluant dans le temps à partir des données bruitées. Il est par exemple utilisé pour déterminer la position et la vitesse d'un véhicule à partir de ses données GPS. L'avantage de ce filtre est qu'il a la capacité de prédire des paramètres et de rectifier les erreurs des capteurs et du modèle lui-même. Les inconvénients sont qu'il s'agit d'un filtre complexe avec un coût calculatoire important et qu'il nécessite qu'on puisse décrire précisément le modèle. Étant donné son coût de calcul élevé, c'est un filtre de Butterworth qui a été choisi pour cette étude. En effet, le but est de choisir un filtre qui enlève le bruit en modifiant au minimum le signal utile. Le filtre de Butterworth est réputé pour




Figure 4.2.2 Exemple de l'application du filtre de Butterworth sur l'accélération en z et le tangage. son gain constant dans sa bande passante. Il a été implémenté dans la partie pré-traitement des données par la fonction *butter()* du module signal de la bibliothèque Scipy. L'ordre du filtre a été fixé à 3. Un exemple des données filtrées est donné à la Figure 4.2.2.

### Calcul des variables :

Les deux capteurs permettent de suivre l'accélération selon les trois dimensions (x,y,z), la vitesse angulaire selon les trois dimensions (x,y,z), les quaternions et la fréquence cardiaque.

À partir de ces données brutes, 3 variables utiles ont été extraites :

1. La secousse : (Zhang, L. et al., 2019) a montré que la secousse est une métrique importante dans la prédiction de la fatigue. Ainsi, la secousse a été extraite des données d'accélération selon l'Équation 2 (Section 2.2.2).
2. Le %HRR : En effet, (Hwang & Lee, 2017) a montré que le %HRR était une métrique importante dans la prédiction de la fatigue. Cette métrique a donc été calculée à partir de la fréquence cardiaque mesurée par la montre, selon l'Équation 1 (Section 2.2.2).
3. La flexion du dos (tangage) : D'autres études (Nath et al., 2017; Valero et al., 2016) ont montré que la flexion du dos pouvait également être liée à la mesure de la fatigue. En effet, ces études ont montré que les postures inconfortables comme se pencher fortement en avant, entraînaient également la fatigue physique du travailleur (au niveau musculaire). Étant donné que l'IMU est placé au milieu du dos, il est aisé de calculer la flexion du tronc. Pour cela, les quaternions sont utilisés. Les définitions de bases sont résumées dans l'Annexe D.

Les quaternions sont lus par l'IMU, stockés sur la carte SD et ensuite convertis en angles d'Euler afin d'avoir accès à la flexion du dos. Les équations de conversion utilisées sont les suivantes :

$$\begin{bmatrix} \varphi \\ \theta \\ \psi \end{bmatrix} = \begin{bmatrix} \arctan2(2 * (q_0 q_1 + q_2 q_3), 1 - 2 * (q_1^2 + q_2^2)) \\ \arcsin(2 * (q_0 q_2 - q_3 q_1)) \\ \arctan2(2 * (q_0 q_3 + q_1 q_2), 1 - 2 * (q_2^2 + q_3^2)) \end{bmatrix} \quad (5)$$

Où  $\varphi$  correspond à l'angle de roulis,  $\theta$  à l'angle de tangage et  $\psi$  à l'angle de lacet.  $\arctan2$  est une variante de la fonction arc tangente.  $\arctan2(x, y)$  correspond à l'angle en radians entre la partie positive de l'axe des abscisses d'un plan, et le point de ce plan, de coordonnées (x,y).

Un modèle de l'IMU positionné sur le dos du travailleur a été représenté à l'aide de la bibliothèque VPython, sur Python. La Figure 4.2.3 illustre le positionnement de l'IMU (en bleu) sur le dos du travailleur (en gris), selon les trois angles d'Euler. Seul le tangage sera considéré dans cette étude puisque c'est celui qui donne accès à la flexion du tronc.




Figure 4.2.3 Orientation de l'IMU en fonction des 3 angles d'Euler, illustré par VPython.

#### *Génération des descripteurs :*

Plusieurs tailles de fenêtres temporelles avec et sans chevauchement ont été testées à partir des informations tirées de la littérature. En effet, (Sedighi Maman et al., 2020) ont calculé la taille de ces fenêtres temporelles à partir du temps de réalisation de la tâche répétitive de leurs tests. Étant donné que dans cette étude, le but est de quantifier la fatigue physique sur des activités non répétitives, réalisées dans un environnement non-contrôlé, une autre technique a dû être choisie. Le but étant de trouver un compromis entre avoir assez de données et être capable de capter des variations significatives. Ainsi, 4 tailles de fenêtres à savoir 2s, 10s, 15s et 30s ont été testées, chacune soit sans chevauchement, avec 25% de chevauchement et 50% de chevauchement. Les meilleures performances ont été obtenues avec des fenêtres de 30s et un chevauchement de 50%.

Sur chacune des fenêtres temporelles, trois mesures statistiques ont été calculées, à savoir :

- La moyenne, à l'aide de la fonction `.mean()` de la bibliothèque numpy.
- L'écart type, à l'aide de la fonction `.std()` de la bibliothèque numpy.
- Le coefficient de variation (CV), à l'aide de la fonction `stats.variation()` de la bibliothèque scipy. Ce coefficient est un rapport entre l'écart type et la moyenne.

$$CV = \frac{\sigma}{\mu} \quad (6)$$



Où  $\sigma$  est l'écart type et  $\mu$  la moyenne.

Les descripteurs ont été générés en fonction de chaque niveau de fatigue comme décrit dans la Figure 4.2.4. Cela a été fait afin d'éviter d'avoir des descripteurs correspondants à des niveaux de fatigue intermédiaires (ce qui pourrait rendre la classification plus compliquée).

Ainsi, 51 descripteurs ont été calculés pour chacun des sujets. Ces descripteurs sont listés plus loin dans ce mémoire, dans le chapitre concernant l'article soumis pour publication (Chapitre 5, Section 5.2.3). Étant donné que les modèles sont développés pour chaque sujet, les descripteurs liés aux informations personnelles n'ont pas été utilisés pour le modèle prédictif.




Figure 4.2.4 Génération du descripteur « moyenne du tangage » à partir de la série temporelle du tangage, selon les 4 niveaux de fatigue donnés par le sujet (vert = 1(faible), bleu=2(moyenne), orange=3(élevé), rouge=4(très élevé). a) Tangage en fonction du temps. b) Moyenne du tangage calculé sur des fenêtres temporelles glissantes de 30s avec 50% de chevauchement.

#### Réduction de la dimensionnalité :

Dans cette étude, la réduction de la dimensionnalité a été adaptée à chacun des modèles, ainsi les trois techniques décrites dans la section 2.3.5, à savoir la méthode de filtrage, d'emballage et intégrée, ont été utilisées. Pour le modèle de *Bagged Trees*, une méthode de filtrage basée sur un test statistique ANOVA a été utilisée. Pour le modèle de *Random Forest*, c'est une méthode d'emballage qui a été utilisée par la fonction *features\_importances()*. Enfin, la régression logistique a été pénalisée avec la technique LASSO.

## 4.2.2. Construction et validation du modèle

### *Normalisation des descripteurs :*

Deux types de normalisation, à savoir la normalisation standard et la normalisation robuste ont été testés (section 2.3.6). Les deux types de normalisation ont donné sensiblement les mêmes résultats donc seule la normalisation standard a été retenue.

### *Gérer les données déséquilibrées :*

La construction de la méthode d'analyse et de traitement des données s'est faite à partir d'un premier jeu de données obtenu par la réalisation par 5 sujets d'une tâche en laboratoire (détaillée dans la section 4.3). En observant ces données, il est apparu que les données n'étaient pas équilibrées, c'est-à-dire que la proportion des exemples appartenant à chacune des classes (respectivement les niveaux de fatigue faible, moyen, élevé et très élevé) n'était pas la même pour chacun des participants (Figure 4.2.5). En effet, il est possible de noter que la classe majoritaire pour le participant P0 est la classe n°1 (correspondant à un niveau faible de fatigue), alors que la classe majoritaire pour le participant P4 est la classe n°3 (correspondant à un niveau élevé de fatigue).

Il s'agit donc d'un cas de classification déséquilibrée.

	Classe1	Classe2	Classe3	Classe4
<b>P0</b>	51000	45000	7500	0
<b>P1</b>	36000	52500	0	0
<b>P2</b>	43500	45000	15000	0
<b>P3</b>	13500	22500	22500	0
<b>P4</b>	13500	30000	37500	0

Figure 4.2.5 Proportion de chacune des classes pour le premier ensemble de données, pour 5 participants (capture d'écran d'un code Python).

Seules les méthodes de rééchantillonnage (à savoir une méthode de suréchantillonnage aléatoire et de sous-échantillonnage aléatoire) et de génération d'exemples synthétiques (à savoir SMOTE) ont été testées car ce se sont les plus faciles à mettre en œuvre. De plus, la bibliothèque *imblearn* de Python donne les outils nécessaires pour appliquer ces méthodes.

### *Choix du modèle :*

Le problème d'apprentissage automatique développé dans cette étude était une classification multi-classes puisque le but était de classer les données selon 4 niveaux de fatigue différents. Sur la base des résultats des études mentionnées dans la revue des connaissances, trois classificateurs ont été testés :

1. La régression logistique (Sedighi Maman et al., 2017).
2. Le *Random Forest* (Sedighi Maman et al., 2020).
3. Le classificateur *Bagged Trees* (Umer et al., 2020).

### *Validation croisée :*

Dans un premier temps, les exemples d'entrées ont été divisés en ensemble d'entraînement (85%) et un ensemble de test (15%) à l'aide de la fonction *train\_test\_split()* de la bibliothèque scikit-learn. L'ensemble d'entraînement est utilisé pour ajuster le modèle, et l'ensemble de test est utilisé pour évaluer l'apprentissage du modèle. L'objectif de cette division est d'évaluer la performance du modèle sur des nouvelles données (inconnues pour lui) et d'ainsi éviter le risque de surapprentissage (ou triche de la part du modèle). Ensuite, une méthode de validation croisée est appliquée sur l'ensemble d'entraînement. Il s'agit d'une méthode courante en apprentissage machine qui permet d'obtenir des résultats peu biaisés et souvent moins optimistes qu'avec seulement la division en entraînement/test. Pour la validation croisée, l'ensemble d'entraînement est divisé en  $k$  sous-ensembles. Puis, la procédure suivante est appliquée de manière itérative :

1. Le modèle est entraîné en utilisant  $k-1$  des sous-ensembles comme données d'entraînement.
2. Le modèle est évalué sur le sous ensemble restant.

La mesure de performance de l'entraînement par validation croisée est la moyenne des performances calculées à chaque division. Le principe de cette technique est illustré dans la Figure 4.2.6. Cette méthode possède donc un unique paramètre  $k$ , qui correspond au nombre de sous-ensembles créés à partir de l'ensemble d'entraînement et ainsi au nombre de fois où le modèle est ajusté. Pour cette étude, et conformément aux travaux présentés dans la littérature, le paramètre  $k$  a été fixé à 10.

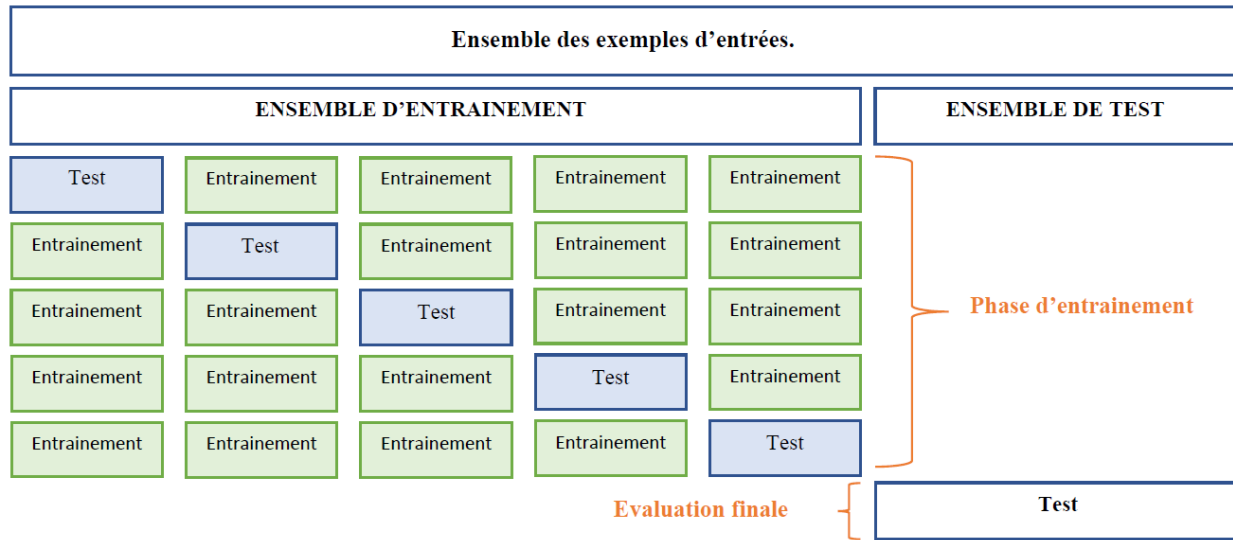


Figure 4.2.6 Description du principe de la validation croisée.

### 4.2.3. Optimisation et performance

*Choix des métriques :*

Dans cette étude, la performance du modèle a été évaluée à l'aide de quatre métriques :

1. L'exactitude, définie comme le rapport entre les exemples correctement classés et le nombre total d'exemples (Tharwat, 2020).

$$\text{Exactitude} = \frac{\text{Nombres de prédictions correctes}}{\text{Nombre de prédictions total}} \quad (7)$$

Dans le cas d'une classification multi-classes, l'exactitude est calculée pour chacune des classes.

2. La précision (ou valeur prédictive positive). Dans un problème de classification déséquilibré avec plus de deux classes, la précision est calculée comme la somme des vrais positifs dans toutes les classes, divisée par la somme des vrais positifs et des faux positifs dans toutes les classes.

$$\text{Précision} = \frac{\sum_i \text{Vrais positifs}(i)}{\sum_i \text{Vrais positifs}(i) + \sum_i \text{Faux positifs}(i)} \quad (8)$$

Où  $i$  correspond aux nombres de classes.

L'exactitude et la précision ont une limitation principale : elles sont sensibles aux données déséquilibrées car elles dépendent des distributions de données. Par conséquent, deux autres métriques, moins influencées par les distributions de données, ont été ajoutées :

3. Le rappel (ou sensibilité). Dans un problème de classification déséquilibré avec plus de deux classes, le rappel est calculé comme la somme des exemples positifs correctement classés dans toutes les classes, divisée par le nombre total d'exemples positifs dans toutes les classes.

$$Rappel = \frac{\sum_i Vrais\ positifs(i)}{\sum_i Vrais\ positifs(i) + \sum_i Faux\ négatifs(i)} \quad (9)$$

Où  $i$  correspond au nombre de classes.

4. Le score F1. Cette métrique permet de combiner précision et rappel dans une seule métrique qui capture les deux propriétés. Il s'agit plus précisément d'une moyenne harmonique entre la précision et le rappel.

$$F1 = 2 * \frac{Précision * Rappel}{Précision + Rappel} \quad (10)$$

Les valeurs du score F1 vont de 0 à 1, où des valeurs proches de 1 indiquent des performances de classification plus élevées (Tharwat, 2020). Selon (Alduayj & Rajpoot, 2018) et (Bertoli et al., 2021), le score F1 est reconnu comme une métrique pertinente pour faire face aux jeux de données déséquilibrés.

*Optimisation des hyperparamètres du modèle :*

Pour les données d'entraînement, des transformateurs permettent de les transformer (normalisation et échantillonnage) pour ensuite utiliser les données en entrée d'un modèle. Ensuite, le transformateur et le modèle définis et entraînés précédemment sont appliqués aux données de test pour faire de nouvelles prédictions. En combinant les transformateurs et le modèle, un *pipeline* est créé, c'est-à-dire, une chaîne de transformation.

Pour cette étude, un type de normalisation (standard), trois types d'échantillonnages (ROS, RUS et SMOTE) et 3 modèles (LR, RF, *Bagged Trees*) ont été utilisés donc 9 chaînes de transformation ont été créées (Tableau 4.2.1).

Tableau 4.2.1 Récapitulatif des chaînes de transformation créées.

Normalisation	Modèle	Échantillonnage	# Pipeline
Standard	Régression logistique (LR)	RUS	1
		ROS	2
		SMOTE	3
	<i>Random Forest</i> (RF)	RUS	4
		ROS	5
		SMOTE	6
	<i>Bagged Trees</i>	RUS	7
		ROS	8
		SMOTE	9

Le transformateur et l'estimateur ont chacun des hyperparamètres qui peuvent être ajustés. Par exemple pour la forêt d'arbre, il est possible de choisir le nombre d'arbres utilisés, la profondeur de ces derniers (nombre de nœuds), etc. Chacune des chaînes de transformation possède deux transformateurs et un modèle, cela représente beaucoup d'hyperparamètres à régler. Une méthode d'optimisation d'hyperparamètres aléatoire *RandomizedSearchCV()* proposée par la librairie scikit-learn a été utilisée (Korstanje, 2021). Cette méthode choisit au hasard des ensembles d'hyperparamètres pour chaque élément de la chaîne de transformation et les teste. La méthode rapporte alors les meilleures performances et les hyperparamètres correspondants.

### 4.3 Application

La méthode proposée a ensuite été testée lors de 4 applications distinctes réalisées dans un ordre chronologique :

1. La première mise en application consistait en la réalisation d'une tâche répétitive en laboratoire. Cette première application avait pour objectif de valider que le système de capteurs ainsi que la méthode d'analyse et de traitement des données proposés permettaient effectivement de quantifier la fatigue physique d'un sujet lors de la réalisation d'une tâche répétitive physiquement exigeante dans un environnement contrôlé.
2. La deuxième mise en application consistait en la réalisation de deux tâches répétitives en laboratoire. Cette deuxième application avait pour objectif de valider qu'un modèle d'apprentissage supervisé était capable de quantifier la fatigue physique d'un sujet réalisant deux tâches répétitives et physiquement exigeantes distinctes.

3. La troisième mise en application consistait en une activité d'aménagement paysager (aplatissement d'une terrasse). L'objectif de cette application était de valider que la méthode de traitement des données permettait de quantifier la fatigue physique d'un sujet lors de la réalisation d'une activité multitâche réalisée dans un environnement non-contrôlé.
4. La quatrième mise en application consistait à suivre 3 travailleurs de la construction pendant 3 matinées consécutives de travail. L'objectif de cette dernière mise en application était d'identifier si la méthode développée lors des 3 premières applications pouvait également être appliquée à la quantification de la fatigue physique d'un travailleur de la construction pendant sa journée de travail.

La Figure 4.3.1 résume la chronologie de ces 4 mises en application.




Figure 4.3.1 Description des 4 mises en application réalisées pour valider l'équipement de capteurs et la méthode de traitement des données.

La procédure expérimentale a été approuvée par le Conseil d'éthique de Polytechnique Montréal (CER-2021-37-D) et les participants ont donné leur consentement au début de l'expérimentation. Tous les participants ont déclaré être en bonne santé.

### 4.3.1. Mise en application n°1 : Réalisation d'une tâche répétitive dans un environnement contrôlé (en laboratoire)

#### *Participants :*

Pour cette étude de cas, quinze participants (6 femmes, 9 hommes, âgés de 20 à 29 ans) ont été recrutés. Le Tableau 4.3.1 présente les caractéristiques démographiques et pertinentes des participants.

Tableau 4.3.1 Caractéristiques pertinentes des sujets qui ont réalisé la première mise en application.

Participant	Genre	Age (années)	Taille (cm)	Masse (kg)
P0	M	26	190	92
P1	M	27	184	86
P2	M	29	183	80
P3	F	20	165	65
P4	F	25	162	58
P5	F	23	165	60
P6	M	28	171	55
P7	M	23	170	66
P8	M	28	170	68
P9	M	29	163	66
P10	F	21	175	59
P11	M	28	177	75
P12	F	21	153	55
P13	M	22	185	75
P14	F	23	170	70

#### *Description des tâches :*

Les participants ont effectué deux sessions expérimentales en laboratoire, une sur deux jours différents. Chaque session expérimentale impliquait la réalisation d'une tâche physiquement fatigante qui a duré une heure, sans pause. Les participants ont fourni leur niveau de fatigue entre 1 et 4 toutes les 5 minutes. Avant le début de l'expérience, les participants ont été initiés à chaque tâche pour définir leur cadence.



Les tâches physiquement exigeantes en laboratoire réalisées par les participants sont décrites ci-dessous :

1. La tâche de levage (Figure 4.3.2) : Le but de cette tâche était d'évaluer les mouvements et la fatigue liés au levage (Valero et al., 2016). Une période de marche a été ajoutée, car il s'agit d'une composante omniprésente dans de nombreuses tâches professionnelles de la construction (Baghdadi et al., 2021; Lu, Megahed, Sese et Cuvuto, 2017). La tâche peut être divisée en quelques étapes : Transporter une boîte de 10 kg. Marcher 7m. Poser la boîte sur le sol. Soulever la boîte jusqu'au premier étage (+74cm). Soulever la boîte jusqu'au deuxième étage (+60cm). Descendre la boîte jusqu'au premier étage puis au sol et revenir au point de départ.




Figure 4.3.2 Photos prises pendant la réalisation de la tâche de levage.

2. La tâche de pavement : Cette tâche s'inspire des travaux des paysagistes pour lesquels le dos est très sollicité. Elle peut être divisée en plusieurs étapes: Transporter la brique de 10 kg depuis le premier étage. Marchez 7m. Poser la brique sur le sol. La déplacer sur le sol. Revenir au point de départ et poser la brique à l'étage suivant. Répéter l'expérience et changer de niveau à chaque fois. L'objectif du niveau changeant était de reproduire une palette de briques diminuant avec le temps.

### 4.3.2. Mise en application n°2 : Réalisation de deux tâches répétitives dans un environnement contrôlé (en laboratoire)

Pour cette mise en application, la procédure expérimentale est la même que pour la mise en application précédente (section 4.3.1). La principale différence entre les deux réside dans la modélisation. En effet, pour la 1<sup>ère</sup> mise en application, chaque modèle a pris en entrée les données extraites d'une seule tâche (soit la tâche de levage, soit la tâche de pavement), tandis que pour la 2<sup>e</sup> mise en application, le modèle a pris en entrée les données extraites de la combinaison des deux tâches.

L'objectif principal de prendre les données extraites des deux tâches comme entrées est de valider si un seul modèle est capable de quantifier la fatigue sur deux activités répétitives différentes.

### 4.3.3. Mise en application n°3 : Activité multitâche d'aménagement paysager (environnement non-contrôlé)

*Participants :*

Comme il est plus difficile et plus long d'organiser des activités multitâches dans un environnement non contrôlé, seuls trois participants (1 femme, 2 hommes, âgés de 25 à 28 ans) ont été recrutés pour cette troisième mise en application. Le Tableau 4.3.2 présente les caractéristiques pertinentes des sujets.

Tableau 4.3.2 Caractéristiques pertinentes des sujets qui ont réalisé la mise en application sur le chantier non professionnel.

Participant	Genre	Age (années)	Taille (cm)	Masse (kg)
P0	M	28	185	86
P1	M	28	177	75
P2	F	25	163	58

*Description de l'activité :*

Chaque participant a effectué une demi-journée (5 heures) de travaux d'aménagement paysager. Cette mise en application consistait en une activité réalisée dans un environnement non contrôlé au cours de laquelle tous les participants étaient libres de passer d'une tâche à une autre. Aucune cadence n'était imposée et les pauses étaient libres. Les participants ont fourni leur niveau de fatigue

toutes les 15 minutes. Cette expérience consistait en une activité d'aménagement paysager au cours de laquelle les sujets devaient aplatir une terrasse. Pour ce faire, les participants ont effectué un ensemble de sous-tâches :

- Retirer les dalles existantes (30kg) et les déplacer.
- Creuser un trou (3,81m x 4,7m x 0,2m).
- Aplatir et remplir successivement (couches de 5 cm d'épaisseur).
- Remettre les dalles dans le sol de surface aplatie.

#### 4.3.4. Mise en application n°4 : Sur un chantier professionnel

##### *Participants :*

Comme il n'est pas facile de s'introduire sur un chantier professionnel, seuls trois participants (3 hommes, âgés de 24 à 46 ans) ont été recrutés pour cette dernière mise en application. Le Tableau 4.3.3 présente les caractéristiques pertinentes des sujets.

Tableau 4.3.3 Caractéristiques pertinentes des travailleurs de la construction, suivis pour la 4ème mise en application.

Participant	Genre	Age (années)	Taille (cm)	Masse (kg)
P0	M	46	162	68
P1	M	25	160	82
P2	M	24	158	60

##### *Description du chantier :*

Les travailleurs de la construction ont été suivis au cours de trois demi-journées (5 heures) de travaux d'aménagement paysager. Ce chantier d'aménagement paysager consistait à paver une chaussée par la réalisation des sous-tâches suivantes:

- Détruire la chaussée existante.
- Aplatir la chaussée en deux étapes : « à la main » (Figure 4.3.4) et avec une machine (Figure 4.3.)
- Découper les pavés.
- Placer les pavés (Figure 4.3.5).
- Aplatir de nouveau.
- Remplir à l'aide de terre.

Au cours de cette expérience, nous avons simplement suivi la continuité du chantier. Une pause de 40 minutes a été imposée par le responsable du site en milieu de demi-journée.



Figure 4.3.3 Aplatir le sol avec une machine.




Figure 4.3.4 Aplatissement du sol à la main.



Figure 4.3.5 Poser les nouveaux pavés.

## CHAPITRE 5     ARTICLE 1: QUANTIFICATION OF PHYSICAL FATIGUE BY COMBINING AN IMU AND A HEART RATE MONITOR: PROOF OF CONCEPT IN A NON-CONTROLLED ENVIRONMENT.

Cet article a été soumis le 10 décembre 2021 dans la revue Automation in Construction.

Mathilde Hochedel<sup>1,1</sup>, Maxime Raison<sup>2</sup>, Sofiane Achiche<sup>2</sup>

<sup>1</sup> *Department of Biomedical Engineering, Polytechnique Montréal, Montréal, Canada.*

<sup>2</sup> *Department of Mechanical Engineering, Polytechnique Montréal, Montréal, Canada.*

**Abstract** – Each year, 1.7% of construction workers suffer from an injury serious enough to take time off work. One of the major reasons for this, is the fatigue induced by the highly physically demanding nature of construction tasks. To monitor physical fatigue in real-time, wearable sensors such as heart rate monitors and inertial measurement units (IMUs) have been recognized in professional athletics and in the transportation industry. However, in the construction field, their use generally remains limited to either solely one task or to multitasking activity within laboratory settings. This study aims to quantify the physical fatigue during multitasking activities in a non-controlled environment by combining an IMU and a heart rate monitor. The developed quantification method was tested on three case studies chronologically: 1) on data extracted from a repetitive task performed by fifteen subjects in a controlled environment, 2) on data extracted from two repetitive tasks performed by fifteen subjects in a controlled environment and 3) for a multitasking activity performed by three subjects in a non-controlled environment. In all cases, Borg's Rating of Perceived Exertion was used as a subjective scale to obtain the fatigue level experienced by the participants. Three classifier models, namely the logistic regression, the random forest, and the bagging, were tested for physical fatigue quantification. The main results showed that the proposed method allows for the quantification of physical fatigue during a half day of multitasking activities in a non-controlled environment with a F1 score of 78,6% using a random

---

<sup>1</sup> Corresponding author at: Department of Biomedical Engineering, Polytechnique Montréal, 2500 Chemin de Polytechnique, Montréal, QC H3T 1J4, Canada.

Email address: [mathilde.hochedel@polymtl.ca](mailto:mathilde.hochedel@polymtl.ca) (M. Hochedel)

forest model for a maximum of 18 features. As proof of concept on three participants, this study is the first showcasing the potential ability of wearable sensors to quantify physical fatigue during multitasking activities in a non-controlled environment.

**Keywords** – Physical fatigue, Physiological metrics, Wearable technologies, Data Analysis, Feature Selection, Machine Learning.

## **5.1 Introduction**

This Section addresses the general context of fatigue at work (1.1), the monitoring of physical fatigue in workers (1.2), and the objective of the study (1.3).

### **5.1.1. Fatigue at work**

According to the U.S. Bureau of Labor Statistics (BLO), 195 600 cases of injuries were reported on construction sites in 2018 (Statistics, 2019). One of the major reasons behind health and safety issues faced by the construction industry is the highly physically demanding nature of construction tasks (Yu et al., 2019). Indeed, construction workers are frequently exposed to heavy workloads and long work schedules without sufficient breaks to recover from overexertion (Aryal et al., 2017; Yu et al., 2019; Zhang, M. et al., 2015).

Such circumstances expose construction workers to the risk of fatigue development (Yu et al., 2019). The U.S. BLO indicated that 33% of all work-related musculoskeletal injuries and disorders in the U.S. construction industry were attributed to fatigue and overexertion (Statistics., 2016).

Fatigue is a risk factor at work as it may lead to decrease motivation and vigilance, as well as potential accidents and injuries (Zhang, M. et al., 2015). Fatigue was identified as a potential risk factor for slip induced falls, one of the "fatal four" causes of fatalities in the construction industry according to the Occupational Safety and Health Association (Aryal et al., 2017).

To overcome these challenges in the construction industry, it is essential to effectively monitor and manage fatigue in construction workers to ensure a more sustainable and productive workforce for the industry in the future (Anwer, Shahnawaz et al., 2021).

### 5.1.2. Monitoring physical fatigue in workers

Fatigue involves physical fatigue and mental fatigue. Physical fatigue occurs after prolonged physical workloads and can reduce the capacity of individuals to perform physical work efficiently (Gawron, 2000). Similarly, mental fatigue occurs after prolonged mental workloads and may lead to reduced behavioral and cognitive performances (Boksem & Tops, 2008).

Because most construction workers (such as manual laborers) may not require a high level of mental alertness (Aryal et al., 2017), this study only focuses on the monitoring and the quantifying of physical fatigue in construction workers.

The traditional solutions used to measure physical fatigue can be classified into subjective and objective methods (Anwer, Shahnawaz et al., 2021), as detailed in the two following subsections.

#### *Subjective methods: reports*

Subjective methods rely on workers report of their physical fatigue perception.

Because of the subjective component of workers' reports, the measures of fatigue are tailored to the situation in which fatigue is being studied (Anwer, Shahnawaz et al., 2021; Aryal et al., 2017; Zhang, M. et al., 2015). For example, Borg's *Rating of Perceived Exertion* (RPE) scale is used to collect the worker's perceived exertion (Borg, 1998). The RPE scale is linear, from 6 to 20 and was proposed by G. Borg as an attempt to quantify subjective symptoms of how people perceive the exertion level of their work (Aryal et al., 2017). As it is used to measure an individual's exertion, breathlessness and fatigue during physical work, the Borg's scale is highly relevant for the occupational health and safety practice (Williams, 2017). Another example is the *Need for Recovery Scale* which asks 11 questions to assess the workers' demand for rest. The purpose of this scale is to identify the first symptoms of fatigue at work by tracking the need for recovery during the last hours of work or immediately after work (van Veldhoven & Broersen, 2003).

Self-reported methods are easy to implement but not suitable to investigate construction workers' fatigue (Yu et al., 2019). The reasons are: a) The reporting process may interrupt normal work activity (Anwer, Shahnawaz et al., 2021; Sedighi Maman et al., 2020). b) Self-reporting only provides the final fatigue status, so the data cannot support the investigation of physical fatigue

development (Yu et al., 2019). c) They are impractical for continuous fatigue monitoring (Anwer, Shahnawaz et al., 2021; Yu et al., 2019).

In this study, the Borg's RPE scale was used to obtain the subjective level of fatigue experienced by the participants due to its simplicity and wide use within the ergonomics literature (Sedighi Maman et al., 2017).

#### *Objective methods: sensors*

Objective methods rely on using one or more sensor technologies to monitor physiological signals or biomechanical changes in human body behavior (Sedighi Maman et al., 2020).

To overcome the limitations of subjective methods, some researchers attempted to monitor various physiological metrics through wearable sensors with the aim of assessing real-time physical fatigue with minimal interference in ongoing construction activities (Anwer, Shahnawaz et al., 2021). Indeed, with the continued advancements in wearable technologies and the decrease of their costs, wearable sensors are widely considered for fatigue monitoring systems. The advantages of using wearable technologies include portability, non-invasiveness, affordability, multi-functionality, and reliability (Baghdadi et al., 2021). Recently, several studies used these wearable technologies with the aim of monitoring various physiological and biomedical metrics to model construction workers' fatigue. The most used metrics are presented in Table 5.1.1. And some related studies are detailed in the following paragraphs.

Table 5.1.1 Physical fatigue indicators, direction of change with fatigue development and related studies.

Signals	Changes with fatigue development	Studies
Cardiovascular metrics	Heart rate increases when fatigue increases.	(Hwang & Lee, 2017)
Thermoregulatory metrics	Skin temperature increases during construction activities.	(Aryal et al., 2017), (Umer et al., 2020), (Anwer, S. et al., 2020)
Jerk metrics	Jerk values increase with fatigue development.	(Zhang, L. et al., 2019), (Sedighi Maman et al., 2020)

*Cardiovascular and thermoregulatory metrics* - (Hwang & Lee, 2017) investigated the usefulness of affordable percent HR reserve (%HRR) using a wristband from a case study of 19 workers in construction sites. The %HRR is a percentage of an individual's heart rate capacity being used (Sedighi Maman et al., 2020). Their results showed the potential of this continuous measurement



in capturing significant physical demand variations (Hwang & Lee, 2017). (Anwer, S. et al., 2020) quantified physical fatigue using wearable cardiorespiratory and thermoregulatory sensors during a simulated construction task. They reported a strong correlation between HR and the corresponding subjective fatigue measured by a Borg Scale. (Umer et al., 2020) and (Aryal et al., 2017) both explored the use of combined cardiorespiratory and thermoregulatory measures to model physical exertion using Machine Learning algorithms. Their results implied that cardiorespiratory parameters and local skin temperature could be good surrogates for measuring physical fatigue.

*Jerk metrics* – Jerk is the temporal derivative of the acceleration, and it has been widely studied for fatigue quantification. Because physical fatigue adversely affects the control and the quality of the movement, workers with fatigue demonstrate increased jerk values (Zhang, L. et al., 2019). Inertial measurement units (IMUs) are inexpensive and reliable sensors that are used to capture a subject's acceleration and motion data (Sedighi Maman et al., 2020). (Zhang, L. et al., 2019) investigates the application of a Machine Learning approach to automatically recognize jerk changes due to physical exertion using IMUs. They concluded that jerk is a useful indicator of physical exertion. (Sedighi Maman et al., 2020) detected physical fatigue during simulated manufacturing tasks thanks to IMUs and generalized regression models. They found that only one IMU on the torso is needed for fatigue detection with an average accuracy higher than 0.850 and a random forest model comprised of fewer than <7 features.

Recently, research works reported that the prediction of physical fatigue could be improved by combining information from two or more physiological metrics (Anwer, Shahnawaz et al., 2021). For example (Umer et al., 2020) succeeded to predict 95% of physical fatigue using a combination of HR, thermoregulatory and respiratory metrics. This accuracy dropped to 57% when only HR data was used to predict fatigue. (Aryal et al., 2017) and (Umer et al., 2020) showed promising results about thermoregulatory metrics. However, measurement sites (cheek, ear, forehead and temple (Aryal et al., 2017)) could be disturbing or even inaccessible for construction workers during a whole day in the field. On the other hand, (Sedighi Maman et al., 2020) demonstrated that IMUs are very good surrogates for fatigue detection. That is why, the sensor-based equipment used for this investigation was composed of one IMU and one heart rate monitor. Their type and location will be discussed in the Method section.

### 5.1.3. Objective of the study

The studies mentioned above showed promising results in terms of the physical fatigue monitoring thanks to wearable technologies. However, their major drawback is that these results were obtained from experiments carried out in a controlled environment. Indeed, many studies only focus on physical fatigue identification and/or quantification during independent physically demanding repetitive tasks (Sedighi Maman et al., 2017; Sedighi Maman et al., 2020; Valero et al., 2016) or during a controlled sequence of tasks (Zhang, L. et al., 2019). Yet, construction is in a dynamic, diverse, and transient environment (Techera et al., 2018). For the techniques developed to be applicable on construction sites, they must consider the following qualifiers of a construction site:

- Dynamic: cadence is not imposed during the performance of tasks. The workers have a window of time to do their work but are free to slow down when they feel tired, or to speed up when they feel rested enough.
- Diverse: construction work generally encompasses tasks that can be very different.
- Transient: workers are free to go from one task to another.

The main objective of this paper is to develop a data-driven method to model physical fatigue during a multitasking activity performed in a non-controlled environment. The non-controlled environment makes it possible to represent the dynamic and transient aspects of construction sites, the multitasking activity, the diversity.

To achieve this main objective, sensor-based equipment composed of an IMU and an HR monitor, and a data-driven method were developed. Specifically, the Data Analysis aims to quantify an individual's physical fatigue through the classification of the data into 4 levels of fatigue, low, medium, high, and very high, based on Borg's RPE scale, as shown in Figure 5.1.1.

This investigation was divided into three chronological case studies:

1. The aim of the first case study was to validate that the proposed method allowed the quantification of physical fatigue during one independent task performed in a controlled environment (SO1).

2. To approach the diverse aspect, a second case study was carried out to identify if the proposed method could quantify the physical fatigue of two different repetitive tasks, performed in a controlled environment (SO2).
3. Finally, a third case study was developed to identify if the proposed method allows the quantification of physical fatigue during a multitasking activity in a non-controlled environment (SO3).

RPE	Level of exertion	Verbal anchors	Fatigue level
6	No exertion	I am not tired; this is similar to resting	1- Low
7			
7.5	Extremely Light		
8		I am not tired; this is similar to walking	
9	Very Light		
10			
11	Light	I feel fine to continue	2- Medium
12			
13	Somewhat hard		
14		I am getting tired, but I can continue	3- High
15	Hard (heavy)		
16			
17	Very hard	I am very tired; I have to push myself to continue	4- Very High
18			
19	Extremely hard	This is one of the hardest things I have done	
20	Maximal exertion		

Figure 5.1.1 Borg's RPE scale with the four levels of fatigue.

## 5.2. Methods

Figure 5.2.1 presents the five main phases of the data driven approach developed to quantify physical fatigue. These 5 phases are described in the following sections.




Figure 5.2.1 Proposed framework for physical fatigue quantification.

### 5.2.1. Data acquisition

*Equipment* – For the measurement system, all technical choices were made respecting the following design constraints: the system must be completely autonomous, it must be light, and non-invasive. Thus, each participant was equipped with one central unit (Figure 5.2.2. a). This central unit was composed of:

- One IMU (Adafruit BNO055) composed of one 3-axis accelerometer, one 3-axis gyroscope and one 3-axis magnetometer,
- One SD card,
- One micro-controller (Adafruit Huzzah Feather ESP32),
- One battery.

The 3-axial data of acceleration, angular velocity and magnetic field were filtered by a compensatory filter (McGinnis et al., 2014). Then, they were recorded on the SD card at a sampling rate of 25Hz. The gravity and the unit quaternions were also recorded on the SD card at the same sampling rate. The mathematical properties of unit quaternions make them ideal for representing rotations in three dimensions. Instead of representing a change of orientation by three separate rotations, quaternions use just one rotation. This saves time and storage.

As the torso (Sedighi Maman et al., 2017; Sedighi Maman et al., 2020) is a cumbersome position to place a sensor, according to the landscaping workers, the central unit was placed on the back as in Figure 5.2.2. c). At this place, the IMU could capture the trunk flexion (Nath et al., 2017).

An HR monitor was placed on the arm and connected via Bluetooth with the central unit (Figure 5.2.2 c)). The HR monitor was placed on the arm for two reasons:

The wrist (Sedighi Maman et al., 2017; Sedighi Maman et al., 2020) was not a viable choice as during professional landscaping work, workers are not allowed to wear watches and/or bracelets for safety reasons.

The chest (Sedighi Maman et al., 2020) was impractical since it would have required the participants to undress to place it.

The sensors were calibrated before each use.




Figure 5.2.2 a) Central unit. b) Sensors' localization: heart rate armband and IMU in the back. c) Heart rate armband.

### 5.2.2. Data cleaning and variable extraction

*Data cleaning* – First, an exploratory Data Analysis was used to visualize the data and to check for missing or erroneous data. Secondly, the 3-axial data of acceleration, angular velocity, magnetic field, and the gravity were filtered with a zero-lag low pass 3<sup>rd</sup> order Butterworth filter.

*Variable extraction* –Three variables were then extracted from the row filtered data: the jerk, the Euler angles and the %HRR.

The jerk was computed from the IMU since (Sedighi Maman et al., 2020; Zhang, L. et al., 2019) showed that it is a relevant indicator of physical fatigue. The temporal derivative of the acceleration resultant was obtained by numerical approach and calculated as in Equation 11.

Euler angles were computed from the IMU since (Sedighi Maman et al., 2017; Sedighi Maman et al., 2020; Valero et al., 2016) showed that biomechanical features are good predictors for physical fatigue detection. Conversion equations from quaternions to Euler angles are presented below in Equation 12.  $\Phi$ ,  $\theta$ ,  $\psi$  are the Euler angle (roll, pitch, and yaw respectively). And  $q_0, q_1, q_2, q_3$  are the four quaternions recorded by the IMU, among w, x, y, and z, respectively.

Then, the HR data was normalized through the computation of the percent %HRR as in the following Equation 13.  $HR$  is the heart rate recorded by the system,  $HR_{max} = 220 - age$  is the maximum heart rate reached by a person and  $RHR$  is the individual's resting HR.

$$Jerk = \frac{da}{dt} \text{ where } a = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (11)$$

$$\begin{bmatrix} \phi \\ \theta \\ \psi \end{bmatrix} = \begin{bmatrix} atan2(2 * (q_0 q_1 + q_2 q_3), 1 - 2 * (q_1^2 + q_2^2)) \\ asin(2 * (q_0 q_2 - q_3 q_1)) \\ atan2(2 * (q_0 q_3 + q_1 q_2), 1 - 2 * (q_2^2 + q_3^2)) \end{bmatrix} \quad (12)$$

$$\%HRR = \frac{HR - RHR}{HR_{max} - RHR} * 100 \quad (13)$$

### 5.2.3. Data pre-processing

*Feature generation* – Raw data cannot be directly used in predictive models which is why data information was summarized through features calculated on specific time windows. The model was used for non-controlled environment experiments, so features had to be *task-independent*. Thus, the length of the time windows was not calculated from the duration of the task as in (Sedighi Maman et al., 2017; Sedighi Maman et al., 2020) but from a trade-off between capturing the intensity and variation changes and having enough data. 51 features per participant were thus calculated. These features are presented in Table 5.2.1. Since each participant had their own model, personal features were not used for the features-based predictive model.

Table 5.2.1 Sets of features generated from the raw data for each participant.

Category	#	Definition
Statistical	1, 2, 3	Mean acceleration x, y and z
	4	Mean acceleration resultant
	5	Mean jerk
	6, 7, 8	Mean gyroscope x, y and z
	9	Mean gyroscope resultant
	10, 11, 12	Mean gravity x, y and z
	13	Mean HR
	14	Mean %HRR
	15, 16, 17	CV acceleration x, y and z
	18	CV acceleration resultant
	19	CV jerk
	20, 21, 22	CV gyroscope x, y and z
	23	CV gyroscope resultant
	24, 25, 26	CV gravity x, y and z
	27	CV HR
	28	CV %HRR
	29, 30, 31	Std acceleration x, y and z
	32	Std acceleration resultant
	33	Std jerk
	34, 35, 36	Std gyroscope x, y and z
	37	Std gyroscope resultant
	38, 39, 40	Std gravity x, y and z
	41	Std HR
	42	Std %HRR
	43	Mean PITCH
	44	CV PICTH
	45	Std PITCH
Biomechanical features	46	Max PITCH
	47	Max acceleration z
Personal features	48	Age
	49	Gender
	50	Height
	51	Weight

*Dimension reduction* – Only a small subset of all calculated features is relevant for physical fatigue quantification (Mustaqeem et al., 2017). Using all the features can lead to poor model generalization since the model may be reproducing noise in the features, leading to poor classification results (Drover et al., 2017). Dimensional reduction is considered as a well-recognized pre-processing step in Data Mining, modeling, visualization, and Data Analysis (Mustaqeem et al., 2017).

The proposed feature selection followed two steps: 1) a *filter* method: a select-k-best feature selector was implemented. This selector is based on ANOVA F-statistics which selects features that account for the most variance between classes (Drover et al., 2017) Several values for variance k included in were tested. This first series of experiments allowed for the identification of the minimal number of features needed for the prediction. 2) a *feature selection algorithm* was computed. Depending on the model selected, a *wrapper* method or an *embedded* method was used. Wrapper methods encompass algorithms that are built around a random forest classifier as a wrapper. This gives access to the importance of each feature in the prediction of the model. This technique is fully explained in (Mustaqeem et al., 2017). The embedded method used is a LASSO regression that has inbuilt penalization functions to reduce overfitting (Sedighi Maman et al., 2020).

#### 5.2.4. Model construction and validation

*Normalization and sampling* – All the data was normalized with a standard scaler. The four instances of fatigue, namely low, medium, high, and very high were not equally balanced for all datasets. Indeed, the classes corresponding to high levels of fatigue (3 and 4) were less represented than the others. It is necessary to deal with class imbalance since it provides misleading classification accuracy. Three resampling methods were tested:

1. Random Over Sampling (ROS): This object over-samples the minority class(es) by picking samples with or without replacement.
2. Random Under Sampling (RUS): This object under-samples the majority class(es) by randomly picking samples with or without replacement.
3. Synthetic Minority Oversampling Technique (SMOTE): Rather than just duplicate examples from the minority class as for ROS, this technique synthesizes new examples from the minority class.

*Model selection* – The Machine Learning problem developed in this study was a multi-class classification to classify the data according to 4 different levels of fatigue. Based on the results of the studies mentioned before, three classifiers were tested:



1. Logistic Regression (LR) (Sedighi Maman et al., 2017) which is a statistical model. This algorithm is designed for binary classification but can be adapted for use for multi-class problems.
2. Random Forest classifier (RF) (Sedighi Maman et al., 2020) which is an ensemble model. It essentially trains multiple decision-trees and averages their collective decisions together.
3. Bagging classifier (Umer et al., 2020) which is an ensemble meta-estimator that fits base classifiers each on random subsets of the original dataset and then aggregate their individual predictions (either by voting or by averaging) to form a final prediction.

*Cross validation* – Input data was split into training sets (85%) and testing sets (15%). To avoid over-fitting, the k-folds cross validation practice was used. In this approach, the training set is split into k smaller sets. The procedure below is then followed for each of the k-folds:

1. The model is trained using k-1 of the folds as training data.
2. The resulting model is validated on the remaining part of the data.

The performance measure reported by k-fold cross-validation is the average of the values computed in the loop. The literature suggests that 10-folds cross validation may reduce the variation between the train and test performance.

*Metrics* – In this study, the model performance was evaluated through the use of four metrics.

1. Accuracy, defined as a ratio between the correctly classified samples to the total number of samples (Tharwat, 2020).
2. Precision, which represents the proportion of positive samples that were correctly classified to the total number of positive predicted samples (Tharwat, 2020).

Accuracy and precision have a main limitation: these are sensitive to the imbalanced data because they depend on data distributions. Consequently, two more metrics, less influenced by data distributions, were added:

3. Recall, which represents the positive samples correctly classified samples to the total number of positive samples (Tharwat, 2020).
4. F1 Score, which represents a harmonic average between precision and recall as in Equation 14.

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (14)$$

The F1 Score values range from zero to one, where higher values indicate higher classification performance (Tharwat, 2020). According to (Alduayj & Rajpoot, 2018) and (Bertoli et al., 2021), the F1 score is recognized as a relevant metric to deal with imbalanced datasets.

### 5.2.5. Optimization

Nine pipelines allowing the association of sampling techniques and models were created. They are presented in Table 5.2.2. Both samplers and models have hyper-parameters that can be optimized. Because it represents a lot of hyper-parameters to tune, the RandomizedSearchCV method provided by the scikit-learn library (Korstanje, 2021), was used. This method randomly chooses sets of hyperparameters for each pipeline element and tests it. The method then reports the best performance and the corresponding hyper-parameters.

Table 5.2.2 Pipelines created by associating a sampling method and a model.

Model	Sampler	# Pipeline
Logistic Regression	RUS	1
	ROS	2
	SMOTE	3
Random Forest	RUS	4
	ROS	5
	SMOTE	6
Bagging Classifier	RUS	7
	ROS	8
	SMOTE	9

### 5.3. Case studies

Three case studies were carried out to respond to the 3 sub-objectives of the study, as detailed in Figure 5.3.1:

1. Fifteen participants performed one repetitive task in a controlled environment (SO1)

2. Fifteen participants performed two repetitive tasks in a controlled environment (SO2).
3. Three participants performed a multitasking activity in a non-controlled environment (SO3).

The experimental procedure was approved by the Ethics Committee of Polytechnique Montreal, and participants provided informed consent at the start of the experiment. All participants declared being in good health.

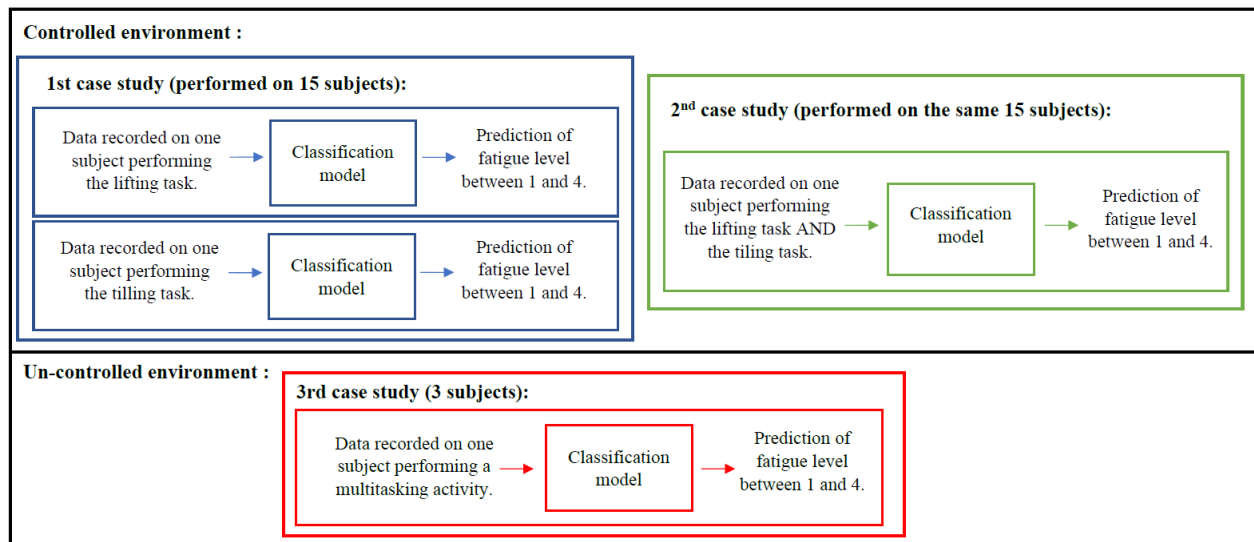


Figure 5.3.1 Description of the three case studies.

### 5.3.1. Case study n°1: one repetitive task performed in a controlled environment

#### 5.3.1.1. Data collection

For this case study, fifteen participants (6 female, 9 male; age 20-29 years) were recruited. Table 5.3.1 presents the demographic and relevant characteristics of the participants.

Table 5.3.1 Relevant characteristics of the participants for the application in controlled environment.

Participant	Gender	Age (years)	Height (cm)	Weight (kg)
P0	M	26	190	92
P1	M	27	184	86
P2	M	29	183	80
P3	F	20	165	65
P4	F	25	162	58
P5	F	23	165	60
P6	M	28	171	55
P7	M	23	170	66
P8	M	28	170	68
P9	M	29	163	66
P10	F	21	175	59
P11	M	28	177	75
P12	F	21	153	55
P13	M	22	185	75
P14	F	23	170	70

Participants completed two in-lab experimental sessions, one on each of two different days. Each experimental session involved the completion of one physically fatiguing task that lasted one hour without a break. Participants provided their subjective fatigue level on a scale from 1 to 4 every 5 minutes. Before the start of the experiment, the participants were introduced to each task to set their cadence.

The physically demanding in-lab tasks are described below:

1. The lifting task (Figure 5.3.2): The aim of this task was to assess lifting-related motions and fatigue (Valero et al., 2016). A walking period was added because it is a pervasive component of many occupational tasks in manufacturing and construction (Baghdadi et al., 2021; Lu et al., 2017). The task can be divided into a few steps: Carry the 10kg box. Walk 7m. Put the box on the ground. Lift the box to the first level (+74cm). Lift the box to the second level (+60cm). Place the box at the first level then on the ground and go back to the starting point.

2. The tiling task (Figure 5.3.3): This task was inspired by landscaping workers tasks for which the back is highly solicited. The task can be divided into a few steps: Carry the 10kg brick from the first level. Walk 7m. Put down the brick. Move it on the ground. Go back to the starting point and place the brick on the next level. Repeat the experiment and change




Figure 5.3.2 Lifting task. a) Lift to the second floor. b) Box on the ground. c) Complete description.




Figure 5.3.3 Tiling task complete description.

the level each time. The aim of the changing level was to reproduce a palette of bricks decreasing with time.

### 5.3.1.2. Data pre-processing

All the steps discussed in Section II were deployed for this application. Two participants were removed from the data because the system failed to record during the second task. For each participant, the first 3 minutes of experimental data were removed to avoid capturing the learning effects (Sedighi Maman et al., 2020).

The features were extracted according to each level of fatigue as described in Figure 5.3.4. This was made to avoid mid-level fatigue features. For both tasks, features were extracted from 50% overlapping time windows of 30s.




Figure 5.3.4 Feature extraction of the pitch of participant P1 according to the four levels of fatigue (green = 1, blue = 2, orange = 3 and red = 4). a) Monitored pitch. b) Mean of the pitch calculated on 30s sliding windows with 50% overlapping.

### 5.3.2. Case study n°2: Two repetitive tasks performed in a controlled environment

For this case study, the experimental procedure is the same as for the previous case study. The main difference between them is in the modeling. Indeed, for the 1st case study, each model took as inputs the data extracted from a single task (namely the tiling task, or the lifting task), while for the second case study, the model took as inputs the data extracted from the combination of both tasks.

The main goal of taking the data extracted from both tasks as inputs is to validate whether a single model is able to quantify fatigue on two different repetitive activities.

### 5.3.3. Case study n°3: Multitasking activity performed in a non-controlled environment

#### 5.3.3.1. Data collection

As it is more difficult and longer to organize multitasking activities in a non-controlled environment, only three participants (1 female, 2 male, aged 25-28 years) were recruited for this third case study. Table 5.3.2 presents the relevant characteristics of the subjects.

Table 5.3.2 Relevant characteristics of the participants for the application in non-controlled environment.

Participant	Gender	Age (years)	Height (cm)	Weight (kg)
P0	M	28	185	86
P1	M	28	177	75
P2	F	25	163	58

Each participant completed one half day (5 hours) of landscaping work. This experiment was a non-controlled work during which all participants were free to go from one task to another. No cadence was imposed, and rest breaks were free. Participants provided their subjective fatigue level each 15 minutes. This experiment consisted of a landscaping activity during which workers had to flatten a terrace. To do this, participants carried out a set of sub-tasks:

- Remove existing slabs (30kg) and move them.
- Dig a hole (3,81m x 4,7m x 0,2m) (Figure 5.3.5 b)).
- Flatten and successively refill (5cm thick layers) (Figure 5.3.5 a)).
- Put the slabs back in the flattened surface ground.

### 5.3.3.2. Data pre-processing

All steps presented in Section II were deployed for this experiment. As for the application with the laboratory settings (case studies n°1 and n°2), the features were extracted according to each level of fatigue as described in Figure 5.3.4. This was made to avoid mid-level fatigue features. For this application, features were also extracted from 50% overlapping time windows of 30s.




Figure 5.3.5 Landscaping work. a) Dig the hole. b) Global view of the work.

## 5.4. Results

The results are presented in three sections, corresponding to the three case studies of the paper:

1. Results of physical fatigue quantification for one repetitive task performed in a controlled environment (SO 1).
2. Results of physical fatigue quantification for two repetitive tasks performed in a controlled environment (SO 2).
3. Results of physical fatigue quantification for a multitasking activity performed in non-controlled environment (SO 3).



#### **5.4.1. Physical fatigue quantification for one repetitive task in a controlled environment (SO1)**

As the performances obtained by the RUS technique are low and the performances obtained by ROS and SMOTE sampler techniques are generally identical, only the results according to the ROS technique are presented.

Table 5.4.1 a) and b) show the performances obtained for the two tasks namely the lifting task and the tiling task, performed in a controlled environment. For each task, the average (the standard deviation) of the four metrics is presented. The highest performances were highlighted in bold.

#### **5.4.2. Physical fatigue quantification for two repetitive tasks in a controlled environment (SO2)**

To verify that the proposed method is indeed capable of identifying physical fatigue in the participants performing two tasks in a controlled environment, a model taking as input the data recorded from each of the tasks was developed. Table 5.4.1 c) shows the average performances obtained for each of the 13 participants. The highest performances were highlighted in bold.

Table 5.4.2 shows the F1 score obtained for each of the participants with a RF-ROS model in 3 different configurations. For the first column, all the features – from both the IMU and the HR monitor- were given as input to the model. For the second column, only the features extracted from the HR monitor were given as input. It corresponds to a subset of the 6 features: mean\_HRR, CV\_HRR, std\_HRR, mean\_HR, CV\_HR and std\_HR. For the third column, only the features extracted from the IMU were given as input. It corresponds to a subset composed of all features except the six mentioned above.

Figure 5.4.1 shows the importance rates of HR-based features and IMU-based features respectively according to the RF-ROS model, for each participant.

Table 5.4.1 Mean performance and the corresponding standard deviation of the classification methods for fatigue quantification for the tasks performed in controlled environment.

	Accuracy	Precision	Recall	F1 score	Features
<i>a) Lifting Task</i>					
<b>LR – ROS</b>	<b>0.84 (0.10)</b>	<b>0.83 (0.10)</b>	<b>0.86 (0.09)</b>	<b>0.83 (0.10)</b>	<b>4.4 (1.5)</b>
RF – ROS	0.82 (0.11)	0.82 (0.11)	0.82 (0.12)	0.80 (0.12)	12.6 (3.1)
Bagging – ROS	0.79 (0.10)	0.78 (0.11)	0.80 (0.10)	0.78 (0.10)	9 (4.5)
<i>b) Tiling task</i>					
LR – ROS	0.82 (0.08)	0.78 (0.1)	0.81 (0.09)	0.78 (0.09)	4.7 (1.4)
<b>RF – ROS</b>	<b>0.86 (0.06)</b>	<b>0.83 (0.08)</b>	<b>0.80 (0.10)</b>	<b>0.80 (0.09)</b>	<b>13.5 (3.6)</b>
<b>Bagging – ROS</b>	<b>0.85 (0.08)</b>	<b>0.83 (0.10)</b>	<b>0.81 (0.11)</b>	<b>0.81 (0.10)</b>	<b>9.7 (3.9)</b>
<i>c) Both Tasks</i>					
LR – ROS	0.72 (0.11)	0.70 (0.10)	0.75 (0.11)	0.71 (0.11)	9 (4.3)
<b>RF – ROS</b>	<b>0.80 (0.08)</b>	<b>0.79 (0.12)</b>	<b>0.77 (0.11)</b>	<b>0.77 (0.12)</b>	<b>14.1 (4.9)</b>
Bagging – ROS	0.76 (0.09)	0.73 (0.11)	0.75 (0.12)	0.74 (0.11)	10,5 (4.6)

Table 5.4.2 Mean values for the F1 score of the ROS-RF model when inputs are the data from both tasks.

# Participant	F1 score		
	All features	Only HR	Only IMU
P1	82 %	69 %	71 %
P2	88%	65%	83%
P3	81%	70%	82%
P5	89%	79%	78%
P6	88%	61%	93%
P7	79%	55%	80%
P8	83%	57%	84%
P9	88%	63%	91%
P10	77%	73%	60%
P11	75%	63%	70%
P12	79%	58%	80%
P13	80%	54%	82%
P14	91%	93%	82%



Figure 5.4.1 Feature Importance rates of HR-based features and IMU-based features calculated for each participant for a single model which took as inputs data extracted from combined tasks performed in the controlled environment.

### 5.4.3. Physical fatigue quantification for multitasking activity in a non-controlled environment (SO3)

Since the RF-ROS model gives the highest performances (Table 5.4.1 c)) for the multitasking activity performed in a controlled environment, only the results related to it are presented for the application in a non-controlled environment. Table 5.4.3 shows the erased score for each of the 3 participants. The average number of features used for this application was  $17.6 \pm 4.04$ . As for Table 5.4.2, the F1 score is distributed according to the three configurations: with all features, with only HR-based features and with only IMU-based features.

Figure 5.4.2 shows the importance rates of HR-based features and IMU-based features respectively according to the RF-ROS model, for each participant.

Table 5.4.3 Average values for the F1 score: with all features, with only HR-based features and with only IMU-based features.

# Participant	F1 score		
	All features	Only HR	Only IMU
P0	84%	56%	77%
P1	70%	51%	71%
P2	82%	63%	77%
<b>Average over all participants</b>	<b>78.6%</b>	<b>56.7%</b>	<b>75%</b>




Figure 5.4.2 Feature Importance rates of HR-based features and IMU-based features calculated for each participant for the multitasking activity performed in non-controlled environment.

## 5.5. Discussion

### 5.5.1 Quantifying physical fatigue during one repetitive task performed in a controlled environment (SO1)

The first objective was to validate the proposed method through the quantification of physical fatigue during simulated construction tasks performed in a controlled environment. The results presented in Table 5.4.1 a) and b) show that the proposed method allows the quantification of the physical fatigue through 4 levels with a F1 score of 83% for the lifting task and 80% for the tiling task. For the lifting task, the ROS technique paired with a logistic regression model using a maximum of 13 features gave the best performances. For the tiling task, the best performance was

obtained with a ROS technique paired with a random forest classifier comprised of a maximum of 14 features.

These results are comparable to those reported in the literature, especially in (Sedighi Maman et al., 2020) and (Aryal et al., 2017). Indeed, (Sedighi Maman et al., 2020) obtained an accuracy of 85% for the physical fatigue identification during a task performed in laboratory settings. The task was completed by 15 participants who were equipped with an IMU on the torso and a HR monitor. (Aryal et al., 2017) recorded the HR and the skin temperature of 12 participants performing a laboratory experiment and obtained a classification accuracy of 82%.

### **5.5.2. Quantifying physical fatigue during two repetitive tasks performed in a controlled environment (SO2)**

This objective was to validate that the proposed method was able to quantify physical fatigue during a multitasking activity performed in a controlled environment. The results presented in Table 5.4.1 c) show that a ROS technique paired with a random forest classifier using a maximum of 14 features can effectively quantify the physical fatigue for a multitasking activity performed with laboratory settings with a F1 score of 77%.

### **5.5.3 Quantifying physical fatigue during a multitasking activity performed in a non-controlled environment (SO3)**

The final and main objective was to quantify physical fatigue during multitasking activities in a non-controlled environment. The results presented in Table 5.4.3 are promising since they show that a ROS technique paired with a random forest classifier comprised of a maximum of 18 features makes it possible to quantify the physical fatigue of a participant during a multitasking activity performed in a non-controlled environment with a F1 score of 78.6 %, on average.

The number of features used seems to increase with the complexity of the number of tasks. Further studies are expected to optimize the number of features.

#### 5.5.4. Discussion on the usefulness of combining both sensors

To confirm that the combination of the HR monitor and the IMU indeed improves the performance of physical fatigue quantification, the usefulness of both sensors was investigated.

Two main types of physical fatigue are possible: whole body fatigue and localized muscle fatigue (Cavuoto & Megahed, 2016; Sedighi Maman et al., 2020). The overall physical fatigue results from the interactions between local (muscular) and central (cardiovascular) factors (Aryal et al., 2017). Thus, if the most important features are derived from the IMU, one could conclude that the participant is experiencing localized muscle fatigue, near the IMU location. If the most important features are derived from the HR sensor, one could conclude that the participant is experiencing whole body fatigue (Sedighi Maman et al., 2020). The identification of the type of physical fatigue the participants feel, can lead to reducing the number of sensors used and to give more precise feedback to participants, and then eventually to construction workers.

In Table 5.4.2, one can note that the IMU-based model seems to give closer performances to the all-features model than the HR-based one. Indeed, the mean performance for the modeling with all features is 17% higher than the HR-based modeling and only 3% higher than the IMU-based modeling. However, this tendency is not true for all participants. From Table 5.4.2 and Figure 5.4.1, three behaviors were observed among the 13 participants as detailed in Table 5.5.1.

Table 5.5.1 Description of the characteristics of the three behaviors observed among the 15 participants performing a multitasking activity in a controlled environment.

#	Participants	Characteristics	Type of fatigue
1	P10, P14	<ul style="list-style-type: none"> <li>HR-based model performances &gt; 70%</li> <li>HR importance rates features are 10% higher than the IMU</li> </ul>	whole body fatigue
2	P1, P2, P6, P7, P8, P9, P11, P12, P13	<ul style="list-style-type: none"> <li>HR-based model performances <math>\leq</math> 70%</li> <li>IMU importance rates features are 10% higher than the HR</li> </ul>	back localized fatigue
3	P3, P5	<ul style="list-style-type: none"> <li>HR-based model performance and IMU-based model performances <math>\geq</math> 70%.</li> <li>between HR importance rates features and IMU importance rates features <math>\leq</math> 10%.</li> </ul>	Overall fatigue (global and localized)

Two specific behaviors emerged among the participants regarding the way the two types of fatigue interact with each other (Table 5.4.2 and Figure 5.4.1). Indeed, for P3, P6, P7, P8, P9 and P13, whole-body fatigue and localized back fatigue seem to be in opposition since, the performance obtained with all features is less important than with one or the other subset. On the contrary, for all other participants, the two types of fatigue seem to reinforce each other since the performance obtained with all features is more important than with one or the other subset. To try to explain this situation, we looked for similarities and differences among the demographic information of the participants. Unfortunately, no specific explanation seems to justify these observations. It would therefore be necessary to reproduce these experiences with larger and more diverse cohorts of participants.

These observations can also be made for the three participants performing the multitasking activity in the non-controlled environment. Indeed, following the previous reasoning and thanks to Table 8, one can observe that the three participants seem to experience localized muscle fatigue, since the HR-based performances are 56%, 51% and 63%, respectively. Nevertheless, Figure 5.4.2 shows that:

- For participant P1, HR rates features are 9% higher than IMU-based features.
- For participant P2, HR rates features are 7% lower than IMU-based features.
- For participant P3, the difference of HR rates features and IMU rates features is only 2%.

Thus, one can observe that even if specific behaviors appear at the level of feature's importance rates, the categorization of the participants into groups as above, is not so obvious. Indeed, judging from the performances given by Table 5.4.3 and the features importance rates given by Figure 5.4.2, P0 and P2 seem to experience overall fatigue.

Therefore, one can conclude that during both multitasking activities – *i.e.* the two tasks in the controlled environment and the landscaping activity in a non-controlled environment –, subjects experienced the two types of physical fatigue, namely whole-body fatigue and localized muscle fatigue. Both sensors are thus useful for the physical fatigue quantification.

It is important to note that the two types of fatigue are not correlated to the task and/or activity completed since, in this study, all participants completed the same activity but felt different types

of fatigue. More studies would be necessary to better understand the behaviors of the two types of fatigue as well as their factors.

### **5.5.5. Limitations**

A few limitations could influence the strength of our conclusions. First, the sample size used in both applications is small. Indeed, only 15 participants completed the first application and three participants in the second. These numbers don't represent the diversity of the population. Secondly, none of the participants, for either case study, had any experience in the construction field. In the future, further cases studies need to be carried out with participants from the construction industry, to confirm these observations on a professional population. Thirdly, we validated our method using Borg's perceived exertion scale first developed to measure physical effort, not physical fatigue. We accepted that this assumption is reasonable based on (Mehta & Cuvuto, 2015) reporting where they stated "[...] muscle activation, perception of discomfort, and/or motivation, might make a greater contribution to fatigue development than peripheral factors" (Mehta & Cuvuto, 2015). It is worth noting that the level of physical exertion might not always coincide with the level of fatigue (Lee et al., 2021). Fourthly, the proposed method did not consider any external parameters such as temperature, humidity, noise, or pollution. Thanks to the development of wearable technologies, it has become easier to collect this kind of information and for long periods of time. Thus, other studies could be carried out considering these environmental conditions and identify if they have an impact on the workers' physical fatigue and if so, to what extent.

## **5.6. Conclusion**

The main purpose of this study was to quantify physical fatigue during a multitasking activity performed in a non-controlled environment, by combining an HR sensor and an IMU.

The main result showed that the proposed method allows the physical fatigue quantification during a half-day of multitasking activity in a non-controlled environment with an F1 score of 78.6% and a random forest model comprised of a maximum of 18 features. This study also highlighted the usefulness of both sensors. Indeed, the proposed analysis showed that both the IMU and HR monitor recorded two types of physical fatigue, namely localized muscle fatigue (back) and whole-body fatigue. Thus, both are useful for the purpose of quantifying overall physical fatigue.



However, this analysis was not able to explain why participants who performed the same activity may experience either one of two types of fatigue or both. More studies are expected on this topic.

The results are important because this study – as a proof of concept – is the first one showing the potential ability of quantifying physical fatigue during a multitasking activity performed in a non-controlled environment, thanks to the analysis of data monitored by an IMU and an HR monitor. A future perspective is to increase the number of participants and activities in a non-controlled environment.

## **5.7. Funding resources**

This work was supported by MITACS Organism [n°IT18646], Vancouver, Canada.

## CHAPITRE 6 RÉSULTATS COMPLÉMENTAIRES

Cette section n'apporte pas de résultats supplémentaires à la recherche ; il s'agit simplement d'une partie exploratoire. En effet, les paragraphes suivants présentent une solution développée dans le but de quantifier la fatigue physique des travailleurs de la construction sur le terrain à partir de données qui n'ont pas pu être étiquetées. Cette solution est basée sur des méthodes présentées dans l'article (Sedighi Maman et al., 2020) mais qui avaient été appliquées dans un cadre différent (tâche répétitive réalisée en laboratoire). Les résultats présentés ici sont donc à prendre comme des observations. D'autres sessions de tests avec davantage de participants ainsi que de nouvelles solutions doivent être réalisées avant de pouvoir tirer des conclusions.

### 6.1 Difficultés rencontrées

La phase de test sur le chantier de construction a été réalisée en étroite collaboration avec l'entreprise partenaire Technologies Biolift Inc. En effet, nous avons pu nous joindre à des phases de tests qui avaient déjà été organisées au préalable dans le but de tester leur exosquelette. Nous n'avons donc pas pu choisir le type de chantier, le nombre de travailleurs recrutés et la durée des tests.

Plusieurs difficultés qui n'avaient pas été rencontrées pendant les trois premières mises en application et qui n'avaient pas été anticipées ont été rencontrées.

La période de tests a eu lieu en plein mois d'août sous une forte vague de chaleur. Cette situation a entraîné deux complications. Premièrement, les travailleurs transpiraient énormément ce qui a empêché le capteur de fréquence cardiaque de fonctionner correctement. La montre s'est donc régulièrement déconnectée ce qui a rendu la fréquence cardiaque mesurée lors de ces tests, peu fiable et donc peu exploitable. Deuxièmement, le système de capteur a donné davantage chaud aux travailleurs et ces derniers ont souvent demandé à interrompre la phase de test plus tôt que prévu pour le retirer. Ainsi, il a été impossible de collecter autant de données que ce qui était attendu au départ (sur une journée entière et pas seulement une demi-journée).

De plus, une des difficultés majeures était que les travailleurs ne semblaient ressentir aucune fatigue, ou du moins évaluaient leur fatigue comme faible systématiquement. Nous avons donc pris le temps de discuter avec eux à la fin des tests pour comprendre la raison de cette situation. En

effet, il était nécessaire de savoir si cela était dû à l'échelle subjective choisie qui n'était pas adaptée ou pas assez précise. De plus, il était difficile d'interagir avec les travailleurs pendant la phase de test et de leur demander une description de leurs symptômes car nous ne pouvions pas les interrompre dans leur travail. La discussion à la fin des tests a été très intéressante car elle a révélé que les travailleurs ne ressentaient effectivement pas l'évolution de leur fatigue sur une si petite période de temps.

## 6.2 Solution proposée pour le traitement des données

Étant donné que les travailleurs de la construction ont tous estimé leur niveau de fatigue à faible sur toute la durée du test, il a été nécessaire de trouver un autre moyen d'étiqueter les données afin d'appliquer la méthode de traitement des données proposés dans le chapitre précédent (Section 4.2). Ainsi, une solution inspirée de (Sedighi Maman et al., 2020) a été testée. Cette solution consiste à attribuer les 20 premières minutes de test à la classe correspondant à l'état non-fatigué et les 20 dernières minutes à l'état fatigué. Les données intermédiaires (« neutre » sur la Figure




Figure 6.2.1 Étiquetage des données : premières 20 minutes à non-fatigué (en vert) et 20 dernières à fatigué (en rouge). Les données entre ces deux périodes (en bleu) n'étant pas prises en compte pour le modèle. a) Étiquetage du tangage. b) Étiquetage de la résultante de l'accélération. c) Étiquetage de la secousse.

6.2.1) ont alors été retirées de l'ensemble des données d'entrée. Il s'agit donc ici de réaliser une classification binaire uniquement entre les états fatigués et non-fatigués. Un exemple de cette solution, appliquée sur une demi-journée de test sur un des travailleurs de la construction est illustrée sur la figure ci-dessous (Figure 6.2.1).

## 6.3 Résultats

Comme la labellisation a été réalisée manuellement en affectant les 20 premières minutes de chacune des phases de test à la classe non fatigué, et les 20 dernières à la classe fatigué, les données étaient également réparties entre les classes. Outre la transformation d'échantillonnage, toute la procédure présentée dans la section 4.2 a été suivie. Les résultats présentés dans le Tableau 6.3.1 montrent les performances de classification obtenues avec les données prises lors des 3 demi-journées consécutives pour chacun des travailleurs. Ces performances ont été obtenues avec un modèle de *Random Forest* couplé à une méthode de suréchantillonnage aléatoire. Ces résultats semblent montrer que le modèle est capable de détecter la fatigue physique d'un travailleur de la construction avec une exactitude moyenne de 79.7%.

Tableau 6.3.1 Performances d'une classification binaire avec un modèle de forêt aléatoire obtenue pour chacun des travailleurs de la construction, en prenant en entrée les données issues des 3 demi-journées de tests.

	Exactitude (%)	Précision (%)	Rappel (%)	Score F1 (%)
P0	85	85	85	85
P1	78	78	79	78
P2	76	76	76	76
Moyenne	79.7	79.7	80	79.7

La limite principale à la solution proposée ci-dessus est que, contrairement à l'étude de (Sedighi Maman et al., 2020), les travailleurs de la construction réalisaient différentes tâches sur la période de tests (et pas seulement une tâche répétitive).

Cela soulève donc des questions quant à l'interprétation possible des valeurs de performances lues sur le Tableau 6.3.1. Étant donné que les mouvements entre le début et la fin de la séance de tests

ne sont pas les mêmes, nous avons cherché à comprendre ce que le modèle prédisait exactement. Pour cela, nous avons regardé les descripteurs utilisés pour la prédiction de fatigue, pour chacun des participants. L'objectif de cette démarche était d'identifier si des descripteurs communs apparaissaient entre les différents sujets par exemple, la moyenne de la résultante de l'accélération. Cependant, aucun descripteur commun n'est apparu. A ce stade, plusieurs interprétations des performances présentées dans le Tableau 6.3.1 sont donc envisageables :

- Le modèle d'apprentissage supervisé n'est pas capable de prédire la fatigue physique des travailleurs à partir des données labellisées manuellement, et les performances présentées sont donc fausses ou trop optimistes.
- Les symptômes de fatigue sont différents d'un travailleur à un autre (comme discuté dans la section 5.5.4) donc les descripteurs utilisés pour la prédiction de la fatigue ne sont pas les mêmes pour chacun des sujets.

D'autres études réalisant des tests sur des chantiers de la construction sont attendues afin d'identifier la bonne interprétation.

## CHAPITRE 7 DISCUSSION GÉNÉRALE

L'objectif général de ce projet de recherche, qui était de concevoir un système de quantification de la fatigue physique par la combinaison d'une centrale inertielle et d'un moniteur de fréquence cardiaque lors d'activités multitâches réalisées dans un environnement non-contrôlé, a été atteint. Dans cette section, un résumé de la discussion de l'article est présenté. Puis, une discussion sur les résultats complémentaires portant sur la quantification de la fatigue physique des travailleurs de la construction pendant leur journée de travail est également présentée. Finalement, les limites et perspectives qui découlent de ce projet de recherche sont détaillées.

La taille des échantillons (3 sujets) pour l'activité d'aménagement paysager et sur le chantier professionnel de la construction, est très petite dans ce domaine de recherche. C'est pourquoi, ces applications sont à considérer comme des preuves de concept.

### 7.1 Synthèse de l'article

Les résultats de l'article soumis (Chapitre 5) ont démontré que le système de capteurs ainsi que la méthode d'analyse et de traitement des données proposés permettent de quantifier la fatigue physique sur une tâche répétitive, réalisée en laboratoire (HR1). En effet, un modèle *Random Forest* couplé à une méthode de suréchantillonnage aléatoire est capable de quantifier la fatigue physique de 15 sujets avec un score F1 moyen de 83% (pour la tâche de levage) et de 80% (pour la tâche de pavement). De plus, les résultats de l'article ont également montré qu'un modèle d'apprentissage supervisé permet de quantifier la fatigue physique d'un sujet à partir de données cardiaques et inertielles enregistrées lors de deux tâches répétitives distinctes réalisées en laboratoire (HR2). En effet, un modèle *Random Forest* couplé à une méthode de suréchantillonnage aléatoire, est capable de quantifier la fatigue physique de 15 sujets réalisant deux tâches répétitives distinctes en laboratoire avec un score F1 moyen de 77%.

Les résultats de l'article soumis ont enfin démontré que le système de capteurs ainsi que la méthode d'analyse et de traitement des données proposés permettent la quantification de la fatigue physique au cours d'une demi-journée d'activité multitâche dans un environnement non-contrôlé avec un score F1 moyen de 78.6% (HR3). Ce résultat est obtenu à l'aide d'un classificateur de type *Random Forest* composé d'un maximum de 18 descripteurs.

L'étude présentée dans l'article a également mis en évidence l'utilité des deux capteurs, à savoir le capteur IMU et le moniteur de fréquence cardiaque. En effet, l'analyse proposée a montré que l'IMU et le moniteur de fréquence cardiaque enregistraient deux types de fatigue physique différents, la fatigue musculaire (au niveau du dos) et la fatigue globale (du corps entier). Ainsi, les deux capteurs sont nécessaires à la quantification de la fatigue physique. Cependant, cette analyse n'a pas été en mesure d'expliquer pourquoi les sujets qui ont effectué la même activité ont pu ressentir l'un des deux types de fatigue, ou les deux. D'autres études sont attendues sur ce sujet. Les résultats de cette étude sont importants car – en tant que preuve de concept sur 3 participants –, elle est à la première à montrer la capacité potentielle d'un capteur IMU et d'un moniteur de fréquence cardiaque à quantifier la fatigue physique lors d'une activité multitâche réalisée dans un environnement non-contrôlé.

## **7.2 Analyse des résultats complémentaires**

Le but de la 4<sup>e</sup> mise en application était de vérifier si le système de capteurs développé ainsi que la méthode d'analyse et de traitement des données permettaient de quantifier la fatigue physique d'un travailleur de la construction lors de plusieurs demi-journées de travail consécutives (HR4). Les résultats complémentaires (Chapitre 6) montrent que cela n'est pas si simple. La première raison est liée au caractère hostile de l'environnement des chantiers de la construction. En effet, dans cette étude par exemple, la longue exposition sous une forte chaleur a engendré un dysfonctionnement du moniteur de fréquence cardiaque. Il est donc nécessaire, pour les études à venir, de prendre ces facteurs environnementaux en compte lors du choix des capteurs. La deuxième raison est liée à la perception de la fatigue des travailleurs de la construction qui a semblé être différente par rapport aux sujets non issus du domaine de la construction (qui ont réalisé les 3 premières applications). Afin de contourner cette difficulté, il serait envisageable de reproduire la méthode présentée dans cette recherche, en commençant par réaliser les 3 premières mises en applications avec des travailleurs issus du domaine de la construction, afin notamment de trouver des échelles plus adaptées à leurs perceptions de fatigue, et d'ainsi être capable d'étiqueter les données dans toutes les circonstances.

### 7.3 Limites et perspectives

Bien que l'objectif général de ce projet de recherche ait été atteint, les résultats ont également montré que la méthode proposée dans cette étude n'est pas directement applicable pour la quantification de la fatigue physique des travailleurs de la construction lors de leur journée de travail, en raison de plusieurs limitations.

#### *Robustesse des capteurs :*

Afin d'obtenir des meilleurs résultats, il est nécessaire d'opter pour une nouvelle stratégie concernant le choix des capteurs. En effet, ceux-ci doivent être capables de faire face aux conditions climatiques hostiles des chantiers de la construction. Pour cela, une solution serait de s'orienter vers des capteurs plus onéreux mais plus robustes, comme ceux de la marque POLAR utilisés dans les études de (Sedighi Maman et al., 2017; Sedighi Maman et al., 2020) ou de la marque GARMIN utilisés dans l'étude de (Aryal et al., 2017). Une autre solution serait d'identifier les moniteurs de fréquence cardiaques utilisés dans le domaine de l'athlétisme ou du sport en général. En effet, dans ce domaine, les capteurs sont également soumis à des conditions difficiles comme la transpiration (dans le cas de la course par exemple), ou à des chocs et mouvements violents (dans le cas du saut en longueur par exemple).

#### *Nombre de sujets :*

La taille des échantillons, pour chacune des applications, est très petite. En effet, seulement 15 sujets ont réalisé les deux premières mises en applications en laboratoire et 3 sujets ont réalisé respectivement les deux dernières. Ces chiffres ne permettent pas de représenter la diversité de la population dans l'industrie de la construction.

#### *Niveau d'expérience des sujets :*

Lors de la 4<sup>e</sup> mise en application, il est apparu que les travailleurs de la construction avaient une perception différente de la fatigue par rapport aux sujets non issus du domaine de la construction. Cette différence peut s'expliquer par le niveau d'expérience des sujets. Deux pistes de réflexion découlent de cette observation. Premièrement, il pourrait être intéressant de réaliser davantage d'expériences sur les chantiers de construction avec des travailleurs ayant des niveaux d'expérience différents. Le but serait alors de mieux comprendre l'impact du niveau d'expérience des sujets sur



leur perception de fatigue. Deuxièmement, cette observation met en lumière une limite du protocole concernant la durée des tests. En effet, il serait intéressant de scinder la mise en application sur les chantiers en deux phases distinctes. La première session de tests pourrait avoir lieu au début de la période de la construction (avril/mai dans le cas du Québec) et la deuxième session, à la fin de la période (novembre dans le cas du Québec). Ainsi, si les chantiers restent sensiblement les mêmes pour les deux périodes (un chantier de pavement de rue dans les deux cas par exemple), il serait alors possible d'étiqueter les données prises lors de la première session de test comme fatigué, et les données prises lors de la deuxième comme non-fatigué. Cette stratégie permettrait d'avoir davantage de données et de plus facilement identifier l'occurrence et le développement de la fatigue des travailleurs.

#### *Facteurs environnementaux :*

L'étude proposée n'a pas pris en compte les facteurs environnementaux tels que la température, l'humidité, le bruit ou la pollution. Grâce au développement des technologies portables, il est devenu plus facile de collecter ce type de données et sur de longues périodes. Ainsi, d'autres études pourraient être menées en considérant ces facteurs environnementaux et identifier s'ils ont un impact sur la fatigue physique des travailleurs et si oui, dans quelle mesure.

## CHAPITRE 8 CONCLUSION

La présente étude avait pour but de concevoir un système de quantification de la fatigue physique par la combinaison d'une centrale inertielle et d'un moniteur de fréquence cardiaque lors d'activités multitâches réalisées dans un environnement non-contrôlé.

La première étape de cette étude consistait à identifier des signaux physiologiques indicateurs de fatigue et à concevoir un système de capteurs portables afin de pouvoir les suivre de manière continue. Étant donné que ce système de capteurs était voué à être utilisé sur les chantiers de la construction, les choix techniques ont été réalisés de telle sorte à minimiser le caractère invasif et à favoriser son acceptation par les travailleurs de la construction. Ensuite, une méthode d'analyse et de traitement des données a été mise en place afin de permettre la classification des données brutes (lues par les capteurs) selon 4 niveaux de fatigue : faible, moyen, élevé et très élevé. Enfin, cette méthode a été testée de manière chronologique sur 4 applications distinctes.

Cet enchaînement chronologique a permis d'adapter progressivement notre méthode aux contraintes d'un chantier de la construction. En effet, un chantier de la construction est à la fois diversifié, dynamique et transitoire. Ainsi, l'objectif de la première mise en application était de valider que la méthode proposée permettait effectivement la quantification de la fatigue physique lors d'une tâche répétitive réalisée dans un environnement contrôlé, en la confrontant aux performances obtenues par la littérature. La deuxième mise en application a été réalisée pour aborder l'aspect diversifié d'un chantier de la construction. Cette application avait pour but de valider qu'un modèle de classification pouvait quantifier la fatigue physique de deux tâches répétitives distinctes exécutées dans un environnement contrôlé. Puis, la troisième étude de cas a été conduite afin d'ajouter l'aspect transitoire, à travers la réalisation d'une activité multitâche dans un environnement non-contrôlé. Enfin, la dernière mise en application avait pour objectif de vérifier si la méthode proposée était capable de s'adapter à un chantier de la construction.

À la suite de ces mises en application, la présente étude a montré que le système de capteurs et la méthode d'analyse et de traitements de données proposés permettaient effectivement de quantifier la fatigue physique dans un environnement contrôlé avec des performances proches de celles obtenues dans la littérature et dans un environnement non-contrôlé avec des hautes performances. La transition sur le chantier de la construction a permis de mettre en lumière des difficultés (liées

aux conditions climatiques difficiles et à la perception de la fatigue par des professionnels), qui n'avaient pas été rencontrées lors des applications précédentes. Ces difficultés ont prouvé que d'autres études étaient nécessaires afin d'être effectivement capable de quantifier la fatigue physique des travailleurs de la construction durant leurs journées de travail.

De nos jours, grâce au développement des technologies portables et à l'ère des données massives, il est désormais possible de surveiller en temps réel une grande quantité de données. En effet, comme le montre cette étude, des technologies portables légères et peu coûteuses permettent d'équiper les travailleurs de plusieurs capteurs pour surveiller leur fatigue physique. De plus, grâce aux technologies sans fil, il est également possible d'équiper l'environnement des travailleurs pour prendre en compte dans la modélisation de la fatigue, des facteurs environnementaux tels que la chaleur, la pollution ou l'humidité. Enfin, les développements du traitement des données massives permettent d'envisager des études à très grande échelle, ce qui permettrait de modéliser et d'utiliser des facteurs personnels tels que la qualité du sommeil, les habitudes de vie ou encore le niveau d'expérience dans la quantification de la fatigue physique des travailleurs de la construction.

## RÉFÉRENCES

- Alduayj, S. S., & Rajpoot, K. (18-19 Nov. 2018 2018). *Predicting Employee Attrition using Machine Learning*. 2018 International Conference on Innovations in Information Technology (IIT) (p. 93-98). <https://doi.org/10.1109/INNOVATIONS.2018.8605976>
- Amini, M.-R. (2020). Principes de base en apprentissage supervisé. *Machine Learning*. hal-03049016
- Anwer, S., Li, H., Antwi-Afari Maxwell, F., Umer, W., & Wong Arnold Yu, L. (2021). Evaluation of Physiological Metrics as Real-Time Measurement of Physical Fatigue in Construction Workers: State-of-the-Art Review. *Journal of Construction Engineering and Management*, 147(5), 03121001. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0002038](https://doi.org/10.1061/(ASCE)CO.1943-7862.0002038)
- Anwer, S., Li, H., Antwi-Afari, M. F., Umer, W., & Wong, A. Y. L. (2020). Cardiorespiratory and Thermoregulatory Parameters Are Good Surrogates for Measuring Physical Fatigue during a Simulated Construction Task. *Int J Environ Res Public Health*, 17(15). <https://doi.org/10.3390/ijerph17155418>
- Aryal, A., Ghahramani, A., & Becerik-Gerber, B. (2017). Monitoring fatigue in construction workers using physiological measurements. *Automation in Construction*, 82, 154-165. <https://doi.org/https://doi.org/10.1016/j.autcon.2017.03.003>
- Awad, M., & Khanna, R. (2015). Support Vector Machines for Classification. Dans M. Awad & R. Khanna (édit.), *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers* (p. 39-66). Apress.
- Baghdadi, A., Cavuoto, L. A., Jones-Farmer, A., Rigdon, S. E., Esfahani, E. T., & Megahed, F. M. (2021). Monitoring worker fatigue using wearable devices: A case study to detect changes in gait parameters. *Journal of Quality Technology*, 53(1), 47-71. <https://doi.org/10.1080/00224065.2019.1640097>
- Baghdadi, A., Megahed, F. M., Esfahani, E. T., & Cavuoto, L. A. (2018). A machine learning approach to detect changes in gait parameters following a fatiguing occupational task. *Ergonomics*, 61(8), 1116-1129. <https://doi.org/10.1080/00140139.2018.1442936>
- Bertoli, G. D. C., Júnior, L. A. P., Saotome, O., Santos, A. L. D., Verri, F. A. N., Marcondes, C. A. C., . . . Oliveira, J. M. P. D. (2021). An End-to-End Framework for Machine Learning-Based Network Intrusion Detection System. *IEEE Access*, 9, 106790-106805. <https://doi.org/10.1109/ACCESS.2021.3101188>
- Biswas, D., Simões-Capela, N., Hoof, C. V., & Helleputte, N. V. (2019). Heart Rate Estimation From Wrist-Worn Photoplethysmography: A Review. *IEEE Sensors Journal*, 19(16), 6560-6570. <https://doi.org/10.1109/JSEN.2019.2914166>
- Boksem, M. A. S., & Tops, M. (2008). Mental fatigue: Costs and benefits. *Brain Research Reviews*, 59(1), 125-139. <https://doi.org/https://doi.org/10.1016/j.brainresrev.2008.07.001>
- Borg, G. (1998). *Borg's perceived exertion and pain scales*. Humain Kinetics.
- Brownlee, J. (2018). Resampling Methods. Dans M. L. Mastery (édit.), *Statistical Methods for Machine Learning*.

- Caldwell, J. A., Caldwell, J. L., Thompson, L. A., & Lieberman, H. R. (2019). Fatigue and its management in the workplace. *Neuroscience & Biobehavioral Reviews*, 96, 272-289. <https://doi.org/https://doi.org/10.1016/j.neubiorev.2018.10.024>
- Cavuoto, L., & Megahed, F. (2016). *Understanding Fatigue and the Implications for Worker Safety* ASSE Professional Development Conference and Exposition.
- Dietterich, T. G. (2002// 2002). *Machine Learning for Sequential Data: A Review*. Structural, Syntactic, and Statistical Pattern Recognition, Berlin, Heidelberg (p. 15-30).
- Drover, D., Howcroft, J., Kofman, J., & Lemaire, E. D. (2017). Faller Classification in Older Adults Using Wearable Sensors Based on Turn and Straight-Walking Accelerometer-Based Features. *Sensors (Basel)*, 17(6). <https://doi.org/10.3390/s17061321>
- Fard, M. M. (2020). *Learning data representations in unsupervised learning*, Université Grenoble Alpes]. <https://tel.archives-ouvertes.fr/tel-03151389>
- Garimella Surya, A., Senouci, A., & Kim, K. (2020). Monitoring Fatigue in Construction Workers Using Wearable Sensors. *Construction Research Congress 2020*, 86-94. <https://doi.org/doi:10.1061/9780784482872.010>
- 10.1061/9780784482872.010
- Gawron, V. J., French, J., & Funke, D. . (2000). An overview of fatigue. . Dans C. Press (édit.), *Stress, Workload, and Fatigue (1st ed.)*. Taylor and Francis Group.
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (vol. Second Edition). O'Reilly Media.
- Hadi Mansourifar, W. S. (2020). Deep Synthetic Minority Over-Sampling Technique. <https://arxiv.org/abs/2003.09788>
- Huysamen, K., de Looze, M., Bosch, T., Ortiz, J., Toxiri, S., & O'Sullivan, L. W. (2018). Assessment of an active industrial exoskeleton to aid dynamic lifting and lowering manual handling tasks. *Applied Ergonomics*, 68, 125-131. <https://doi.org/https://doi.org/10.1016/j.apergo.2017.11.004>
- Hwang, S., & Lee, S. (2017). Wristband-type wearable health devices to measure construction workers' physical demands. *Automation in Construction*, 83, 330-340. <https://doi.org/10.1016/j.autcon.2017.06.003>
- Karvekar, S., Abdollahi, M., & Rashedi, E. (2019). A Data-Driven Model to Identify Fatigue Level Based on the Motion Data from a Smartphone. *bioRxiv*, 796854. <https://doi.org/10.1101/796854>
- Korstanje, J. (2021). The Random Forest. Dans J. Korstanje (édit.), *Advanced Forecasting with Python: With State-of-the-Art-Models Including LSTMs, Facebook's Prophet, and Amazon's DeepAR* (p. 179-191). Apress.
- Lee, G., Lee, S., & Brogmus, G. (2021). FEASIBILITY OF WEARABLE HEART RATE SENSING-BASED WHOLE-BODY PHYSICAL FATIGUE MONITORING FOR CONSTRUCTION WORKERS.

- Lu, L., Megahed, F. M., Sesek, R. F., & Cavuoto, L. A. (2017). A survey of the prevalence of fatigue, its precursors and individual coping mechanisms among U.S. manufacturing workers. *Appl Ergon*, 65, 139-151. <https://doi.org/10.1016/j.apergo.2017.06.004>
- McGinnis, R. S., Cain, S. M., Davidson, S. P., Vitali, R. V., McLean, S. G., & Perkins, N. C. (2014). *Validation of Complementary Filter Based IMU Data Fusion for Tracking Torso Angle and Rifle Orientation* ASME 2014 International Mechanical Engineering Congress and Exposition. <https://doi.org/10.1115/IMECE2014-36909>
- Mehta, R. K., & Cavuoto, L. A. (2015). The effects of obesity, age, and relative workload levels on handgrip endurance. *Appl Ergon*, 46 Pt A, 91-95. <https://doi.org/10.1016/j.apergo.2014.07.007>
- Mustaqeem, A., Anwar, S. M., Majid, M., & Khan, A. R. (11-15 July 2017 2017). *Wrapper method for feature selection to classify cardiac arrhythmia*. 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (p. 3656-3659). <https://doi.org/10.1109/EMBC.2017.8037650>
- Nath, N. D., Akhavian, R., & Behzadan, A. H. (2017). Ergonomic analysis of construction worker's body postures using wearable mobile sensors. *Applied Ergonomics*, 62, 107-117. <https://doi.org/https://doi.org/10.1016/j.apergo.2017.02.007>
- Sadeghniiat-Haghighi, K., & Yazdi, Z. (2015). Fatigue management in the workplace. *Industrial psychiatry journal*, 24(1), 12-17. <https://doi.org/10.4103/0972-6748.160915>
- Sedighi Maman, Z., Alamdar Yazdi, M. A., Cavuoto, L. A., & Megahed, F. M. (2017). A data-driven approach to modeling physical fatigue in the workplace using wearable sensors. *Applied Ergonomics*, 65, 515-529. <https://doi.org/https://doi.org/10.1016/j.apergo.2017.02.001>
- Sedighi Maman, Z., Chen, Y.-J., Baghdadi, A., Lombardo, S., Cavuoto, L. A., & Megahed, F. M. (2020). A data analytic framework for physical fatigue management using wearable sensors. *Expert Systems with Applications*, 155, 113405. <https://doi.org/https://doi.org/10.1016/j.eswa.2020.113405>
- Siddiqi, M. A., & Pak, W. (2021). An Agile Approach to Identify Single and Hybrid Normalization for Enhancing Machine Learning-Based Network Intrusion Detection. *IEEE Access*, 9, 137494-137513. <https://doi.org/10.1109/ACCESS.2021.3118361>
- Statistics, U. S. B. o. L. (2019). *2018 Survey of Occupational Injuries & Illnesses - Chats Package [PowerPoint slides]*
- Statistics, U. S. B. o. L. (2021). *EMPLOYER-REPORTED WORKPLACE INJURIES AND ILLNESSES – 2020*
- Statistics., U. S. B. o. L. (2016). *Nonfatal Occupational Injuries and Illnesses Requiring Days Away From Work*.
- Techera, U., Hallowell, M., Littlejohn, R., & Rajendran, S. (2018). Measuring and Predicting Fatigue in Construction: Empirical Field Study. *Journal of Construction Engineering and Management*, 144(8). [https://doi.org/10.1061/\(asce\)co.1943-7862.0001513](https://doi.org/10.1061/(asce)co.1943-7862.0001513)
- Tharwat, A. (2020). Classification assessment methods. *Applied Computing and Informatics*, 17(1), 168-192. <https://doi.org/10.1016/j.aci.2018.08.003>

- Umer, W., Li, H., Yantao, Y., Antwi-Afari, M. F., Anwer, S., & Luo, X. (2020). Physical exertion modeling for construction tasks using combined cardiorespiratory and thermoregulatory measures. *Automation in Construction*, 112, 103079. <https://doi.org/https://doi.org/10.1016/j.autcon.2020.103079>
- Valero, E., Sivanathan, A., Bosché, F., & Abdel-Wahab, M. (2016). Musculoskeletal disorders in construction: A review and a novel system for activity tracking with body area network. *Applied Ergonomics*, 54, 120-130. <https://doi.org/https://doi.org/10.1016/j.apergo.2015.11.020>
- van Veldhoven, M., & Broersen, S. (2003). Measurement quality and validity of the “need for recovery scale”. *Occupational and Environmental Medicine*, 60(suppl 1), i3. [https://doi.org/10.1136/oem.60.suppl\\_1.i3](https://doi.org/10.1136/oem.60.suppl_1.i3)
- Williams, N. (2017). The Borg Rating of Perceived Exertion (RPE) scale. *Occupational Medicine*, 67(5), 404-405. <https://doi.org/10.1093/occmed/kqx063>
- Yu, Y., Li, H., Yang, X., Kong, L., Luo, X., & Wong, A. Y. L. (2019). An automatic and non-invasive physical fatigue assessment method for construction workers. *Automation in Construction*, 103, 1-12. <https://doi.org/https://doi.org/10.1016/j.autcon.2019.02.020>
- Zhang, L., Diraneyya, M. M., Ryu, J., Haas, C. T., & Abdel-Rahman, E. M. (2019). Jerk as an indicator of physical exertion and fatigue. *Automation in Construction*, 104, 120-128. <https://doi.org/https://doi.org/10.1016/j.autcon.2019.04.016>
- Zhang, M., Sparer, E. H., Murphy, L. A., Dennerlein, J. T., Fang, D., Katz, J. N., & Caban-Martinez, A. J. (2015). Development and validation of a fatigue assessment scale for U.S. construction workers. *American Journal of Industrial Medicine*, 58(2), 220-228. <https://doi.org/10.1002/ajim.22411>. <https://doi.org/https://doi.org/10.1002/ajim.22411>

## ANNEXE A DESCRIPTION DES ALGORITHMES DE CLASSIFICATION UTILISÉS

Description du principe de l'algorithme du *Random Forest* :

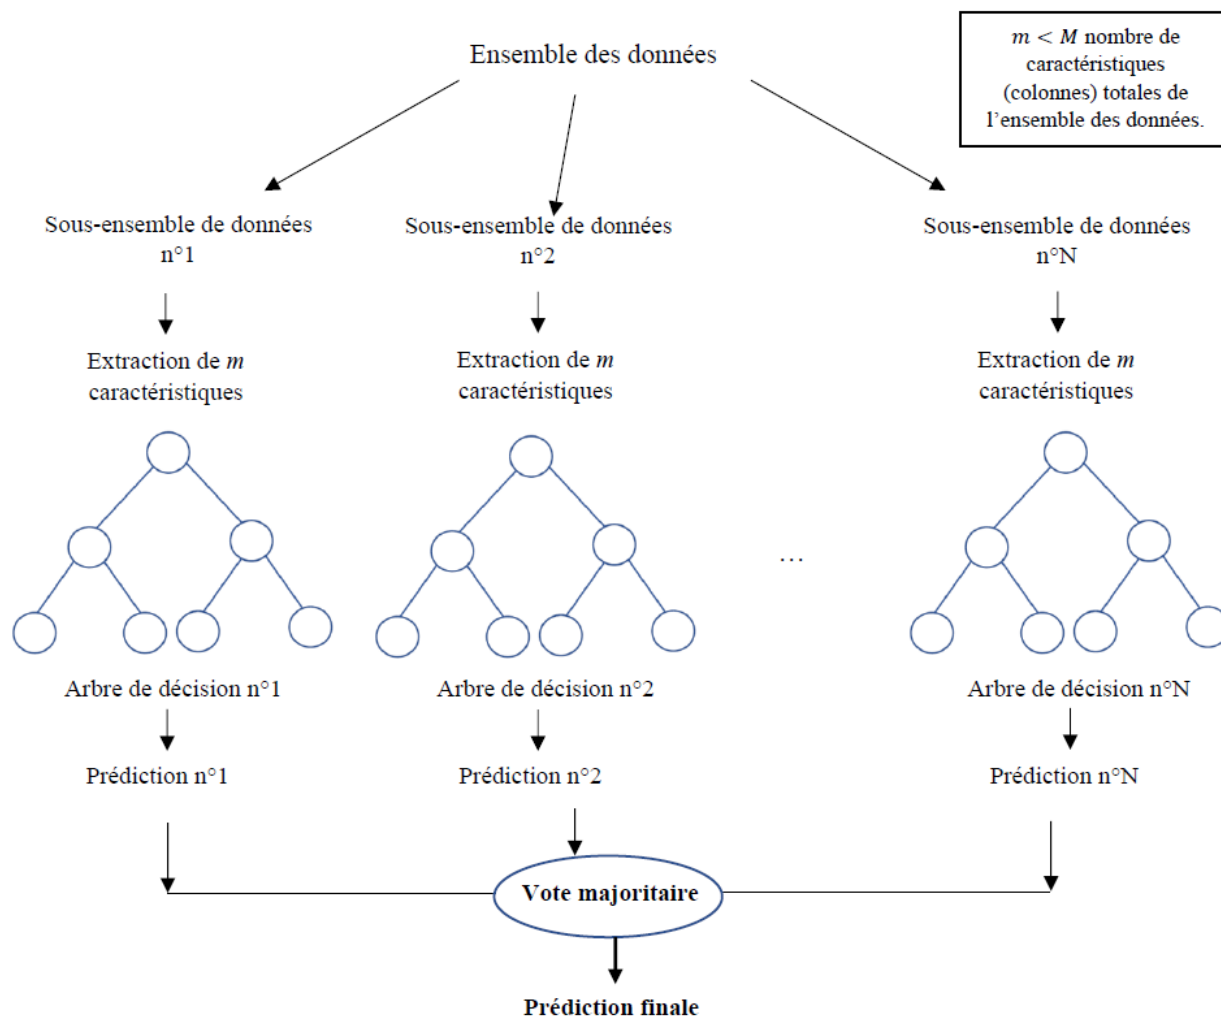


Figure A.1 Description du principe du modèle de Random Forest.

Description du principe de l'algorithme du *Boosted Trees* :



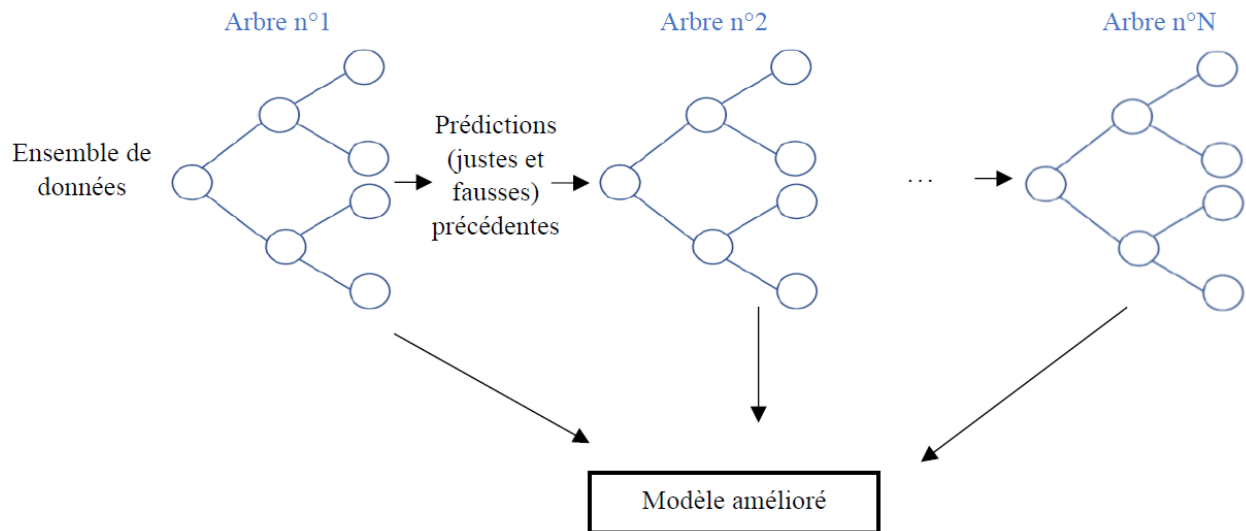


Figure A.2 Description du principe de l'algorithme du Boosted Trees.

Description du principe de l'algorithme du *Bagged Trees* :

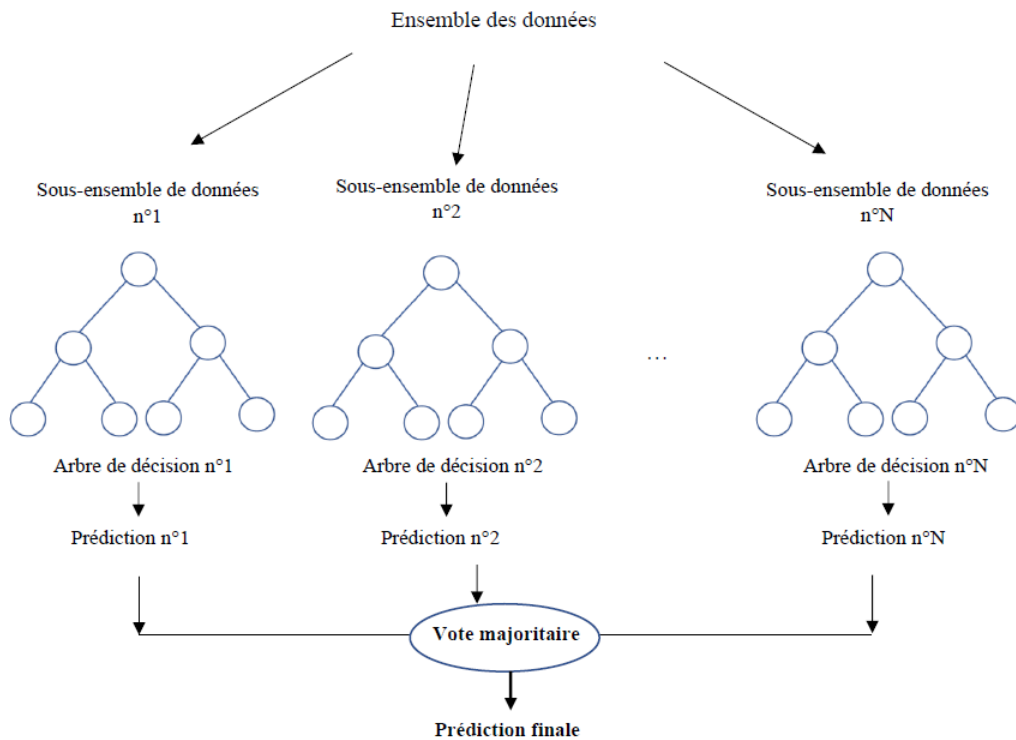


Figure A.3 Description du principe de l'algorithme du Bagged Trees.

## ANNEXE B DÉTAILS CONCERNANT L'ÉQUIPEMENT DE CAPTEURS

Exemple de fichier .csv enregistré sur la carte SD :

	sample	quat.w	quat.x	quat.y	quat.z	acc.x	acc.y	acc.z	gyr.x	gyr.y	gyr.z	grav.x	grav.y	grav.z	acc	gyr	mag	sys	HR
0	20.0	0.69	-0.24	0.66	0.16	-1.01	-0.05	-0.13	7.56	-21.00	-11.75	-9.73	-1.20	0.05	3	3	3	3	116
1	20.0	0.69	-0.24	0.66	0.16	-1.02	-0.02	-0.20	8.88	-5.25	-8.31	-9.72	-1.22	0.05	3	3	3	3	116
2	20.0	0.69	-0.24	0.66	0.16	-1.41	-0.05	0.01	6.81	21.69	-6.19	-9.72	-1.24	-0.01	3	3	3	3	116
3	20.0	0.69	-0.24	0.67	0.16	-1.48	-0.21	0.09	11.94	17.06	-1.00	-9.72	-1.24	-0.04	3	3	3	3	116
4	20.0	0.69	-0.24	0.67	0.15	-1.47	-0.25	0.15	12.56	4.69	1.87	-9.72	-1.23	-0.06	3	3	3	3	116

Figure B.1 Exemple de fichier .csv enregistré sur la carte SD.

Détail de la mise en fonctionnement et de la calibration de l'équipement de capteurs :

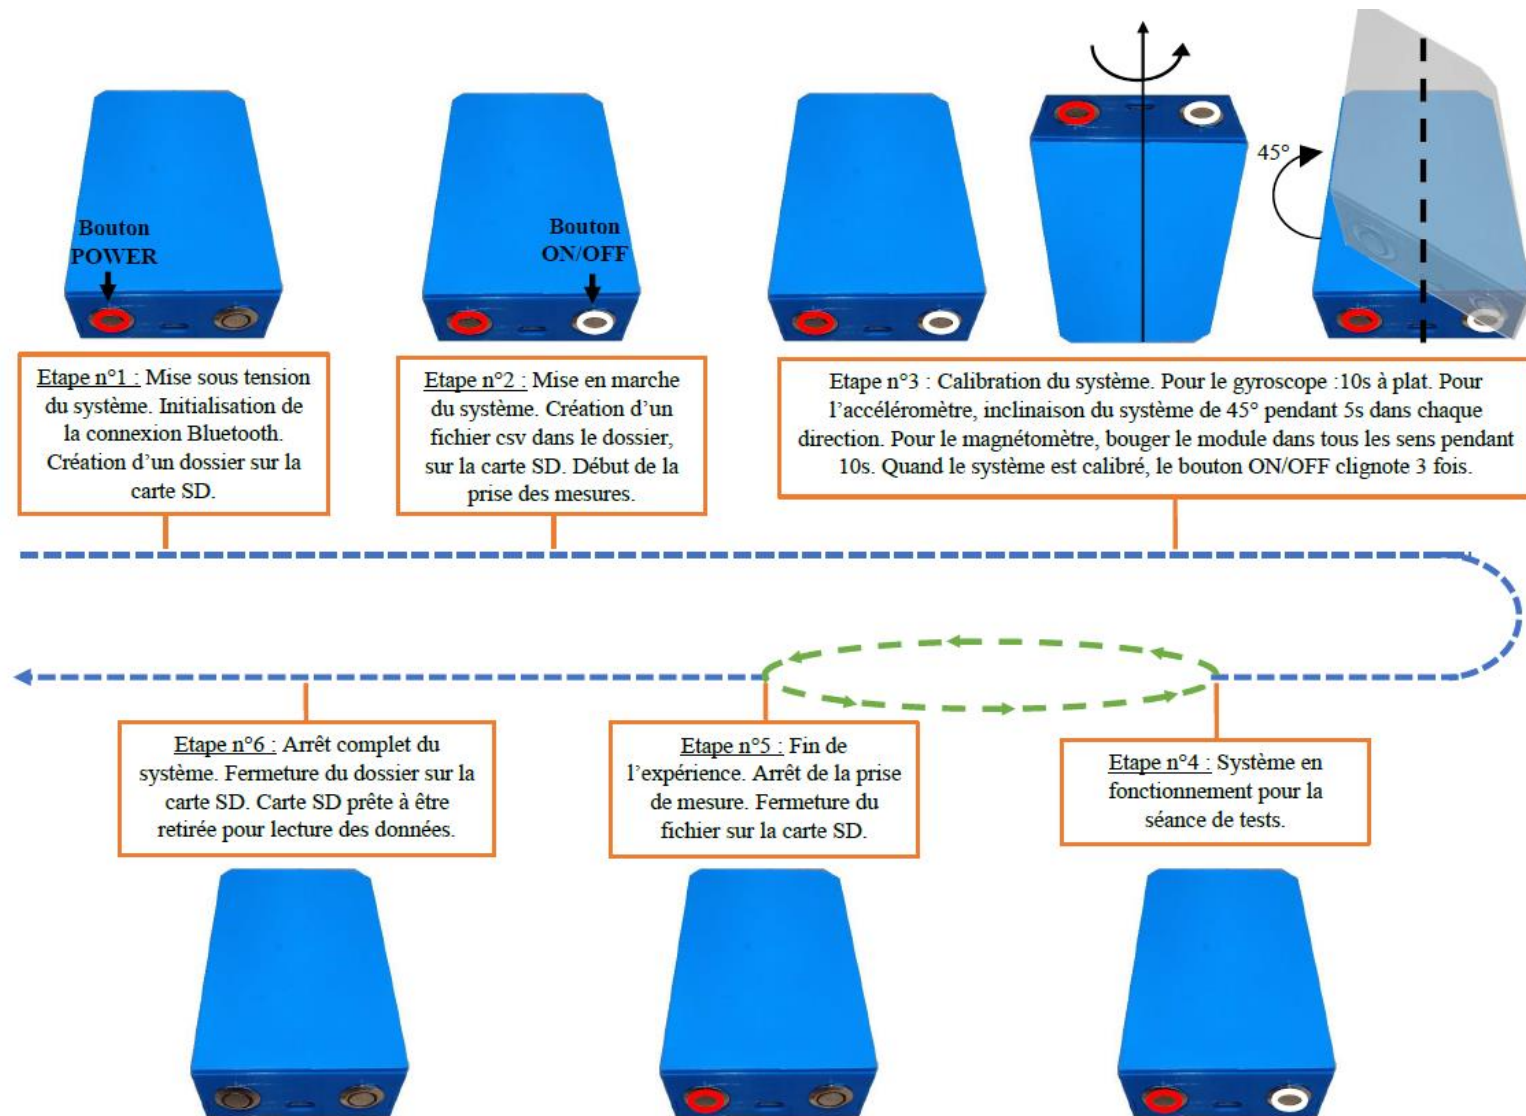


Figure B.2 Principe de fonctionnement et de calibration de l'équipement de capteurs.

## ANNEXE C DÉTAILS DES FONCTIONS DE VISUALISATION DES DONNÉES EN PYTHON.

### Fonction *dtypes()* :

Cette fonction est proposée par la librairie Panda sur Python. Elle retourne le type de variable de chacune des colonnes du tableau voulu.

```
[5]: P0_.dtypes

[5]: sample      float64
      quat.w      float64
      quat.x      float64
      quat.y      float64
      quat.z      float64
      acc.x       float64
      acc.y       float64
      acc.z       float64
      gyr.x       float64
      gyr.y       float64
      gyr.z       float64
      grav.x      float64
      grav.y      float64
      grav.z      float64
      acc         int64
      gyr         int64
      mag         int64
      sys         int64
      HR          int64
      dtype: object
```

Figure C.1 Exemple de la  
fonction *dtypes()*.

### Fonctions *isna()* et *sum()* :

Ces deux fonctions sont proposées par la librairie Panda sur Python. Utilisées conjointement, ces fonctions permettent de renvoyer le nombre de valeurs manquantes pour chacune des colonnes d'un tableau.

```
[7]: P0_.isna().sum()
```

```
[7]: sample      0
     quat.w      0
     quat.x      0
     quat.y      0
     quat.z      0
     acc.x       0
     acc.y       0
     acc.z       0
     gyr.x       0
     gyr.y       0
     gyr.z       0
     grav.x      0
     grav.y      0
     grav.z      0
     acc         0
     gyr         0
     mag         0
     sys         0
     HR          0
     dtype: int64
```

Figure C.2 Exemple  
des fonctions *isna()* et  
*sum()*.

### Fonction *heatmap()* :

Cette fonction est proposée par la librairie Searborn sur Python. Elle permet de visualiser la répartition des valeurs manquantes dans un tableau, en colorisant les cellules correspondantes d'une certaine couleur.

```
[16]: plt.figure(figsize=(20,10))
      sns.heatmap(data.isna(), cbar=False)
```



Figure C.3 Exemple de la fonction *heatmap()*.

### Fonction *describe()* :

Cette fonction est proposée par la librairie Panda sur Python et permet de décrire un tableau de données en renseignant les informations utiles (nombre d'éléments, min, max, moyenne etc) pour chacune des colonnes.

```
P0_.describe()
```

	quat.w	quat.x	quat.y	quat.z
<b>count</b>	131667.000000	131667.000000	131667.000000	131667.000000
<b>mean</b>	0.553396	-0.249921	0.337961	0.382862
<b>std</b>	0.394259	0.222318	0.328588	0.240268
<b>min</b>	-0.380000	-0.760000	-0.440000	-0.040000
<b>25%</b>	0.470000	-0.320000	0.100000	0.190000
<b>50%</b>	0.690000	-0.190000	0.460000	0.290000
<b>75%</b>	0.810000	-0.100000	0.630000	0.610000
<b>max</b>	0.980000	0.270000	0.840000	0.990000

Figure C.4 Exemple de la fonction *describe()*.

#### Fonction *clustermap()* :

Cette fonction est proposée par la librairie Seaborn sur Python. Elle permet une représentation visuelle (par code de couleur), des corrélations entre les différentes colonnes d'un tableau.

```
plt.figure(figsize=(12,8))
sns.clustermap(P0_.corr(), annot=True)
```




Figure C.5 Exemple de la fonction *clustermap()*.

## ANNEXE D QUATERNIONS

Les quaternions sont des nombres dans un sens généralisé. Ils englobent les nombres réels et complexes dans un système de nombres où la multiplication n'est plus une loi commutative. Ils sont régis par les relations suivantes :

$$i^2 = j^2 = k^2 = ijk = -1 \quad (15)$$

$i, j$  et  $k$  étant les trois éléments qui engendrent l'ensemble des quaternions  $\mathbf{H}$  (algèbre associative unifère sur le corps des nombres réels  $\mathbb{R}$ )

Les quaternions fournissent une notation mathématique commode pour représenter l'orientation et la rotation d'objets en 3 dimensions. Ils sont plus simples à composer et évitent le blocage de cardan [Annexe] par rapport aux angles d'Euler et sont plus stables et efficaces que les matrices de rotation. Un quaternion unitaire est décrit par :

$$\mathbf{q} = [q_0 \quad q_1 \quad q_2 \quad q_3]^T = [q_w \quad q_x \quad q_y \quad q_z]^T \quad (16)$$

$$|\mathbf{q}|^2 = q_0^2 + q_1^2 + q_2^2 + q_3^2 = q_w^2 + q_x^2 + q_y^2 + q_z^2 = 1 \quad (17)$$

Il est possible d'associer, de manière intuitive, un quaternion avec une rotation autour d'un axe, de la manière suivante :

$$\begin{cases} q_0 = q_w = \cos(\text{angle de rotation}/2) \\ q_1 = q_x = \sin(\text{angle de rotation}/2) * \cos(\text{angle entre l'axe de rotation et l'axe des x}) \\ q_2 = q_y = \sin(\text{angle de rotation}/2) * \cos(\text{angle entre l'axe de rotation et l'axe des y}) \\ q_3 = q_z = \sin(\text{angle de rotation}/2) * \cos(\text{angle entre l'axe de rotation et l'axe des z}) \end{cases}$$

Les an d'Euler servent notamment à représenter l'orientation d'un solide par rapport à un repère (Figure D.1).






Figure D.1  $\phi$  (roulis),  $\theta$  (tangage) et  $\psi$  (lacet).  
 L'axe  $N$  représente l'axe  $x$  intermédiaire autour  
 duquel se produit la rotation du roulis.