



**HAL**  
open science

# Reconnaissance d'activité humaine en natation : apports du deep learning pour le monitoring de l'entraînement basé centrale inertielle

Antoine Bouvet

## ► To cite this version:

Antoine Bouvet. Reconnaissance d'activité humaine en natation : apports du deep learning pour le monitoring de l'entraînement basé centrale inertielle. Sciences du Vivant [q-bio]. 2021. dumas-03279856

**HAL Id: dumas-03279856**

**<https://dumas.ccsd.cnrs.fr/dumas-03279856v1>**

Submitted on 6 Jul 2021

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

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



Distributed under a Creative Commons Attribution - NonCommercial - NoDerivatives 4.0 International License



**UNIVERSITÉ  
RENNES 2**



UNIVERSITÉ BRETAGNE LOIRE

UFR STAPS DE RENNES

Mémoire de Master 2 à finalité recherche

Année universitaire 2020-2021

Discipline : STAPS

Mention : *Entraînement et Optimisation de la Performance Sportive*

---

# Reconnaissance d'activité humaine en natation : apports du *deep learning* pour le monitoring de l'entraînement basé centrale inertielle

---

Présenté par : Antoine BOUVET

Encadrants :

Erwan DELHAYE (ENS Rennes, laboratoire M2S)

Nicolas BIDEAU (Université Rennes 2, laboratoire M2S)



*"Chaque aspect de l'apprentissage ou tout autre caractéristique de l'intelligence peut être si précisément décrit, qu'une machine peut être conçue pour le simuler."* Conférence de Dartmouth, 1956.

# Remerciements

Après bientôt deux ans de travail à ses côtés, je tiens à remercier du fond du coeur Erwan Delhaye. Plus qu'un tuteur académique me guidant et m'initiant non sans difficultés aux joies toutes relatives de la programmation informatique appliquée aux sciences du sport, j'ai avant tout trouvé dans nos échanges un collègue véritablement passionné de recherche disponible à toute heure, un camarade d'activité physique et de festivité et avant tout... un ami. Plus même, un "Tonton" qui à sa manière -dans et hors de la simple recherche scientifique, dans les bons et surtout dans les mauvais moments du quotidien- m'a bousculé dans mes certitudes, m'a ouvert l'esprit sur un champ des possibles auquel je serai passé outre et m'a ainsi invité à considérer des choix aussi bien scientifiques que personnels dont je ne regrette rien aujourd'hui. Quand je repense au projet initial de M1 dont nous discutions à Guerlédan il y a deux ans, à toutes ces soirées à refaire le monde du monitoring en natation où les idées de recherche fusent aussi vite que les pintes en se rêvant de tout révolutionner et à l'audace qui a été la tienne de se lancer et m'amener vers le *machine* et le *deep learning* pour deux stapsiens, je me dis que jamais je n'aurai pu rêver meilleur "encadrant". Pour ces moments de vie, de partage et d'enrichissement intellectuel, les marques de confiance que tu m'as témoigné et surtout tout le temps que tu m'as accordé -pourtant si précieux en thèse, je m'en rends compte maintenant- je souhaiterais t'adresser ma plus profonde reconnaissance.

Fruit d'un travail d'équipe j'espère que tu trouveras en ce mémoire un point d'appui pour ta thèse, ce serait du moins un honneur pour moi de pouvoir te rendre au millième la hauteur de l'investissement que tu as consacré à ma formation.

A Nicolas Bideau, Benoît Bideau et Guillaume Nicolas, pour m'avoir intégré pleinement dans l'équipe natation du laboratoire M2S avec leur bonne humeur et leurs blagues. J'ai eu l'opportunité de participer à des semaines entière d'expérimentation, avec un matériel de pointe et des nageurs de haut-niveau, sur des projets de recherche Sciences 2024. Je mesure la chance qui est la mienne d'avoir pu côtoyer un tel environnement en tant qu'étudiant et d'appréhender les mécanismes de la recherche sur ces projets où les enjeux dépassent la simple production scientifique. Je remercie par ailleurs Nicolas Bideau de m'avoir mis le pied à l'étrier du dispositif DIGISPORT qui m'a permis de me former dans des aspects de *data science* indispensables à mon projet de recherche, mais néanmoins absents d'un cursus classique en STAPS. Pour cette raison je souhaite remercier l'ENSAI et notamment Cécile Terrien de m'avoir accueilli et Matthieu Marbac-Lourdelle pour ses enseignements et l'intérêt qu'il porte à mon projet futur. Je n'ai qu'une hâte, celle de pouvoir continuer de tels échanges entre *sport science* et *data science* durant le PréLab.

Je tiens également à remercier le département 2SEP de l'ENS Rennes et son directeur Jean-Nicolas Renaud pour ses conseils avisés en cette année au contexte sanitaire singulier. Choisir de faire un M2 cette année à été le meilleur choix possible tant il m'a ouvert des perspectives et opportunités futures pour la thèse et le PréLab. A ce titre, j'adresse toute ma gratitude au département 2SEP et ses enseignants, pour nous offrir les qualités d'études inestimables qui sont les nôtres et nous apporter les conditions d'un perpétuel épanouissement intellectuel.

Aussi, un grand merci à tous les nageurs qui ont accepté de participer à la campagne de mesure de ce mémoire, la puissance du *machine learning* reposant en partie sur la quantité de données à disposition, sans eux ce mémoire n'aurait jamais vu le jour. L'accès à une piscine fut (encore plus) compliqué cette année, je tiens donc à remercier les acteurs nous en ayant accordé l'accès : Jacques Bolzer et Adrien Guilloret.

# Table des matières

<b>1</b>	<b>Liste des abréviations</b>	<b>5</b>
<b>2</b>	<b>Introduction</b>	<b>9</b>
<b>3</b>	<b>Cadrage théorique : reconnaissance d'activité en natation par centrale inertielle -perspectives de monitoring à l'entraînement-</b>	<b>11</b>
3.1	Concept de charge et de monitoring en natation : facteurs déterminants, méthodologies de mesure et éléments contextuels pour le développement d'un outil autonome de recueil de variables d'activité . . . . .	12
3.1.1	L'individualisation : une pratique nécessaire . . . . .	13
3.1.2	Quantification et liens entre paramètres de la charge d'entraînement et variations de performance : quelles variables retenir pour un outil de monitoring ? . . . . .	14
3.2	Technologie inertielle et Intelligence Artificielle au service de la reconnaissance d'activité natatoire . . . . .	17
3.2.1	<i>Inertial Measurements Units</i> (IMU) et leurs intérêts : un outil en vogue en science du sport et prometteur en natation . . . . .	18
3.2.2	Un nouveau paradigme méthodologique pour la reconnaissance d'activité humaine : des règles heuristiques aux données pour la classification des séries temporelles . . . . .	19
3.3	Reconnaissance d'activité et monitoring de la performance natatoire basé IMU . . . . .	24
3.3.1	Recueil de métriques via des règles heuristiques/seuils paramétriques . . . . .	24
3.3.2	Recueil de métriques via des modèles de <i>machine learning</i> reposant sur un <i>features engineering</i> humain . . . . .	27
3.3.3	Recueil de métriques via des modèles de <i>deep learning</i> automatisant le <i>features engineering</i> . . . . .	29
<b>4</b>	<b>Problématique</b>	<b>32</b>
4.1	Objectifs . . . . .	32
4.2	Hypothèses . . . . .	32
<b>5</b>	<b>Matériels et méthodes</b>	<b>34</b>
5.1	Participants . . . . .	34
5.2	Organisation expérimentale . . . . .	34
5.2.1	Centrale inertielle . . . . .	34
5.2.2	Enregistrement vidéo . . . . .	35
5.3	Protocole expérimental . . . . .	36
5.4	Traitement des données . . . . .	37
5.4.1	Labellisation des données vidéos . . . . .	37

5.4.2	Données inertielles et modèle de <i>deep learning</i> développé . . . . .	37
5.4.3	Post traitement de l' <i>output</i> du réseau et calcul de métriques de performance . . . . .	41
<b>6</b>	<b>Résultats</b>	<b>43</b>
6.1	Performances de classification d'activité du modèle . . . . .	43
6.2	Métriques de performances spatio-temporelles . . . . .	44
6.2.1	Temps intermédiaires . . . . .	45
6.2.2	Autres métriques d'activité natatoire . . . . .	46
<b>7</b>	<b>Discussion</b>	<b>47</b>
7.1	Apports, limites et perspectives scientifiques . . . . .	47
7.1.1	Modèle de reconnaissance d'activité natatoire . . . . .	47
7.1.2	Calcul de métriques spatio-temporelles à l'entraînement . . . . .	48
7.2	Perspectives sportives : applications au monitoring de l'entraînement . . . . .	50
<b>8</b>	<b>Conclusion</b>	<b>54</b>
<b>9</b>	<b>Annexes</b>	<b>66</b>
9.1	Annexe 1 : Variables permettant la quantification quotidienne et individuelle de l'entraînement de nageurs de niveau national et international (Mujika, 2017) . . . . .	66
9.2	Annexe 2 : Illustration de la singularité du signal inertiel selon la nage et les phases d'activités . . . . .	67
9.3	Annexe 3 : Vue schématique des relations entre IA, ML et DL (d'après Chollet et al. (2018) . . . . .	67
9.4	Annexe 4 : Apports conceptuels sur le fonctionnement d'un algorithme de <i>deep learning</i> (d'après Chollet et al. (2018)) . . . . .	68
9.5	Annexe 5 : synthèse des principales études de la littérature utilisant des méthodologies de type seuils/règles heuristiques pour monitorer nos variables d'activité identifiées comme d'intérêts . . . . .	69
9.6	Annexe 6 : Critères d'exigences d'un système de monitoring de l'activité en natation selon la population cible (d'après Mooney et al. (2017)) . . . . .	72
9.7	Annexe 7 : Définitions <i>gold-standard</i> des différents LT . . . . .	72
9.8	Annexe 8 : caractéristiques des sujets de de la campagne de mesure . . . . .	74
9.9	Annexe 9 : Lettre d'information relative à la campagne de mesure . . . . .	75
9.10	Annexe 10 : Formulaire de consentement éclairé relatif à la campagne de mesure . . . . .	76
9.11	Annexe 11 : Illustration du processus de labellisation manuelle des vidéos . . . . .	76
9.12	Annexe 12 : Justification de la <i>window size</i> . . . . .	77
9.13	Annexe 13 : <i>Offset</i> constaté entre le vecteur $y$ et $\hat{y}$ . . . . .	78
9.14	Annexe 14 : Évolution de la fonction de coût et de l' <i>accuracy</i> des <i>training</i> et <i>validation sets</i> au cours de l'entraînement du réseau . . . . .	79
9.15	Annexe 15 : Agrément statistique des LT END au <i>gold-standard</i> vidéo . . . . .	79
9.16	Annexe 16 : Preuve de concept pour l'utilisation du coefficient d'autocorrélation pour le compte des coups de bras . . . . .	80

# Chapitre 1

## Liste des abréviations

- 4N : Quatre Nage
- BA : *Backstroke* ou référence au label "Dos crawlé"
- BU : *Butterfly* ou référence au label "Papillon"
- BR : *breaststroke* ou référence au label "Brasse"
- CAM : Référence à la méthode d'évaluation *gold-standard* (vidéo) de la variable
- CNN : *Convolutionnal Neural Network* ou modèle de *deep learning* utilisant une ou plusieurs *layers* composée(s) de neurones à convolutions
- DL : *Deep Learning*
- FINA : Fédération Internationale de Natation
- FR : *Frontcrawl* ou référence au label "Crawl"
- HAR : *Human Activity Recognition*
- IA : Intelligence Artificielle
- IMU : *Inertial Measurement Unit* ou référence à la méthode d'évaluation automatique de la variable
- JO : Jeux Olympiques
- LSTM : *Long Short Term Memory* ou modèle de *deep learning* utilisant une ou plusieurs *layers* composée(s) de neurones récurrents à mémoire court et long terme
- LT : *Lap Time*
- LoA : *Limits of Agreement*
- MAPE : *Mean Absolute Percent Error*
- ML : *Machine Learning* ou référence aux méthodologies d'apprentissage automatique
- MLP : *MultiLayer Perceptrons*
- MPE : *Mean Percent Error*
- NL : Nage Libre
- RMS : *Root Mean Square*
- RMSE : *Root Mean Square Error*
- RS : *Rest* ou référence au label "repos"
- SVM : *Support Vector Machine*
- TEM : *Typical Error of Measurement*
- TU : *Turn* ou référence au label "virage"
- UN : *Underwater* ou référence au label "coulée"
- WA : *Wall-Push* ou référence au label "poussée sur le mur"

# Table des figures

3.1	Mise en évidence des traces et patterns accélérométriques singuliers lors d'évènements de l'activité natatoire : poussée au mur, coup de bras et virages (Davey et al., 2008) (A), poussée au mur, coulée et crawl (James et al., 2011) (B) . . . . .	18
3.2	Chaîne de reconnaissance de forme pour la prédiction d'activité humaine par apprentissage automatique . . . . .	22
3.3	Vue schématique du fonctionnement d'un réseau de neurones. L'élément principal à retenir et traduisant "l'apprentissage profond" est que le score de la fonction de perte est utilisé comme signal feedback pour ajuster les paramètres du modèle (Chollet et al., 2018) . . . . .	23
3.4	Schéma illustrant les différences entre programmation traditionnelle et apprentissage automatique . . . . .	24
4.1	Vue schématique de la problématique guidant le travail de recherche . . . . .	33
5.1	Positionnement anatomique du capteur sur le sacrum du sujet (ici avant pose de Tegaderm). Photo prise par les opérateurs avec la permission du nageur . . . . .	35
5.2	Schéma du dispositif expérimental utilisé lors de la campagne de mesure . . . . .	35
5.3	Illustration de la phase de <i>preprocessing</i> : exploitation du <i>template</i> issu de la labellisation vidéo pour la construction de fichiers CSV regroupant les <i>inputs</i> (signal IMU) et <i>targets</i> (labels) . . . . .	39
5.4	Signal accélérométrique et gyroscopique durant deux 100m 4N consécutifs et labels d'activité associés . . . . .	39
6.1	Matrice de confusion ( <i>F1-score</i> ) pour le modèle après <i>post-processing</i> . . . . .	43
6.2	Visualisation des prédictions d'activité du réseau avant et après <i>post-processing</i> et comparaison à la réalité attendue . . . . .	44
6.3	Graphique de Bland-Altman et densité de répartition des différences entre LT mesurés par gold-standard et centrale inertielle . . . . .	45
6.4	Graphique de Bland-Altman et densité de répartition des différences entre LT mesurés par gold-standard et chronomètre manuel . . . . .	46
7.1	Vue générale de l'activité du nageur sur la séance . . . . .	50
7.2	Analyse globale des métriques : focus sur la série cible . . . . .	51
7.3	Analyse spécifique des métriques de performance temporelles : focus sur la série cible . . . . .	51
7.4	Analyse spécifique des métriques de performance spatiales : focus sur la série cible . . . . .	52
7.5	Analyse spécifique des métriques de performance d'efficacité : focus sur la série cible . . . . .	52
9.1	Variables utilisées pour quantifier quotidiennement et individuellement l'entraînement sur la saison entière (Mujika et al. (1995); Mujika et al. (1996)) . . . . .	66
9.2	Signal IMU normalisé sur un 100m quatre nages (données personnelles) . . . . .	67

9.3	Schéma illustrant les relations entre les concepts d'Intelligence Artificielle, de <i>machine learning</i> et de <i>deep learning</i> d'après Chollet et al. (2018) . . . . .	67
9.4	Critères requis pour un système de monitoring de l'entraînement de nageurs loisirs et compétitifs selon Mooney et al. (2017)) . . . . .	72
9.5	Lettre d'information relative à la campagne de mesure . . . . .	75
9.6	Formulaire de consentement éclairé relatif à la campagne de mesure . . . . .	76
9.7	Processus de labellisation manuelle des données vidéos à partir des classes d'activités retenues pour la construction de <i>templates</i> par sujet . . . . .	77
9.8	Performance de classification moyenne de 18 modèles pour la reconnaissance d'activité nata-toire en fonction de la taille de fenêtre retenue . . . . .	78
9.9	Comparaison des vrais labels d'activités et de la prédiction filtrée du modèle sur le <i>testing set</i> : mise en évidence d'un <i>offset</i> . . . . .	79
9.10	Fonction de coût et <i>accuracy</i> au cours de l'entraînement du modèle . . . . .	79
9.11	Graphique de Bland-Altman et densité de répartition des différences entre LT mesurés par gold-standard et centrale inertielle . . . . .	80
9.12	Preuve de concept pour l'utilisation du coefficient d'autocorrélation afin de compter le nombre de coups de bras en crawl . . . . .	81
9.13	Preuve de concept pour l'utilisation du coefficient d'autocorrélation afin de compter le nombre de coups de bras en dos . . . . .	81
9.14	Preuve de concept pour l'utilisation du coefficient d'autocorrélation afin de compter le nombre de coups de bras en brasse . . . . .	82
9.15	Preuve de concept pour l'utilisation du coefficient d'autocorrélation afin de compter le nombre de coups de bras en papillon . . . . .	82

# Liste des tableaux

5.1	Protocole expérimental de l'étude . . . . .	36
5.2	Identification des différentes phases données à l'algorithme de reconnaissance d'activité natatoire	37
5.3	Critères de labellisation vidéo des différentes phases d'activités natatoire retenues . . . . .	38
5.4	Architecture et paramétrisation du réseau . . . . .	40
6.1	Validité de mesure des temps intermédiaires par IMU par rapport au <i>gold-standard</i> . . . . .	45
6.2	Validité de mesure des temps intermédiaires par chronomètre par rapport au <i>gold-standard</i> . .	46
9.1	Tableau présentant les principaux résultats de la littérature HAR natation basée seuils/règles heuristiques pour la reconnaissance du type de nage . . . . .	70
9.2	Tableau présentant les principaux résultats de la littérature HAR natation basée seuils/règles heuristiques pour la reconnaissance des événements singuliers de l'activité natatoire (poussée au mur, virage, touche) . . . . .	71
9.3	Critère de définition des différentes catégories de temps intermédiaires selon la nature de la nage	73
9.4	Caractéristiques principales des sujets de l'étude. NAT = natation, TRI = triathlon, N = national, IR = interrégional, R = Régional D = départemental, Re = récréationnel . . . . .	74

## Chapitre 2

# Introduction

La différence relative entre le premier et le dernier de la finale masculine du 100 NL des JO a continuellement diminué de 4,3% en 1976 à 1,7% en 2016 (Ganzevles et al., 2017). Cette réduction des écarts dans le sport de haut niveau suit une tendance exponentielle. Ils ont considérablement diminué au fil des années. Cela a parallèlement augmenté d'autant plus les innovations nécessaires pour atteindre des améliorations de la performance, désormais de l'ordre de la fraction de seconde (Peterson et al., 2005). Pour répondre à ces exigences croissantes du haut-niveau actuel, les entraîneurs et scientifiques sont continuellement à la recherche de stratégies d'optimisation de la performance et de l'entraînement (James et al., 2004). Cette densification couplée à une augmentation continue du niveau de performance, imposent aux nageurs de se préparer différemment pour la compétition. Cela a pour conséquence d'augmenter la charge de travail pesant sur les athlètes (Feijen et al., 2020a) en se répercutant dans les programmes d'entraînements. Ils sont de nos jours très souvent volume-dépendant et caractérisés par une continuité permanente sur l'année avec peu de temps accordé à la récupération lors de phases de coupure inter-saisons (Pink and Tibone (2000); Tate et al. (2012)). On estime ainsi le volume d'entraînement moyen de nageurs élites à 57,1km/semaine (Feijen et al., 2020b). Une telle exposition chronique de l'organisme aux stimuli de l'activité, bien que nécessaire, peut conduire les nageurs à s'entraîner trop dur par rapport à leurs capacités (Sein et al., 2008). Cela les impactent d'une récupération insuffisante mais pourtant requise pour des adaptations optimales au programme d'entraînement (Olbretch, 2007). Ces fortes charges conduisent à augmenter le risque de blessure des tissus mous, les douleurs et les insatisfaction associées à la pratique (Walker et al., 2012) : les douleurs aux épaules sont ainsi particulièrement fréquentes (Bak (2010); Wolf et al. (2009)) et avec une prévalence extrêmement élevée de 91% c'est une cause majeure d'arrêt de la pratique (Weldon and Richardson, 2001). Un constat se dégage alors de ces pratiques d'entraînement modernes qui se modulent pour répondre à la compétitivité accrue : elles tendent vers une augmentation des demandes et contraintes biologiques sur les organismes et entraînent alors une haute incidence de blessure. Il est donc indispensable d'individualiser, de réguler, et d'ajuster la prescription d'entraînement de manière personnelle pour chaque athlète. Afin d'éviter des désadaptations chronique de l'homéostasie néfastes à la performance. Cela nécessite une évaluation continue, valide et reproductible, de l'activité des nageurs à l'entraînement. En conséquence de ce cadre général, **le monitoring de la charge d'entraînement des nageurs est devenu au cours des années un concept clé de la performance qui nécessite recherche et investigation** (Mountjoy et al., 2016). Il passe par une quantification de la charge via divers paramètres relatifs à l'activité humaine. Cela s'opérationnalise sur le terrain par le développement d'outils de reconnaissance d'activité garantissant la possibilité de recueillir de manière régulière des données fiables sur l'entraînement des athlètes, offrant une évaluation précise de leur charge, et permettant d'appréhender les effets et réponses à l'entraînement de chacun à travers un suivi longitudinal.

Traditionnellement les coachs en natation gèrent l'entraînement via un chronomètre manuel -permettant de déterminer le temps sur une distance spécifique (Craig and Pendergast, 1979)- qu'ils couplent à des observations techniques de l'activité de leur nageur (Ohgi et al., 2014). Cette méthode simple, rapide, et donc pratique, permet une évaluation empirique spatio-temporelle de la performance, à savoir du « *comportement donné, d'un individu donné (ou d'un groupe d'individus donnés) dans une situation donnée à un moment donné* » (Fleishman et al., 1984).

L'utilisation du chronomètre est sujette à l'erreur humaine avec un écart-type de mesure par rapport à l'analyse vidéo de 0,6s (Davey et al., 2004). L'erreur augmente avec le nombre de nageurs supervisés. Les groupes d'entraînements actuels en regroupent souvent au minimum 10 qui réalisent toutes leurs actions en même temps et à des côtés opposés du bassin. L'entraîneur est de plus dans l'incapacité d'enregistrer en chronique ces relevés chronométriques afin d'analyser l'activité effective de ses nageurs. Pour mener à bien la séance, évaluer ses effets, et monitorer l'entraînement de manière individuelle, l'entraîneur a dès lors besoin d'obtenir et d'enregistrer des informations -à minima temporelles- pour tous. Actuellement il lui est difficile de mener à bien cette mission de monitoring dans une démarche opérationnelle. C'est ainsi qu'une demande du terrain concernant la capacité à recueillir ce type de données objectives se fait ressentir (Burkett and Mellifont, 2008) et émane particulièrement des staff et athlètes eux-mêmes afin de fournir une aide au processus de décision et de régulation de l'entraînement : "*rather than coaches 'seing' to make recommendations, we need objective solution to aid their decision-making processes*" (Callaway, 2015). Pour ne pas appesantir l'entraîneur de cette tâche de monitoring et de le recentrer sur son rôle de technicien plutôt que de "coach-horloge", l'utilisation de technologies de reconnaissance d'activité humaine permettant un relevé et un enregistrement automatique de variables peut s'avérer utile dans la recherche d'une optimisation du processus d'entraînement. Ces procédés ont alors pour but de libérer du temps d'expert en catalysant les appréciations technique de l'entraîneur.

Ces assertions mettent en lumière un besoin croissant d'outils de monitoring en natation retrouvé dans la littérature (Ganzevles et al., 2017). Cette nécessité fait écho au contexte général de la performance natatoire évoqué plus haut et est pleinement guidée par des attentes du terrain comme le font remarquer Michaels et al. (2016) : "*feedback from elite coaches has indicated that development of this could be an extremely useful addition to their training regime*". Néanmoins mettre en place un système de monitoring automatique de l'entraînement en natation basé sur la mesure directe de l'activité du nageur demeure un challenge scientifique, technique et technologique. Notamment car le milieu aquatique complexifie le déploiement desdits outils (Michaels et al., 2016) et leur généralisation à des athlètes de niveaux et techniques de nage hétérogènes rend difficile la validité et reproductibilité des métriques évaluées. En revanche la prolifération récente des moniteurs inertiels d'activité *low-cost*, composés d'un accéléromètre et d'un gyroscope tri-axiaux, comme les montres connectées ou le Triton redéfinit le champ des possibles de l'analyse de la motricité et offre de nos jours des perspectives d'intérêts en *Human Activity recognition* (HAR) (Attal et al., 2015). Notamment à des fins sportives d'analyse et d'optimisation de l'entraînement : "*wearable sensor technologies hold the key to unlocking novel performance assessment and there is interest in the development of sports technology*" (Callaway, 2015). Par ailleurs l'émergence de nouvelles méthodologies de traitement des signaux inertiels, notamment via des paradigmes basés Intelligence Artificielle (IA) (Cust et al., 2019), permettent aujourd'hui d'envisager l'élaboration d'un outil robuste de reconnaissance d'activité natatoire, pré-requis pour du monitoring. Cela notamment par la meilleure capacité de généralisation du *deep learning* (DL) sur des tâches de HAR par rapport aux méthodologies classiques de la littérature (Nweke et al., 2018).

La natation jusqu'à présent contrainte par son milieu aquatique complexificateur se trouve donc pleinement impactée pour le monitoring de l'entraînement par ces évolutions et perspectives techno-méthodologiques.

## Chapitre 3

# Cadrage théorique : reconnaissance d'activité en natation par centrale inertielle -perspectives de monitoring à l'entraînement-

Nager est une pratique impliquant la résolution d'un triple problème : à la fois réduire les résistances à l'avancement et maximiser les forces propulsives tout en diminuant le plus possible le coût physiologique de la locomotion aquatique (Sanders, 2002). La prédominance de contraintes biomécaniques et physiologiques imposées à l'organisme pour la locomotion aquatique guide notre idée d'un nécessaire monitoring de l'activité humaine à l'entraînement en natation. Qui plus est de manière automatisée.

L'entraînement sportif s'inscrit comme un processus par lequel les athlètes sont exposés à un stimulus d'exercice systématique et répétitif (une dose) dans le but d'induire par compensation physiologique des adaptations conduisant à des fonctions désirables (des réponses) : retarder la survenue de la fatigue, augmenter la puissance développée, affiner la coordination motrice ou réduire le risque de blessure (Mujika, 2017). Nous positionnons donc notre vision de l'entraînement sportif dans le cadre de ce modèle dose-réponse visant à perturber de manière transitoire l'homéostasie biologique afin de stimuler des adaptations de l'organisme conséquentes et bénéfiques à l'élévation du niveau de performance (Borresen and Lambert, 2009). Les entraîneurs considèrent généralement que le résultat de ce processus d'entraînement dépend de la nature et de la quantité du stimulus, et ont compris que la relation dose-réponse de l'entraînement est cruciale pour prescrire les séances en conséquence (Lambert and Mujika, 2013). En effet, un équilibre fin entre stress causé par l'exercice et récupération est nécessaire pour une élévation des capacités de performance (Smith, 2003) : *"the training adaptations are associated with changes in performance. Finding the optimal balance between training load and recovery is crucial for sports performance"* (García-Ramos et al., 2015). Néanmoins, afin d'analyser et d'établir des relations entre l'entraînement réalisé et les adaptations en résultant, une quantification valide et reproductible de la charge d'entraînement réalisée par l'athlète est une condition préalable. Il n'est simplement pas possible d'identifier les effets de l'entraînement sans une quantification précise de cette charge (Mujika, 2013). Notons que cette évaluation repose sur des méthodes de reconnaissance d'activité humaine, natatoire dans notre cas, et appliquées en l'occurrence à l'entraînement sportif.

A cause des facteurs environnementaux du milieu aquatique contraignant le développement technologique nécessaire, l'évaluation de l'activité du nageur est aujourd'hui archaïque comparée aux autres disciplines à

dominantes physiologiques comme le cyclisme ou la course à pied. Quantifier la charge en natation par le relevé chronique de métriques d'activité humaine n'est pas chose aisée. Cela induit un monitoring de l'entraînement difficile : *"while the 'response' can be measured rather easily, either as a change in performance in the laboratory or field or as a physiological adaptation, the 'dose' imposes more difficulty and logistical challenges"* (Lambert and Borresen, 2010). D'une part l'apport des nouvelles technologies inertielles portatives sous forme de capteur embarqué offrant les conditions d'une mesure sans perturbations peut alors se présenter comme un axe d'amélioration du monitoring de l'entraînement en natation, en automatisant la collecte de données sur les athlètes. D'autre part, l'exploration de méthodologies récentes en plein essor dans le champ de la HAR, fondées sur l'IA et plus particulièrement le DL appliqué aux séries temporelles, semblent offrir des solutions de traitement innovantes et prometteuses desdites données brutes récoltées. Cela permet d'envisager le dépassement des limites actuelles de la littérature sur la quantification de métriques d'entraînement en natation. Notamment en terme de généralisation en condition réelles et ainsi fournir un véritable outil utilisable en routine et par tout type de nageurs.

### 3.1 Concept de charge et de monitoring en natation : facteurs déterminants, méthodologies de mesure et éléments contextuels pour le développement d'un outil autonome de recueil de variables d'activité

*"Accurate monitoring of the athlete's training load is a key concept for optimizing performance while reducing risk of injury"* (Feijen et al., 2020a). Le concept de charge d'entraînement apposée aux athlètes à l'entraînement comme en compétition ainsi que son monitoring sont devenus des sujets avec une importance grandissante en sciences du sport et convoquant une approche multidisciplinaire (Bourdon et al., 2017). Monitorer la charge d'entraînement est essentiel : pour déterminer dans quelles mesures un athlète s'est adapté au programme réalisé, pour comprendre ses réponses individuelles, pour mesurer la fatigue et les besoins conséquents de récupération ou encore pour minimiser les risques de surmenage fonctionnel et prévenir le surentraînement, blessures ou maladies (Taylor et al., 2012). Ainsi, avoir à disposition des entraîneurs et staff des outils de monitoring permettant des mesures robustes sur un grand nombre de nageurs -donc généralisables- est devenu un enjeu majeur de la recherche de performance.

*"Analyzing internal and external training loads has become a critical issue in elite sport practice and research. [...] This implements an understanding of the individual's responses to training, assessing fatigue and the associated need for recovery, in order to minimize the risk of functional overreaching, injury and illness"* (Collette et al., 2018). La charge d'entraînement -qu'elle soit interne ou externe- répond à un but d'ajustement de la prescription d'exercice tout en déterminant la relation entre cette charge objectivée -la dose d'entraînement- et la performance quotidienne de l'athlète (Mujika, 2017). Cela permet de s'assurer de la pertinence de l'entraînement. Par ailleurs, les métriques quantifiées pour déterminer la charge offrent la possibilité de catégoriser le stimulus d'entraînement dans des zones d'intensité relatives à la sollicitation de processus métaboliques et physiologiques singuliers. Certaines métriques, notamment cinématiques, peuvent également donner des indications singulières sur la manière dont l'athlète réalise ce stimulus physiologique donné (ex : nombre de coups de bras par longueur et métriques associées : amplitude, *swolf score*, fréquence de nage, rapport fréquence/amplitude etc...). L'analyse de ces métriques facilite l'évaluation de ce qui a été réellement réalisé par l'athlète au cours de la séance et la comparaison de cette activité effective aux prescriptions initiales de l'entraîneur. De plus, implémenter un tel procédé de manière chronique permet d'évaluer les progrès et par la même l'état de forme de l'athlète. Donc les besoins conséquents de modification de la charge d'entraînement. Naturellement cette catégorisation doit être propre aux capacités et objectifs de

chaque nageurs. Afin d'offrir une solution de monitoring personnalisée et adaptée, qui contribue à optimiser leur développement en offrant une meilleure régulation de l'entraînement et la possibilité de détecter les maladaptations en amont (Roos et al., 2013).

Ainsi, le monitoring quantitatif et qualitatif du stimulus vécu par l'athlète assiste et informe l'entraîneur sur l'activité effective du nageur et le renseigne en conséquence sur l'atteinte ou non du plan d'entraînement initial, qu'il peut dès lors réguler et ajuster à chacun. Ces variables constituent autant d'outils de catalyse de l'expertise de l'entraîneur par l'aide à la décision et à l'élaboration/régulation des séquences d'entraînement. Toutefois pour espérer atteindre ces objectifs de monitoring il faut avoir à disposition un modèle de HAR spécifique à l'entraînement sportif en natation permettant de quantifier la charge d'entraînement par la collecte de métriques d'activité. Or l'implémentation de telles méthodes demeure difficile sur le terrain et encore plus en natation comme le notent García-Ramos et al. (2015) : *"to date no effective method has been described for assessing training loads in swimming that can discriminate between different types of time intervals"*

### 3.1.1 L'individualisation : une pratique nécessaire

*"The fact that swimmers applied different solutions to cope with the task highlights the necessity of individual monitoring of elite athletes"* (Ganzevles et al., 2017). En plus de mettre en place une organisation segmentaire singulière, un sujet peut répondre différemment à un stimulus d'entraînement donné (Bouchard and Rankinen, 2001). Ainsi la charge absolue requise pour générer une adaptation varie grandement d'un athlète à un autre (Halsen, 2014). Cette variation interindividuelle de réponse à l'entraînement et le besoin conséquent d'un monitoring individualisé s'en trouve encore plus renforcé à haut-niveau puisqu'il est noté un haut degré de spécificité en terme de charge et d'adaptations à l'entraînement (Collette et al. (2016); Julian et al. (2017)) ainsi que de statut de la balance stress-récupération (Hecksteden et al., 2017). Une approche individualisée est alors importante pour s'assurer que la charge vécue par l'athlète correspond avec les intentions initiales du coach (Wallace et al., 2009). Cette problématique est aujourd'hui centrale dans les pratiques d'entraînement en natation où le coach prescrit une séance bien souvent identique pour tous les athlètes, ou différenciant a minima sprinteurs et demi-fondeurs, ayant alors des répercussions biologiques parfois très éloignées de sa volonté.

Il est donc nécessaire de proposer des pratiques de monitoring chroniques et individualisées par athlète dès lors que l'on souhaite en retirer des *insights* pertinents : *"we recommend performing intra individual evaluations as well as repeated measurements to establish an individual baseline from which changes can be determined in order to enable a training optimization through individual athletes monitoring"* (Collette et al., 2018). Cela peut par exemple passer une paramétrisation de zones d'intensités individuelles basées sur l'allure de nage de chacun.

Nous pouvons en retenir qu'un outil de monitoring visant à offrir une vision systémique sur l'entraînement réalisé par les nageurs doit fournir des indices et métriques mettant en relief des variables de charge externe avec les capacités performatives de chaque individu afin de s'assurer d'un stimulus d'entraînement en adéquation avec l'intention première de l'entraîneur (Crowcroft et al., 2017). Cela permet la réduction de l'écart entre activité prescrite et activité effective du nageur et in fine la prévention des adaptations négatives à l'entraînement (Soligard et al., 2016). Ces assertions nous guideront tout au long du développement de notre outil de monitoring afin d'être en cohérence avec les attendus de la haute performance. L'apport des nouvelles technologies et méthodologies de traitement évoquées précédemment peut alors permettre de

faciliter la mise en place d'un tel monitoring automatique individualisé en situation réelle. Sans ces contributions à la reconnaissance d'activité natatoire, intégrant les méthodologies de HAR adaptées aux contraintes de la natation et de l'entraînement sportif, le monitoring singulier serait extrêmement chronophage pour l'entraîneur et le staff.

### 3.1.2 Quantification et liens entre paramètres de la charge d'entraînement et variations de performance : quelles variables retenir pour un outil de monitoring ?

*"In swimming, distance and/or speed are often used to monitor the external training load"* (García-Ramos et al., 2015). Les pratiques usuelles de mesure de la charge en natation se basent sur la combinaison du volume nagé, de l'intensité de l'effort et de la fréquence des séances. Toutefois la nature du monitoring et de la surveillance de charge varie grandement selon le sport considéré et ses facteurs de performance (Laursen and Buchheit, 2019). Dans les sports individuels à dominante physiologique comme le cyclisme, la natation et la course à pied, la fatigue et les maladaptations homéostatiques sont souvent le résultat de haute charge d'entraînement. De ce fait, le management de cette charge à travers le monitoring est particulièrement important (Pyne and Martin, 2011). Il est alors généralement basé sur le volume d'entraînement, la durée et l'intensité de celui-ci (Halson, 2014). Par exemple, l'annexe 9.1 présente un ensemble de variables utilisées pour quantifier l'entraînement chez des nageurs de niveau national et international (Mujika et al. (1995); Mujika et al. (1996)). Deux variables fondamentales de l'entraînement en natation se dégagent de la littérature : le volume et l'intensité. Il nous importe d'éclaircir le lien de chacune avec les variations de performance afin d'en évaluer leur importance relative pour l'élaboration d'un outil pertinent de monitoring automatique de l'entraînement en natation.

#### Volume et performance : une variable sacralisée dans les pratiques usuelles d'entraînement

Une croyance empirique forte et persistante dans l'entraînement en natation stipule que l'amélioration de la force et de l'endurance sont proportionnelles au volume de travail réalisé (Costill et al., 1991). En effet, les pratiques largement diffusées et ancrées chez les entraîneurs sont basées sur le postulat qu'une augmentation du volume produit systématiquement des réponses adaptatives qui vont directement mener à une amélioration de la performance (Chatard and Stewart, 2011). On observe ainsi une augmentation du volume au fil des ans, passant chez des élites d'environ 1300-1700km/an en 1968 à environ 1900-3500km/an en 1980 (Platonov and Jonco, 1988). Cette philosophie plaçant la variable du volume au cœur du processus d'entraînement, parfois au détriment de l'intensité, n'est pas systématiquement validée par la littérature. Mujika et al. (1995) notent par exemple qu'une augmentation du volume d'entraînement de 749 à 1475km/saison n'est pas significativement corrélée avec la performance chez 18 sprinteurs internationaux. De plus, des pratiques de « kilométrage bouche-trou » ont été mise en lumière dans les prescriptions d'entraînement (Stewart and Hopkins, 1997), les entraîneurs ajoutant à foison du volume à allure lente et modérée pour atteindre le volume cible dans la séance. Pire encore, doubler le volume d'entraînement, passant de 5km/jour à 9,4km/jour sur 6 semaines, n'a pas d'effets constatés sur les capacités aérobies ou anaérobies, tandis que la vitesse maximale de sprint et la performance sont diminuées (Costill et al., 1991).

Ces constats mis en lumière par la littérature indiquent qu'il semble exister chez des nageurs de haut-niveau un seuil critique de volume au-delà duquel l'augmentation de volume génère davantage une perte de la capacité à stimuler des adaptations positives à l'entraînement au profit d'adaptations négatives. C'est-à-dire de maladaptations à la charge, tandis que l'intensité de l'entraînement devient le paramètre clé pour produire des réponses favorables élevant le niveau de performance (Chatard and Stewart, 2011). Néanmoins, un haut

volume à basse intensité est toutefois nécessaire et important, en plus d'être culturellement ancré dans les pratiques communes d'entraînement en natation. Car il permet d'améliorer le processus de récupération consécutif au stress aigu d'une séance et ainsi permettre une meilleure tolérance à de futurs entraînements à haute intensité et exigeant physiologiquement (Sharp, 1993). La capacité de glisse dans l'eau peut aussi être développée avec l'augmentation du volume à basse intensité ce qui produit une réduction conséquente du coût énergétique de la nage (Chatard et al., 1990). Enfin, la natation, sport où la part kinesthésique et perceptive de sensations d'appuis propulsifs dans l'élément liquide fuyant étant importante, le volume à basse intensité permet aux nageurs d'entretenir et de rechercher ces informations sensorielles. Dès lors le volume a malgré tout une importance non négligeable comme le note Collette et al. (2018) : *"it is assumed that in endurance sports such as swimming, volume has a greater impact on the recovery-stress state than duration"*.

Au final, bien que le volume soit une variable culturellement indispensable en natation, l'intensité apparaît comme un facteur de préoccupation notable -chez des nageurs réalisant déjà un fort volume- pour mener à bien le processus d'entraînement. Il convient donc, en plus du volume nagé, de la monitorer avec grand intérêt dans une démarche valide et reproductible, garante d'informations pertinentes pour le staff.

### **Intensité et performance : une variable d'intérêt pour un monitoring pertinent**

L'intensité d'un exercice se mesure par différents moyens reflétant la charge interne ou externe : temps intermédiaire ou *lap time* (LT), fréquence cardiaque, consommation d'oxygène, cotation d'effort ressenti ou encore lactatémie. Ainsi Mujika et al. (1995) proposent une mesure de l'intensité d'entraînement spécifique à la natation et fondée sur cinq zones de lactatémie. Cela permet une quantification de la répartition des intensités, à la fois dans l'entraînement de manière aiguë mais aussi au cours de la saison de façon chronique. Mais la méthode est cependant invasive et présente certaines limites quant à son utilisation sur le terrain. La mesure la plus valide, reproductible et surtout pratique en routine semble alors être l'évaluation des temps de nage sur une distance donnée car les mesures physiologiques ont des cinétiques singulières associées à des temps de latence trop long pour être adaptées à des conditions d'entraînement de natation où il n'y a pas d'état stable. L'entraînement intermittent est en effet la norme (Chatard and Stewart (2011); Laursen and Buchheit (2019)). Wakayoshi et al. (1992) confirment ce constat en notant que d'un point de vue pratique, les allures d'entraînement sont un bon marqueur de l'intensité de la séance. Plus récemment, Wright and Stager (2013) notent qu'il est crucial pour les coachs de natation de monitorer la vitesse de nage durant les entraînements : cette vitesse pouvant être reflétée, pour chaque longueur, par les LT.

L'intensité de l'exercice apparaît dans la littérature comme un facteur clé d'importance prépondérante pour produire des effets d'entraînement pertinents chez des athlètes entraînés (Acevedo and Goldfarb, 1989). En effet, Mujika et al. (1995) ont étudié, chez 18 sprinteurs internationaux, les relations entre les paramètres de la charge et les variations de performance à l'échelle de la saison et relatent que l'intensité moyenne durant la saison, plus encore que le volume ou la fréquence, est le paramètre majeur influençant significativement les améliorations de performance ( $r=0,69$ ,  $p<0,01$ ). Cela a aussi été retrouvé dans d'autres disciplines à dominantes physiologiques comme chez des coureurs à pied (Mikesell and Dudley, 1984), des cyclistes (Nearly et al., 1992) et des skieurs de fond (Rusko, 1987). L'importance de cette variable se trouve renforcée à l'aune des pratiques d'entraînement polarisé qui sont de plus en plus en vogue chez les athlètes d'endurance élite réalisant un volume très important (Seiler and Kjerland, 2006). Cela implique qu'à la fois l'intensité moyenne et haute sont importantes pour l'athlète afin d'optimiser les adaptations et la maîtrise technique à un niveau requis (Seiler (2010); Stöggl and Sperlich (2014)). Il est donc nécessaire que les méthodes de quantification de la charge d'entraînement et de monitoring balayent cette entière gamme d'intensité d'entraînement, en plus d'autres variables précédemment évoquées comme le volume et la fréquence (Mujika et al., 1995).

En conséquence, monitorer l'intensité des entraînements, notamment par la mesure robuste et automatique des LT, est fondamental au vu de l'importance relative de cette variable dans la production d'effets adaptatifs bénéfiques à la performance et à fortiori dans le processus de décision et de régulation du programme d'entraînement par les staffs. En effet, nous partageons cette affirmation de [Ohgi et al. \(2014\)](#) : *the authors believe that swimming time is the most important quantitative parameter for the swimming training*".

Il ressort de cet état de l'art concernant les paramètres de la charge en natation que l'intensité devient un paramètre clé pour optimiser la performance au lieu du volume classiquement utilisé comme variable de référence chez des athlètes déjà bien entraînés. Malgré l'importance de la variable d'intensité, celle-ci présente toutefois en pratique une faible adhérence ([Stewart and Hopkins, 1997](#)). En conséquence nous pensons que l'élément central au coeur du développement d'un outil autonome de monitoring de l'entraînement en natation doit être cette variable d'intensité, objectivée par les LT, et la répartition des intensités à l'entraînement. A celle-ci nous rajoutons la considération d'autres paramètres d'analyse macroscopiques comme microscopique que sont le volume et des variables cinématiques comme le compte des coups de bras et ses métriques dérivées. La capacité à détecter les phases d'une séance d'entraînement de natation (poussée au mur, coulée, type de nage, virage, repos, etc...) est une condition nécessaire et préalable pour garantir le calcul de toutes ces métriques. En effet implémenter un système de monitoring tel que nous le décrivons ne peut s'opérationnaliser que par la capacité à classer finement l'activité du nageur au cours d'une séance d'entraînement comme l'évoque [Brunner et al. \(2019\)](#) : *"in order for a smartwatch to replace the duties of a coach, it therefore should be able to differentiate between styles and exercises, as well as reliably recognize when swimmer switches the style, turns or takes a break"*. Notons néanmoins que nous ne partageons pas cette idée de remplacer le coach par le développement d'outils de monitoring automatique. Nous voyons plutôt ces outils comme des moyens de catalyse de l'expertise technique des entraîneurs par la libération de temps d'experts de ces tâches chronophages au quotidien et à l'aide à la décision pour l'ajustement du programme d'entraînement. Les métriques alors calculées et leur visualisation sous forme adaptée permettent une catégorisation du stimulus d'entraînement individuel grâce à la quantification de la répartition des nages et de leurs intensités relatives ainsi qu'une évaluation de l'atteinte ou non des objectifs individuels de séance prescrits par le coach. Cela fait pleinement écho au contexte actuel du monitoring sportif avec le développement de nombreuses interfaces d'analyses de l'activité et d'applications associées.

Ce procédé s'inscrivant pleinement dans les enjeux et exigences de la haute performance natatoire ainsi que dans les pratiques de l'entraînement actuel en natation, cela nous amène à nous interroger sur un moyen efficient et pratique, c'est-à-dire automatique et utilisable en routine, de produire de tels *feedbacks* d'entraînement. Les récentes avancées technologiques irriguant aujourd'hui les sciences du sport et le monde de l'entraînement, capteurs inertiels portatifs en tête, couplées à l'émergence de certains paradigmes d'intelligence artificielle redéfinissant le champ des possibles de la HAR appliquée au sport ([Cust et al., 2019](#)), apparaissent désormais comme une potentielle source de réponse à ces nouveaux besoins émanant de la recherche de performance. Il convient désormais d'identifier les outils et méthodes propres au champ de la HAR permettant : (1) de recueillir et déterminer ces variables de l'activité humaine en milieu aquatique, (2) de s'assurer de la robustesse de leur collecte au vu des contraintes de l'entraînement sportif en natation et de l'exigence de précision nécessaire à un monitoring sportif efficace.

## 3.2 Technologie inertielle et Intelligence Artificielle au service de la reconnaissance d'activité natatoire

"Among the coach's principal duties are monitoring the swimmers permanently, evaluating their performance and providing for their improvement" (Hamidi Rad et al., 2020). Afin d'aider les athlètes et entraîneurs dans cette tâche désormais indispensable, les innovations technologiques actuelles et notamment l'utilisation de capteurs portatifs à technologie accélérométrique et gyroscopique ont permis de mesurer les mouvements, d'évaluer des charges de travail et de déterminer des index et indicateurs d'adaptations à l'entraînement dans le but de maximiser la performance sportive tout en minimisant le risque potentiel de blessure (Li et al. (2016); Seshadri et al. (2017)). En natation, l'utilisation de technologies récentes est reconnue comme un levier fondamental pour améliorer les performances compétitives (Magalhães et al., 2014) notamment d'un point de vue biomécanique en permettant une analyse détaillée du mouvement effectué et un affinement de la technique de nage (Pansiot et al., 2010). C'est dans ce contexte que la portabilité des centrales inertielle (IMU) est grandement appréciée pour des mesures embarquées d'activité et de monitoring de charge dans de nombreuses disciplines sportives (Seshadri et al., 2019).

Néanmoins les contraintes inhérentes à la mesure ambulatoire de l'activité physique en environnement aquatique ont largement complexifié le développement et l'application de technologies en natation d'une part, et en condition écologique d'entraînement d'autre part. Ainsi, le système vidéo (opto-électronique ou non) incarne l'outil classique d'analyse des paramètres spatio-temporels du mouvement et est considéré actuellement comme un *gold-standard* (Mooney et al. (2015); Seifert et al. (2015)). Bien que largement utilisée et même si cette technique est avancée comme hautement valide, reproductible, et utile pour des mesures épisodiques elle est cependant très chronophage en termes d'analyse des images. En particulier car celle-ci ne peut être qu'à moitié automatisée (Nikodelis et al., 2005), et présente certaines limites : le nombre potentiel de cycles de nage analysés est réduit du fait d'une possibilité d'étude du mouvement contrainte par la localisation et la taille du champ de capture (Lee et al., 2011) qui ne peut atteindre qu'un volume maximal de 30 mètres cubes (Seifert et al., 2014). De plus le recueil des données est fastidieux car basé sur la position spatiale de marqueurs anatomiques au cours du mouvement qui ne sont pas toujours identifiables dans l'eau dû à des phénomènes d'occultations voire de perte de marqueurs (Hellard et al., 2008). Enfin, le traitement des données, en particulier la reconstruction, est long et favorise l'accumulation d'erreurs (Wilson et al., 1999). Au final, c'est un outil ne pouvant pas être utilisé pour monitorer l'entraînement au jour le jour en natation (Callaway et al., 2009) et cela malgré l'apparition de caméras permettant des captures *markerless* avec un traitement des données en temps réel.

En réponse à ces limites, les IMU ont vu leur popularité grandement augmenter. On retrouve ce constat aussi bien dans la littérature spécifique HAR de par leurs avantages certains (Cornacchia et al., 2017) comme le résume Nweke et al. (2018) : "*Motion sensors [...] provide important information that facilitate recognition and monitoring of users' movement such as walking, standing or running*". Mais également dans la littérature spécifique natation puisque le nombre de publications les utilisant pour de l'analyse de mouvement natatoire explose (Guignard et al., 2017). En effet si l'on considère que les caractéristiques clés d'un capteur permettant d'évaluer avec fiabilité des paramètres de nage sont : sa portabilité, sa validité et le fait qu'il n'entrave pas le mouvement (Cuesta-Vargas et al., 2010) ou ne produise pas une traînée hydrodynamique additionnelle trop importante. Alors les IMU sont un candidat remplissant tous ces critères avec le développement de capteurs inertiels à bas coût, de petite taille et léger, spécifiquement adaptés à la mesure embarquée d'activité physique humaine (Altun et al., 2010). Capable de recueillir de l'information inertielle selon 6 degrés de libertés, ces outils sont largement utilisés pour étudier les postures et mouvements humains (Wong et al., 2007) de par leur

capacité à quantifier l'accélération, la vitesse angulaire ainsi que la direction et l'orientation du déplacement (Gastin et al., 2014). Leur intérêt dans les activités sportives réside dans leur capacité à enregistrer les patterns de mouvements spécifiques répétés à l'entraînement et en compétition (Camomilla et al. (2018); Chambers et al. (2015)), offrant dès lors les conditions d'un traitement temporel et fréquentiel permettant la reconnaissance d'activité humaine garante de paramètres clés sur l'activité physique réalisée. La natation étant une activité cyclique comprenant des événements singuliers (poussée au mur, virage, touche), il est alors possible d'exploiter la périodicité du signal inertiel ainsi que sa spécificité selon l'action réalisée afin d'identifier des indicateurs de la performance (Silva et al., 2011). La figure 3.2 illustre à partir d'exemples de la littérature ces concepts fondant les idées de reconnaissance d'activité natatoire et de monitoring d'entraînement en natation : en effet on y voit clairement les occurrences de virages, poussées au mur, coup de bras ainsi que le pattern accélérométrique singulier de la coulée. L'annexe 9.2 présente, sur des données personnelles des auteurs, le même genre de représentations de la singularité du signal inertiel par nage et phase (poussée, coulée, virage, etc...) sur un 100m 4N.

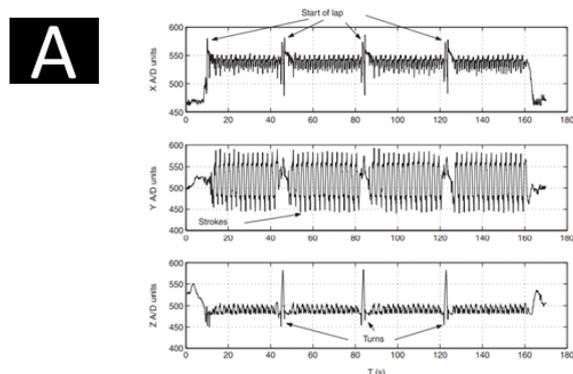


Figure 2. Typical 4 x 50-m freestyle acceleration data obtained using the platform, with key features highlighted. A/D, analogue to digital convertor value; T, time in seconds.

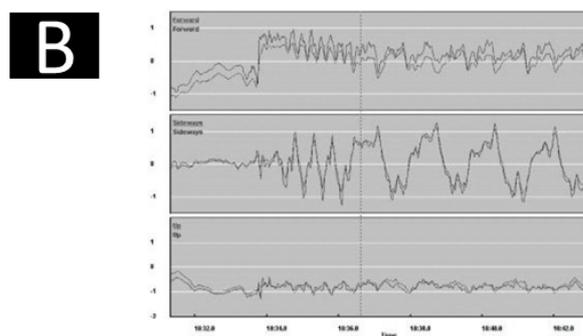


Fig. 1. Sample inertial sensor data for swimmer showing tri-axial accelerometer data obtained from wall push off, underwater swimming and four freestyle strokes.

FIGURE 3.1 – Mise en évidence des traces et patterns accélérométriques singuliers lors d'évènements de l'activité natatoire : poussée au mur, coup de bras et virages (Davey et al., 2008) (A), poussée au mur, coulée et crawl (James et al., 2011) (B)

Dès lors, un monitoring de l'activité du nageur à l'entraînement est envisageable -sous réserve d'une méthodologie adéquate de traitement des signaux IMU (cf. plus bas)- et cela constitue l'objectif final de ce travail de recherche dans la lignée de cette citation de Ganzevles et al. (2017) : "Continuous monitoring of the training process with tri-axial accelerometers might offer additional information on dose-response relationships and the balance between load and load capacity. This makes tri-axial accelerometers a powerful tool for coaches to optimize the training program."

### 3.2.1 Inertial Measurements Units (IMU) et leurs intérêts : un outil en vogue en science du sport et prometteur en natation

"The development of wearable devices for sports practitioners can present several noticeable repercussions in the sport community, both in reference to the optimization of the training process of elite athletes, as well as to the promotion of safety regulations within rehabilitation [...] there is a relatively reduced number of biomechanical signal monitoring systems being used for swimming performance analysis today". (Silva et al., 2011). Face à ce manque d'outil de monitoring portables en natation et suite à l'émergence des IMU en sciences du sport, des systèmes micro électromécaniques ont été développés pour mesurer des paramètres clés de la performance natatoire (Ohgi et al. (2003); Davey et al. (2004); Dadashi et al. (2013)). En natation,

ils s'articulent globalement autour de deux catégories d'analyses spatio-temporelles : (1) la reconnaissance d'activité s'agrégeant dans la classification de paramètres cinématiques lors de différentes phases allant du départ du mur à la nage en passant par le virage, (2) l'analyse de paramètres spécifiques d'évaluation de la performance découlant de cette reconnaissance d'activité comme par exemple la fréquence, l'amplitude, la vitesse, l'action des membres inférieurs ou encore la coordination du corps (Hamidi Rad et al. (2020); Mooney et al. (2015)).

L'utilisation d'IMU ouvre alors la porte au monitoring entièrement programmé, automatisé, continu et avec une haute fiabilité dans l'estimation de données d'entraînement (Ganzevles et al., 2017). Elles peuvent par ailleurs être ensuite stockées et analysées longitudinalement. C'est ainsi que Davey et al. rapportent dès 2008 des LT calculés par accéléromètres aussi fidèles que des données manuellement enregistrées par chronomètre en comparaison au *gold-standard* vidéo. Ces nouveaux instruments de mesure offrent des avantages conséquents en permettant de s'affranchir des restrictions liées à l'analyse vidéo (cf. plus haut) tout en proposant une mesure chronique de métriques pertinentes dans l'entraînement d'un groupe complet de nageurs. L'entraîneur peut alors se concentrer sur son rôle d'observateur des athlètes.

In fine, *"as much useful parameters as possible will be extracted from the inertial sensor data"* (Lecoutere and Puers, 2014). Les perspectives d'utilisations des IMU en contexte d'entraînement de natation pour du monitoring sont très riches. Elles permettent à l'entraîneur de quantifier de manière personnelle le stimulus d'entraînement administré via l'exploitation d'un outil. Ce dernier doit, à partir de données accélérométriques et gyroscopiques, s'articuler autour de : (1) la détermination de variables relatives à la charge (externe) d'entraînement, (2) la visualisation rapide de l'atteinte ou non des objectifs de séance et de métriques spatio-temporelles de performance. Cela dans l'optique finale d'adapter les contraintes biologiques découlant de l'entraînement sur l'organisme de l'athlète. L'objectif étant que celles-ci stimulent de façon optimale les phénomènes adaptatifs conduisant à une élévation du niveau de performance. C'est le principe de l'entraînement sportif, qui s'en trouve ainsi optimisé. Néanmoins pour être en cohérence avec les attendus de terrain, il importe désormais de pouvoir mesurer et quantifier quotidiennement, par des méthodologies basées HAR adéquates, les variables d'intérêts définies précédemment dans l'entraînement des nageurs. Le but étant de tendre vers un outil à destination des entraîneurs et *sport data scientist* se voulant pratique, utilisable en routine, et efficace pour le monitoring. Pour cela, il importe de rechercher des méthodologies de traitement des séries temporelles exploitant la périodicité et spécificité de l'activité humaine en natation (pour plus de détails voir annexe 9.2). En effet les signaux inertiels sont des flux de données à une dimension que l'on appelle des séries temporelles, c'est-à-dire une suite finie de données (accélérométriques ou gyroscopiques) indexées par le temps. Traiter des signaux IMU revient donc à travailler sur des séries temporelles multivariées. Les méthodologies adoptées pour ce traitement se doivent d'être reproductibles. Plus encore, généralisables à des nageurs de technique et niveau hétérogènes. Le tout dans un environnement contrôlé et standardisé qu'est celui d'une séance d'entraînement en natation.

### 3.2.2 Un nouveau paradigme méthodologique pour la reconnaissance d'activité humaine : des règles heuristiques aux données pour la classification des séries temporelles

Pour mesurer des paramètres de l'activité humaine comme le calcul de métriques de performance sportives, les données inertielles sont traitées (*data-processing*) via des algorithmes exploitant le caractère périodique et spécifique des actions. La revue de littérature de Mooney et al. (2015) détaille les principaux algorithmes et méthodes disponibles à cette date pour obtenir, à partir des signaux IMU, ces paramètres d'intérêts

en natation. Ces méthodologies de traitement des données sont presque toutes basées sur une méthode de programmation dite traditionnelle où l'humain vient, à l'aide de règles heuristiques paramétriques (*hardcoded rules*) définies arbitrairement et appliquées aux données, traiter et classifier les signaux pour en produire des réponses souhaitées : des paramètres spatio-temporels et/ou fréquentiels d'activité.

Cette programmation traditionnelle englobe un ensemble de techniques issues du domaine temps-fréquence. C'est-à-dire basées sur l'application de seuils et de recherche d'extremums locaux sur le signal accélérométrique et/ou gyroscopique ou sur des *features* calculés : *"threshold-based classifier compares different features to a predefined threshold, generally fixed by the user"* (Attal et al., 2015). En natation cela permet d'identifier des événements significatifs comme les touches, les poussées au mur ou encore les virages (Pan et al., 2016). Bien que largement utilisées dans la littérature et efficaces dans le cadre d'une application restreinte à la population initiale d'étude sur laquelle ces seuils ont été recherchés, souvent de niveau homogène et en faible nombre, ces techniques souffrent d'une généralisation extrêmement faible et variable qui vient biaiser leur reproductibilité : *"this threshold depended on each individual swimmer"* (Ohgi et al., 2014). En effet, ces règles de programmation codées en dur ont été définies pour être efficace sur la population et le protocole d'étude mais pas forcément sur une autre population étrangère à la base de données initiale qui peut présenter des patterns inertiels d'activités différents et biaisant les seuils fixés : *"this classification method is sensitive to the chosen thresholds values"* (Attal et al., 2015). En conséquence ce paradigme algorithmique de traitement des données en HAR, malgré sa pertinence pour la production scientifique via des applications en environnement standardisé et contrôlé, est mis en défaut lors de son application en condition réelle de situation d'entraînement et qui plus est pour une utilisation sur des nageurs hétérogènes à la base de données initiale. C'est ainsi qu'une des grandes limites de la littérature actuelle sur le monitoring d'entraînement en natation basé IMU se situe dans l'utilisation de méthodes non généralisables s'inscrivant dans des protocoles parfois contrôlés, du moins standardisés, et in fine non représentatif de la réalité de l'entraînement (Brunner et al. (2019) ; Tarasevičius and Serackis (2020)). De par leur faible robustesse en situation écologique, les algorithmes actuellement présentés dans la littérature ne permettent pas de monitorer un large panel de nageurs dans toutes les situations pouvant être rencontrées lors d'un entraînement : *"the results are not accurate enough to support a serious training regimen"* (Brunner et al., 2019). Il faudrait pour appliquer une telle méthode rechercher et calculer, pour chaque nageur d'un groupe d'entraînement, des seuils individuels qui seraient de plus potentiellement mis en défaut avec un changement de technique de nage du sujet au cours du temps (effet fatigue, effet de l'entraînement, etc...). Au final et en utilisant cette méthode traditionnelle s'inscrivant dans le paradigme de l'IA symbolique, il est impossible d'envisager un monitoring pertinent en situation réelle en particulier car *"no solution has been designed for full usability"* (Michaels et al., 2016). Ces règles explicites ne peuvent résoudre des problèmes complexes de HAR puisque leur capacité d'adaptation est restreinte. En réponse aux limites de ces modèles la considération d'algorithmes à apprentissage statistique basés IA pour la reconnaissance d'activité humaine et sportive en général et le monitoring de l'entraînement natatoire en particulier peut s'apparenter à une issue propice (Cust et al., 2019) comme le note Callaway dès 2015 : *"this could be built into a learning algorithm to reduce the need for human interaction in the future"*.

*"Rather than programmers crafting data-processing rules by hand, could a computer automatically learn these rules by looking at data?"* (Chollet et al., 2018). Les actuels progrès et la démocratisation d'un nouveau paradigme de programmation -le *machine learning* (ML)- ouvre aujourd'hui le champ des possibles quant au développement d'une méthodologie de traitement des signaux IMU robuste, transposable et donc généralisable. La force de l'apprentissage automatique réside dans le fait que l'ordinateur découvre seul et construit, par apprentissage statistique et computation à partir d'exemple de ce que l'on attend de lui, un ensemble de règles heuristiques pour exécuter le traitement de données d'une tâche : *"machine learning algorithms learn*

from data input for automated model building and perform tasks without being explicitly programmed" (Cust et al., 2019). L'humain a alors pour rôle de fournir à la machine des données *input* ( $X$ ) ainsi que les réponses désirées associées à ces données ( $Y$ ). Les algorithmes de ML vont alors chercher à produire en *output* des règles de traitement pour lier les  $X$  aux  $Y$ . Cette approche est particulièrement intéressante dans le cas où l'humain ne connaît pas à l'avance ces principes dans les données et permet, plutôt que de linéariser les surfaces de décision (*decision boundary*) par exemple pour un problème de classification via une valeur seuil stricte, de modéliser une manière d'atteindre des réponses que l'on connaît déjà. Ces règles produites par la machine sont ensuite appliquées à de nouvelles données *input* ( $X$ ) pour lesquelles les réponses sont cette fois inconnues. C'est cette notion d'exposition de la machine aux données qui sous-tend le terme d'apprentissage automatique : l'algorithme vient à partir de nombreux exemples d'une tâche trouver une structure statistique dans ces exemples qui permet au système d'établir des règles de traitement pour automatiser la tâche initiale. Ainsi, "a machine learning system is trained rather than explicitly programmed" (Chollet et al., 2018). Notons néanmoins que l'implémentation de telles méthodologies de classification, nommées apprentissage supervisé (Mohssen Mohammed, 2017), requiert de très grande base de données labellisées (*labelled dataset*) afin de suffisamment exposer l'algorithme à des exemples de  $X$  et de  $Y$  ainsi qu'une puissance de calcul notable (*hardware*), et souvent limitante (Attal et al., 2015).

### **Le *deep learning* comme solution au biais de généralisation en *Human Activity Recognition* ?**

Le ML permet de traiter avec des bases de données très grande, complexe et hétérogène. En effet par sa nature empirique de recherche de représentations appropriées des données *input* et de leur transformation dans le sens d'une exploitation optimale pour la tâche demandée, il constitue un candidat prometteur pour prendre en compte la variabilité inter et intra sujet de l'activité natatoire. Cela dans l'optique d'un outil de reconnaissance et de classification lors de l'entraînement en modélisant -on parle de *mapping*- des *inputs* (ex : des signaux IMU) à des *outputs* cibles (ex : le label "poussée au mur", "coulée", "crawl", etc...) via l'observation de très nombreux exemples de paires *input-output*.

Dans le champ de l'IA, on différencie le ML à proprement parler du DL (voir annexe 9.3 pour une vue schématique des différents concepts). Le premier utilise des *features* pré-définis pour réaliser le *mapping* des  $X$  vers les  $Y$ . C'est-à-dire des caractéristiques des données agrégeant de l'information temporelles ou fréquentielles sur celles-ci (ex : statistiques descriptives, résultats d'une Analyse en Composante Principale, etc...) et requérant donc un minimum de connaissance humaine extérieure à travers un *features engineering* : calcul puis sélection de ces *features* ensuite utilisés par l'algorithme pour construire des représentations sur les données et apprendre les fameuses règles de traitement appliquées in fine (Halilaj et al., 2018). Ce *features extraction* est une part vital du processus de HAR puisque les performances d'un système de reconnaissance d'activité humaine dépendent de la capacité du modèle à créer des représentations appropriées et efficaces dans les données (Abidine et al., 2018). Toutefois le *features engineering* en ML dit classique repose lui aussi sur la connaissance d'expert puisque qu'aucune procédure universelle de *features selection* n'existe et le choix de *features* appropriés pour le développement d'un modèle définit à une tâche de HAR repose bien souvent sur des intuitions heuristiques (Zdravevski et al., 2017). Au final le *features engineering* sur lequel repose le ML conduit à des limites quant à sa capacité à modéliser des activités humaines complexes tout en étant extrêmement chronophage (Ronao and Cho, 2016) : "feature extraction and selections methods that are manually extracted using expert domain knowledge [...] are task or applications dependent and cannot be transferred to activity of similar patterns." (Nweke et al., 2018). Par ailleurs, l'activité humaine étant par nature translationnelle, c'est-à-dire composée sur une dimension temporelle de plusieurs sous-activités dans l'action principale, il est nécessaire de capturer ces variations spatio-temporelles d'activité, qui ne sont pas

capturés par un *features engineering* manuel pour une détection précise des détails d'une activité complexe (Kautz et al., 2017).

La figure 3.2.2 illustre ce processus classique de HAR via ML. Avec tout d'abord une première phase de *features engineering* reposant sur l'expertise d'un opérateur pour l'extraction et la sélection de représentations sur les données *inputs* d'activité humaine. Puis la phase de reconnaissance d'activité à proprement parler avec l'ajustement d'un modèle à apprentissage statistique liant les *features*  $X$  aux labels d'activité cible  $Y$ . Cela permet ensuite d'obtenir une prédiction d'activité  $\hat{Y}$ .

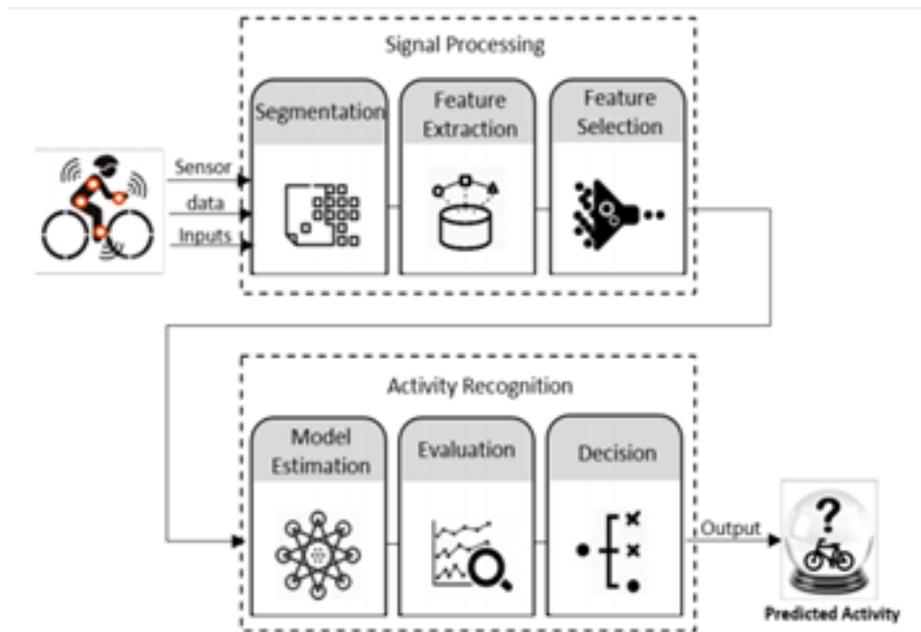


FIGURE 3.2 – Chaîne de reconnaissance de forme pour la prédiction d'activité humaine par apprentissage automatique

Le DL, sous-champ spécifique du ML, présente lui une nouvelle manière d'apprendre ces représentations issues des données en construisant automatiquement des *features* via une architecture stratifiée et successives de différentes couches de traitement computationnel toutes apprises spontanément à partir de l'exposition aux données. Cela a pour résultat de considérablement augmenter la pertinence des représentations construites tout en automatisant le processus de *features engineering* : "to solve the above problems, studies have delved into techniques that involve automatic features extraction with less human efforts using deep learning techniques" (Nweke et al., 2018). Pour ce faire, le DL utilise des algorithmes de types réseaux de neurones artificiels en référence à la neurobiologie (voir figure 3.2.2 et annexe 9.4 pour une présentation conceptuelle succincte d'un réseau de neurones). Nous pouvons considérer ces réseaux profonds comme un ensemble d'étages opératoires de distillation de l'information et de représentations sur les données où celles-ci passent dans différents filtres successifs et s'en trouvent purifiées au regard de la tâche finale du réseau. Ces modèles offrent la possibilité de totalement se libérer de ce processus de *features engineering* en automatisant la construction de représentation dans les données (LeCun et al., 2015). C'est une des forces du DL pour le traitement des séries temporelles que constituent les signaux inertiels. Sans s'appesantir dans le détail des considérations mathématiques des réseaux de neurones, nous abordons ce concept dans son versant pratique et applicatif en le résumant comme tel : "deep learning is a mathematical framework for learning representations from data [...] a multistage way to learn data representations" (Chollet et al., 2018).

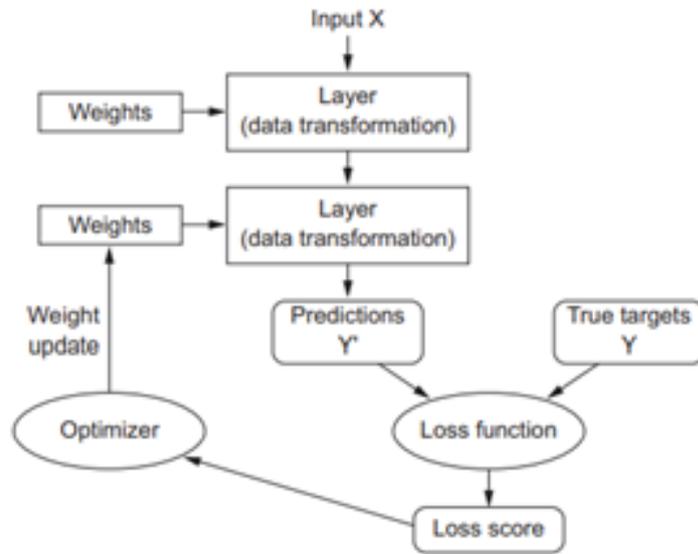


FIGURE 3.3 – Vue schématique du fonctionnement d'un réseau de neurones. L'élément principal à retenir et traduisant "l'apprentissage profond" est que le score de la fonction de perte est utilisé comme signal feedback pour ajuster les paramètres du modèle (Chollet et al., 2018)

Au final, au lieu que l'humain fasse intervenir ses connaissances dans un *features engineering* manuel pouvant être mis en défaut au regard de problématique de variabilité intra-classe et de similarité inter-classes (Bulling et al., 2014), le DL automatise complètement cette étape cruciale d'une procédure de ML en apprenant tous les *features* en une seule étape et en même temps (*joint feature learning*). Cela a pour conséquence une grande simplification de la mise en oeuvre du ML avec un modèle de DL unique, simple, de bout-en-bout, plus puissant et sans besoin de *features engineering* préalable : "deep learning models that provide enhanced system performance, flexibility, robustness and remove the need to depend on conventional handcrafted features (Nweke et al., 2018). Ce nouveau paradigme de programmation, en plus de présenter de meilleures performances sur de nombreux problèmes de classification (ex : challenge ImageNet), offre une alternative de réponse aux limites actuelles de la littérature en terme de généralisation des algorithmes produits puisque les règles de traitement sont directement issues de la base de données initiale et ajustées au cours de l'entraînement du réseau par la minimisation d'une fonction de coût. Ainsi, une base de données comprenant suffisamment de variabilité inter et intra nageurs peut permettre d'envisager un modèle de DL généralisable à tous.

La démonstration méthodologique précédente ainsi que les constats issus de la littérature sur le monitoring en natation nous font penser que l'exploration du DL pour la reconnaissance d'activité et le monitoring de la performance natatoire basé IMU est un objet de recherche à fort intérêt scientifique doublé d'enjeux sportifs conséquents. La figure 3.2.2 schématise les deux paradigmes de programmation évoqués ici et illustre le basculement méthodologique s'opérant actuellement dans la littérature portant sur la reconnaissance d'activité humaine en général et le monitoring de l'entraînement en natation en particulier.

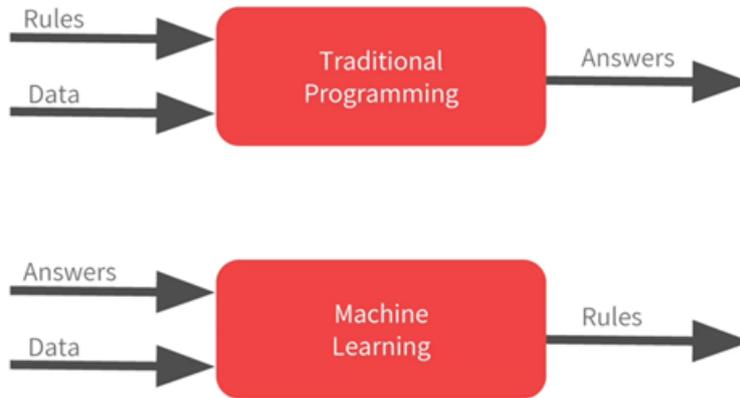


FIGURE 3.4 – Schéma illustrant les différences entre programmation traditionnelle et apprentissage automatique

### 3.3 Reconnaissance d'activité et monitoring de la performance natatoire basé IMU

Nous avons vu qu'il ressort de la littérature un changement de paradigme récent dans le développement d'algorithmes à visée de reconnaissance d'activité en général, et en natation par voie de conséquence. Celui-ci vise à répondre à un problème de robustesse des outils développés afin qu'ils puissent traiter avec une grande hétérogénéité de niveaux natatoire et en situation écologique d'entraînement. Il s'agit désormais de voir plus précisément la déclinaison de ces 3 grandes catégories de méthodologies (seuils/règles heuristiques, ML avec *features* manuels prédéfinis, DL) dans la littérature spécifique natation. A l'aune de l'analyse précédente (cf. 3.1), la quantification des variables d'intensités -par les LT- et de volume -par la distance nagée- est indispensable. La variable de coups de bras par longueur et ses dérivées sont également d'importance notable. Par ailleurs et dans l'optique d'un outil de monitoring efficace en natation, celui-ci doit être capable de remplir (à minima) les critères évoqués par Brunner et al. (2019) : *"differentiate between styles and exercises, as well as reliably recognize when the swimmer switches the style, turns or takes a break"*.

Ainsi, nous centrerons cette partie sur l'analyse des principales études ayant cherché à collecter en natation et par la mesure inertielle les variables spatio-temporelles qui émergent de notre analyse précédente comme d'intérêts : type de nage, nombre de coups de bras par longueurs, identification d'évènements singuliers dans l'activité (touche, virage, poussée au mur, coulée) sous-tendant le calcul des LT, de la distance nagée, ou de variables temporelles d'intérêt pour l'évaluation de la performance.

#### 3.3.1 Recueil de métriques via des règles heuristiques/seuils paramétriques

Comme détaillé précédemment, l'approche classique de monitoring en natation s'inspire de la programmation traditionnelle. C'est-à-dire utilisant la détection de pics (*findpeaks*) et d'extremum locaux, l'utilisation de *features* calculés à la main et/ou de méthodes de *zero-crossing* sur signal filtré. Tout cela repose sur la fixation de seuils pré-définis dans le domaine temporel ou fréquentiel. Dès lors ces méthodes de traitement des données sont largement basées sur l'habileté d'un opérateur humain à exploiter des connaissances dites à priori sur le mouvement de nage. Celles-ci permettent de produire un ensemble de règles heuristiques appliquées aux données dans le but de produire une classification du style de nage ou un décompte des longueurs, par l'identification des virages et poussées au mur, ainsi que le compte des coups de bras par longueurs. Comme nous l'avons illustré figure 3.2, la discrimination des nages tout comme le compte des longueurs et

coups de bras pour un observateur humain est facilement réalisable en regardant les signaux inertiels (Pansiot et al. (2010); Lecoutere and Puers (2014); Andreoni et al. (2014)). Ainsi chaque pattern de nage a ses propres caractéristiques distinctives (Silva et al., 2011) et les évènements clés comme les poussées au mur ou les virages sont clairement identifiables puisque qu'ils produisent un pic visible sur le signal accélérométrique et gyroscopique (Mooney et al., 2015). Par ailleurs la périodicité du signal est représentative des mouvements de rotation répétitifs du corps lors des différents patterns de nage et permettent de facilement identifier les cycles de nage. Toutefois, il peut être difficile de transposer cette triviale analyse humaine à une méthode de classification automatique, et surtout robuste en condition réelle d'entraînement pour de nombreux nageurs.

Davey et al (2004; 2008) proposent des seuils sur l'énergie du signal accélérométrique au sacrum et sur l'orientation du capteur (via la polarité antéropostérieure) pour l'identification du type de nage avec 96,1% de précision ainsi que des seuils sur l'accélération longitudinale pour la détection des poussées au mur avec  $0,32 \pm 0,58$ s de différence dans le calcul des LT comparativement au *gold-standard* vidéo. Cette méthode abondamment retrouvée dans la littérature est parfois couplée avec d'autres techniques comme des fonctions de *zero-crossing* ou de *findpeaks*. Notons aussi que le signal gyroscopique est quelquefois utilisé en complément du signal accélérométrique car pouvant offrir des gains de précisions dans le calcul des métriques (Fulton et al. (2009); Dadashi et al. (2012)) comme le notent Ganzevles et al. (2017) : "*further improvements can be obtained by using information from additional sensors, such as gyroscopes*". Il en ressort que cette méthode dite classique utilisant des seuils paramétriques soit directement sur le signal inertiel soit sur des *features* (énergie du signal, statistiques descriptives, etc...) demeure une référence pour de nombreux auteurs et est largement utilisée dans la littérature pour de la reconnaissance et classification de nage (Yuen (2010); Lecoutere and Puers (2016); Delgado-Gonzalo et al. (2016); Ganzevles et al. (2017)) ainsi que pour de l'identification de poussée au mur, virage ou touche (Bachlin et al. (2008); Le Sage et al. (2010); Le Sage et al. (2011); James et al. (2011); Bächlin and Tröster (2012); Callaway (2015); Michaels et al. (2016); Ganzevles et al. (2017); Ramos Félix et al. (2019)) avec différents positionnements anatomique du (ou des) IMU : haut et bas du dos (sacrum), poignet ou tête.

Implémenter une telle méthodologie requiert cependant de trouver une paramétrisation optimale des seuils utilisés dans les fonctions de traitement des signaux IMU afin de coller avec la population expérimentale. Il est donc extrêmement difficile de traiter avec la variabilité de technique de nage inter et intra athlète mais également dans un environnement expérimental sans contrôle strict des actions des sujets et avec des interférences inter nageurs. En effet le pattern de nage, bien que hautement reproductible, présente de légères différences entre athlètes et évolue pour un même athlète au fil du temps. C'est pourquoi raisonner en terme de seuils pour ces tâches de reconnaissance de l'activité natatoire peut conduire à des erreurs de classification lorsque les algorithmes sont généralisés à une nouvelle population. Afin de prendre en compte ces limites, Ganzevles et al. (2017) ont adapté de manière empirique leurs seuils à leur population expérimentale aboutissant à 99% de précision pour la classification de nage. Mais leur base de données comprenant 13 nageurs de classe mondiale est relativement petite et avec extrêmement peu de variabilité. Cela vient biaiser la généralisabilité de leurs seuils. Plus récemment Ramos Félix et al. (2019) ont utilisé des seuils sur les valeurs angulaires de tangage pour détecter les virages et les touches avec 100% de précision dans la segmentation des longueurs et seulement 2 virages sur 181 mal classifiés en touche. Toutes les études décrites précédemment se concentrent sur la reconnaissance d'activité natatoire à un niveau macroscopique et sont limitées à une unique technique ou phase de nage ce qui est insuffisant pour un monitoring quotidien d'élites. En conséquence, une amélioration du design retrouvé dans la littérature peut être de quantifier la capacité des algorithmes développés à s'adapter à des sujets ne faisant pas partie du *training* et *validation set*. Actuellement, seulement une étude basée sur l'utilisation de seuils/règles heuristiques considère cet aspect et est capable d'analyses

à un niveau microscopique en différenciant poussée au mur, glisse, ondulations, nage et virage en utilisant des méthodes de *preprocessing* lourdes comme l'Analyse en Composante Principale, l'analyse fréquentielle, la détection de variations brusques (*sharp change detection*) ou la décomposition empirique du signal (*empirical mode decomposition*) avant l'application de seuils paramétriques (Hamidi Rad et al., 2020). Néanmoins, malgré des résultats prometteurs et la considération d'un *training* et *testing set*, leurs algorithmes souffrent d'un manque de généralisation dû à un protocole incluant une unique vitesse de 80% et une population homogène de nageurs nationaux.

La détection des coups de bras a été très largement investiguée dans la littérature via des méthodes de détection et summation de pics accélérométriques pour une longueur donnée (Mooney et al., 2015). Davey et al (2004; 2008) furent les premiers à proposer cette méthode de *findpeaks* classique sur l'accélération médiolatérale visant à identifier des paires de maxima et minima locaux. Malgré de bons résultats à  $\pm 1$  coup de bras (Davey et al. (2008); Chakravorti et al. (2013)), les débuts et fin de longueurs demeurent de potentielles sources d'erreurs. Cela suggère qu'exploiter seulement l'action de rotation du corps n'est pas toujours un indicateur de réalisation d'un coup de bras (Anthony and Chalfant, 2010). Pour autant, nombreuses sont les études reprenant cette méthodologie avec différents positionnements anatomiques de capteurs et différents signaux inertiels sur lesquels sont appliqués les *findpeaks* : Daukantas et al. (2008), Pansiot et al. (2010), Siirtola et al. (2011) Bächlin and Tröster (2012), Callaway (2015). Notons que Ganzevles et al. (2017) propose via cette méthode de recherche des extremums locaux sommant accélération verticale et médio-latérale le premier algorithme de compte des coups de bras fonctionnant dans toutes les nages là où ces derniers étaient par le passé exclusif au crawl (James et al., 2004) ou différencié par nage (Siirtola et al., 2011). Une autre étude récente de Ramos Félix et al. (2019) utilise le décompte des paires maximum-minimum locaux, pas sur les signaux inertiels mais sur les angles de roulis et de tangage calculés. Ils en ressortent une haute précision du compte des coups de bras : 95,7% en DS, 97,5% en CR, 92% en PP et 91,5% en BR. La plus faible précision retrouvée sur les nages simultanées est attribuée à des erreurs de l'algorithme sur le dernier mouvement avant la touche ou le virage ce qui confirme les assertions précédemment retrouvées dans la littérature. Nous pouvons en retenir que "*these solutions are easy to implement but how to find a universal threshold for swimmers is a critical issue*" (Pan et al., 2016). De nouveau les seuils sont mis en défaut avec une population de niveau et technique hétérogène (Beanland et al., 2014). Une autre méthodologie de la littérature pour compter les coups de bras fondée sur ce paradigme de programmation traditionnelle vise à utiliser des méthodes de *zero-crossing* (Stamm et al. (2012); Hagem et al. (2013); Chakravorti et al. (2013)). Celles-ci s'appliquent bien souvent sur l'axe longitudinal pour les nages simultanées et sur l'axe médio-latéral pour les nages alternées (Le Sage et al., 2011). Pour autant "*sensory values may frequently cross zero points (due to noises), and thus the stroke count will be incremented unexpected*" (Pan et al., 2016). Chercher à réduire ce bruit dans le signal par un filtrage adapté semble une première piste de réponse à ces limites. Par ailleurs, d'autres méthodologies dans le domaine fréquentiel sont retrouvées dans la littérature. C'est ainsi qu'Ohgi et al. (2014) propose de déterminer la fréquence de nage sur des intervalles de 4s via le calcul de puissance spectrale du signal par transformation de Fourier rapide afin d'identifier la fréquence pic et la transformer en fréquence de nage en cycles/min. Aucuns résultats n'est cependant présentés par les auteurs. Cette idée exploitant une fois encore la périodicité du pattern de nage est reprise par Michaels et al. (2016) qui réalisent une analyse de densité spectrale sur le signal accélérométrique global.

Nous pouvons en ressortir de la littérature que les méthodologies de *findpeaks* et de *zero-crossing* ne sont pas toujours adaptées pour un monitoring en situation écologique d'entraînement des coups de bras. Leur utilisation repose sur un filtrage efficace du signal permettant d'éliminer le bruit mettant généralement en défaut les méthodes seuils. L'analyse fréquentielle paraît prometteuse mais manque d'approfondissement

dans la littérature. Par ailleurs l'étude de [Pan et al. \(2016\)](#) propose selon nous une méthodologie basées seuils permettant à l'avenir de gagner en robustesse. A partir d'une population de 12 nageurs élités et 12 nageurs récréationnels, ils exploitent la périodicité du pattern de nage via le coefficient de corrélation du signal entre chaque motif élémentaire consécutifs. Un seuil de 0,45 est par la suite appliqué à ce coefficient  $r$  pour compter les occurrences de coups de bras. Notons que cette idée de corrélation entre signaux dans l'optique de découper le signal inertiel par cycle de nage est retrouvée chez [Zhuang and Xue \(2019\)](#). Ceux-ci exploitent l'autocorrélation du signal au cours du temps à des fins de HAR en natation. Plus précisément d'extraction d'intervalles comprenant des cycles de nages du signal originel afin d'appliquer par la suite des méthodologies de reconnaissance de nage basées DL. Cela nous conforte dans l'intérêt d'utiliser à terme, dès lors que l'on cherche la méthode type seuils la plus robuste pour compter les coups de bras, le coefficient d'autocorrélation du signal inertiel. Néanmoins nous retiendrons de la littérature que l'utilisation de méthodes de *findpeaks* et de *zero-crossing* directement sur les signaux inertiels, dès lors que ceux-ci sont bien filtrés, apparaît aujourd'hui comme la méthode la plus simple, c'est-à-dire la moins chronophage et avec une bonne reproductibilité. A ce titre, l'utilisation d'un filtre Butterworth de second ordre passe bande avec une fréquence de coupure entre 0,1 et 1Hz permet de très facilement compter les occurrences de coups de bras en crawl ([Ganzevles et al., 2019](#)). Nous pensons qu'élargir cette méthode aux quatre nages en exploitant à la fois le signal accélérométrique et gyroscopique filtré constitue une piste prometteuse pour le monitoring des coups de bras.

Les annexes [9.1](#) et [9.2](#) détaillent les principales études évoquées dans le corps du texte et utilisant des méthodes seuils pour la reconnaissance du type de nage et l'identification des événements singuliers de l'activité.

L'intérêt de ces méthodes reposant sur des règles heuristiques réside dans leur relative simplicité de mise en place et sans coût computationnel élevé comme les techniques de ML. Elles reposent principalement sur les concept de périodicité du pattern de nage et de spécificité par nage. Le compte des coups de bras par *findpeaks* et/ou *zero-crossing* apparaît pertinent écologiquement dans la mesure où le signal est filtré convenablement. Parallèlement, l'inconvénient majeur résultant de la littérature est que ces valeurs seuils sont définies à partir d'une population uniforme, réduite, sur un protocole non représentatif des conditions réelles d'entraînement et généralement sans *validation* et/ou *testing set*. Cela a pour conséquence une faible généralisation, transposition et opérationnalisation des algorithmes en condition réelle d'entraînement et à une population étrangère à celle de l'étude initiale. En effet, comme le mentionne [Brunner et al. \(2019\)](#), nombreuses sont les études à collecter leurs données à partir d'un petit échantillon de nageurs élités dans des conditions expérimentales non réalistes. Lorsque l'utilisation de ces algorithmes basés programmation traditionnelle pour de la reconnaissance d'activité natatoire est élargie à des nageurs inconnus, les performances de classification chute drastiquement par rapport au contexte expérimental standardisé. C'est ainsi que l'étude de [Hamidi Rad et al. \(2020\)](#), la plus récente à ce jour sur du monitoring en natation par IMU utilisant une méthodologie de type règles heuristiques/seuils, conclue sur cette phrase : "*to improve the algorithms, we consider investigating machine learning methods, which can better deal with inter and intra variability of swimmer's technique*".

### 3.3.2 Recueil de métriques via des modèles de *machine learning* reposant sur un *features engineering* humain

Une approche utilisant des méthodes de classification basées *machine learning* peut offrir de nouvelles perspectives pour la reconnaissance des différentes phases d'activité en natation. Ainsi [Siirtola et al. \(2011\)](#) proposent l'utilisation de classifieurs linéaires et quadratiques pour la discrimination entre CR, BR et DS à

partir de données d'IMU portées à la main et au tronc. Cet algorithme utilise des *features* calculés préalablement sur la base d'une fenêtre glissante. Bien que leur population expérimentale soit réduite à seulement  $n=11$  nageurs, leur approche méthodologique de validation du modèle est intéressante puisqu'ils utilisent un *leave-one-out* (équivalent d'un *k-fold* avec  $n$  *fold*) permettant une vue d'ensemble des performances du modèle sur tout le *dataset*. Des techniques d'apprentissage non supervisé sont également explorées dans la littérature : Pansiot et al. (2010) utilisent un capteur positionné à la tête et un algorithme de type *k-mean* à partir de *features* sur l'orientation afin d'identifier des frontières de décision entre les différents types de nages. Toutefois aucune autre précision n'est rapportée concernant notamment le nombre de sujets, leur expertise, et les résultats ne mentionnent pas de métriques objectives d'évaluation des performances de l'algorithme. Un des premiers protocole expérimental de la littérature investiguant tous les types de nage est celui de Jensen et al. (2013) à travers 2\*200 4N. Avec un positionnement de capteur sous le bonnet et une population de 12 nageurs, les auteurs utilisent ici également un modèle linéaire reposant sur 8 *features* statistiques par signal calculés sur des intervalles allant de 1 à 20s : le meilleur résultat de classification (90,6%) est atteint avec une fenêtre de 13s. Plus récemment, Zhuang and Xue (2019) illustre la puissance du ML pour la classification des 4 nages avec, à partir d'un *features extraction* de statistiques temporelles et fréquentielles, des résultats de classification moyennes allant de 96% à 97,8% selon les classifieurs utilisés. Bien que proposant un *testing set* différent des données d'apprentissage, leur design expérimental manque cependant de cohérence écologique.

Nous l'avons vu plus haut, la force du ML repose sur sa capacité à extraire des règles de traitement de la masse de données. Dès lors, un pré requis indispensable pour l'utilisation des méthodes d'apprentissage automatique est de disposer d'une base de données pertinente : c'est-à-dire large, avec de la variabilité inter sujets, et incluant l'ensemble des situations et vitesses retrouvées en situation écologique (variation intra sujets). C'est ainsi que le travail d'Ohgi et al. (2014) se positionne comme une première avancée de la littérature en se basant sur la base de données la plus grande retrouvée à ce jour. En enregistrant les données issues de 45 nageurs portant un IMU au torse et réalisant 16\*50m (4 par nage progressif d'allure moyenne à rapide), les auteurs proposent une méthode d'analyse de l'activité natatoire. Alors que la segmentation des longueurs et le calcul des LT se fondent sur la discrimination entre phase d'activité et de repos via un *findpeaks* sur l'accélération antéropostérieure, donc via une méthode dite traditionnelle, la classification de la nage se réalise par deux méthodes de ML. Les *features* retenus sont des statistiques descriptives (moyenne, variance, asymétrie) calculés sur des fenêtres de 4s, 5s après l'identification d'une poussée au mur. Ceux-ci servent à agrémenter un arbre de décision ainsi qu'un réseau de neurones à perceptrons multicouches (MLP). La validation croisée des modèles s'effectue via un échantillons de taille  $n=10$ . Malgré de bons résultats de classification de nage (91,1% pour les deux méthodes) et au regard de la variabilité inter-individuelle de technique, on peut s'interroger sur la pertinence du modèle à généraliser de telles performances sur des nageurs inconnus à l'entraînement initial du modèle. Par ailleurs le protocole se déroule en condition ultra-standardisées et la reconnaissance d'activité par apprentissage automatique est ici limitée à la classification de nage.

Plus récemment Ramos Félix et al. (2019), en se basant sur le calcul de l'enveloppe énergétique moyenne par longueur présenté par Davey et al. (2008) combiné à des règles empiriques (seuils sur l'orientation du capteur à la tête), entraînent deux classifieurs : un modèle de *Support Vector Machine* (SVM) et un réseau de neurones artificiel ici aussi de type MLP. Leur base de données est plus restreinte avec 13 triathlètes de niveau divers et un protocole varié incluant les 4N. Bien que présentant également des résultats intéressants avec 100% de reconnaissance du DS et entre 89 et 89,6% pour les autres styles, l'évaluation de leur modèle est basée -comme pour Ohgi et al. (2014)- sur un *hold-out* séparant un *training set* de 122 longueurs et un *testing set* de 30 longueurs. Ainsi des données de sujets identiques peuvent se retrouver à la fois pour

l'entraînement et la validation du modèle ce qui induit un fort biais de généralisation et de transposition des modèles développés à une application en condition réelle sur des nageurs inconnus.

A ce problème de généralisation des méthodes, se traduisant en des modèles à bas biais mais forte variance, s'ajoute également la confusion fréquente des classifieurs entre BR et PP, du fait d'une proximité spatio-temporelle du pattern de nage, et cela même dans des design expérimentaux qui ne présentent pas de *testing set* (Siirtola et al. (2011); Kon et al. (2015); Jensen et al. (2013); Choi et al. (2014)). Pour palier à cela, Omae et al. (2017) explorent l'utilisation de méthode de ML dites *ensemble learning*, c'est-à-dire combinant plusieurs algorithmes pour augmenter les performances comme les *random forest*, *extreme gradient boosting*, etc..., ainsi que l'utilisation de *features* spécifiques pour discriminer BR et PP. Leur étude est une référence en terme de méthodologie, notamment via l'utilisation de données de validation des modèles étrangères à l'apprentissage initial. mais leur protocole souffre de validité écologique avec seulement 13 sujets réalisant 2\*25m et en ayant la consigne explicite de ne pas réaliser de poussée au mur. Néanmoins leurs résultats montrent une nette amélioration de la discrimination entre BR et PP et une *accuracy* globale supérieure à 95%.

En dépit des résultats prometteurs présentés à travers cette littérature utilisant des modèles de ML basés sur un *features engineering* humain pour la classification de nage, la généralisation de leurs performances pose question dans la perspective d'une application sur le terrain. Cela est principalement causé par des lacunes méthodologiques avec l'utilisation de données de validation issues de sujets non étrangers à l'apprentissage initial, de population expérimentale homogène et de protocole ultra standardisés avec peu de réalité écologique. Par ailleurs ces méthodes de ML, principalement concentrées sur la reconnaissance de la nage, ne couvrent qu'une infime partie de l'activité natatoire qui inclue également la discrimination des touches, poussées au mur, virage, coulées et phases de repos. Pour les monitorer, les études ici présentées le faisant ont recourt à des règles empiriques issues de connaissances à priori ce qui nous ramène au premier lot de méthodologies évoquées au point 3.3.1. Enfin, tous ces modèles de ML reposent sur un *features engineering* réalisé par l'humain, et donc sur la base de ses connaissances, dont on peut faire l'hypothèse qu'elles peuvent être mises en défaut d'une part, et outrepassées par une machine d'autre part à travers une automatisation du *features engineering*. Notons enfin qu'il n'existe à notre connaissance aucune étude dans la littérature cherchant à compter le nombre de coups de bras via un modèle de régression ou de classification basé IA.

### 3.3.3 Recueil de métriques via des modèles de *deep learning* automatisant le *features engineering*

Pour exploiter pleinement les possibilités offertes par les algorithmes d'apprentissage automatique tout en dépassant les limites susmentionnées, les approches basées DL ont commencé à être investiguées dans la littérature pour de la reconnaissance d'activité natatoire. Ainsi Brunner et al. (2019) sont les premiers à explorer cette méthode à travers un *Convolutionnal Neural Network* (CNN) avec une capacité de reconnaissance de la nage affichant un F1-score de 97,4% et une capacité de comptage des longueurs d'une précision de 99,2%. Leur base de données est très large avec 40 nageurs de niveaux variés et les données ont été recueillies en situation réelle d'entraînement via un capteur au poignet ce qui est une première avancée dans la littérature. Leur méthode d'évaluation utilise un *leave-one-subject-out* ce qui est, à notre connaissance, la méthode la plus rigoureuse retrouvée dans la littérature et déjà évoquée par Pansiot et al. dès 2010. Celle-ci permet de réellement appréhender les capacités de généralisation d'un algorithme. Malgré ses hautes performances de classification valide écologiquement, la reconnaissance d'activité englobe les phases de virages, poussées au mur, coulée et repos en une unique phase dite de transition. Néanmoins ces phases "non-nagées" sont

déterminantes pour la performance (Maglischo (2003); Mooney et al. (2015)) et donc son analyse; nous pensons qu'un système de monitoring à destination de nageurs élités ne peut faire l'économie de l'analyse spatio-temporelle de ces phases dites microscopiques selon la classification proposée par Hamidi Rad et al. (2020). Ce biais vient principalement du fait d'une incapacité des auteurs à labelliser leurs signaux IMU sur un faible empant temporel via analyse vidéo. La labellisation est réalisée manuellement par les sujets au cours de l'entraînement (start et stop) ce qui la contraint à être, certes plus rapide, mais macroscopique et laissant de côté ces phases singulières. De plus, leurs signaux sont labellisés quand 75% d'une fenêtre de 6s est composée d'une unique classe. Une telle labellisation est alors pertinente pour un monitoring de nageurs récréatifs mais insuffisant pour des élités. Pour cela, une labellisation manuelle du signal IMU *frame* par *frame* semble, bien que très chronophage, véritablement indispensable pour l'entraînement de modèles de DL considérant toutes les phases de l'entraînement en natation. Par ailleurs, Mooney et al. (2017) mettent en lumière les exigences nécessaires à un système de monitoring automatique de l'entraînement pour des nageurs et entraîneurs de haut-niveau (voir annexe 9.6). Retenons notamment une précision de calcul des LT de  $\pm 0,3s$ , 100% de précision de reconnaissance de nage et  $\pm 1$  coups de bras par longueurs. En conséquence, de futurs travaux doivent être menés dans l'optique de développer un modèle atteignant ces critères. Nous pensons que le DL constitue un outil prometteur pour atteindre une telle précision dans la quantification des métriques d'activités.

Pour autant les travaux de Brunner et al. (2019) font référence dans la littérature. En particulier car réunir une telle base de données labellisées -condition sine qua pour tirer profit des algorithmes de ML/DL-, n'est pas chose aisée. Ainsi de récents travaux s'appuient sur les données de ces auteurs, les seules publiées et disponibles en *open-source* (<http://bit.ly/2IvhS3m>), pour explorer d'autres architectures de DL par exemple. C'est ainsi que Tarasevičius and Serackis (2020) utilisent des cellules neuronales bi-*Long Short Term Memory* (LSTM) pour construire un réseau de reconnaissance d'activité natatoire basé sur les 5 classes et la méthodologie générale de Brunner et al. (2019). Notons néanmoins qu'ils fournissent en *input* du réseau des *features* temporels et fréquentiels calculés à la main ce qui contrecarre l'intérêt majeur des approches DL à traiter directement sur les données brutes sans intervention préalable de connaissances humaines. Leurs résultats avancent un F1-score global de 91,39% pour les 5 classes investiguées. Zhuang and Xue (2019) proposent, à partir d'un *training set* de 12 sujets et d'un *testing set* de 4 sujets réalisant avec une IMU au poignet 4\*25m dans chaque nage, la comparaison d'un modèle de DL basé CNN et de différents modèles de ML (SVM, *Naives Bayes*, *Random Forest*, *K-nearest neighbors*) pour la classification des 4 nages. Bien que l'étude manque de pertinence écologique dans une optique de monitoring d'entraînement, notamment à cause d'un *dataset* réduit comprenant peu de participants et seulement la reconnaissance de la nage, elle illustre la pertinence du DL puisque le CNN atteint la deuxième meilleure performance de classification avec 97,9% derrière le SVM. Par ailleurs, cette étude témoigne de l'essor de l'objet sportif dans le champ de la HAR et illustre l'importance grandissante de la reconnaissance d'activité : "*In contrast to many existing HAR methods, we consider the sport-related activity monitoring problem to be a human activity detection and recognition (HADR) task*" Zhuang and Xue (2019).

Au final, il ressort de la littérature que les modèles basés DL constitue un puissant vecteur d'amélioration du monitoring natatoire par une capacité de reconnaissance d'activité hautement reproductible et généralisable. A condition d'avoir suffisamment de données pour entraîner de tels modèles. Ces améliorations viennent notamment du fait d'une automatisation du *features engineering* et de l'adoption de méthodologie de validation des modèles plus pertinentes. C'est-à-dire utilisant un *validation* et/ou un *testing set* étranger au *training set*. Les limites actuelles à l'implémentation de telles méthodologies reposent sur la difficulté à rassembler de larges bases de données de niveau et situations diverses pour l'entraînement des réseaux

de neurones ainsi que leur labellisation manuelle *frame* par *frame* qui, bien que chronophage, semble indispensable pour la considération des phases microscopiques de l'entraînement. Actuellement, aucune méthode de DL n'a été investiguée pour constituer un modèle de classification fin de l'activité et un modèle de régression du nombre de coups de bras par longueurs dont le monitoring est aujourd'hui exclusivement basé sur des approches seuils dans le domaine spatio-temporel et/ou fréquentiel. Par ailleurs, puisque la littérature disponible ne considère pas la reconnaissance des événements clés (touche, virage, poussée au mur) par apprentissage automatique, aucune des méthodes actuellement disponibles n'est en mesure de calculer des métriques de performance spatio-temporelles comme les LT de manière robuste.

L'exploration de méthodologies de DL et leur exploitation au service du monitoring de l'entraînement pour la quantification de métriques d'intérêts semble bel et bien des éléments d'avenir. Gardons néanmoins à l'esprit que des méthodologies plus classiques (ex : seuils sur signal filtré de manière adéquate) peuvent parfois s'avérer très pertinente car moins chronophage et plus simple à mettre en oeuvre. C'est notamment le cas dans la littérature natation pour le compte des coups de bras qui montre une bonne robustesse avec des méthodologies de *findpeaks* et/ou de *zero-crossing* sur signal filtré en CR. Nous pensons que la combinaison de méthodes basées intelligence artificielle pour la reconnaissance globale d'activité et de méthodes classiques de traitement du signal pour le calcul de métriques singulière à une échelle plus réduite est une alliance prometteuse pour le monitoring natatoire. A la fois pour catalyser le processus d'accompagnement scientifique de la performances des athlètes tout en recentrant l'entraîneur sur son rôle de technicien. Nous en concluons que de futurs travaux sont nécessaires en HAR spécifique à l'entraînement en natation. Ceux-ci doivent prendre le sens du déploiement d'un outil de monitoring utilisable en routine capable de recueillir des métriques d'intérêts pour la performance et le suivi de la charge d'entraînement. Pour cela, une étape préalable demeure la constitution d'une base de données labellisée, large et comprenant de la variabilité inter et intra sujet afin de soutenir l'entraînement d'un classifieur d'activité adapté.

# Chapitre 4

## Problématique

Évaluer la charge d’entraînement des nageurs est devenu indispensable à l’aune des exigences actuelles de la haute performance. Des paramètres de la charge externe comme la variable d’intensité et ses répartitions à l’entraînement jouent un rôle central dans les adaptations positives à l’entraînement. Tout comme le sont les paramètres cinématiques de fréquence-amplitude et des variables d’efficacité pour le suivi des athlètes. Pourtant et par manque de méthodologies scientifiques robustes de reconnaissance d’activité humaine en natation, la quantification de ces métriques d’intérêts est difficilement réalisable par les entraîneurs de manière chronique qui sont de plus dans l’incapacité d’enregistrer ces relevés longitudinalement pour les analyser post-entraînement et ainsi réguler leur prescriptions. En conséquence, le monitoring de l’entraînement en natation est peu développé et bien que la littérature montre l’émergence du *Deep Learning* comme prometteur pour le traitement des signaux inertiels sur des tâches de *Human Activity Recognition*, aucune méthode automatique et généralisable ne permet actuellement de récolter des données spatio-temporelles valides à un niveau macroscopique et microscopique sur l’entraînement de nombreux nageurs en condition réelle.

La figure 4.2 propose une vue schématique de la problématisation retenue pour ce travail de recherche au regard des enjeux sportifs et des limites de la littérature discutés précédemment.

### 4.1 Objectifs

Un des objectifs principaux de ce travail de recherche est le développement, test et validation d’un outil de reconnaissance d’activité natatoire généralisable basé IMU et *deep learning*. Ce modèle vise à la collecte et au stockage de variables spatio-temporelles relatives à la charge externe, la cinématique et l’efficacité en natation en accord avec les critères d’exigences évoqués par [Mooney et al. \(2017\)](#) (cf. 9.6). Parallèlement à cet objectif, il s’agit préalablement de construire et constituer une base de données comprenant des signaux IMU entièrement labellisés des différentes classes d’actions lors d’un entraînement en natation. Cette étape chronophage et complexe est néanmoins primordiale car indispensable pour l’entraînement de réseaux de neurones sous-tendant de futurs travaux visant à la quantification de métriques d’activité. Ladite base de données doit être construite à partir de situations en condition réelle d’entraînement et comprenant de la variabilité inter et intra sujets.

### 4.2 Hypothèses

Hypothèse 1 : Le modèle de HAR développé est robuste (valide et reproductible) et généralisable pour l’évaluation et le stockage des variables d’intérêts dans une population étrangère à l’apprentissage initial du modèle.

Hypothèse 2 : L'outil développé permet le monitoring individuel de l'entraînement du nageur et offre ainsi les conditions de l'optimisation de sa performance.

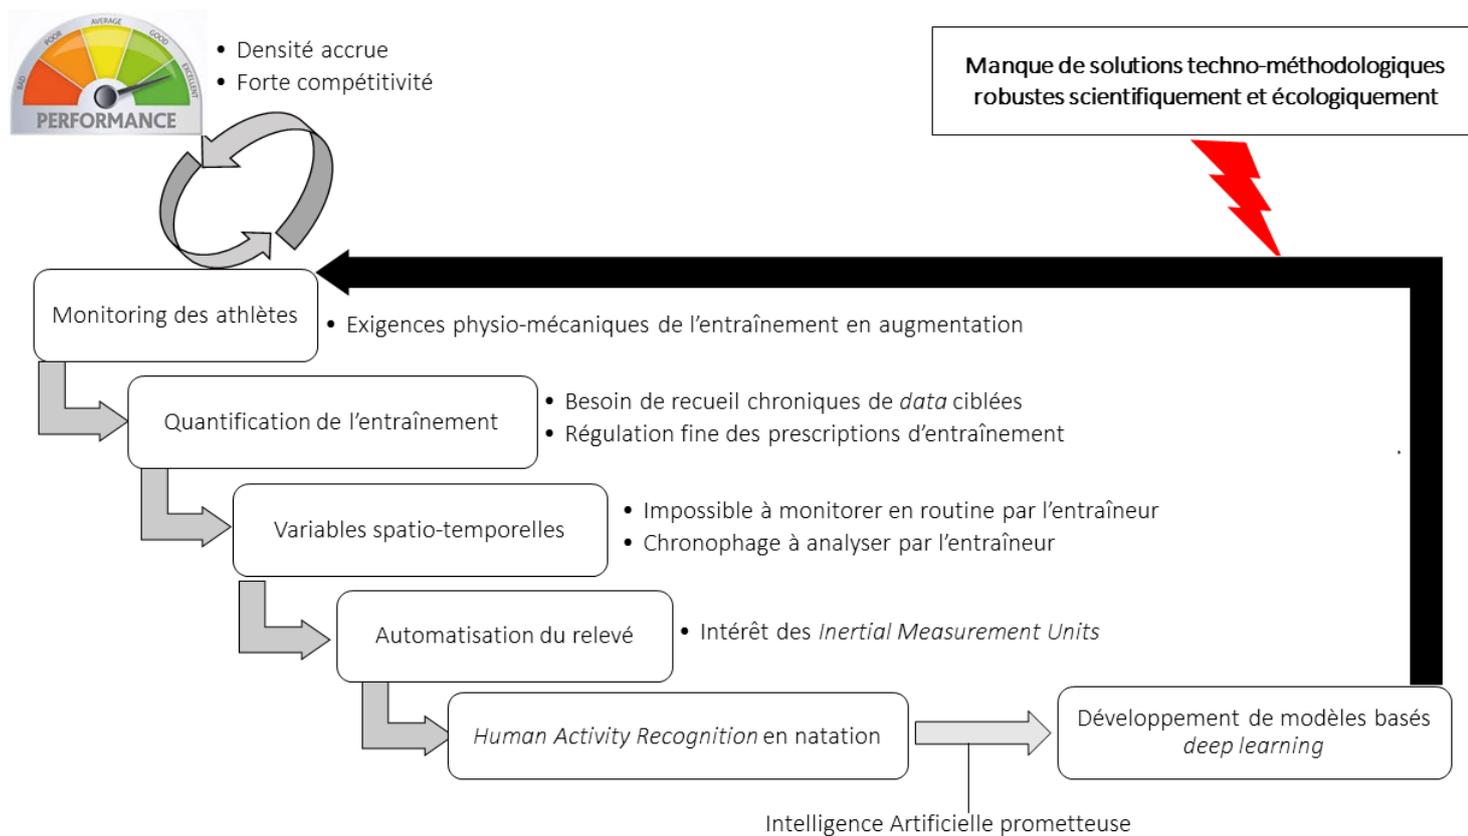


FIGURE 4.1 – Vue schématique de la problématique guidant le travail de recherche

# Chapitre 5

## Matériels et méthodes

### 5.1 Participants

Les données utilisées furent récoltées sur 35 nageurs et triathlètes de niveau récréationnel à national. Tous les participants à la campagne de mesure, 11 femmes et 24 hommes (âge :  $23,23 \pm 8,85$ ans, taille :  $176,48 \pm 9,61$ cm, poids :  $65,81 \pm 10,79$ kg, IMC :  $21,05 \pm 2,46 \text{ m.kg}^{-2}$ , années de pratiques de la natation :  $8,88 \pm 2,95$ ), ont été mis préalablement au courant des mesures réalisées et du but de l'étude via une lettre d'information (voir annexe 9.5). Ils ont par la suite signé un formulaire de consentement éclairé (voir annexe 9.6) en accord avec la déclaration d'Helsinki. Les responsables légaux ont assuré cette tâche dans le cas des sujets mineurs. Les caractéristiques individuelles des sujets sont présentées dans le tableau 9.4 en annexe. Celles-ci décrivent une base de données hétérogène incluant une grande variabilité inter-sujets avec des nageurs allant d'un niveau loisir/récréationnel à Elite et des triathlètes de niveau régional à D1.

### 5.2 Organisation expérimentale

Les mesures se sont déroulées dans 4 piscines de 25m en bassin intérieur.

#### 5.2.1 Centrale inertielle

Les participants furent équipés d'une IMU à 9 degrés de liberté (Cometa WaveTrack, Milano, Italy) composée d'un accéléromètre, gyroscope et magnétomètre 3D. Pour les besoins des expérimentations, seulement les données accélérométriques et gyroscopiques ont été enregistrées. Celles-ci sont échantillonnées à la même fréquence de  $280 \text{ Hz}$  avec une étendue de mesure respectivement de  $\pm 8 \text{ g}$  et  $\pm 1000 \text{ deg.}^{-1}$  avec une résolution de 16bits. Le capteur, moulé dans une coque de plastique protectrice rendant le dispositif étanche, a une masse de 10g et des dimensions de  $44 \times 27 \times 9,5$ mm.

La centrale inertielle est positionnée sur le sacrum, au regard du processus spinal de S2, au point médian entre les épines iliaques postérieures. Ce positionnement anatomique est sélectionné compte tenu de son confort pour le nageur et de la faible perturbation hydrodynamique et kinesthésique qu'il engendre. En raison de sa proximité avec le centre de masse du corps, c'est une localisation largement retrouvée dans la littérature et considérée comme la meilleure pour une mesure uni-capteur : "*sacrum as the most appropriate sensor location for a single sensor analysis system, which aims to cover both macro and micro level parameters*" (Hamidi Rad et al., 2020). La position de l'IMU est telle que son système de coordonnées est défini comme suit :  $x$  sur l'axe longitudinal pointant vers le crâne,  $y$  sur l'axe médio-latéral et  $z$  sur l'axe antéro-postérieur (voir figure 5.1). La fixation est assurée par un scotch double face hypoallergénique recouvert d'un

adhésif médical imperméable (Tegaderm, 3M, Cergy-Pontoise, France). Après enregistrement, les données sont exportées sur le logiciel *EMG and Motion Tools* (Cometa, Milano, Italy) où un rééchantillonnage à 2000Hz est effectué.

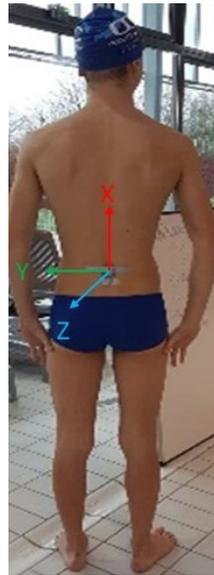


FIGURE 5.1 – Positionnement anatomique du capteur sur le sacrum du sujet (ici avant pose de Tegaderm). Photo prise par les opérateurs avec la permission du nageur

### 5.2.2 Enregistrement vidéo

Trois caméras vidéos ont été utilisées pour la validation des résultats basés IMU. Deux d’entre-elles (GoPro Hero 8, San Mateo, California, USA) filment en direction des murs de bord du bassin à 30 Hz et sont placées sous l’eau à 1m de profondeur au niveau de la ligne d’eau. Elles visent à voir et identifier temporellement tous les évènements de contact du nageur avec le mur. La troisième (Handycam HDR-XR550, Sony, Minato-ku, Tokyo, Japan) filmant à 25 Hz est utilisée comme caméra *travelling* suivant le nageur au cours du protocole. Elle vise pour sa part à enregistrer toutes les actions du sujet en continu d’un point de vue externe (voir figure 5.2). Toutes sont synchronisées avec l’IMU, via sa diode d’allumage permettant de fixer un  $t_0$  commun, afin d’identifier les occurrences temporelles des différentes actions du nageur (poussée au mur, coulée, nature de la nage, virage, touche, repos, coups de bras).

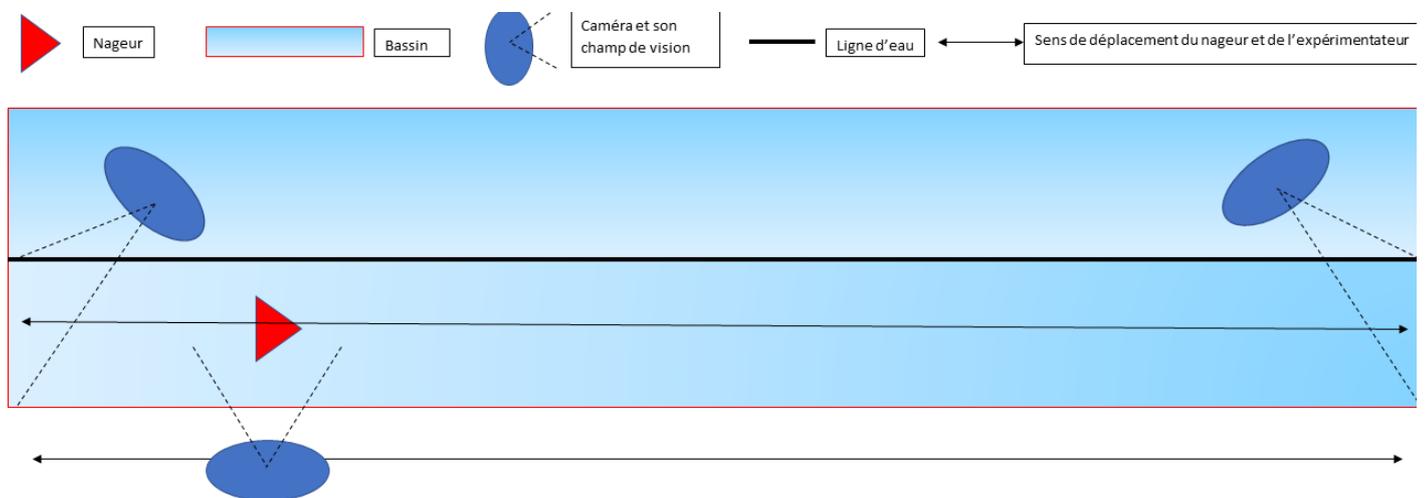


FIGURE 5.2 – Schéma du dispositif expérimental utilisé lors de la campagne de mesure

### 5.3 Protocole expérimental

Après un échauffement standardisé de 15 minutes les sujets réalisent le protocole suivant :  $3 \times 100\text{m } 4\text{N}$  dans l'ordre conventionnel à allure moyenne (80% vitesse maximale) entrecoupés d'une minute de récupération passive. Puis après 3 minutes de repos les nageurs accomplissent dans un ordre aléatoire 100m dans chaque nage avec 2' de récupération entre chaque. Il est demandé aux sujets de réaliser ces 100m progressivement de sorte que le premier 25m soit lent (70% vitesse maximale), le deuxième à vitesse moyenne (80% vitesse maximale), le troisième rapide (90% vitesse maximale) et le dernier à vitesse maximale. Enfin, il est demandé aux athlètes de sortir de l'eau et de marcher 50m le long de la piscine. Le tableau 5.1 synthétise le protocole expérimental retenu. Chaque temps intermédiaire est enregistré par un opérateur à l'aide d'un chronomètre manuel pour de futures analyses (voir ci-dessous).

Ce protocole vise à reproduire un maximum de situations et de mouvements réalisés par les nageurs lors d'un entraînement classique en intégrant notamment toutes les nages à différentes intensités et tous les types de virages possibles. Il permet donc d'induire dans notre base de données une forte variabilité intra-sujets au regard des manquements mis en lumière précédemment dans la littérature. Aucune indications spécifiques de la part des expérimentateurs ne fut données aux sujets au regard de leur manière de nager. En effet nous pensons qu'il est primordial de mettre les nageurs dans une situation la plus écologique possible dans l'idée de construire un classifieur d'activité robuste intégrant toutes les actions possibles d'un entraînement.

Série	Distance (m)	Consigne	Récupération post-série
1	300	$3 \times 100\text{m } 4\text{N}$ allure moyenne r : 1'	R : 3'
2	400	$4 \times 100$ 1/nage progressif par 25m (facile-moyen-vite-max) r : 2'	Sortie de l'eau et 50m marche
Total	700m nagé et 50m marché		

TABLE 5.1 – Protocole expérimental de l'étude

La base de données ainsi constituée comprend environ 25 minutes de données par sujet et 700m de nage soit plus de 875 minutes d'enregistrement de données IMU et vidéos associées. Celle-ci est composée plus spécifiquement de 245 longueurs de papillon (BU), dos crawlé (BA), brasse (BR), crawl (FR), 980 phases de coulées (UN) et de poussées au mur (WA), 735 phases de virage (TU), 280 phases de repos (RS) et 35 phases de marche (voir ci-dessous pour un détail des labels). La durée de chaque phase n'étant pas égale, le *dataset* est relativement asymétrique (*unbalanced dataset*) avec plus d'échantillons de repos et de nage que de poussées au mur et de virages par exemple. Le tableau 5.2 synthétise les différentes phases d'activités identifiées dans la base de données.

Grâce à la variabilité de pattern de nage inter-sujets induite par les caractéristiques de notre population et la variabilité intra-sujets induite par le protocole, qui est de plus exhaustif concernant les phases d'activité de l'entraînement en natation et réalisé en situation écologique, notre base de données s'inscrit en réponse aux limites actuelles de la littérature pour une reconnaissance d'activité robuste et généralisable

Label	Description de la phase d'activité	Code d'identification
BU	Nage papillon	2
BA	Nage dos crawlé	4
BR	Nage brasse	5
FR	Nage crawl	6
UN	Coulée	1
TU	Virage	3
RS	Phase de repos (repos et marche)	7
WA	Poussée au mur	0

TABLE 5.2 – Identification des différentes phases données à l'algorithme de reconnaissance d'activité natatoire

## 5.4 Traitement des données

### 5.4.1 Labellisation des données vidéos

Les données vidéos synchronisées ont été labellisées par annotation manuelle de l'instant de début et/ou de fin de chaque phase via les logiciels Adobe Premiere Pro ou Pinnacle selon la liste de labels décrite dans le tableau 5.2. Cette phase de labellisation nous permet de savoir, à chaque *frame* et donc à tout instant, l'action qu'est en train de réaliser le nageur. Cela dans le but d'entraîner un classifieur à reconnaître ces différentes phases d'activités à partir du signal IMU. L'annexe 9.7 présente en détails et illustre le processus de labellisation des données vidéos à partir des 3 caméras pour la constitution d'un *template* d'activité par sujet.

Les définitions des labels d'activités retenues pour l'annotation manuelle par un opérateur sont décrites dans le tableau 5.3. Ceux-ci couvrent l'entière gamme d'actions possibles lors d'un entraînement de natation à l'exception des départs plongés, jambes et éducatifs. A partir de cette numérisation des actions des nageurs, nous avons calculé les LT par nage. Ceux-ci sont déterminés par caméra (CAM) et constituent donc notre *gold-standard*. Les définitions des LT sont spécifiques selon la nage et le type de longueur (début, fin ou à l'intérieur d'un intervalle) afin de correspondre avec la réalité de chronométrage sur le terrain (voir annexe 9.3 pour le détail de calcul *gold-standard* des LT).

### 5.4.2 Données inertielles et modèle de *deep learning* développé

#### Pré traitement des données

Cette étape de *preprocessing* est réalisée via Matlab (The Mathworks™, Natick, MA, USA, R2020b, 64 bit). Les données brutes de chaque capteur ont été filtrées avec un filtre de Butterworth passe-bas du second ordre incluant une fréquence de coupure de 10 *Hz*. Les signaux sont par la suite *downsample* à 50 *Hz* afin d'obtenir une fréquence d'échantillonnage plus adéquate avec l'entraînement de modèles de *deep learning*. C'est-à-dire moins coûteuse computationnellement. Enfin, les *templates* d'activité précédemment construit par labellisation manuelle des données vidéos (voir annexe 9.7) sont exploités afin de construire un fichier CSV par sujet comprenant pour chaque *frame* les 6 signaux inertiels associés au label d'activité (voir figure 5.4.2). A chaque label est associé un numéro de classe selon la nomenclature présentée dans le tableau 5.2. Ces fichiers sont ensuite directement utilisés pour l'entraînement des réseaux de neurones (cf. ci-dessous). Si l'on reprend les termes évoqués précédemment, ces CSV regroupent donc les *inputs*  $X$  de notre modèle

-les 6 signaux inertiels- ainsi que les *outputted target Y* -les labels d'activité-. Il s'agit désormais de réussir à entraîner un classifieur basé DL pour réaliser le *mapping* de ces *X* sur les *Y* de manière robuste et surtout généralisable afin de permettre la reconnaissance d'activité natatoire à partir de données IMU. La figure 5.4.2 reflète ce processus en mettant en relief les signaux IMU et la labellisation vidéo sur deux 100m 4N consécutifs.

Label	Début	Fin
Poussée au mur (WA)	Première <i>frame</i> où le nageur passe d'une position pseudo-verticale à horizontale ou première <i>frame</i> après une fin de TU ou RS	Dernière <i>frame</i> où les pieds du nageur sont en contact avec le mur
Coulée (UN)	Première <i>frame</i> après une fin de WA	Première <i>frame</i> où les mains du nageur se dissocient et la position flèche est rompue
Papillon (BU)	Première <i>frame</i> après une fin de UN où le nageur est en BU	Première <i>frame</i> où les mains du nageur touchent le mur
Dos crawlé (BA)	Première <i>frame</i> après une fin de UN où le nageur est en BA	Première <i>frame</i> où le nageur entame sa dernière traction de bras après être repassé sur le ventre
Brasse (BR)	Première <i>frame</i> après une fin de UN où le nageur est en BR	Première <i>frame</i> où les mains du nageur touchent le mur
Crawl (FR)	Première <i>frame</i> après une fin de UN où le nageur est en FR	Première <i>frame</i> où le nageur entame sa dernière traction de bras avant le virage
Virage (TU)	Première <i>frame</i> après une fin de BU, BA, BR ou FR	Première <i>frame</i> où les pieds du nageur entrent en contact avec le mur
Repos (RS)	Première <i>frame</i> après une fin d'intervalle en BU ou BA ou première <i>frame</i> où le nageur touche le mur avec sa main en FR et BA ou première <i>frame de marche</i>	Début de WA (cf. ci-dessus) ou dernière <i>frame de marche</i>

TABLE 5.3 – Critères de labellisation vidéo des différentes phases d'activités natatoire retenues

### **Windowing et architecture du réseau**

La base de données globale est tout d'abord aléatoirement séparée en un *validation* et un *training set* via une méthode de *leave-one-subject-out* (LOSO) conformément à sa pertinence dans la littérature pour l'appréciation des capacités de généralisation du modèle entraîné. De ce *training set* un deuxième sujet est extrait au hasard pour former un *testing set*. Ces sujets extérieurs à l'apprentissage initial du réseau seront utilisés pour évaluer les performances du modèle (cf. point suivant).

A partir des données des fichiers sujets CSV construits en 2D préalablement lors de la phase de *preprocessing* (voir figure 5.4.2) une étape de *windowing* des données est réalisée. Le signal est découpé en fenêtres de taille 90 (soit 1,8s) *overlappées* de 1 *frame*. A chaque fenêtre est attribuée le label du milieu de la fenêtre,

soit celui de la 45<sup>ème</sup> *frame*. La *window size* a un impact fort sur les performances finales de classification d'un réseau (Nweke et al., 2018). Ce choix de taille de fenêtre est ici issu de travaux parallèles à ce mémoire de recherche utilisant la même base de données (voir annexe 9.8).

Imu_Acc_X	Imu_Acc_Y	Imu_Acc_Z	Imu_Gyro_X	Imu_Gyro_Y	Imu_Gyro_Z	Phase
0.0576518500898549	-0.181474572566891	1.00495253311523	11.6496996874434	50.0927737617042	11.793664424507	0
0.0551309864735114	-0.0940881347388881	0.99300522317054	1.8494730953475	50.1732711860065	12.1750949382499	0
0.0405831873435973	-0.0188603575167426	0.980312090726998	-7.95707108720554	51.7647690885936	9.40638286782915	0
0.0324788952744361	-0.0267595257409889	0.954009290080343	-15.0273885156865	53.2598919135892	2.45743207407819	0
0.0422001266749497	-0.103540036252812	0.927435271638057	-15.4158046093192	53.2675194923714	-5.36497605766279	0
0.0544934688906952	-0.156597263655306	0.923881961911023	-10.4884834804034	49.2791018405199	-10.4186522105408	0
0.0870698730414184	-0.137387760936916	0.969992632137464	0.347943426792294	42.0017329357156	-12.9291199290957	0
0.165831471253973	-0.145510299235592	1.11082861538979	25.6361228257412	36.2518046163702	-17.3217215574221	0
0.269447104395729	-0.241669446730643	1.31136533702208	56.3490416247447	37.579776539174	-18.8017122215855	0
0.35466263808679	-0.302976403186289	1.38054498428378	43.1775328619263	42.4364668108607	-0.671347322092142	0
0.378822607183346	-0.151468120954957	1.28264946510151	-0.209673117042008	44.1368249589293	20.552400411802	0
0.393426039894641	-0.0053461940859492	1.16995899952201	-0.885797565879404	41.5036080215204	10.5436457564766	0
0.43565808480907	-0.074045736294859	1.1277555204675	25.737949110691	36.8396901674649	-8.27297561539141	0
0.479021465029238	-0.146045273601356	1.15002834742423	31.3782353725017	34.9701414531885	-6.32420533918137	0
0.533946457275748	-0.12259597302915354	1.20259589737586	8.31284035331	36.5021839206028	9.20527288920986	0

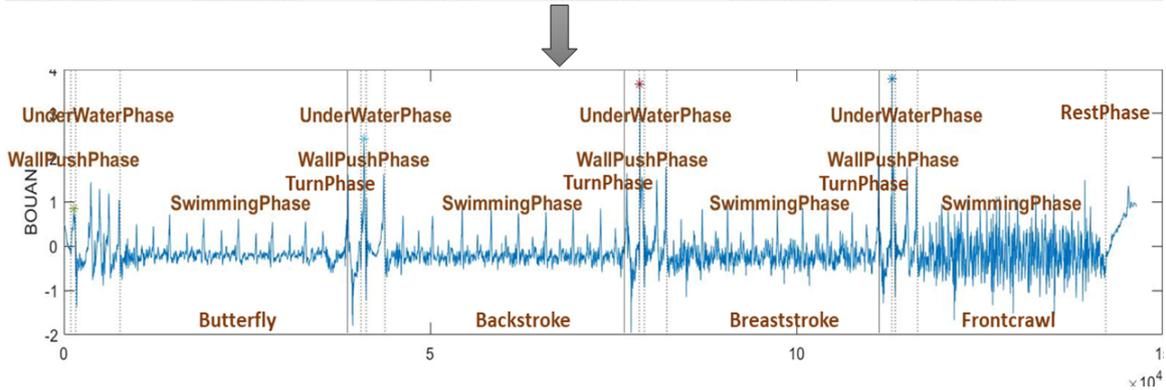


FIGURE 5.3 – Illustration de la phase de preprocessing : exploitation du template issu de la labellisation vidéo pour la construction de fichiers CSV regroupant les inputs (signal IMU) et targets (labels)

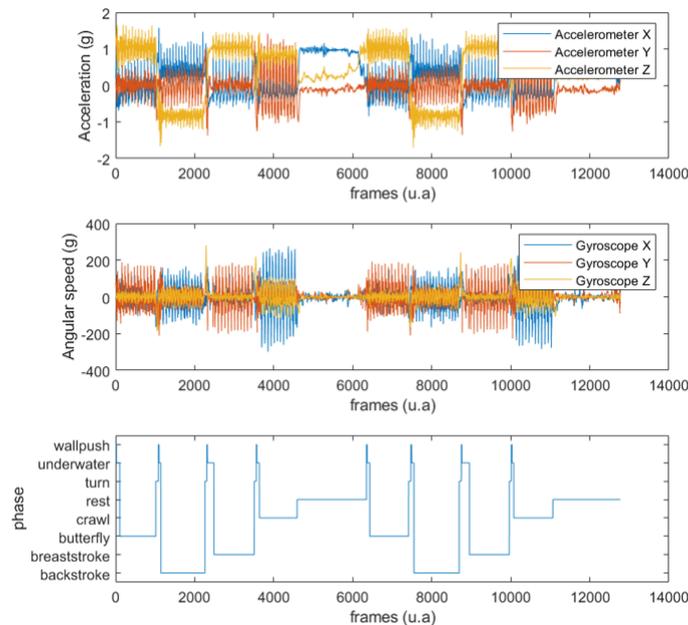


FIGURE 5.4 – Signal accélérométrique et gyroscopique durant deux 100m 4N consécutifs et labels d'activité associés

Trois fichiers (*training*, *validation*, *testing*) 3D sont ainsi formés. Ces données ont alors les dimensions suivantes : nombre de *frames* dans le *set* \* 7 \* 90. Les fenêtres des *training* et *validation set* sont par la suite mélangées aléatoirement afin de réduire les risques d'*overfitting* du réseau. Ensuite les données 3D sont réorganisées en 2D et adoptent les dimensions suivantes : nombre de *frames* dans le *set* \* 630. Enfin, une étape de normalisation des données est réalisée en centrant et réduisant chaque valeur par la moyenne et l'écart-type

calculés sur toute la base de données afin d'éviter le biais créé par l'utilisation de données accélérométriques et gyroscopiques d'ordre de grandeur différents. La dernière étape de ce procédé de manipulation de données consiste à créer trois fonctions générateur (un pour chaque *set*) afin de nourrir l'entraînement du réseau décrit ci-dessous avec des  $x$  de taille (6,90) et un  $y$  de taille (1,) selon une *batch-size* (nombre d'exemples d'entraînements utilisés par itération du réseau) de 64.

Le développement du modèle a été réalisé via TensorFlow (Abadi et al., 2016), une plate forme *open-source* développée par Google Research dédiée au ML, et Keras (Chollet et al., 2015), une interface de programmation Python pour le DL. L'architecture du réseau est présentée dans le tableau 5.4. Celle ci se fonde sur l'utilisation de cellules LSTM (Hochreiter and Schmidhuber, 1997) utilisées de manière bidirectionnelle (Graves and Schmidhuber, 2005) conformément à leur pertinence pour des applications sportives de HAR basées IMU dans la littérature (Cust et al., 2019). L'*input shape* est (6,90), le sujet du *validation set* est KERGW et le sujet du *testing set* est TREEL. Concernant les autres hyperparamètres, le *learning rate*  $\alpha$  initial a été fixé à 0.001 avec une décroissance au fil des *epochs* de l'apprentissage tel que :

$$\alpha = \frac{0.001}{800 \frac{epochs}{100}} \quad (5.1)$$

Le nombre d'*epochs* utilisé pour l'apprentissage est de 10. L'initialisation des poids des paramètres de chaque couche suit une initialisation uniforme de Xavier (Glorot and Bengio, 2010). L'optimiseur choisis pour la mise à jour des paramètres du réseau au cours de son entraînement est l'*Adaptive Moment Estimation* (ADAM) (Kingma and Ba, 2014). Une *batch normalization* est appliquée à l'avant dernière couche du réseau afin de faciliter l'entraînement (Ioffe and Szegedy, 2015). Enfin la fonction de coût choisie est la *sparse categorical cross entropy* conformément à notre volonté d'un modèle de classification multiclasse.

Type de couche	Nombre d'unités	Fonction d'activation	<i>Dropout</i>	<i>Recurrent Dropout</i>
bi-LSTM	64	Tanh	0.25	0.25
bi-LSTM	32	Tanh	0.25	0.25
bi-LSTM	16	Tanh	0.25	0.25
bi-LSTM	16	Tanh	0.25	0.25
Flatten				
Dense	50	ReLU	0.5	
Dense	8	Softmax		

TABLE 5.4 – Architecture et paramétrisation du réseau

## Évaluation des performances du réseau

Les *sets* de validation et de test seront utilisés pour monitorer les performances de reconnaissance du réseau, c'est-à-dire l'appréhension du couple biais/variance du modèle. D'une part au cours de son apprentissage pour ainsi éviter l'*overfitting*, d'autre part à la fin de son apprentissage en tant que témoin des capacités de généralisation à des données d'un sujet inconnu à l'entraînement initial. Lors de cette phase, la métrique d'*accuracy* est utilisée pour monitorer le réseau.

Lors de l'évaluation des performances du réseau sur le *testing set*, les métriques de *precision*, *recall* et *f1-score* par classes sont utilisées ainsi que la visualisation sous forme de matrice de confusion. Nous porterons une attention particulière sur le *f1-score* car "*F-Measure is mainly applied in unbalanced datasets and provides a geometric mean of sensitivity and specificity*" (Nweke et al., 2018). Alors que la *precision* traduit la proportion d'identifications positives comme effectivement correcte, le *recall* exprime lui la proportion

de résultats positifs réels correctement identifiée. Ces deux métriques sont fréquemment en tensions d'où le recours à la F-mesure qui les évaluent simultanément. Elles sont classiquement utilisées dans des applications de HAR, toutefois, notre base de données est largement *unbalanced*, il est donc important de considérer ces indicateurs moyennés pour l'ensemble des classes.

La visualisation de la prédiction d'activité  $\hat{y}$  du réseau comparée à la réalité  $y$  est également un bon moyen d'appréhender la capacité globale du modèle à classifier l'activité natatoire au fil du temps puisque c'est ce vecteur  $\hat{y}$  qui est directement exploité en *post-processing* pour le calcul des métriques d'intérêts sur l'activité du nageur.

### 5.4.3 Post traitement de l'*output* du réseau et calcul de métriques de performance

A partir du  $\hat{y}$ , des métriques spatio-temporelles de performance et de monitoring de l'entraînement sont calculées. Nous avons utilisé le sujet de *testing set* pour cette étape. Ce *post-processing* est réalisé sous Matlab. Il vise tout d'abord à filtrer et lisser les prédictions du réseau en éliminant un maximum d'artefacts et de sauts de prédictions. Par ailleurs un *offset* est empiriquement constaté entre les vecteurs  $y$  et  $\hat{y}$  de sorte que le réseau fait une prédiction avec environ 40 *frames* d'avance sur la réalité (voir annexe 9.9). Nous n'avons pas les moyens computationnel pour quantifier plus objectivement cet *offset*. Nous appliquons donc une correction de +40 *frames* au vecteur  $\hat{y}$ .

En partant de cette classification de l'activité du nageur, les instants de débuts et de fins de nage sont identifiés afin de déterminer les intervalles d'activités et de repos conséquents. Cette détection se base uniquement sur la prédiction du réseau et les changements de classe, de sorte qu'aucun seuils sur le signal n'est appliqué manuellement. Le signal IMU est utilisé uniquement pour trouver plus précisément l'instant de début d'activité via la norme accélérométrique conjointement aux prédictions du modèle. Puis à l'échelle intra-intervalle, les zones frontières (fin de nage, début et fin de virage, début et fin de coulée) sont détectées, toujours grâce aux prédictions d'activités du modèle, afin de déterminer le nombre de longueurs et des instants d'intérêts. De cette segmentation et ces instants sont calculés différentes métriques spatio-temporelles de performance à trois niveaux : une vue globale de la séance, une vue par intervalle de nage, une vue par longueur de nage.

Les métriques calculées sur ces différentes vues sont les suivantes : temps d'activité et de repos, répartition des nages et des intensités de nage dans la séance (selon une classification en 3 zones propre à chaque athlète), vitesse, distance, temps de virage, temps de coulée, distance de coulée, *jerk cost* (Ganzevles et al., 2019) et LT. Le nombre de coups de bras (en CR et DS) et de cycle de nage (en BR et PP) par longueurs est également calculé via un *zero-crossing* sur l'accélération médiolatérale en CR et DS, et via un *findpeaks* sur la vitesse angulaire médiolatérale en BR et PP avec un critère d'espacement inter-pics minimal de 1,25s et une prééminence minimale de 70°/s . Les signaux sont ici filtrés avec un filtre Butterworth de second ordre passe bande entre 0,1 et 1Hz. Cette méthodologie est inspirée des travaux de Ganzevles en CR (2017, 2019) puis élargie et empiriquement validée via des pré-tests. De ce compte des coups de bras est calculé les métriques suivantes par longueurs : fréquence, amplitude, *stroke index* (Costill et al., 1985), *swolf score* (Delgado-Gonzalo et al., 2016). Nous nous focaliserons dans ce présent manuscrit de mémoire de master 2 sur les LT et leur validation conformément à leur importance dans notre cadrage théorique précédent.

### Analyses statistiques

Les analyses statistiques suivantes ont été réalisées avec le logiciel R Studio (Version 1.2.5033, RStudio, Inc). La fiabilité de calcul des LT via IMU et chronomètre par rapport au *gold-standard* vidéo a été déterminé

en calculant différents indicateurs : (1) des statistiques descriptives, (2) l'erreur typique de mesure (TEM) (Hopkins, 2000) et son expression en tant que coefficient de variation (CV) avec intervalles de confiance à 95% associés (IC), (3) le biais de mesure avec ses IC ainsi que les limites d'agrèments (LoA) via une analyse de Bland-Altman (Bland and Altman (1986); Bland and Altman (1999)), (4) le *Root Mean Square Error* (RMSE), (5) le pourcentage d'erreur moyen -MPE-, (6) le pourcentage d'erreur moyen absolu -MAPE-.

Les différents indices statistiques ont été interprétés de la manière suivante : (1) visualisation globale, (2) agrément en tant qu'erreur aléatoire de la mesure : critère de justesse, (3) erreur systématique de mesure : critère de fidélité de l'outil, (4) indicateur caractérisant la taille des écarts entre les deux méthodes : critère d'exactitude, (5) indicateur capturant le degré global de surestimation ou sous-estimation (DeShaw et al., 2018), (6) indicateur capturant l'erreur de mesure imputable à la surestimation comme à la sous-estimation et reflétant l'erreur attendue par mesure (DeShaw et al., 2018). L'utilisation des notions de fidélité, justesse et exactitude des observations se base sur les critères et indicateurs d'auto-évaluation de modèle selon S. Sandoval (2018). Par ailleurs, gardons à l'esprit le critère de  $\pm 0,3s$  de différence entre IMU et *gold-standard* évoqué par Mooney et al. (2017) (pour rappel voir annexe 9.6). Ce critère peut-être apprécié par la MAPE.

# Chapitre 6

## Résultats

### 6.1 Performances de classification d'activité du modèle

L'accuracy sur le *training*, *validation* et *testing set* est respectivement, à la fin des 10 *epochs* d'entraînement, de 95,14%, 94,36% et 93,65%. La figure 6.1 présente une comparaison des  $y$ ,  $\hat{y}$  et  $\hat{y}$  après le *post-processing* et la figure 6.1 montre la matrice de confusion des *F1-score* sur le modèle post-traité appliqué au *testing set*. Le *F1-score* moyenné est alors de 0,86 et le *F1-score* pondéré de 0,96. L'annexe 9.14 présente l'évolution de la fonction de coût et de l'accuracy au cours de l'entraînement du réseau.

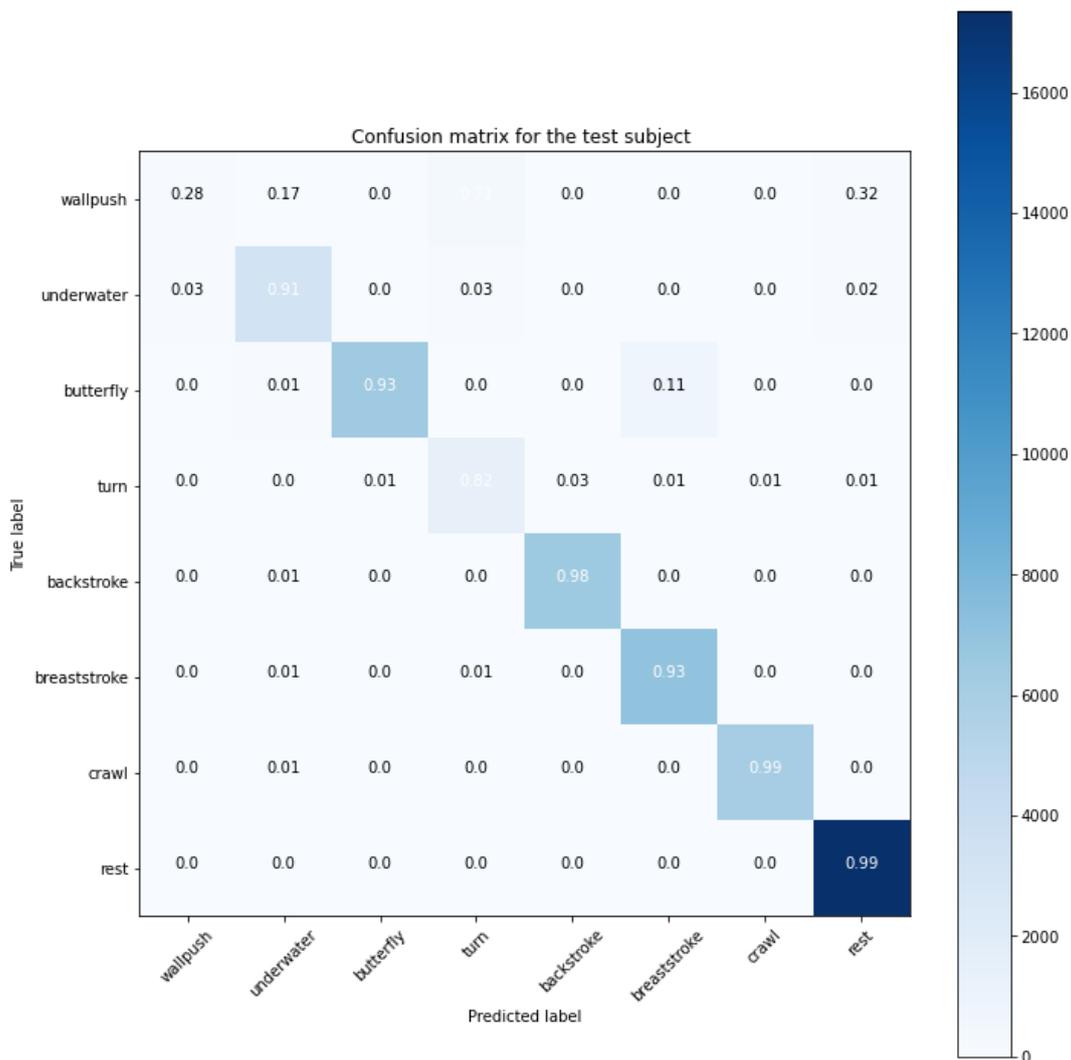


FIGURE 6.1 – Matrice de confusion (*F1-score*) pour le modèle après *post-processing*

On constate que le filtrage des prédictions brutes du modèle permet d'éliminer énormément d'artefacts et petits sauts de prédiction. La structure globale du protocole est bien présente et toutes les zones frontières, déterminantes pour le calcul des métriques de performances, sont bien détectées. On ne relève aucune confusion systématique sur le type de nage. Seule quelques *frames* de BR sont confondues en PP, c'est un constat récurrent de la littérature qui n'introduit que peu d'erreur dans l'optique du monitoring de l'activité. Toutefois les classes avec une durée courte sont celles avec le *F1-score* le plus faible. Cela peut être dû au déséquilibre du nombre d'échantillons d'entraînements dans la base de données et à la difficulté pour un modèle informatique de prédire ces phases d'une durée souvent inférieure à 0,5s. Ainsi certaines poussées au mur ne sont pas du tout détectées, c'est majoritairement la phase la moins bien classifiée et également la plus courte ( $\approx 0,10s$ ). Elle est fréquemment confondue avec ses classes adjacentes : coulée, virage ou repos.

Plot of true labels, predicted, and filtered predicted labels on testing set (TREEL)

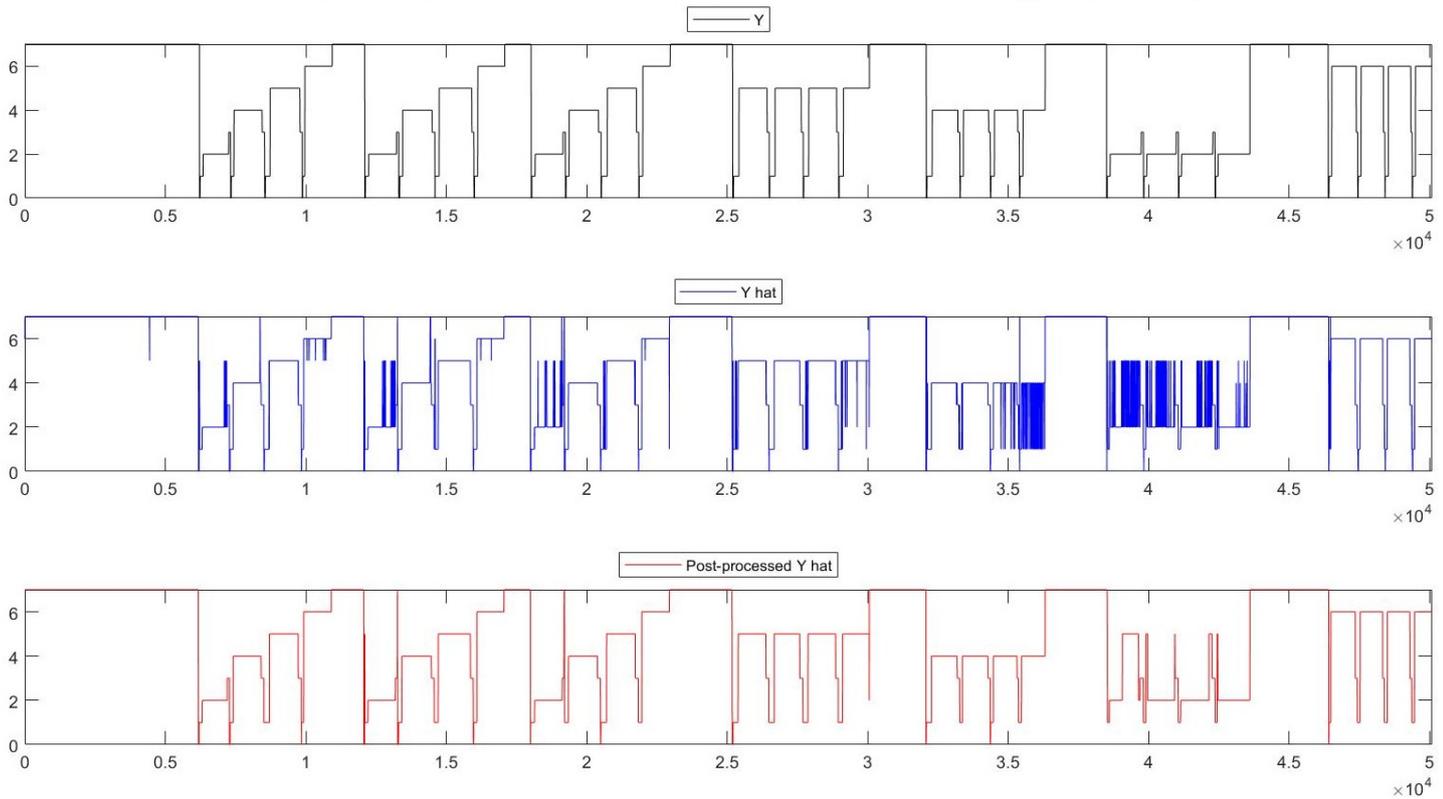


FIGURE 6.2 – Visualisation des prédictions d'activité du réseau avant et après post-processing et comparaison à la réalité attendue

## 6.2 Métriques de performances spatio-temporelles

Comme énoncé précédemment, ce présent mémoire va se focaliser sur la validation du calcul des LT en comparant la mesure de cette variable par *gold-standard* vidéo (CAM), IMU et chronomètre manuel (MAN). Néanmoins, toutes les autres métriques calculées seront également présentées en partie discussion à travers un rapport d'entraînement afin d'illustrer les possibilités de *feed-back* pour l'entraîneur et l'intérêt d'utiliser un tel outil pour le suivi de nageurs. Leur validation à un *gold-standard* vidéo de la même manière que déployé ici pour les LT constitue un axe futur de travail.

### 6.2.1 Temps intermédiaires

Les tableaux 6.1, 6.2 synthétisent les différents indicateurs statistiques d'agrément des méthodes IMU et MAN au *gold-standard*.

Les LT IMU sont légèrement sur-estimés avec une erreur systématique de  $+0,27\%$   $[-0,13\%; 0,42\%]$  au *gold-standard* ( $+0,06s$ ) et un MAPE de  $1,75 \pm 1,82\%$ . Le critère de justesse véhiculant l'erreur aléatoire (TEM) est de  $0,6s$   $[0,57; 0,63s]$  et le critère d'exactitude de l'outil (RMSE) de  $1,98s$  soit  $8,38\%$ . Ce RMSE en apparence élevé par rapport aux autres indicateurs est dû à un échantillon statistique important ( $n=952$ ) et l'on constate sur la figure 6.2.1 une répartition des erreurs entre CAM et IMU globalement comprise entre  $-1$  et  $+1s$  sans visuellement constater une évolution de l'erreur avec la vitesse de nage.

Le critère de Mooney et al. (2017) est respecté pour  $55,15\%$  des LT et l'erreur attendue par mesure est de  $0,42s$  ce qui est hors dudit critère. Notons que sur les  $990$  LT de la base de données,  $952$  ont pu être traités par IMU ce qui représente une perte d'information de  $3,84\%$ . Les LT non enregistrés sont dû à un manque de batterie de l'IMU ou une prédiction d'activité par le modèle trop erronée pour être exploitée en *post-processing*, cela concerne en particulier un sujet de niveau récréationnel à la technique de nage très singulière.

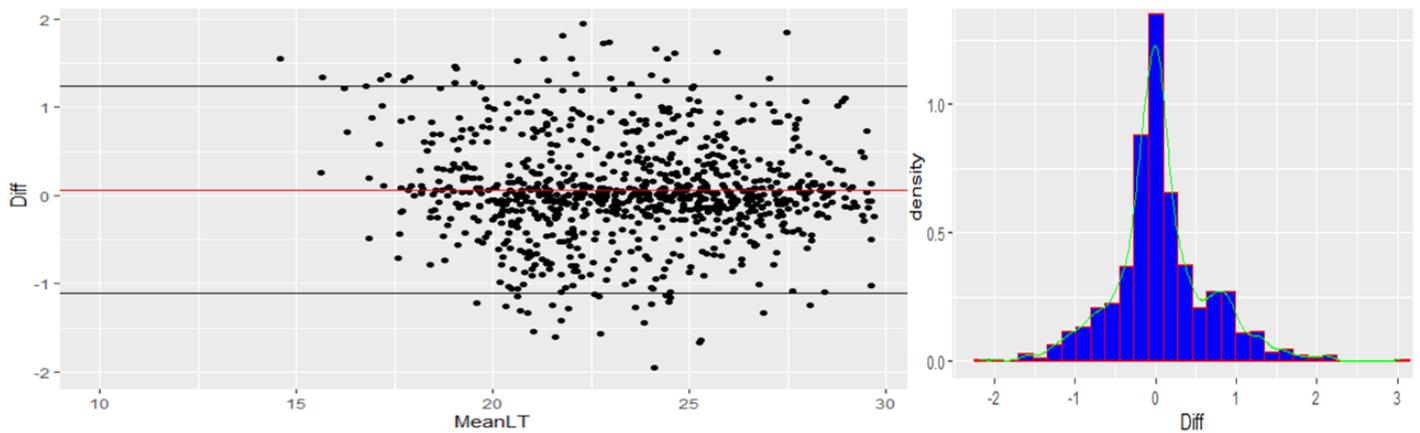


FIGURE 6.3 – Graphique de Bland-Altman et densité de répartition des différences entre LT mesurés par *gold-standard* et centrale inertielle

LT	Moyenne (ET)	Moyenne (ET)	TEM [IC]	TEM as CV [IC]	Biais [IC]	LoA	RMSE	MPE (ET)	MAPE (ET)	p-value
	CAM	IMU								
n=952	22,73s (3,39s)	23,79s (3,35s)	0,60s [0,57s; 0,63s]	2,5% [2,4%; 2,7%]	0,06s [-0,05s; 0,14s]	-1,11s; 1,24s	1,98s	0,27% (2,52%)	1,77% (1,82%)	$p < 0,001$

TABLE 6.1 – Validité de mesure des temps intermédiaires par IMU par rapport au *gold-standard*

Les LT MAN sont légèrement sous-estimés avec une erreur systématique de  $-0,44\%$   $[-0,59\%; -0,29\%]$  à la mesure CAM ( $-0,10s$ ) et un MAPE de  $1,43 \pm 2,04\%$ . Le critère de justesse traduisant l'erreur aléatoire est de  $0,58s$   $[0,55s; 0,61s]$  et le critère d'exactitude de l'outil de  $3,08s$  soit  $12,98\%$ . Bien que ce dernier indicateur

semble élevé, on constate sur la figure 6.2.1 une répartition des erreurs entre CAM et MAN globalement comprise entre -0,75s et 0,5s et une erreur plus faible à mesure que le sujet nage rapidement.

Le critère de Mooney et al. (2017) est respecté pour 65,63% des LT et l'erreur attendue par mesure est de 0,34s ce qui est hors dudit critère. Notons que sur les 990 LT disponibles dans la base de données, 870 ont pu être enregistrés manuellement par les expérimentateurs ce qui représente une perte d'information de 12,12%. Ces LT non chronométrés sont imputables à la mesure humaine.

LT	Moyenne (ET) CAM	Moyenne (ET) MAN	TEM [IC]	TEM as CV [IC]	Biais [IC]	LoA	RMSE	MPE (ET)	MAPE (ET)	p-value
n=870	23,74s (3,39s)	23,63s (3,38s)	0,58s [0,55s; 0,61s]	2,5% [2,4%; 2,6%]	-0,10s [- 0,14s;- 0,07s]	-1,24s; 1,03s	3,08s	-0,44% (2,45%)	1,43% (2,04%)	p=0,001

TABLE 6.2 – Validité de mesure des temps intermédiaires par chronomètre par rapport au *gold-standard*

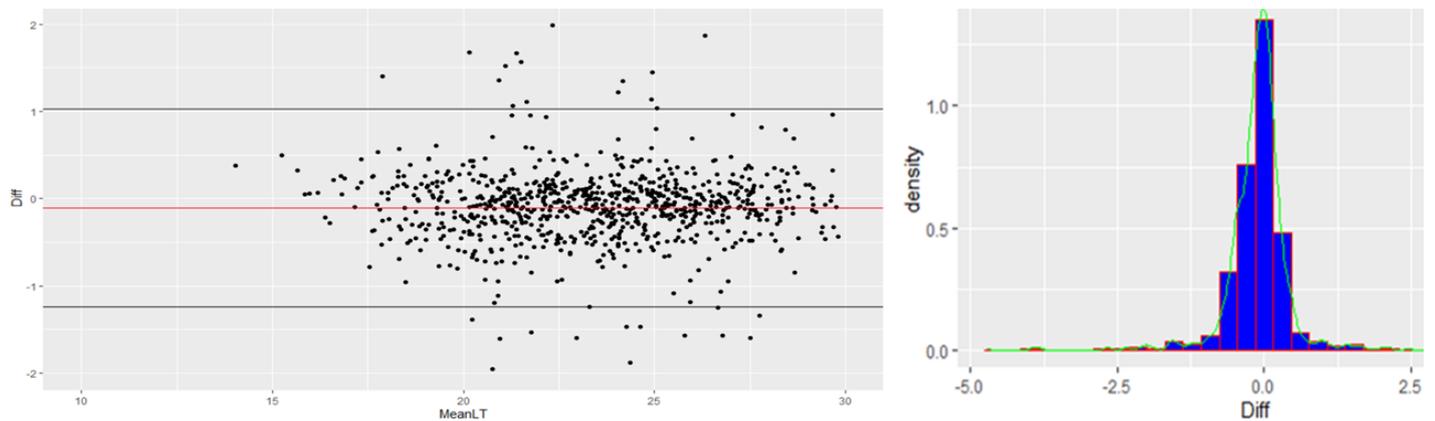


FIGURE 6.4 – Graphique de Bland-Altman et densité de répartition des différences entre LT mesurés par *gold-standard* et chronomètre manuel

## 6.2.2 Autres métriques d'activité natatoire

Les variables spatio-temporelles calculées permettent une analyse à trois échelles. Une vue générale de l'activité du nageur tout d'abord avec la répartition des temps de nage/repos, des intensités via un paramétrage individuel en zones propre à chaque athlète et du type nage. Puis une analyse statistique globale des différentes métriques à l'échelle de la séance propice à la comparaison inter-athlètes et intra-athlètes. Enfin, une analyse spécifique au cours de l'entraînement et selon son déroulement chronologique, pouvant être focalisée par exemple sur la série cible de la séance, et ainsi utile à l'appréhension des réponses cinématiques d'un sujet à l'exercice demandé.

Une illustration de ce rapport d'entraînement via une application au monitoring d'une séance d'un triathlète de niveau national est proposé en partie discussion (voir figures 7.2, 7.2, 7.2).

# Chapitre 7

## Discussion

### 7.1 Apports, limites et perspectives scientifiques

La base de données collectée et labellisée constitue, à l'aune de la littérature actuelle, une des plus riches. En effet seuls [Brunner et al. \(2019\)](#) et [Ohgi et al. \(2014\)](#) présentent plus de sujets avec respectivement 40 et 45 nageurs. Toutefois les sujets retenus et le protocole adopté ne permettent pas d'obtenir une variabilité inter et intra-athlètes notable, caractéristique indispensable pour une généralisation large des algorithmes développés. Nous sommes de plus les premiers à investiguer l'activité natatoire par *data mining* avec une telle pluralité de classes, exhaustive des situations écologiques, et la considération des phases microscopiques indispensables pour un monitoring de la performance à haut-niveau.

Actuellement le seul outil de monitoring en natation commercialisé et disponible sur le marché est le Triton (TritonWear, Toronto, ON M5A3Y5) ([Lehari, 2020](#)). En revanche le peu de littérature scientifique disponible concernant sa validation ([Butterfield \(2017\)](#); [Butterfield et al. \(2019\)](#)) en fait un outil, certes utilisé par de nombreuses fédérations, mais dont la fiabilité n'est pas tranchée. Nous nous appuyons donc en partie sur les données de validation relative à cet outil, couplé aux exigences de la littérature comme les critères de Mooney (voir annexe 9.6), pour discuter le calcul de nos métriques d'activité.

#### 7.1.1 Modèle de reconnaissance d'activité natatoire

Notre modèle propose une reconnaissance d'activité en 8 classes ce qui constitue une avancée majeure de la littérature. Les précédents modèles basés DL n'incluent en effet que les 4 nages et une classe dite de transition ([Brunner et al. \(2019\)](#); [Tarasevičius and Serackis \(2020\)](#)). [Hamidi Rad et al. \(2020\)](#) sont les seuls à explorer les phases microscopiques de l'activité natatoire que sont les poussées au mur, les coulées et les virages mais ne considèrent pas le repos. Leur modèle est fondé sur une approche seuil qui, bien que présentant entre 97 et 100% de *precision* pour la discrimination du type de nage et de faibles erreurs sur l'identification des poussées et virages, ne peut être généralisable en situation écologique à une large population de nageurs. En partie car le protocole n'inclue des vitesses de nage comprises qu'entre 1,0 et 1,9 m/s et des sujets élites. L'utilisation du *machine learning* permet d'outrepasser ce biais de généralisation tout en conservant un fort potentiel d'adaptabilité puisque aucun *overfitting* de notre modèle n'est détecté (cf. annexe 9.14).

Les moins bons résultats de classification de notre modèle concerne les phases courtes (poussée au mur, coulée, virage) avec une confusion fréquente entre celles-ci. Cela est dû à leur faible durée et à leur enchaînement chronologique ainsi qu'à leur nombre relativement plus faible dans la base de données. Entraîner un modèle sur un *balanced dataset* avec 12,5% de chaque classe peut, à ce titre, constituer une piste d'amélioration. Par ailleurs, exploiter la dépendance chronologique des phases d'activités en natation peut s'avérer pertinent pour éviter ce genre d'erreur. Ainsi une poussée au mur est toujours suivie d'une coulée, elle-même

toujours suivie d'une des 4 classes de nage. Notre modèle actuel, basé sur des réseaux de neurones soit une approche informatique du *deep learning*, ne peut considérer ces dépendances entre classes. Explorer des modèles de *deep learning* statistiques comme les modèles de Markov cachés constituerait à ce titre un axe futur de recherche afin de modéliser les probabilités de transition d'une classe à une autre et ainsi affiner la reconnaissance d'activité. Peu d'études explorent à ce jour ce type de classifieurs (Wang et al., 2019) et aucune dans une approche *deep learning*. Pour autant, l'algorithme de *postprocessing* utilisé permet de passer outre ces limites actuelles de reconnaissance et obtenir une prédiction d'activité sous-tendant un monitoring pertinent.

L'architecture du modèle développé ici se base sur des couches de neurones récurrentes semblables à Tarasevičius and Serackis (2020). Une éventuelle piste d'amélioration pourrait être de constituer un modèle hybride croisant CNN et LSTM. Cette approche mixte présente d'excellents résultats dans la littérature Nweke et al. (2018) et apparaît comme un axe de recherche futur d'importance pour la HAR en natation. Les couches de convolutions croisées à des couches de *MaxPooling* permettant d'extraire des *features* que les couches de neurones récurrents viennent traiter comme des séries temporelles. Notons néanmoins que ces architectures sont beaucoup plus coûteuses computationnellement à entraîner et les réseaux bien plus complexes à optimiser car dépendant d'hyperparamètres plus nombreux. Cela explique notamment pourquoi nous n'avons pas creusé cette piste dans ce mémoire.

Enfin et dans l'optique d'une application en routine dans des groupes d'entraînement, il est tout à fait envisageable de développer des modèles individualisés par nageur. A minima, développer des modèles par niveau natatoire constitue une piste supplémentaire de recherche en vue d'une transposition de ces méthodologies au service du monitoring de la performance de tous.

### 7.1.2 Calcul de métriques spatio-temporelles à l'entraînement

Le monitoring automatique des LT par IMU permet une perte d'information minimale par rapport à la mesure manuelle (3,84% VS 12,12%) tout en recentrant l'entraîneur sur son rôle d'observateur et de technicien puisqu'il n'a plus à enregistrer les temps intermédiaires par chronomètre. La pertinence de cette automatisation s'en trouve encore renforcée à mesure que le nombre de nageurs supervisés augmente et permet de catalyser l'expertise technique de l'entraîneur.

Nos résultats sont parmi les plus précis de la littérature et basés sur le plus grand échantillon de LT ( $n=952$ ). En effet la différence au *gold-standard* est de  $0,06s \pm 0,60s$  quand Ganzevles et al. (2017) annoncent  $0,74s \pm 0,26s$  ( $n=132$ ) et Davey et al. (2008)  $-0,32 \pm 0,58s$ . Ces précédentes études sont basées sur une méthodologie de type seuils. Le seul outil basé *machine learning* (sans détails supplémentaires) proposant un monitoring des LT est le Triton (Lehari, 2020). Les seuls résultats à notre disposition sont fondés sur une population restreinte de 20 nageurs et 80 LT avec une précision de  $-0,02s \pm 0,51s$  en CR et  $0,04 \pm 0,57$  en BR (Butterfield et al., 2019). Nous n'avons pas proposé une analyse par type de nage dans ce mémoire, néanmoins nos résultats à l'échelle globale sont relativement semblables à ceux du Triton et cet outil est aujourd'hui le seul utilisé massivement sur le terrain, notamment dans les pays anglo-saxons.

En vue d'une validation pratique de la mesure automatique des LT il est également important de comparer ces résultats à la mesure par chronomètre qui est la norme sur le terrain pour les coaches. C'est ainsi que Davey et al. (2008) rapporte une erreur chronomètre-*gold-standard* de  $0,01 \pm 0,6s$  quand nos données affichent  $-0,1 \pm 0,58s$ . Ainsi l'erreur systématique comme aléatoire d'une mesure manuelle est quasiment identique à celle de notre mesure automatique ( $0,06 \pm 0,60s$ ) ce qui constitue un argument en faveur de la validation de l'outil au regard des pratiques actuelles du terrain.

Enfin, un dernier point de discussion relatif à la validation de la mesure des LT par IMU peut-être

la comparaison de nos résultats aux exigences rapportées dans la littérature et notamment au critère de [Mooney et al. \(2017\)](#) de  $\pm 0,3s$ . Cet auteur pose cette exigence de trois dixième comme en accord avec la mesure manuelle par chronomètre, néanmoins les données de [Davey et al. \(2008\)](#) couplées aux nôtres montrent que l'erreur aléatoire de mesure manuelle est plus autour des 0,6s. Toutefois et afin d'appréhender ce critère, le MAPE est l'indicateur statistique le plus pertinent : celui ci est de 0,34s par chronomètre contre 0,42s par IMU. Ainsi, 65,6% des LT mesurés manuellement répondent favorablement au critère de  $\pm 0,3s$  d'écart au *gold-standard* contre 55,2% par IMU. A l'aune de ce versant de l'analyse statistique la mesure automatique semble légèrement moins précise que la mesure manuelle. Toutefois, au vu du faible écart, qui n'impacte que peu un monitoring chronique de l'entraînement, et du gain d'information sur l'athlète sans contraintes pour l'entraîneur qu'apporte la mesure par IMU, nécessaire à l'optimisation de la performance, nous pensons que la précision est suffisante pour être utilisée en routine dans les groupes d'entraînement.

Pour autant il demeure des pistes d'amélioration de cette précision. On constate que les LT END (dernier LT d'un intervalle) sont ceux avec la plus grande erreur par rapport aux restes des données (cf. annexe 9.15). Ainsi la détermination de l'instant de touche finale (transition nage/repos) est probablement l'évènement le moins bien détecté par le modèle de reconnaissance d'activité et qui ne peut-être que difficilement retrouvé en *post-processing*. Ce constat est en accord avec la littérature qui fait de la touche finale l'instant d'intérêt de l'activité natatoire le plus dur à classifier ([Callaway \(2015\)](#) ; [Davey et al. \(2008\)](#) ; [Ganzevles et al. \(2017\)](#)). De futurs travaux sont donc nécessaires pour l'identifier au mieux et gagner en précision sur le monitoring des LT. A ce titre, les méthodes type seuils extrêmement poussées détaillés par [Hamidi Rad et al. \(2020\)](#) peuvent être une piste pour affiner notre *post-processing*. Enfin, proposer une analyse par catégorie de LT (LT START, LT MIDDLE et LT END), par nage et par sujet ou groupe de niveau de sujet constituent des analyses complémentaires pour mieux cerner les forces et faiblesses actuelles de notre outil que la brièveté de ce mémoire ne nous permet pas d'explorer.

La validation future des autres métriques temporelles de monitoring renvoyées par l'algorithme (temps de virage et de coulée, temps de nage, répartition des nages) via la même méthodologie d'agrément statistique apparaît comme un axe futur de travail pour pleinement valider scientifiquement l'outil même si le modèle affiche des F1-score largement conforme et satisfaisant à l'aune de la littérature disponible.

Enfin, nous avons dans ce présent mémoire déployé une méthodologie pour le compte des coups de bras basée *findpeaks* et *zero-crossing* sur signal filtré nous permettant ensuite de calculer de nombreuses autres métriques (amplitude, fréquence, *stroke index*, *swolf score*). Cette méthode est largement retrouvée dans la littérature, néanmoins appréhender sa validité par agrément statistique est un axe futur de travail. Nous évoquons en revue de littérature qu'une méthodologie type seuils alternative basée sur le coefficient d'autocorrelation du signal lors de la nage permet d'exploiter le caractère périodique du pattern pour compter les occurrences de cycle. Nos pré-tests nous indiquent que cette méthode est prometteuse et mériterait d'être comparé à l'avenir, en terme de validité, à celle plus classique de la littérature que nous avons déployé ici (cf. annexe 9.16, 9.16, 9.16 et 9.16). Cette méthode est fondée sur les travaux de [Zhuang and Xue \(2019\)](#) qui utilise cette notion pour découper les cycles de nages dans une perspective de classification d'activité natatoire via CNN. Nous pensons qu'utiliser une telle approche est pertinente pour le compte des coups de bras de manière généralisable puisque l'analyse est référée au sujet en lui-même et selon son pattern de nage propre à chaque début de longueur. De futurs travaux explorant cette piste semblent prometteur car elle n'a jamais été suivie dans la littérature. Par ailleurs, mettre en place une méthode de compte des coups de bras basée *machine learning* constitue un challenge scientifique qui reste à atteindre. Notons cependant que cela nécessite une labellisation des vidéos très chronophage que nous n'avons pu mener à terme à l'heure de rédiger ce mémoire

## 7.2 Perspectives sportives : applications au monitoring de l'entraînement

L'apport majeur de ce travail de recherche, outre les avancées méthodologiques et scientifiques énoncées précédemment, consiste en sa contribution au monitoring de l'entraînement de nageurs sur le terrain. **En effet, il est désormais possible de collecter en situation réelle d'entraînement de la donnée d'activité humaine en natation sur un large panels de niveau natatoire.**

Ce recueil de données est illustré ci-dessous avec le monitoring d'un triathlète de niveau national (BOUAN) réalisant la séance suivante en piscine publique : (1) échauffement, (2) 4\*25m CR progressif, (3) 2\*(800 d :10'30 + 2\*400 d :5'15) allure proche sv1, (4) récupération. L'analyse globale (voir figure 7.2) et spécifique (voir figures 7.2, 7.2, 7.2) des métriques est focalisée sur la série cible de la séance (3) tandis que la vue générale d'activité (voir figure 7.2) considère la séance dans son intégralité.

Conformément aux travaux précédents de la littérature (Ganzevles et al., 2017), nous faisons apparaître sur ces graphiques des limites de compliances pour faciliter le monitoring. Celles-ci visent à identifier les longueurs où un nageur sort des prescriptions de l'entraîneur en terme de LT et de coups de bras ou quand un nageur montre sur une longueur un paramètre statistiquement éloigné de sa ligne de base pour les autres variables. Cela permet à l'entraîneur de facilement appréhender l'adhérence du nageur à la séance et d'identifier des points de décrochage cinématique et/ou d'efficacité. Les limites de compliances sont fixées, à partir des prescriptions de l'entraîneur, à  $\pm 2\%$  pour les LT et  $\pm 1$  mouvement pour les coups de bras selon les travaux d'Hopkins (2000). Pour les autres variables, les limites sont positionnées à  $\pm 1$  écart-type de la moyenne du paramètre par longueur.

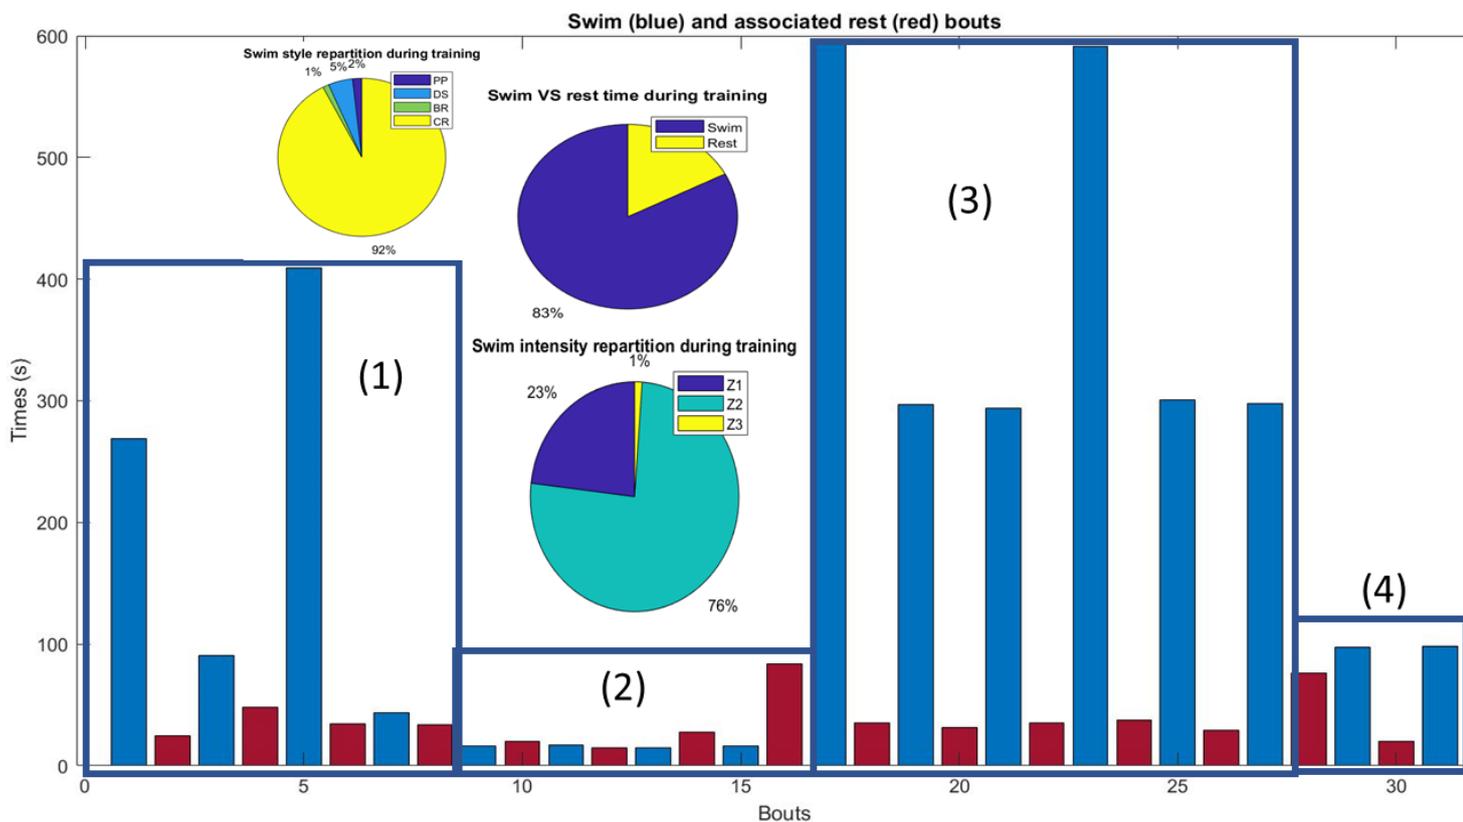


FIGURE 7.1 – Vue générale de l'activité du nageur sur la séance

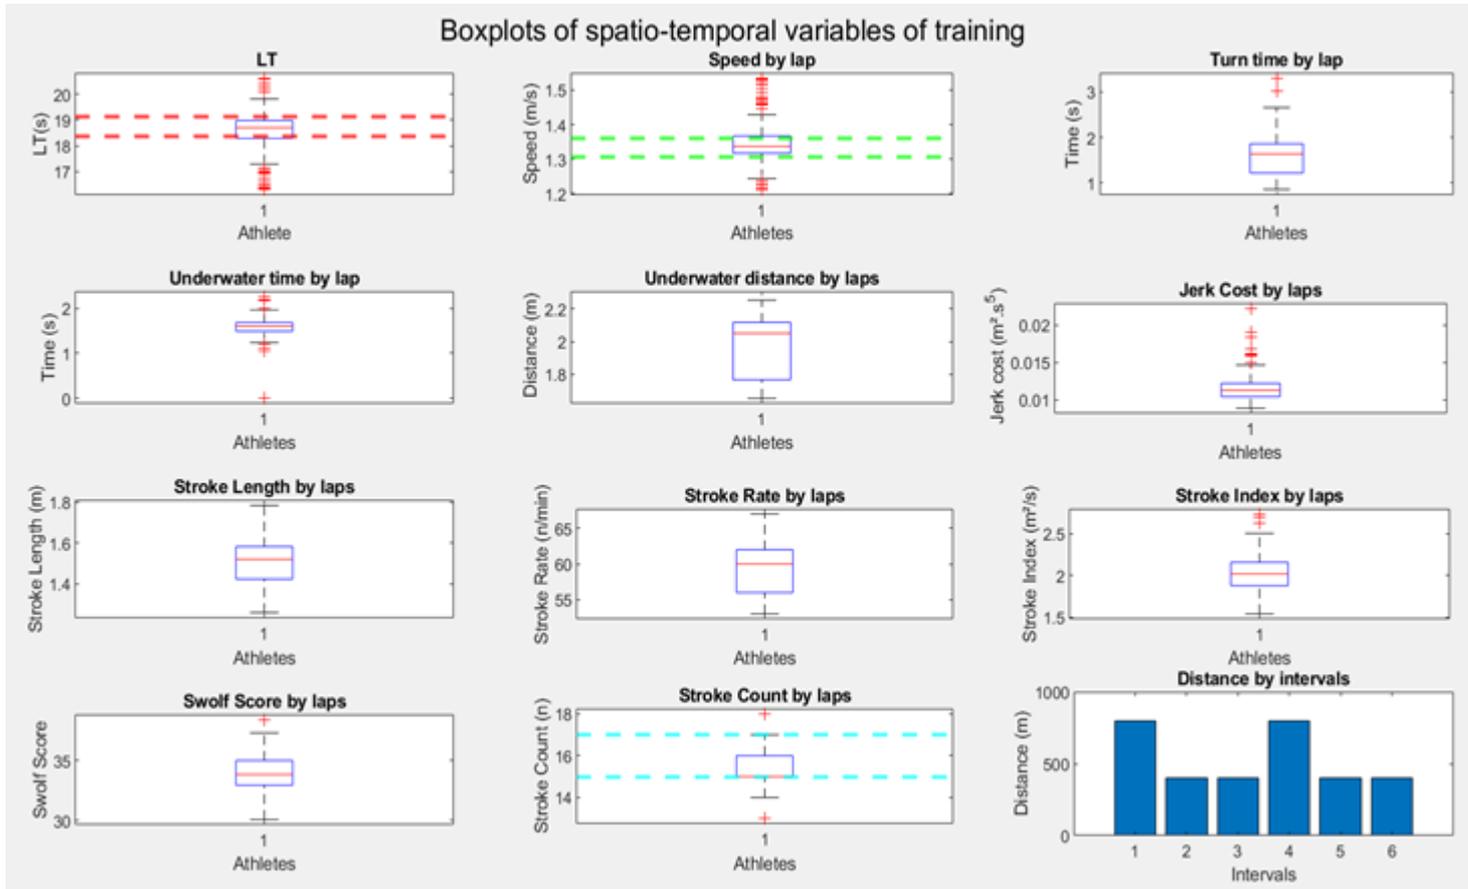


FIGURE 7.2 – Analyse globale des métriques : focus sur la série cible

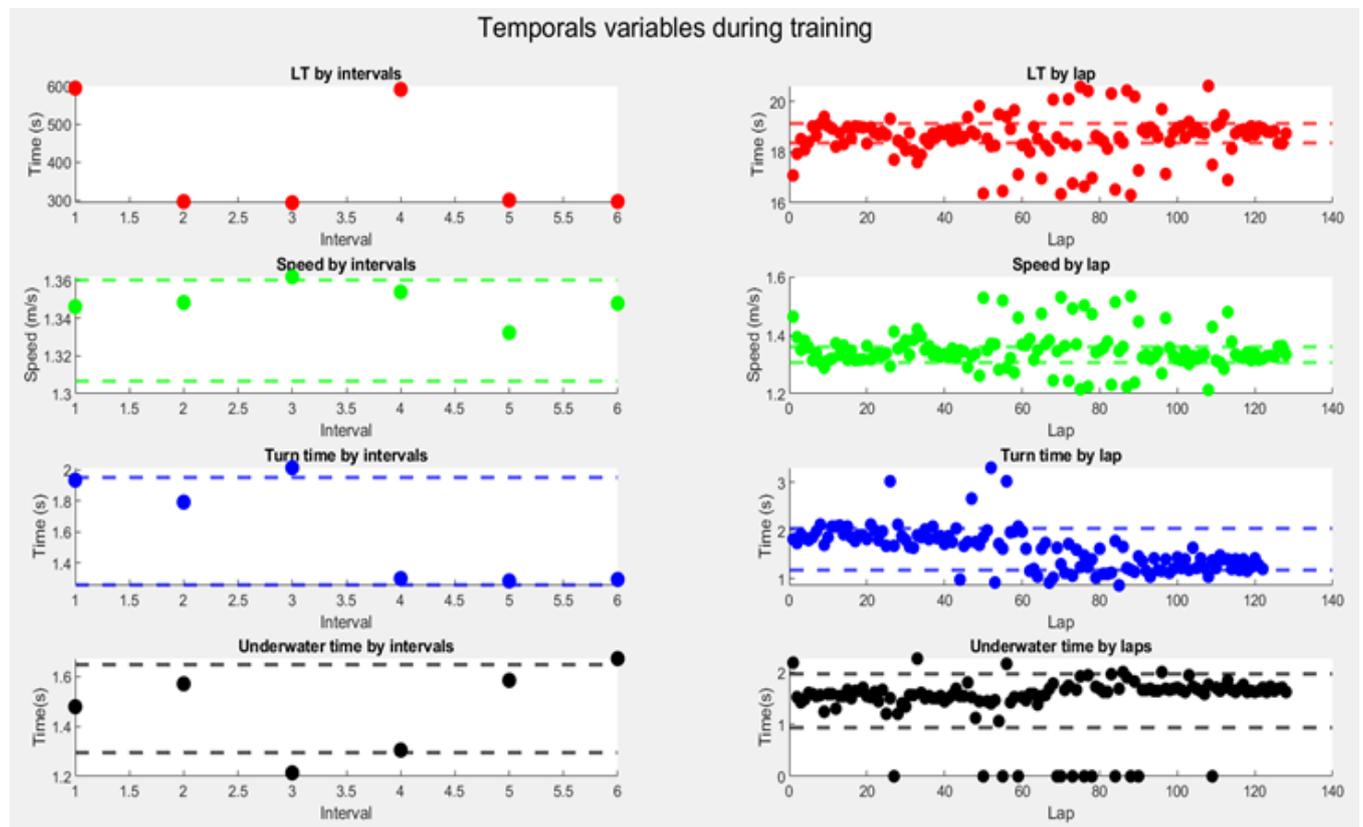


FIGURE 7.3 – Analyse spécifique des métriques de performance temporelles : focus sur la série cible

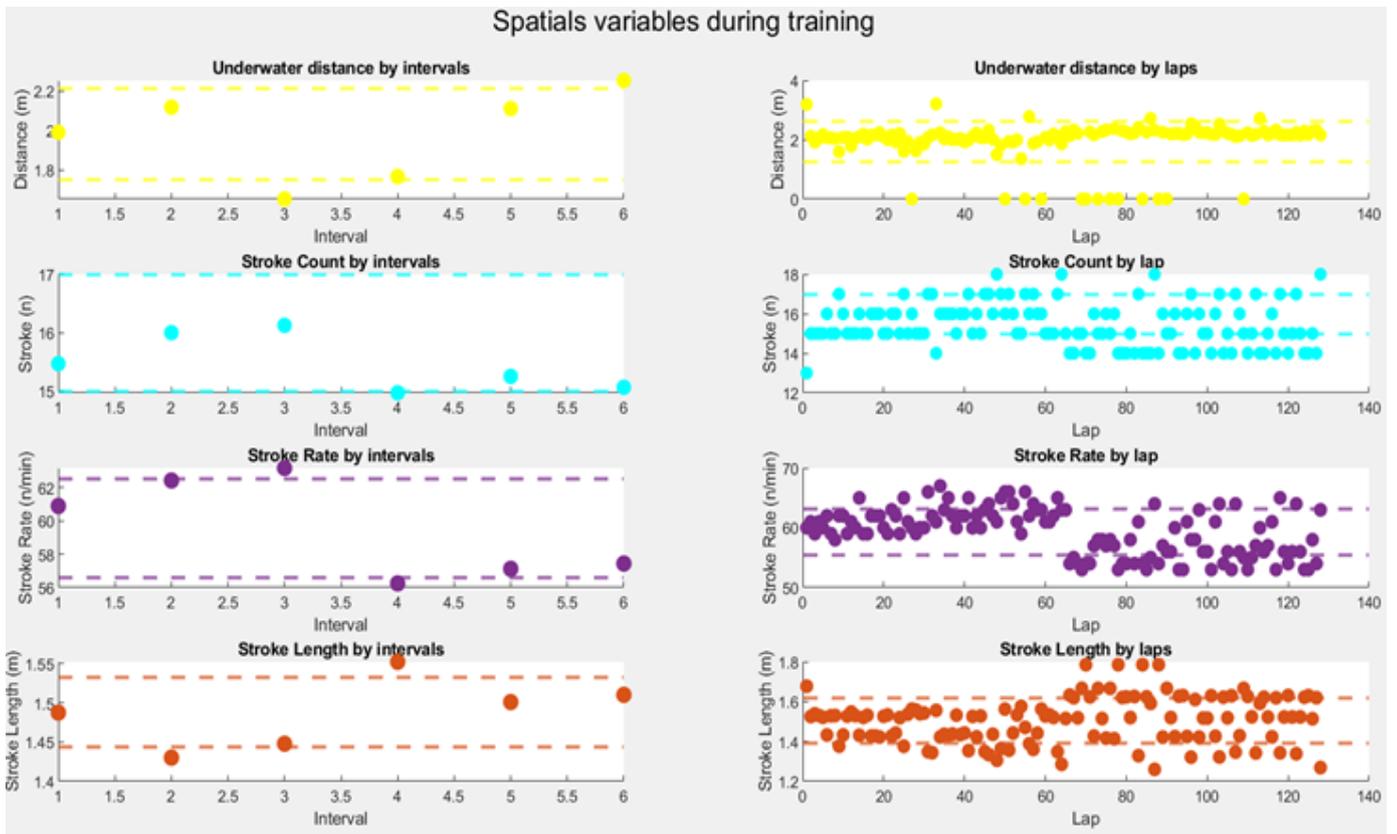


FIGURE 7.4 – Analyse spécifique des métriques de performance spatiales : focus sur la série cible

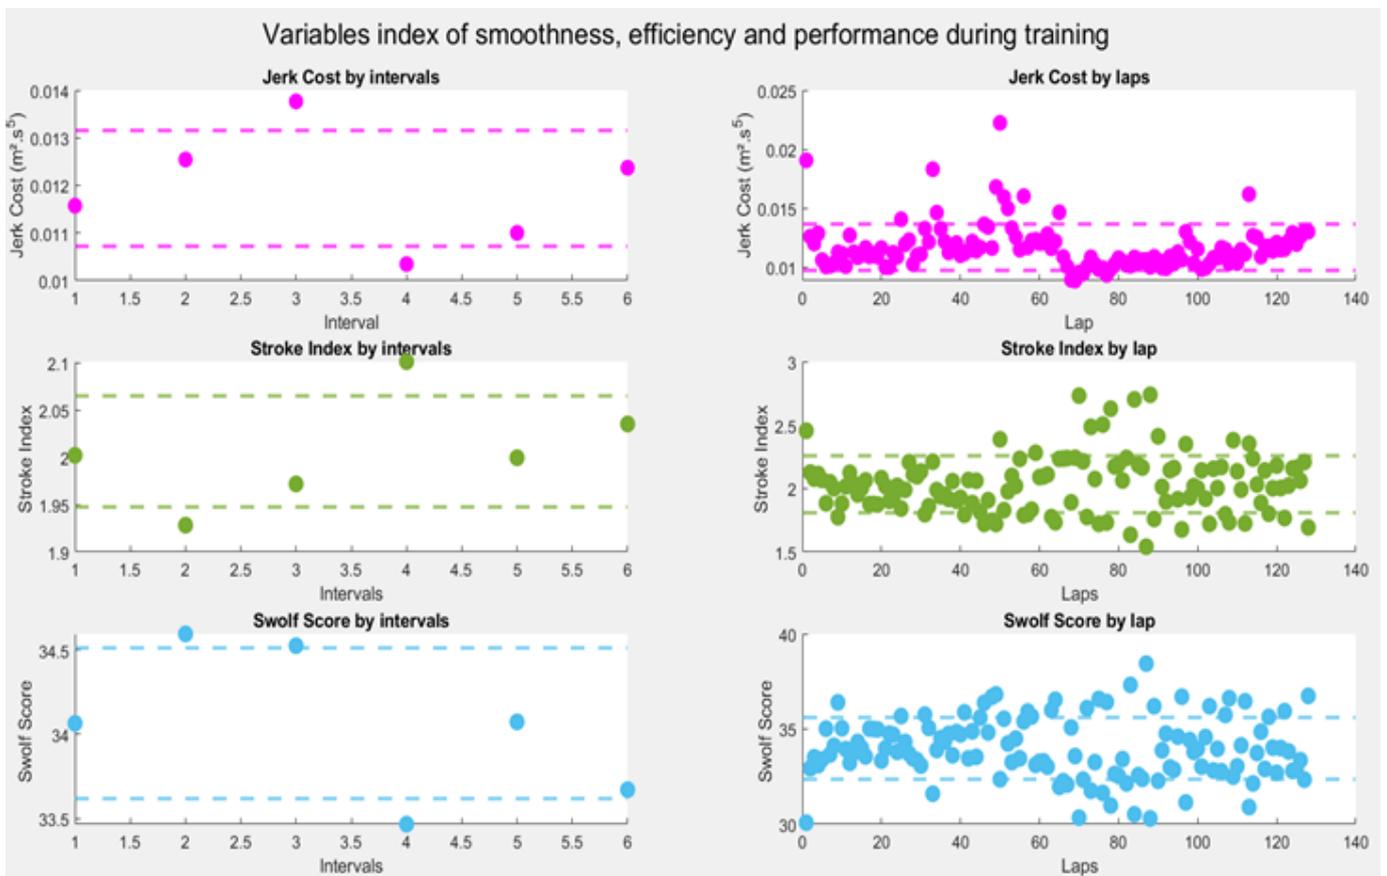


FIGURE 7.5 – Analyse spécifique des métriques de performance d'efficacité : focus sur la série cible

Ce rapport d'entraînement illustre la possibilité de collecte de données sur le terrain. D'autres indicateurs de performance pourraient chercher à être calculés dans le futur, notamment les variations de vitesse instantanées et l'analyse d'accélération intra-cycliques qui sont des facteurs déterminants de la performance (Barbosa et al. (2017); Bassan et al. (2015); Figueiredo et al. (2012)). Désormais envisageable de manière robuste, le recueil de données et variables de performance, de charge d'entraînement et d'efficacité natatoire peut-être exploité dans de nombreuses applications sous-tendant la performance qui souffraient jusqu'à alors d'une très faible disponibilité de données sur les nageurs et complexifiaient fortement les approches développées. Les pratiques des entraîneurs peuvent alors s'en trouver fortement impactée par la disponibilité accrue de ces données d'entraînement sur leur athlètes.

Parmi les variables disponibles, nous retenons que l'utilisation du *jerk cost* en monitoring de routine du nageur est un paramètre clé pour l'entraîneur que nous pensons indispensable de développer dans les pratiques de terrain comme index de technique tant il agrège des concepts déterminant dans l'entraînement comme notamment l'efficacité propulsive, la glisse, les sensations dans l'eau et la fluidité du mouvement (Ganzevles et al., 2019). De manière générale, nos trois variables dite d'efficacité natatoire (*jerk cost*, *stroke index*, *swolf score*) sont des paramètres d'importance pour un entraîneur souhaitant évaluer ses nageurs au jour le jour et en optimiser l'entraînement. D'une part car il ne peut simplement pas les monitorer actuellement sur le terrain en routine et donc y avoir accès facilement et d'autre part car elles sont dans la littérature largement corrélées à la performance et à l'efficacité énergétique (Sánchez and Arellano (2002), Barbosa et al. (2010)). Nous pensons au final qu'exploiter le recueil de ces variables par un outil comme celui développé dans ce mémoire ne peut que catalyser le travail d'un entraîneur tout en donnant des axes d'améliorations précis au nageur et des moyens d'objectivation de son activité à l'entraînement.

La natation peut alors entamer sa transition vers l'ère de l'entraînement connecté à l'heure des montres GPS et autre capteur de puissance. Parmi ces applications nécessitant de la *data* à foison, on peut noter l'identification de la performance et la détection de jeunes talents via le clustering de nageurs (Leroy et al., 2018) -une application pour laquelle l'utilisation du *jerk cost* serait extrêmement prometteuse-, le monitoring de la charge visant la régulation du plan d'entraînement et l'objectivation de l'activité d'un athlète à l'entraînement telle que nous l'avons illustré dans ce mémoire ou encore la modélisation de la performance comme des adaptations à l'entraînement (Carrard et al., 2020), un dernier point qui nous semble très important dans les pratiques d'entraînement modernes tant l'optimisation est nécessaire.

Nous pensons que ces domaines d'application de la *sport science* en natation peuvent subir de plein fouet dans les années à venir l'émergence des outils embarqués de monitoring automatique à l'entraînement garantis par la démocratisation et l'accessibilité de la *data science* en général et du *machine learning* en particulier.

# Chapitre 8

## Conclusion

Ce travail de recherche a exploré l'utilisation du *deep learning* pour le traitement de séries temporelles multivariées (signaux inertiels) sur des tâches de *Human Activity Recognition* en natation. Cela dans une perspective de cohérence avec les attendus de monitoring du terrain relatifs aux exigences de la haute performance. Les résultats témoignent d'un modèle de reconnaissance d'activité basés *long short term memory* bidirectionnel outrepassant la littérature actuelle en considérant plus de classes d'activités et en permettant le calcul de métriques de performances spatio-temporelles avec un *F1-score* moyenné de 0,86 et pondéré de 0,96 sur *testing set*. L'avancée majeure permise par ce travail est la capacité à récolter des données d'entraînement valides à un niveau macroscopique et microscopique, en condition réelle et sur un large panels de nageurs de manière généralisable. Au regard du manque actuel de méthodologies scientifiques et d'outils robustes de reconnaissance d'activité humaine en natation, ce travail constitue un pas en avant vers le monitoring écologique des athlètes et l'accompagnement des entraîneurs dans cette tâche jusque là compliquée et chronophage car non automatisée.

Nos objectifs de recherche sont atteints avec la collecte d'une base de données novatrice de la littérature : large et intégrant une forte variabilité inter et intra-sujets, garante d'un modèle robuste. De nombreuses variables spatio-temporelles et d'efficience difficilement mesurables jusqu'alors en routine sont quantifiables. Seule la validation des temps intermédiaires, métrique d'importance, a été investiguée dans ce mémoire avec une erreur moyenne attendue de 0,42s par rapport au *gold-standard* vidéo. Cette erreur est acceptable à l'aune de la littérature disponible, des outils de monitoring actuellement commercialisés et des pratiques de terrain. De futurs travaux sont nécessaires pour la validation de toutes les autres variables tout comme la recherche et comparaison de méthodologie de compte des coups de bras visant à être plus robuste.

L'introduction de nouvelles technologies au service de l'entraînement constitue un enjeu majeur dont les entraîneurs de natation ne peuvent désormais plus faire l'économie dès lors qu'ils aspirent à la recherche de la haute performance. Les rapprochements récents entre *sport science* et *data science* conduisent à l'émergence d'une *sport data science* qui doit se développer au service du terrain et en fonction de ses besoins par l'accompagnement des entraîneurs et l'optimisation de l'entraînement. Ce développement technologique conduit par les chercheurs ne pourra se faire qu'en collaboration forte avec les staffs afin de répondre à leurs besoins et catalyser leur expertise technique, sans toutefois avoir vocation à les remplacer! En effet, il est nécessaire de garder à l'esprit que la charge d'entraînement et son suivi demeure la conceptualisation scientifique d'une problématique émergente du terrain comme nous le rappelle Joel Filliol : "*The best training load monitoring tool is a coach that pays attention*". Libérer l'entraîneur des contraintes techniques et logistiques du monitoring par des méthodologies automatique et flexibles permet alors à celui-ci d'uniquement exploiter les *output* du système et ainsi se focaliser sur sa gestion quotidienne des athlètes et la régulation du plan d'entraînement. Ce procédé constitue un fort challenge pour la *sport data science* actuellement en plein essor.

# Bibliographie

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., et al. (2016). Tensorflow : Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv :1603.04467*.
- Abidine, B. M., Fergani, L., Fergani, B., and Oussalah, M. (2018). The joint use of sequence features combination and modified weighted svm for improving daily activity recognition. *Pattern Analysis and Applications*, 21(1) :119–138.
- Acevedo, E. O. and Goldfarb, A. H. (1989). Increased training intensity effects on plasma lactate, ventilatory threshold, and endurance. *Medicine and science in sports and exercise*, 21(5) :563–568.
- Altun, K., Barshan, B., and Tunçel, O. (2010). Comparative study on classifying human activities with miniature inertial and magnetic sensors. *Pattern Recognition*, 43 :3605–3620.
- Andreoni, G., Perego, P., Fusca, M. C., Lavezzari, R., and Santambrogio, G. C. (2014). Smart garments for performance and training assessment in sport. In *2014 4th International Conference on Wireless Mobile Communication and Healthcare-Transforming Healthcare Through Innovations in Mobile and Wireless Technologies (MOBIHEALTH)*, pages 267–270. IEEE.
- Anthony, J. J. and Chalfant, S. E. (2010). Multi-state performance monitoring system. US Patent App. 12/691,414.
- Attal, F., Mohammed, S., Dedabrishvili, M., Chamroukhi, F., Oukhellou, L., and Amirat, Y. (2015). Physical human activity recognition using wearable sensors. *Sensors*, 15(12) :31314–31338.
- Bachlin, M., Forster, K., Schumm, J., Breu, D., Germann, J., and Troster, G. (2008). An automatic parameter extraction method for the 7× 50m stroke efficiency test. In *2008 Third International Conference on Pervasive Computing and Applications*, volume 1, pages 442–447. IEEE.
- Bak, K. (2010). The practical management of swimmer’s painful shoulder : etiology, diagnosis, and treatment. *Clinical Journal of Sport Medicine*, 20(5) :386–390.
- Barbosa, T., Chen, S., Morais, J., Costa, M., and Batalha, N. (2017). The changes in classical and nonlinear parameters after a maximal bout to elicit fatigue in competitive swimming. *Human Movement Science*, 58.
- Barbosa, T. M., Bragada, J. A., Reis, V. M., Marinho, D. A., Carvalho, C., and Silva, A. J. (2010). Energetics and biomechanics as determining factors of swimming performance : Updating the state of the art. *Journal of Science and Medicine in Sport*, 13(2) :262–269.

- Bassan, N., T, E., Denadai, B., and Greco, C. (2015). Relationship between fatigue and changes in swim technique during an exhaustive swim exercise. *International journal of sports physiology and performance*, 11.
- Beanland, E., Main, L. C., Aisbett, B., Gastin, P., and Netto, K. (2014). Validation of gps and accelerometer technology in swimming. *Journal of Science and Medicine in Sport*, 17(2) :234–238.
- Bland, J. M. and Altman, D. (1986). Statistical methods for assessing agreement between two methods of clinical measurement. *The lancet*, 327(8476) :307–310.
- Bland, J. M. and Altman, D. G. (1999). Measuring agreement in method comparison studies. *Statistical methods in medical research*, 8(2) :135–160.
- Borresen, J. and Lambert, M. (2009). The quantification of training load, the training response and the effect on performance. *Sports medicine (Auckland, N.Z.)*, 39 :779–95.
- Bouchard, C. and Rankinen, T. (2001). Individual differences in response to regular physical activity. *Medicine and science in sports and exercise*, 33(6).
- Bourdon, P. C., Cardinale, M., Murray, A., Gastin, P., Kellmann, M., Varley, M. C., Gabbett, T. J., Coutts, A. J., Burgess, D. J., Gregson, W., et al. (2017). Monitoring athlete training loads : consensus statement. *International journal of sports physiology and performance*, 12(s2) :S2–161.
- Brunner, G., Melnyk, D., Sigfússon, B., and Wattenhofer, R. (2019). Swimming style recognition and lap counting using a smartwatch and deep learning. In *Proceedings of the 23rd International Symposium on Wearable Computers*, pages 23–31.
- Bulling, A., Blanke, U., and Schiele, B. (2014). A tutorial on human activity recognition using body-worn inertial sensors. *ACM Computing Surveys (CSUR)*, 46(3) :1–33.
- Burkett, B. and Mellifont, R. (2008). Sport science and coaching in paralympic swimming. *International Journal of Sports Science & Coaching*, 3(1) :105–112.
- Butterfield, J. (2017). Concurrent validity and test-retest reliability of an elite tracking system to assess swimming performance variables. Master’s thesis, St Mary’s University, Twickenham.
- Butterfield, J., Tallent, J., Patterson, S. D., Jeffries, O., Howe, L., and Waldron, M. (2019). The validity of a head-worn inertial sensor for measurements of swimming performance. *Movement & Sport Sciences-Science & Motricité*.
- Bächlin, M. and Tröster, G. (2012). Swimming performance and technique evaluation with wearable acceleration sensors. *Pervasive and Mobile Computing*, 8 :68–81.
- Callaway, A., Cobb, J., and Jones, I. (2009). A comparison of video and accelerometer based approaches applied to performance monitoring in swimming. *International Journal of Sports Science & Coaching*, 4 :139–153.
- Callaway, A. J. (2015). Measuring kinematic variables in front crawl swimming using accelerometers : a validation study. *Sensors*, 15(5) :11363–11386.
- Camomilla, V., Bergamini, E., Fantozzi, S., and Vannozzi, G. (2018). Trends supporting the in-field use of wearable inertial sensors for sport performance evaluation : A systematic review. *Sensors*, 18(3) :873.

- Carrard, J., Kloucek, P., and Gojanovic, B. (2020). Modelling training adaptation in swimming using artificial neural network geometric optimisation. *Sports*, 8(1) :8.
- Chakravorti, N., Le Sage, T., Slawson, S. E., Conway, P. P., and West, A. A. (2013). Design and implementation of an integrated performance monitoring tool for swimming to extract stroke information at real time. *IEEE transactions on human-machine systems*, 43(2) :199–213.
- Chambers, R., Gabbett, T. J., Cole, M. H., and Beard, A. (2015). The use of wearable microsensors to quantify sport-specific movements. *Sports medicine*, 45(7) :1065–1081.
- Chatard, J., Lavoie, J., and Lacourl, J. (1990). Analysis of determinants of swimming economy in front crawl. *European journal of applied physiology and occupational physiology*, 61(1-2) :88–92.
- Chatard, J.-C. and Stewart, A. (2011). Training load and performance in swimming. *World Book of Swimming : From Science to Performance*, pages 359–373.
- Choi, W., Oh, J., Park, T., Kang, S., Moon, M., Lee, U., Hwang, I., and Song, J. (2014). Mobydick : an interactive multi-swimmer exergame. In *Proceedings of the 12th ACM Conference on Embedded Network Sensor Systems*, pages 76–90.
- Chollet, F. et al. (2015). Keras : Deep learning library for theano and tensorflow. URL : <https://keras.io/k>, 7(8) :T1.
- Chollet, F. et al. (2018). *Deep learning with Python*, volume 361. Manning New York.
- Collette, R., Kellmann, M., Ferrauti, A., Meyer, T., and Pfeiffer, M. (2018). Relation between training load and recovery-stress state in high-performance swimming. *Frontiers in physiology*, 9 :845.
- Collette, R., Pfeiffer, M., and Kellmann, M. (2016). *Trainings-und Erholungsmonitoring im Leistungssport Schwimmen*. Verlag Dr. Kovač.
- Cornacchia, M., Ozcan, K., Zheng, Y., and Velipasalar, S. (2017). A survey on activity detection and classification using wearable sensors. *IEEE Sensors Journal*, 17(2) :386–403.
- Costill, D., Kovaleski, J., Porter, D., Kirwan, J., Fielding, R., and King, D. (1985). Energy expenditure during front crawl swimming : predicting success in middle-distance events. *International journal of sports medicine*, 6(05) :266–270.
- Costill, D. L., Thomas, R., Robergs, R. A., Pascoe, D., Lambert, C., Barr, S., and Fink, W. J. (1991). Adaptations to swimming training : influence of training volume. *Medicine and science in sports and exercise*, 23 :371–377.
- Craig, A. B. and Pendergast, D. R. (1979). Relationships of stroke rate, distance per stroke, and velocity in competitive swimming. *Medicine and science in sports*, 11 :278–283.
- Crowcroft, S., McCleave, E., Slattery, K., and Coutts, A. J. (2017). Assessing the measurement sensitivity and diagnostic characteristics of athlete-monitoring tools in national swimmers. *International journal of sports physiology and performance*, 12(s2) :S2–95.
- Cuesta-Vargas, A. I., Galán-Mercant, A., and Williams, J. M. (2010). The use of inertial sensors system for human motion analysis. *Physical Therapy Reviews*, 15(6) :462–473.

- Cust, E. E., Sweeting, A. J., Ball, K., and Robertson, S. (2019). Machine and deep learning for sport-specific movement recognition : a systematic review of model development and performance. *Journal of sports sciences*, 37(5) :568–600.
- Dadashi, F., Crettenand, F., Millet, G. P., and Aminian, K. (2012). Front-crawl instantaneous velocity estimation using a wearable inertial measurement unit. *Sensors*, 12(10) :12927–12939.
- Dadashi, F., Millet, G., and Aminian, K. (2013). Gaussian process framework for pervasive estimation of swimming velocity with body-worn imu. *Electronics letters*, 49(1) :44–45.
- Daukantas, S., Marozas, V., and Lukosevicius, A. (2008). Inertial sensor for objective evaluation of swimmer performance. In *2008 11th International Biennial Baltic Electronics Conference*, pages 321–324. IEEE.
- Davey, N., Anderson, M., and James, D. (2008). Validation trial of an accelerometer-based sensor platform for swimming. *Sports Technology*, 1.
- Davey, N., James, D., and Anderson, M. (2004). Signal analysis of accelerometry data using gravity based modeling. *Proceedings of SPIE - The International Society for Optical Engineering*, 5274.
- Delgado-Gonzalo, R., Lemkaddem, A., Renevey, P., Calvo, E. M., Lemay, M., Cox, K., Ashby, D., Willardson, J., and Bertschi, M. (2016). Real-time monitoring of swimming performance. In *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 4743–4746. IEEE.
- DeShaw, K. J., Ellingson, L., Bai, Y., Lansing, J., Perez, M., and Welk, G. (2018). Methods for activity monitor validation studies : an example with the fitbit charge. *Journal for the Measurement of Physical Behaviour*, 1(3) :130–135.
- d’Helsinki, D. (2000). Association médicale mondiale. *Principes éthiques applicables aux recherches médicales sur des sujets humains, 52e Assemblée générale, Édimbourg*.
- Feijen, S., Tate, A., Kuppens, K., Barry, L., and Struyf, F. (2020a). Monitoring the swimmer’s training load : A narrative review of monitoring strategies applied in research. *Scandinavian Journal of Medicine Science in Sports*.
- Feijen, S., Tate, A., Kuppens, K., Claes, A., and Struyf, F. (2020b). Swim-training volume and shoulder pain across the life span of the competitive swimmer : A systematic review. *Journal of athletic training*, 55(1) :32–41.
- Figueiredo, P., Barbosa, T., Vilas-Boas, J. P., and Fernandes, R. (2012). Energy cost and body centre of mass’ 3d intracycle velocity variation in swimming. *European journal of applied physiology*, 112 :3319–26.
- Fleishman, E. A., Quaintance, M. K., and Broedling, L. A. (1984). *Taxonomies of human performance : The description of human tasks*. Academic Press.
- Fulton, S. K., Pyne, D. B., and Burkett, B. (2009). Validity and reliability of kick count and rate in freestyle using inertial sensor technology. *Journal of sports sciences*, 27(10) :1051–1058.
- Ganzevles, S., Vullings, R., Beek, P., Daanen, H., and Truijens, M. (2017). Using tri-axial accelerometry in daily elite swim training practice. *Sensors*, 17 :990.

- Ganzevles, S. P., Beek, P. J., Daanen, H. A., Coolen, B. M., and Truijens, M. J. (2019). Differences in swimming smoothness between elite and non-elite swimmers. *Sports biomechanics*, pages 1–14.
- García-Ramos, A., Feriche, B., Calderón, C., Iglesias, X., Barrero, A., Chaverri, D., Schuller, T., and Rodríguez, F. A. (2015). Training load quantification in elite swimmers using a modified version of the training impulse method. *European journal of sport science*, 15(2) :85–93.
- Gastin, P. B., Mclean, O. C., Breed, R. V., and Spittle, M. (2014). Tackle and impact detection in elite australian football using wearable microsensor technology. *Journal of sports sciences*, 32(10) :947–953.
- Glorot, X. and Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, pages 249–256. JMLR Workshop and Conference Proceedings.
- Graves, A. and Schmidhuber, J. (2005). Framewise phoneme classification with bidirectional lstm and other neural network architectures. *Neural networks*, 18(5-6) :602–610.
- Guignard, B., Rouard, A., Chollet, D., and Seifert, L. (2017). Behavioral dynamics in swimming : The appropriate use of inertial measurement units. *Frontiers in psychology*, 8 :383.
- Hagem, R. M., O’Keefe, S. G., Fickenscher, T., and Thiel, D. V. (2013). Self contained adaptable optical wireless communications system for stroke rate during swimming. *IEEE Sensors Journal*, 13(8) :3144–3151.
- Halilaj, E., Rajagopal, A., Fiterau, M., Hicks, J., Hastie, T., and Delp, S. (2018). Machine learning in human movement biomechanics : Best practices, common pitfalls, and new opportunities. *Journal of Biomechanics*, 81.
- Halson, S. L. (2014). Monitoring training load to understand fatigue in athletes. *Sports medicine*, 44(2) :139–147.
- Hamidi Rad, M., Gremeaux, V., Dadashi, F., and Aminian, K. (2020). A novel macro-micro approach for swimming analysis in main swimming techniques using imu sensors. *Frontiers in Bioengineering and Biotechnology*, 8 :1511.
- Hecksteden, A., Pitsch, W., Julian, R., Pfeiffer, M., Kellmann, M., Ferrauti, A., and Meyer, T. (2017). A new method to individualize monitoring of muscle recovery in athletes. *International Journal of Sports Physiology and Performance*, 12(9) :1137–1142.
- Hellard, P., Dekerle, J., Avalos, M., Caudal, N., Knopp, M., and Hausswirth, C. (2008). Kinematic measures and stroke rate variability in elite female 200-m swimmers in the four swimming techniques : Athens 2004 olympic semi-finalists and french national 2004 championship semi-finalists. *Journal of sports sciences*, 26(1) :35–46.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8) :1735–1780.
- Hopkins, W. G. (2000). Measures of reliability in sports medicine and science. *Sports medicine*, 30(1) :1–15.
- Ioffe, S. and Szegedy, C. (2015). Batch normalization : Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning*, pages 448–456. PMLR.
- James, D. A., Burkett, B., and Thiel, D. V. (2011). An unobtrusive swimming monitoring system for recreational and elite performance monitoring. *Procedia Engineering*, 13 :113–119.

- James, D. A., Davey, N., and Rice, T. (2004). An accelerometer based sensor platform for insitu elite athlete performance analysis. In *SENSORS, 2004 IEEE*, pages 1373–1376. IEEE.
- Jensen, U., Prade, F., and Eskofier, B. M. (2013). Classification of kinematic swimming data with emphasis on resource consumption. In *2013 IEEE International Conference on Body Sensor Networks*, pages 1–5. IEEE.
- Julian, R., Meyer, T., Fullagar, H. H., Skorski, S., Pfeiffer, M., Kellmann, M., Ferrauti, A., and Hecksteden, A. (2017). Individual patterns in blood-borne indicators of fatigue—trait or chance. *Journal of strength and conditioning research*, 31(3) :608–619.
- Kautz, T., Groh, B. H., Hannink, J., Jensen, U., Strubberg, H., and Eskofier, B. M. (2017). Activity recognition in beach volleyball using a deep convolutional neural network. *Data Mining and Knowledge Discovery*, 31(6) :1678–1705.
- Kingma, D. P. and Ba, J. (2014). Adam : A method for stochastic optimization. *arXiv preprint arXiv :1412.6980*.
- Kon, Y., Omae, Y., Sakai, K., Takahashi, H., Akiduki, T., Miyaji, C., Sakurai, Y., Ezaki, N., and Nakai, K. (2015). Toward classification of swimming style by using underwater wireless accelerometer data. In *Adjunct Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2015 ACM International Symposium on Wearable Computers*, pages 85–88.
- Lambert, M. and Mujika, I. (2013). Physiology of exercise training. *Recovery for Performance in Sport. Champaign, IL : Human Kinetics*, pages 3–8.
- Lambert, M. I. and Borresen, J. (2010). Measuring training load in sports. *International journal of sports physiology and performance*, 5(3) :406–411.
- Laursen, P. and Buchheit, M. (2019). *Science and Application of High-Intensity Interval Training*. Human Kinetics.
- Le Sage, T., Bindel, A., Conway, P., Justham, L., Slawson, S., and West, A. (2010). Development of a real time system for monitoring of swimming performance. *Procedia Engineering*, 2 :2707–2712.
- Le Sage, T., Bindel, A., Conway, P., Justham, L., Slawson, S., and West, A. (2011). Embedded programming and real-time signal processing of swimming strokes. *Sports Engineering*, 14 :1–14.
- Lecoutere, J. and Puers, R. (2014). Wireless communication with miniaturized sensor devices in swimming. *Procedia Engineering*, 72 :398–403.
- Lecoutere, J. and Puers, R. (2016). Tracking elite swimmers in real time with wearable low-power wireless sensor networks. *Procedia engineering*, 147 :627–631.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature*, 521(7553) :436–444.
- Lee, J., Burkett, B., Thiel, D., and James, D. (2011). Inertial sensor, 3d and 2d assessment of stroke phases in freestyle swimming. *Procedia Engineering*, 13 :148–153.
- Lehari, T. V. H. (2020). Wireless metric calculating and feedback apparatus, system, and method. US Patent 10,529,250.

- Leroy, A., MARC, A., DUPAS, O., REY, J. L., and Gey, S. (2018). Functional data analysis in sport science : Example of swimmers' progression curves clustering. *Applied Sciences*, 8(10).
- Li, R. T., Kling, S. R., Salata, M. J., Cupp, S. A., Sheehan, J., and Voos, J. E. (2016). Wearable performance devices in sports medicine. *Sports health*, 8(1) :74–78.
- Magalhães, F., Vannozzi, G., Gatta, G., and Fantozzi, S. (2014). Wearable inertial sensors in swimming motion analysis : A systematic review. *Journal of Sports Sciences*, 33.
- Maglischo, E. W. (2003). *Swimming fastest*. Human kinetics.
- Michaels, S., Taunton, D. J., Forrester, A. I., Hudson, D. A., Phillips, C. W., Holliss, B. A., and Turnock, S. R. (2016). The use of a cap-mounted tri-axial accelerometer for measurement of distance, lap times and stroke rates in swim training. *Procedia engineering*, 147 :649–654.
- Mikesell, K. A. and Dudley, G. A. (1984). Influence of intense endurance training on aerobic power of competitive distance runners. *Medicine and science in sports and exercise*, 16(4) :371–375.
- Mohssen Mohammed, Muhammad Badruddin Khan, E. B. M. B. (2017). *Machine Learning : Algorithms and Applications*. Milton : CRC Press.
- Mooney, R., Corley, G., Godfrey, A., Quinlan, L. R., and ÓLaighin, G. (2015). Inertial sensor technology for elite swimming performance analysis : A systematic review. *Sensors (Basel, Switzerland)*, 16.
- Mooney, R., Quinlan, L. R., Corley, G., Godfrey, A., Osborough, C., and ÓLaighin, G. (2017). Evaluation of the finis swimsense® and the garmin swim™ activity monitors for swimming performance and stroke kinematics analysis. *PloS one*, 12(2).
- Mountjoy, M., Junge, A., Alonso, J., Clarsen, B., Pluim, B., Shrier, I., Van den Hoogenband, C., Marks, S., Gerrard, D., Heyns, P., et al. (2016). Consensus statement on the methodology of injury and illness surveillance in fina (aquatic sports). *British journal of sports medicine*, 50(10) :590–596.
- Mujika, I. (2013). The alphabet of sport science research starts with q. *International journal of sports physiology and performance*, 8(5) :465–466.
- Mujika, I. (2017). Quantification of training and competition loads in endurance sports : Methods and applications. *International journal of sports physiology and performance*, 12 Suppl 2 :S29–S217.
- Mujika, I., Chatard, J.-C., Busso, T., Geysant, A., Barale, F., and Lacoste, L. (1995). Effects of training on performance in competitive swimming. *Canadian journal of applied physiology*, 20(4) :395–406.
- Mujika, I., Chatard, J.-C., Busso, T., Geysant, A., Barale, F., and Lacoste, L. (1996). Use of swim-training profiles and performances data to enhance training effectiveness. *Journal of Swimming Research*, pages 23–29.
- Neary, J., Martin, T., Reid, D., Burnham, R., and Quinney, H. (1992). The effects of a reduced exercise duration taper programme on performance and muscle enzymes of endurance cyclists. *European journal of applied physiology and occupational physiology*, 65(1) :30–36.
- Nikodelis, T., Kollias, I., and Hatzitaki, V. (2005). Bilateral inter-arm coordination in freestyle swimming : effect of skill level and swimming speed. *Journal of sports sciences*, 23 :737–745.

- Nweke, H. F., Teh, Y. W., Al-Garadi, M. A., and Alo, U. R. (2018). Deep learning algorithms for human activity recognition using mobile and wearable sensor networks : State of the art and research challenges. *Expert Systems with Applications*, 105 :233–261.
- Ohgi, Y. (2004). Measurement of acceleration and angular velocity of forearm motion in swimming-prototype ii : Tri-axial acceleration and gyroscope sensor data logger. *The Engineering of Sport*, 5 :536–542.
- Ohgi, Y., Ichikawa, H., Homma, M., and Miyaji, C. (2003). Stroke phase discrimination in breaststroke swimming using a tri-axial acceleration sensor device. *Sports Engineering*, 6(2) :113–123.
- Ohgi, Y., Kaneda, K., and Takakura, A. (2014). Sensor data mining on the kinematical characteristics of the competitive swimming. *Procedia Engineering*, 72 :829–834.
- Olbretch (2007). *The Science of Winning : Planning, Periodizing and Optimizing Swim Training*, chapter Definitions and principles of training. Antwerp, Belgium.
- Omae, Y., Kon, Y., Kobayashi, M., Sakai, K., Shionoya, A., Takahashi, H., Akiduki, T., Nakai, K., Ezaki, N., Sakurai, Y., et al. (2017). Swimming style classification based on ensemble learning and adaptive feature value by using inertial measurement unit. *Journal of Advanced Computational Intelligence and Intelligent Informatics*, 21(4) :616–631.
- Pan, M.-S., Huang, K.-C., Lu, T.-H., and Lin, Z.-Y. (2016). Using accelerometer for counting and identifying swimming strokes. *Pervasive and Mobile Computing*, 31 :37–49.
- Pansiot, J., Lo, B., and Yang, G.-Z. (2010). Swimming stroke kinematic analysis with bsn. In *2010 International Conference on Body Sensor Networks*, pages 153–158. IEEE.
- Peterson, M., Rhea, M., and Alvar, B. (2005). Applications of the dose-response for muscular strength development : A review of meta-analytic efficacy and reliability for designing training prescription. *Journal of strength and conditioning research / National Strength Conditioning Association*, 19 :950–8.
- Pink, M. M. and Tibone, J. E. (2000). The painful shoulder in the swimming athlete. *Orthopedic clinics of north america*, 31(2) :247–261.
- Platonov, V. N. and Jonco, N. (1988). *L'entraînement sportif : théorie et méthodologie*. Revue EPS.
- Pyne, D. and Martin, D. (2011). *Fatigue - insights from individual and team sports*, pages 177–186. Nova Publishers.
- Ramos Félix, E., da Silva, H. P., Olstad, B. H., Cabri, J., and Lobato Correia, P. (2019). Swimbit : A novel approach to stroke analysis during swim training based on attitude and heading reference system (ahrs). *Sports*, 7(11) :238.
- Ronao, C. A. and Cho, S.-B. (2016). Human activity recognition with smartphone sensors using deep learning neural networks. *Expert Systems with Applications*, 59 :235–244.
- Roos, L., Taube, W., Brandt, M., Heyer, L., and Wyss, T. (2013). Monitoring of daily training load and training load responses in endurance sports : what do coaches want. *Schweizerische Zeitschrift für Sportmedizin und Sporttraumatologie*, 61(4) :30–36.
- Rusko, H. (1987). The effect of training on aerobic power characteristics of young cross-country skiers. *Journal of sports sciences*, 5(3) :273–286.

- S. Sandoval, A. Momplot, L. B. (2018). *Critères indicateurs d'auto-évaluation des modèles dans le cadre de l'autosurveillance réglementaire des systèmes d'assainissement pour permettre au maître d'ouvrage de juger son modèle*. Groupe de Recherche Rhône-Alpes sur les infrastructures et l'eau, version 1-document de travail édition. Groupe de travail Autosurveillance des systèmes d'assainissement.
- Sánchez, J. A. and Arellano, R. (2002). Stroke index values according to level, gender, swimming style and event race distance. In *ISBS-Conference Proceedings Archive*.
- Sanders, R. (2002). New analysis procedures for giving feedback to swimming coaches and swimmers. *Proceedings of XX ISBS-Swimming. Applied Program Swimming. Cáceres : University of Extremadura*, pages 1–14.
- Seifert, L., L'Hermette, M., Komar, J., Orth, D., Mell, F., Merriaux, P., Grenet, P., Caritu, Y., Héroult, R., Dovgalecs, V., and Davids, K. (2014). Pattern recognition in cyclic and discrete skills performance from inertial measurement units. *Procedia Engineering*, 72 :196 – 201. The Engineering of Sport 10.
- Seifert, L., Schnitzler, C., Bideault, G., Alberty, M., Chollet, D., and Toussaint, H. M. (2015). Relationships between coordination, active drag and propelling efficiency in crawl. *Human movement science*, 39 :55–64.
- Seiler, K. S. and Kjerland, G. Ø. (2006). Quantifying training intensity distribution in elite endurance athletes : is there evidence for an “optimal” distribution? *Scandinavian journal of medicine & science in sports*, 16(1) :49–56.
- Seiler, S. (2010). What is best practice for training intensity and duration distribution in endurance athletes? *International journal of sports physiology and performance*, 5(3) :276–291.
- Sein, M., Walton, J., Linklater, J., Appleyard, R., Kirkbride, B., Kuah, D., and Murrell, G. (2008). Shoulder pain in elite swimmers : Primarily due to swim-volume-induced supraspinatus tendinopathy. *British journal of sports medicine*, 44 :105–13.
- Seshadri, D. R., Drummond, C., Craker, J., Rowbottom, J. R., and Voos, J. E. (2017). Wearable devices for sports : New integrated technologies allow coaches, physicians, and trainers to better understand the physical demands of athletes in real time. *IEEE pulse*, 8(1) :38–43.
- Seshadri, D. R., Li, R. T., Voos, J. E., Rowbottom, J. R., Alfes, C. M., Zorman, C. A., and Drummond, C. K. (2019). Wearable sensors for monitoring the internal and external workload of the athlete. *NPJ digital medicine*, 2(1) :1–18.
- Sharp, R. L. (1993). Prescribing and evaluating Interval training sets in swimming : A proposed model. *Journal of Swimming Research*, (9) :36–40.
- Siirtola, P., Laurinen, P., Röning, J., and Kinnunen, H. (2011). Efficient accelerometer-based swimming exercise tracking. In *2011 IEEE Symposium on Computational Intelligence and Data Mining (CIDM)*, pages 156–161. IEEE.
- Silva, A. S., Salazar, A. J., Borges, C. M., and Correia, M. V. (2011). Wearable monitoring unit for swimming performance analysis. In *International Joint Conference on Biomedical Engineering Systems and Technologies*, pages 80–93. Springer.
- Smith, D. J. (2003). A framework for understanding the training process leading to elite performance. *Sports medicine*, 33(15) :1103–1126.

- Soligard, T., Schwelnuus, M., Alonso, J.-M., Bahr, R., Clarsen, B., Dijkstra, H. P., Gabbett, T., Gleeson, M., Häggglund, M., Hutchinson, M. R., et al. (2016). How much is too much?(part 1) international olympic committee consensus statement on load in sport and risk of injury. *British Journal of Sports Medicine*, 50(17) :1030–1041.
- Stamm, A., James, D. A., Hagem, R. M., and Thiel, D. V. (2012). Investigating arm symmetry in swimming using inertial sensors. In *SENSORS, 2012 IEEE*, pages 1–4. IEEE.
- Stewart, A. M. and Hopkins, W. G. (1997). Swimmers’ compliance with training prescription. *Medicine & Science in Sports & Exercise*, 29(10) :1389–1392.
- Stöggel, T. and Sperlich, B. (2014). Polarized training has greater impact on key endurance variables than threshold, high intensity, or high volume training. *Frontiers in physiology*, 5 :33.
- Tarasevičius, D. and Serackis, A. (2020). Deep learning model for sensor based swimming style recognition. In *2020 IEEE Open Conference of Electrical, Electronic and Information Sciences (eStream)*, pages 1–4. IEEE.
- Tate, A., Turner, G. N., Knab, S. E., Jorgensen, C., Strittmatter, A., and Michener, L. A. (2012). Risk factors associated with shoulder pain and disability across the lifespan of competitive swimmers. *Journal of athletic training*, 47(2) :149–158.
- Taylor, K., Chapman, D., Cronin, J., Newton, M. J., and Gill, N. (2012). Fatigue monitoring in high performance sport : a survey of current trends. *J Aust Strength Cond*, 20(1) :12–23.
- Wakayoshi, K., Yoshida, T., Udo, M., Kasai, T., Moritani, T., Mutoh, Y., and Miyashita, M. (1992). A simple method for determining critical speed as swimming fatigue threshold in competitive swimming. *International journal of sports medicine*, 13(05) :367–371.
- Walker, H., Gabbe, B., Wajswelner, H., Blanch, P., and Bennell, K. (2012). Shoulder pain in swimmers : A 12-month prospective cohort study of incidence and risk factors. *Physical therapy in sport : official journal of the Association of Chartered Physiotherapists in Sports Medicine*, 13 :243–9.
- Wallace, L. K., Slattery, K. M., and Coutts, A. J. (2009). The ecological validity and application of the session-rpe method for quantifying training loads in swimming. *The Journal of Strength & Conditioning Research*, 23(1) :33–38.
- Wang, Z., Shi, X., Wang, J., Gao, F., Li, J., Guo, M., Zhao, H., and Qiu, S. (2019). Swimming motion analysis and posture recognition based on wearable inertial sensors. In *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, pages 3371–3376. IEEE.
- Weldon, E. and Richardson, A. (2001). Upper extremity overuse injuries in swimming. *Clinics in Sports Medicine - CLIN SPORT MED*, 20 :423–438.
- Wilson, D. J., Smith, B. K., Gibson, J. K., Choe, B. K., Gaba, B. C., and Voelz, J. T. (1999). Accuracy of digitization using automated and manual methods. *Physical therapy*, 79 :558–566.
- Wolf, B. R., Ebinger, A. E., Lawler, M. P., and Britton, C. L. (2009). Injury patterns in division i collegiate swimming. *The American journal of sports medicine*, 37(10) :2037–2042.
- Wong, W. Y., Wong, M. S., and Lo, K. H. (2007). Clinical applications of sensors for human posture and movement analysis : a review. *Prosthetics and orthotics international*, 31(1) :62–75.

- Wright, B. and Stager, J. (2013). Quantifying competitive swim training using accelerometer-based activity monitors. *Sports Engineering*, 16.
- Yuen, P. (2010). Swim monitor. Technical report, World Intellectual Property Organization, 7 October 2010.
- Zdravevski, E., Lameski, P., Trajkovik, V., Kulakov, A., Chorbev, I., Goleva, R., Pombo, N., and Garcia, N. (2017). Improving activity recognition accuracy in ambient-assisted living systems by automated feature engineering. *IEEE Access*, 5 :5262–5280.
- Zhuang, Z. and Xue, Y. (2019). Sport-related human activity detection and recognition using a smartwatch. *Sensors*, 19(22) :5001.

# Chapitre 9

## Annexes

### 9.1 Annexe 1 : Variables permettant la quantification quotidienne et individuelle de l'entraînement de nageurs de niveau national et international (Mujika, 2017)

**Table 1.** Training variables quantified daily and individually for an entire season in a group of national and international level swimmers.<sup>14,37</sup>

Training variable
Frequency (sessions per day)
Total volume (km)
Intensity I (km below $\leq 2$ mM blood lactate)
Intensity II (km 2-4 mM blood lactate)
Intensity III (km 4-6 mM blood lactate)
Intensity IV (km $\geq 6$ mM blood lactate)
Intensity V (km sprint swimming)
50 m Pool (km)
25 m Pool (km)
Normal swim (km)
Arm pulling (km)
Kicking (km)
Front crawl (km)
Medley (km)
Own stroke (km)
Strength swim (increased resistance to advance, km or min)
Stroke rate (km to develop stroke frequency)
Distance per stroke (km to develop stroke distance)
Weight lifting (dryland strength training, min)

FIGURE 9.1 – Variables utilisées pour quantifier quotidiennement et individuellement l'entraînement sur la saison entière (Mujika et al. (1995); Mujika et al. (1996))

## 9.2 Annexe 2 : Illustration de la singularité du signal inertiel selon la nage et les phases d'activités

Ces singularités permettent de clairement identifier les occurrences de virages, poussées au mur, coulée, ainsi que des évidences différenciatrices entre chaque nage. C'est ce principe qui fonde l'idée de construire un outil de reconnaissance automatique de l'activité natatoire

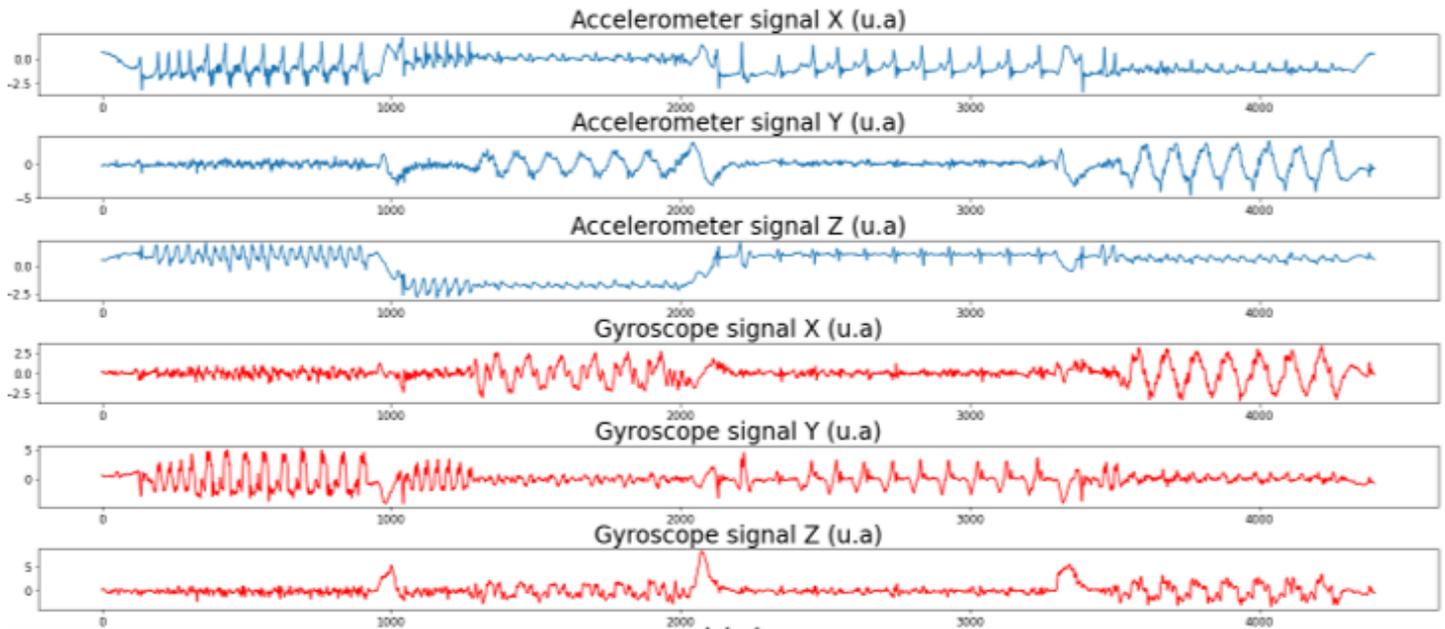


FIGURE 9.2 – Signal IMU normalisé sur un 100m quatre nages (données personnelles)

## 9.3 Annexe 3 : Vue schématique des relations entre IA, ML et DL (d'après Chollet et al. (2018))

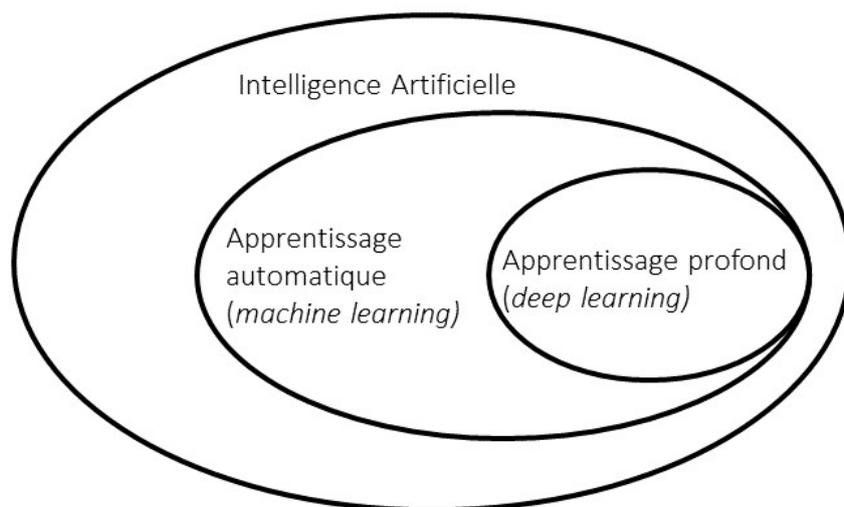


FIGURE 9.3 – Schéma illustrant les relations entre les concepts d'Intelligence Artificielle, de machine learning et de deep learning d'après Chollet et al. (2018)

## 9.4 Annexe 4 : Apports conceptuels sur le fonctionnement d'un algorithme de *deep learning* (d'après Chollet et al. (2018))

Comme énoncé dans le corps du document, le ML consiste en la paramétrisation/ajustement d'un modèle visant au *mapping* d'*inputs*  $X$  (ex : une image, un signal IMU, une radiographie, ...) à des *outputs* cibles  $Y$  (ex : le label "chat", le label "crawl", le label "fracture", ...). Cela est réalisé par l'observation de très nombreuses données exemples d'*input* associées à leur cibles. Les réseaux de neurones profonds réalisent cette association *input-to-target* via une séquence plus ou moins profonde de différentes couches (*layers*) réalisant de simples transformations dans les données entrantes à chaque couches. Ce sont ces transformations de données qui sont apprises, par réglage et affinage des paramètres du modèle, via l'exposition à un très grand nombre d'échantillons d'apprentissage. Elles peuvent par la suite être utilisées sur des données *inputs* étrangères à l'apprentissage initial et dont on ne connaît pas le label cible pour le prédire.

Derrière cette description triviale, différentes notions sont à cerner :

- Les paramètres d'une couche (*weights*) : le terme "apprentissage" dans le cadre d'un modèle de DL signifie la recherche d'une combinaison de valeurs numérique pour les différents paramètres de toutes les couches du réseau telles que ce dernier réalise un *mapping* correct des *inputs* à leur cibles associées.
- La fonction de perte : c'est une fonction mathématiques renvoyant une valeur numérique capturant l'efficacité du réseau a réaliser un *mapping* pertinent. Plus elle est basse plus le réseau est efficace, et donc meilleur est l'ajustement des paramètres. Le fondement du DL est d'utiliser cette valeur de perte comme un signal *feedback* afin d'ajuster les valeurs prises par les paramètres du modèle. Cet ajustement est fait de sorte à minimiser la fonction de perte pour l'exemple parcourant le réseau à l'instant  $t$ . Ce phénomène est réalisé par un optimiseur qui implémente ce qu'on appelle l'algorithme de rétropropagation (diffusion de l'erreur d'apprentissage aux différentes couches du réseau afin d'ajuster les paramètres de chaque couche) : c'est l'algorithme central sous-tendant le processus de DL.
- La boucle d'entraînement : avec chaque exemple dans la base de données (un  $X$  associé à un  $Y$ ) le réseau s'entraîne : les paramètres sont légèrement ajustés à chaque fois dans la bonne direction, c'est-à-dire celle qui minimise la fonction de perte.

Au final, un réseau entraîné est un réseau présentant un ajustement optimal de ses paramètres de telle sorte que sa fonction de perte est minimale. Ce qui équivaut à un réseau pour lequel tous les *outputs* (les prédictions  $Y'$ ) sont aussi proches que possible des labels cibles (les  $Y$ ). La figure 3.2.2 dans le corps du document synthétise cette vision conceptuelle d'un réseau de neurones ici à deux couches. Notons que sur cette figure, le rectangle *layer* peut-être de nature opératoire différente et traduit alors l'architecture du réseau qui peut se composer de couches avec un fonctionnement différent (ex : perceptrons multicouches, *Convolutionnal Neural Network* (CNN), *Recurrent Neural Network*,...).

## 9.5 Annexe 5 : synthèse des principales études de la littérature utilisant des méthodologies de type seuils/règles heuristiques pour monitorer nos variables d'activité identifiées comme d'intérêts

Référence	Méthodologie	Positionnement du capteur	Résultats et/ou détails
<a href="#">Ohgi (2004)</a>	Gamme d'accélération linéaire/vitesse angulaire par nage	Poignet	Evidences différenciatrices entre les nages
<a href="#">Davey et al. (2004)</a>	Type de nage selon polarité Z + contenu énergétique X, Y, Z via seuils = méthodes "seuils"	Sacrum	Pas de résultats publiés mais caractérisation typique du signal accélérométrique par nage
<a href="#">Davey et al. (2008)</a>	Méthodes "seuils"	Sacrum	6 nageurs, 95% de reconnaissance valide de la nage
<a href="#">Yuen (2010)</a>	Méthodes "seuils"	Sacrum	Pas de résultats/détails présentés.
<a href="#">Anthony and Chalfant (2010)</a>	Intuition heuristique (= principe méthode "seuils") et/ou ML	Poignet et/ou sacrum	Pas de résultats présentés (brevet privé)
<a href="#">Siirtola et al. (2011)</a>	ML (classification linéaire/quadratique), <i>features</i> statistiques descriptifs.	Haut du dos et poignet	Haut du dos plus valide que poignet à 5, 10, 25Hz, 3 nages : dos, brasse, crawl.
<a href="#">Silva et al. (2011)</a>	Assertions qualitatives sur les 3 axes selon les nages.	Haut du dos	Pas d'algorithmes et de résultats présentés
<a href="#">Jensen et al. (2013)</a>	Accéléromètre+gyroscope, modèle de régression linéaire à partir de 8 <i>features</i> statistiques	Tête	12 sujets sur 2*200 4N, 95% bonne classification sur <i>testing set</i> de 100 observations.
<a href="#">Ohgi et al. (2014)</a>	ML : arbre de décision et réseau de neurones multiples, <i>features</i> =moyenne, variance, asymétrie	Torse	45 sujets, 91,1% de validité de reconnaissance pour les deux modèles
<a href="#">Lecoutere et Puers (2014, 2016)</a>	Aucuns détails mais accélérométrie + gyroscopie	Tête ou poignet ou sacrum	9 élites sur 200m 4N, 100% validité pour CR, DS, PP et 28% de BR en PP.

<a href="#">Ganzevles et al. (2017)</a>	méthodes "seuils"	Haut du dos	99% validité, 13 nageurs élités.
<a href="#">Ramos Félix et al. (2019)</a>	Acc Z pour identifier DS puis ML : SVM et ANN, <i>features</i> accélérométriques à partir méthode <a href="#">Davey et al. (2004)</a> = moyenne contenu énergétique X, Y, Z	Sacrum	13 triathlètes, 152 observations (48PP, 50BR, 54CR), 89% validité sur <i>testing set</i> de 30 observations

TABLE 9.1 – Tableau présentant les principaux résultats de la littérature HAR natation basée seuils/règles heuristiques pour la reconnaissance du type de nage

Référence	Méthodologie	Positionnement du capteur	Résultats et/ou détails
<a href="#">Davey et al. (2004)</a>	Poussées au mur : variation brusque sur axe longitudinal=extremum locaux puis validation si différence de 1g	Sacrum	11 nageurs, 83 LT en CR, majorité erreurs $\pm 0,5s$ mais futurs ajustements nécessaires
<a href="#">Davey et al. (2008)</a>	algorithme détection touche et poussée initiale (variation orientation axe longitudinal)	Sacrum	6 élités, 200m CR. IMU VS CAM : $-0,32s \pm 0,58s$ , erreur détection poussée initiale
<a href="#">Le Sage et al. (2010)</a>	Fonction compteur occurrence virage en crawl : minimum local = rotation transverse	Sacrum	Peu de données mais comptage automatique concordant avec manuel
<a href="#">Le Sage et al. (2011)</a>	Identification "moment de virage" comme maximum local après zero-crossing sur axe antéropostérieur	Sacrum	200m 4N, comptage automatique concordant avec manuel, pas de calcul de LT et de validation du "moment de virage"
<a href="#">James et al. (2011)</a>	Idem Davey et collaborateurs	précisé	Pas de résultats présentés
<a href="#">Bächlin and Tröster (2012)</a> <a href="#">via les travaux de Bachlin et al. (2008)</a>	Poussée au mur/arrivée par monitoring gradient de pente axe longitudinal	Poignet	8 nageurs, $\pm 0,3s$ (départs) et $\pm 0,2s$ (arrivées) par rapport labelling vidéo

Jensen et al. (2013)	Détection occurrence virage par approche mixte : seuil accéléro Z + modèle de classification (ML) via régression linéaire sur 8 <i>features</i> statistiques descriptifs.	Tête	Accéléromètre+gyroscope, 80% sur validation set de 120 patterns et 88,9% sur testing set de 9 patterns, 12 nageurs sur 200m 4N.
Wright and Stager (2013)	Régression linéaire et équations prédictive counts-distance et counts-vitesse	Poignet + cheville	crawl, $R^2=0,906$ ( $p<0,05$ ) pour distance et $R^2=0,57$ ( $p<0,001$ ) pour vitesse, contrevalidation des équations.
Callaway (2015)	Idem Davey et collaborateurs mais détection manuelle départ/arrivée	Sacrum	12 nageurs, crawl, 95 LT, pas de différence significative avec lapttime gold-standard ( $p=0,115$ ).
Lecoutere and Puers (2016)	Pas de détails sur la détection	Tête	Accéléromètre + gyroscope, 9 nageurs sur 200m 4N, pas de résultats présentés
Michaels et al. (2016)	Détection poussées par grande variation dans magnitude total signal et détection arrivées par changement orientation	Tête	6 élites suivis pendant 3mois, nage à basse intensité et jambes détectés
Ganzevles et al. (2017)	Détection poussées consécutive virage : maximum local enveloppe énergétique axe longitudinal, détection début-fin nage par transition reposnage (critères spécifiques atteints)	Haut du dos	13 élites, protocole avec les quatres nages, Erreur pour LT : $-0,74s(\text{biais})\pm 0,26s(\text{TEM})$ . Détection des touches compliqué : $0,88s\pm 0,57s$ .

TABLE 9.2 – Tableau présentant les principaux résultats de la littérature HAR natation basée seuils/règles heuristiques pour la reconnaissance des évènements singuliers de l’activité natatoire (poussée au mur, virage, touche)

## 9.6 Annexe 6 : Critères d'exigences d'un système de monitoring de l'activité en natation selon la population cible (d'après Mooney et al. (2017))

Ces exigences constituent pour nous un objectif de précision des métriques quantifiées à atteindre dans le développement de méthodologies de reconnaissance d'activité humaine en natation.

**Table 4. The system requirements of recreational and competitive swimmers will differ and have an impact on the level of accuracy required of the swimming monitors.**

System Parameter	Recreational Swimmer	Competitive Swimmer
Lap time	Accuracy required to within $\pm 2$ seconds to monitor trends over time. A variance of 2 seconds over a lap time of 30 seconds equates to a 6.7% error.	Accuracy required to within $\pm 0.3$ seconds in order to be comparable with a stopwatch (current standard)
Stroke count	Accuracy within $\pm 2$ strokes sufficient to monitor trends over time	Accuracy required to lesson more than $\pm 1$ stroke per lap
Swim distance	Key determinant of training progression, accuracy required to within $\pm 5\%$ of actual (i.e. no more than 2 missed/additional laps included per 1,000 m completed in a 25 m pool)	Not applicable to user, training distances pre-prescribed and monitored by coach
Swim speed	Not applicable to user, lap times provide a sufficient metric	Accuracy within $\pm 0.01$ m/s required to relate to required lap time accuracy and also to compare with other reported methods. More concerned with instantaneous speed or speed during different race segments
Stroke rate	Not applicable to user, stroke counts provide a sufficient metric	Accuracy within $\pm 5\%$ adequate (i.e. $\pm 2$ str/min). More concerned with instantaneous stroke rate or stroke rate during different race segments
Stroke length	Accuracy within $\pm 0.2$ m sufficient and related to accuracy of stroke count measure	Accuracy close to 100% required (i.e. errors of no more than 0.1 m) and related to stroke rate measure. More concerned with stroke length during different race segments
Stroke identification	100% accuracy required as errors will be very apparent	100% accuracy required as errors will be very apparent

FIGURE 9.4 – Critères requis pour un système de monitoring de l'entraînement de nageurs loisirs et compétitifs selon Mooney et al. (2017))

## 9.7 Annexe 7 : Définitions *gold-standard* des différents LT

De la numérisation temporelle des différents événements présentés dans le tableau 5.3, 3 catégories de LT ont pu être calculés : le premier LT d'un intervalle (START), le dernier LT d'un intervalle (END), et les LT compris entre ces deux premiers (MIDDLE). Ces 3 catégories répondent à une définition différente selon la nage réalisée (voir tableau ci-dessous). Cette distinction permet d'être en adéquation avec les pratiques des entraîneurs sur le terrain

	START	MIDDLE	END
Nage alternée	Différence de temps entre le début de la poussée initiale et la prochaine occurrence de poussée au mur	Différence de temps entre une occurrence de poussée au mur et la prochaine	Différence de temps entre la dernière occurrence de poussée au mur de l'intervalle et la touche finale
Nage simultanée	Différence de temps entre la poussée initiale et la première occurrence de touche.	Différence de temps entre une occurrence de touche et la prochaine	Différence de temps entre la dernière occurrence de touche de l'intervalle et la touche finale.

TABLE 9.3 – Critère de définition des différentes catégories de temps intermédiaires selon la nature de la nage

## 9.8 Annexe 8 : caractéristiques des sujets de de la campagne de mesure

Sujet	Sexe (M/F)	Age (ans)	Taille (cm)	Poids (kg)	IMC ( $m.kg^{-2}$ )	Pratique (ans)	Spécialité	Niveau
KERGW	M	22	187	80	22,87	12	NAT	IR
SAMFA	M	17	186	64	18,50	5	TRI	N
GANAL	M	16	173	58	19,38	7	TRI	R
ARTVA	M	16	172	51	17,23	8	TRI	R
TREEL	F	14	172	60	20,28	5	NAT	IR
BOUAN	M	21	168	61	21,6	10	TRI	N
FOUPI	M	23	190	84	23,27	7	NAT	D
LECHU	M	24	175	67	21,87	12	NAT	D
ROUEL	M	14	179	55	17,17	5	NAT	R
HUEJE	M	39	NaN	NaN	NaN	NaN	TRI	N
MARNI	M	38	188	75	21,22	NaN	TRI	N
LEMEL	F	16	170	64	22,14	7	NAT	IR
LEFEN	M	22	180	73	22,53	13	TRI	R
KERGO	M	20	185	72	21,03	10	TRI	R
PHIPA	M	21	177	63	20,11	9	TRI	N
DEBPI	M	15	188	56	15,84	5	TRI	R
SIMAL	M	21	182	74	22,34	11	TRI	R
GRECL	M	19	185	68	19,86	11	NAT	IR
SEUAN	M	25	182	75	22,64	13	NAT	D
LEBLA	F	18	160	60	23,43	10	NAT	D
ROXAX	M	46	180	80	24,69	NaN	NAT	Re
DRUBO	M	20	193	80	21,47	7	NAT	D
BOUJU	F	22	165	58	21,30	11	NAT	IR
BIDBE	M	45	NaN	NaN	NaN	NaN	NAT	Re
DELER	M	26	183	93	27,77	3	NAT	Re
BIDNI	M	42	NaN	NaN	NaN	NaN	NAT	Re
BIDTH	F	18	163	56	21,07	10	NAT	N
BREBA	M	18	183	72	21,50	7	NAT	IR
LAULO	M	26	NaN	NaN	NaN	14	TRI	R
RIQCO	F	21	155	53	22,06	10	NAT	D
GALMA	F	21	176	55	17,76	NaN	NAT	Re
LEPNO	F	19	169	57	19,96	10	NAT	IR
MOYCH	F	20	175	69	22,53	7	NAT	R
DEBSA	F	26	170	57	19,72	NaN	NAT	D
LALAR	F	21	160	50	19,53	NaN	NAT	Re

TABLE 9.4 – Caractéristiques principales des sujets de l'étude. NAT = natation, TRI = triathlon, N = national, IR = interrégional, R = Régional D = départemental, Re = récréationnel

## 9.9 Annexe 9 : Lettre d'information relative à la campagne de mesure

### Lettre d'information

---

#### Mesures biomécaniques dans le cadre de travaux de recherche menés au laboratoire Mouvement Sport Santé (M2S)

---

Laboratoire Mouvement Sport Santé (M2S) - Université Rennes 2 ; Ecole Normale Supérieure de Rennes - Campus de Kern Lann - Avenue Robert Schuman - 35170 BRUZ. Responsables de l'étude : Nicolas Bideau, Email : [nicolas.bideau@univ-rennes2.fr](mailto:nicolas.bideau@univ-rennes2.fr)

Madame, Monsieur,

Le laboratoire Mouvement Sport Santé (M2S) souhaiterait mener une étude visant le développement d'une application de terrain permettant : (1) d'évaluer l'activité du nageur via des variables relatives à sa performance et aux entraînements réalisés (2) de quantifier et monitorer la charge externe d'entraînement pour proposer des actions prospectives et rétrospectives de régulation et d'ajustement du plan d'entraînement par l'entraîneur. Dans cette perspective, nous aurions besoin de volontaires afin de participer au protocole de mesure.

Il s'agirait d'enregistrer des signaux ~~accélérométriques~~ et gyroscopiques issus d'une centrale inertielle que vous porterez lors d'une activité de natation.

La série de mesure consistera en un 4\*100m quatre nages à allure moyenne, c'est-à-dire à une vitesse restant dans votre zone de confort, entrecoupé de 30 secondes de récupération. S'ensuivra un 4\*100m -1 dans chaque nage- à allure maximale entrecoupé de 10minutes de récupération. L'ordre des nages pour la seconde partie du protocole sera randomisé. Vous serez pour ces mesures équipé d'une centrale inertielle fixée dans le bas de ~~votre~~ dos (au niveau du sacrum) grâce à un adhésif double face couplé à un adhésif médical (Tegaderm). Ce dispositif et les mesures qui en découlent sont peu invasives et n'entraîneront aucun inconfort ou douleur notables liées à l'installation ou l'utilisation du système pendant la nage.

Ces mesures sont réalisées dans le cadre de travaux de recherche relatifs à une thèse de doctorat en biomécanique des Activités Physiques et Sportives (APS) mené par Erwan Delhaye et d'un mémoire de master 2 en Entraînement et Optimisation de la Performance Sportive (EOPS) mené par Antoine Bouvet à l'Université de Rennes 2 et au laboratoire M2S.

Les risques liés à cette étude sont faibles. La réalisation du protocole vous conduira à réaliser la dernière portion d'intervalles de 100m à intensité maximale qui impliqueront un inconfort du fait de la demande physiologique imposée à votre organisme. L'engagement mental relatif à ce protocole peut aussi conduire à une fatigue nerveuse notable.

Vous pourrez être informé(e) du résultat global de cette étude à l'issue du travail. Votre participation à ce travail et les données recueillies vous concernant resteront strictement confidentielles et ne seront accessibles qu'aux seuls investigateurs, ou à vous-même si vous le désirez. Les données enregistrées feront l'objet d'un traitement informatique. Toutes les données vous concernant sont anonymisées. Votre droit d'accès et de rectification prévu par la loi relative à l'informatique, aux fichiers et aux libertés, pourra s'exercer dans les conditions prévues par la réglementation.

Le responsable de l'étude se tient à votre disposition si vous avez la moindre question.

Nous vous remercions de l'attention que vous porterez à cette lettre.

Signature du participant (majeur) ou de son responsable légal :

FIGURE 9.5 – Lettre d'information relative à la campagne de mesure

## 9.10 Annexe 10 : Formulaire de consentement éclairé relatif à la campagne de mesure

### Formulaire de consentement éclairé

Participation à des mesures biomécaniques dans le cadre de travaux recherche menés au laboratoire Mouvement Sport Santé (M2S)

Laboratoire Mouvement Sport Santé (M2S) -Université Rennes 2 ; Ecole Normale Supérieure de Rennes-Campus de Kern Lann – Avenue Robert Schuman – 35170 BRUZ. Responsables de l'étude : Guillaume Nicolas & Nicolas Bideau. Email : [guillaume.nicolas@univ-rennes2.fr](mailto:guillaume.nicolas@univ-rennes2.fr) & [nicolas.bideau@univ-rennes2.fr](mailto:nicolas.bideau@univ-rennes2.fr)

Je soussigné, Nom : ..... Prénom : .....

né(e) le ..... à ..... (département : .....),

et domicilié à .....

accepte librement et volontairement de participer à ces mesures inertielles réalisées dans le cadre de travaux de recherche au sein du laboratoire M2S de l'Université de Rennes 2 et s'intégrant dans la réalisation d'un travail de thèse de doctorat et de master 2. J'ai compris les mesures qui seraient réalisées et on a répondu à toutes mes questions concernant ces mesures.

Je peux à tout moment décider de stopper ma participation sans motiver ma décision. J'ai compris que les données collectées à l'occasion de ces mesures seront protégées dans le respect de la confidentialité. Elles pourront uniquement être consultées par les seuls opérateurs et chercheurs impliqués dans ces mesures.

J'accepte le traitement informatisé des données à caractère personnel me concernant dans les conditions prévues par la loi Informatique et liberté. Je suis informé(e) de mon droit d'accès et de rectification des données me concernant.

Je certifie être affilié au régime de la sécurité sociale.

#### Le participant (majeur) ou son responsable légal

Nom : .....

Prénom : .....

Date : .....

Souhaitez-vous être tenu au courant de l'avancée du traitement des données (si oui, indiquez votre adresse email) :

Signature précédée de la mention "lu et approuvé" :

Fait en 2 exemplaires originaux, datés et signés : un exemplaire conservé par le participant et un exemplaire conservé par la structure.

FIGURE 9.6 – Formulaire de consentement éclairé relatif à la campagne de mesure

## 9.11 Annexe 11 : Illustration du processus de labellisation manuelle des vidéos

A partir de l'identification visuelle de l'occurrence temporelle de chaque label identifié par la caméra adéquate, un *template* d'activité par sujet est construit manuellement. Ce procédé permet ainsi de labelliser les signaux IMU afin d'entraîner des modèles de *deep learning* pour la reconnaissance des différents labels (les *targets y*).

Sur la figure 9.7 ci-dessous est illustré cette labellisation vidéo pour différentes actions du sujet BOUAN. A gauche de bas en haut : fin d'UN identifiée par la caméra *travelling*, fin de WA identifiée par la GoPro côté départ, fin de BU identifiée par la GoPro côté mur opposé. A droite de bas en haut : recueil manuel du *timecode* des différentes actions, construction d'une table récapitulative avec le début et la fin de chaque action réalisée au cours du protocole.

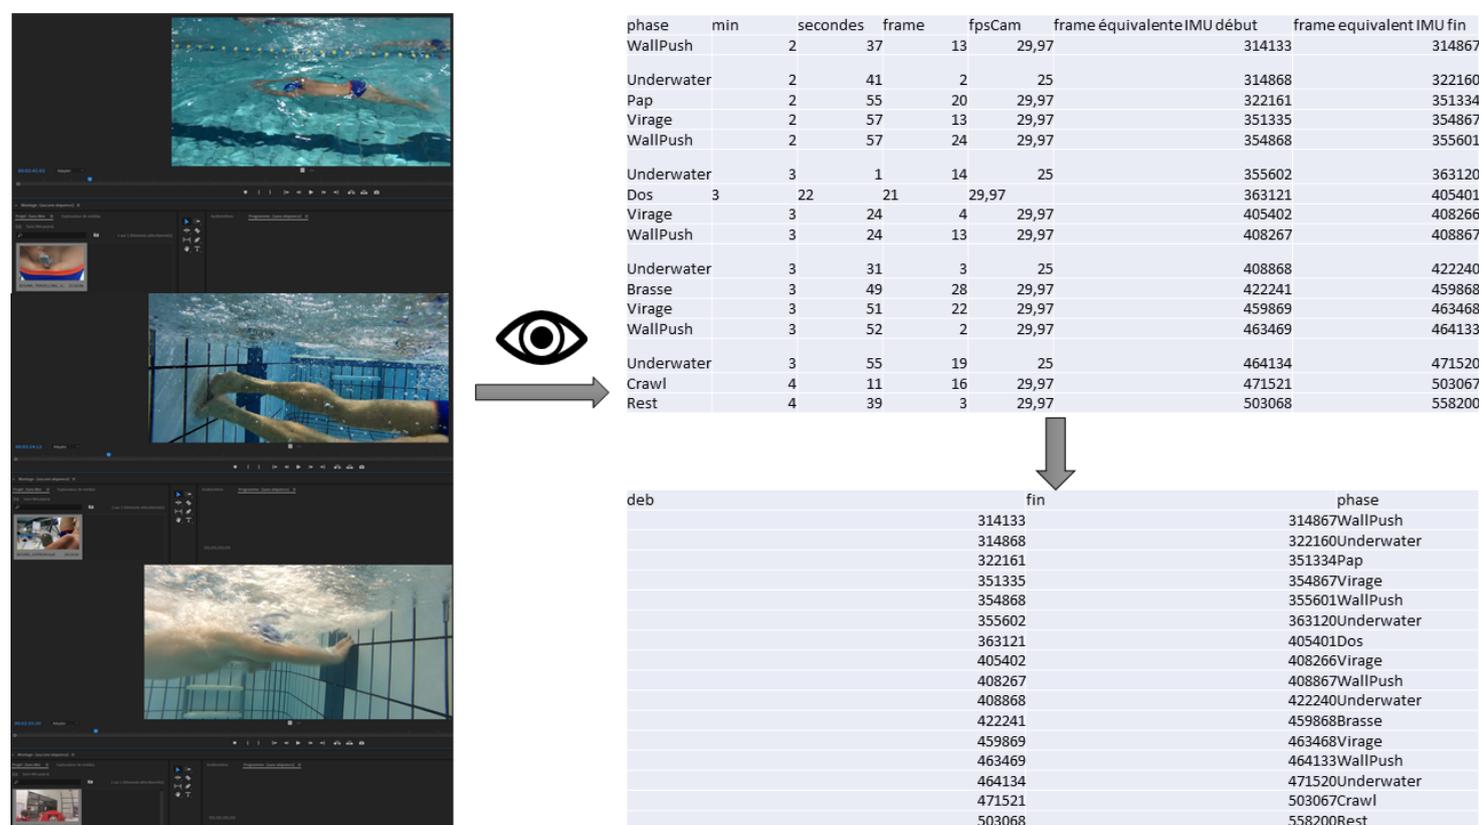


FIGURE 9.7 – Processus de labellisation manuelle des données vidéos à partir des classes d'activités retenues pour la construction de templates par sujet

## 9.12 Annexe 12 : Justification de la *window size*

Nous avons choisi une taille de fenêtre de 90 *frames* soit 1,8s suite à l'analyse de la figure ci-dessous. Celle-ci montre, à partir d'une base de données de 18 sujets inclus dans ce mémoire, les performances de classification (*accuracy*) de 18 modèles ayant chacun en *testing set* un sujet différent (validation en *k-fold* avec *n* fold, chacun étant un sujet de la base de données). Une telle approche, bien qu'extrêmement coûteuse computationnellement (126 modèles entraînés) permet d'avoir une vue globale et généralisable des performances en fonction de la taille de fenêtre retenue.

Cette figure est issue des travaux de thèse de doctorat d'Erwan Delhaye et n'est pas encore publiée.

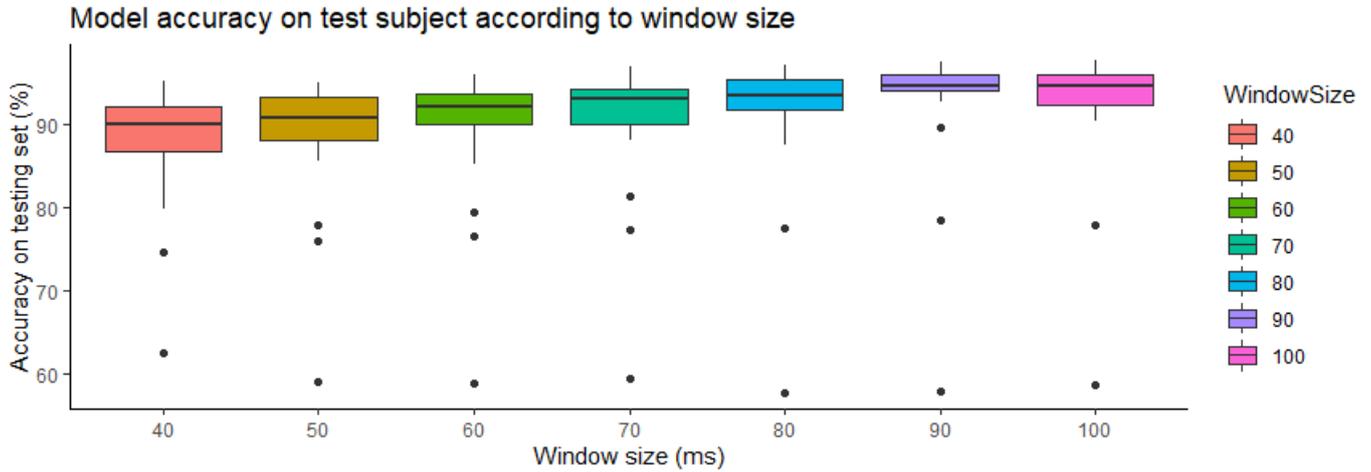


FIGURE 9.8 – Performance de classification moyenne de 18 modèles pour la reconnaissance d’activité nautique en fonction de la taille de fenêtre retenue

### 9.13 Annexe 13 : *Offset* constaté entre le vecteur $y$ et $\hat{y}$

Nous remarquons un *offset* d’environ 40 *frames* sur la prédiction d’activité issue du *testing set*. C’est-à-dire que le modèle fait ses prédictions avec environ 0,8s d’avance sur la réalité. Comme ce décalage est plutôt constant cela ne change pas le calcul des métriques spatio-temporelles de performance. Néanmoins cela affecte grandement les indicateurs de performances de classification d’activité du réseau. Pour cette raison nous corrigeons ce décalage en ajoutant 40 *frames* au vecteur  $\hat{y}$ . Une quantification plus objective de cet *offset* à l’échelle de toute la base de données est nécessaire pour gagner en précision. Nous n’avons pas les moyens computationnels pour le mettre en oeuvre.

La figure 9.9 illustre cet *offset*, ici mis en exergue sur un 100m 4N.

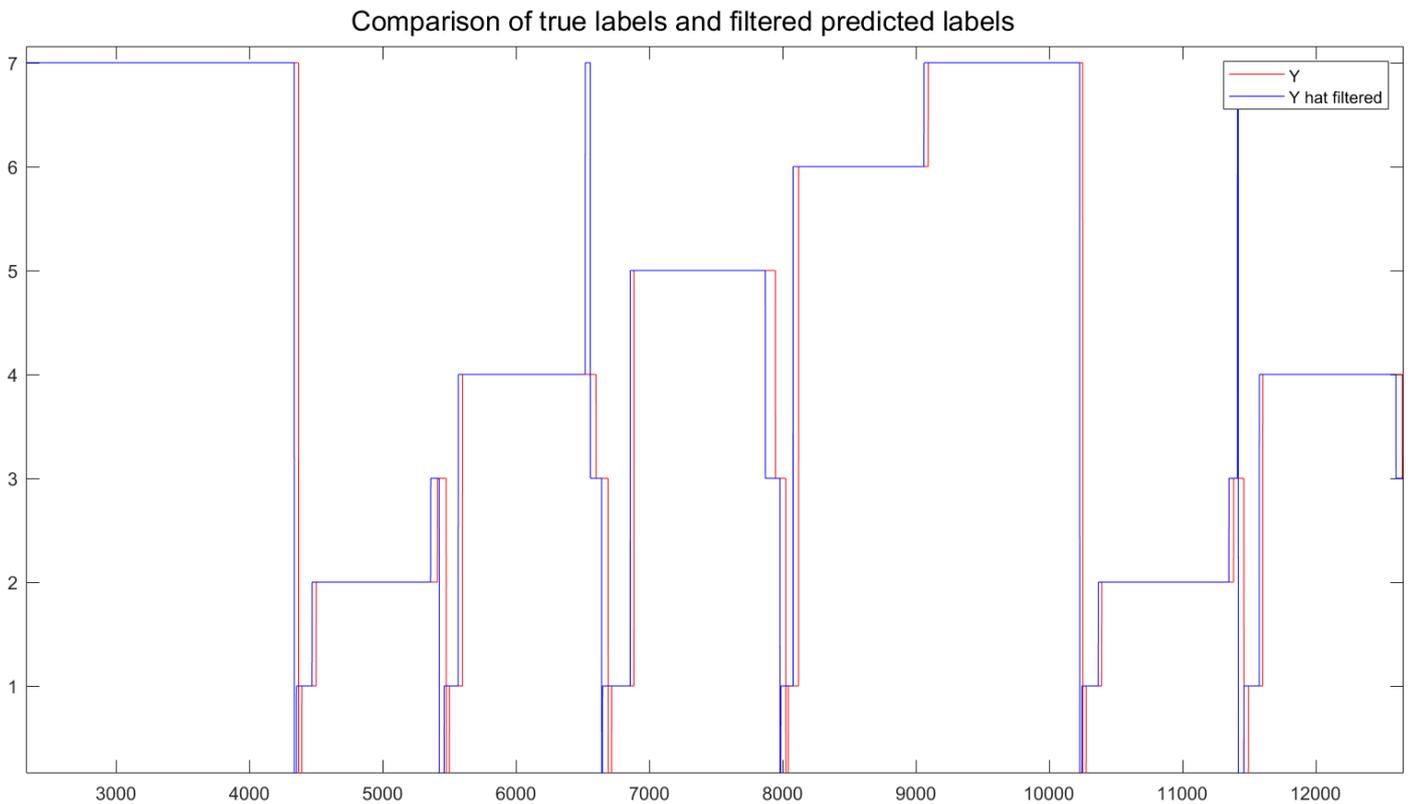


FIGURE 9.9 – Comparaison des vrais labels d’activités et de la prédiction filtrée du modèle sur le testing set : mise en évidence d’un offset

### 9.14 Annexe 14 : Évolution de la fonction de coût et de l’accuracy des training et validation sets au cours de l’entraînement du réseau

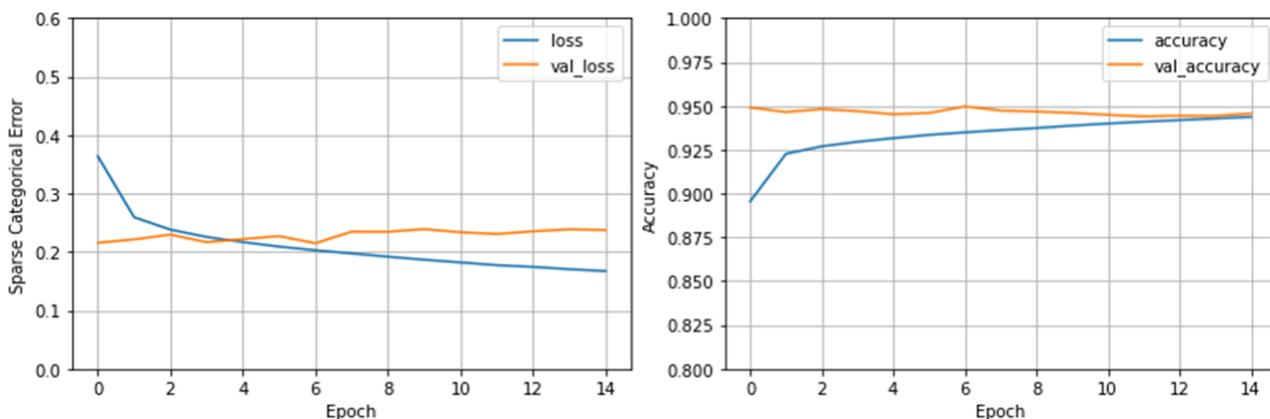


FIGURE 9.10 – Fonction de coût et accuracy au cours de l’entraînement du modèle

### 9.15 Annexe 15 : Agrément statistique des LT END au gold-standard vidéo

On constate que l’erreur de mesure est bien plus grande sur les LT END que pour le reste des données. Ainsi les différences retrouvées sont de  $0,25 \pm 0,98s$  (MAPE de 0,91s) contre  $0,06 \pm 0,60s$  (MAPE de 0,42s) pour le reste des données avec une répartition des différences très importantes autour de -1s et +1s. Ce

constat est en accord avec la littérature qui attribue l'identification de la touche finale d'un intervalle comme l'évènement le plus difficile à classier de l'activité d'un nageur.

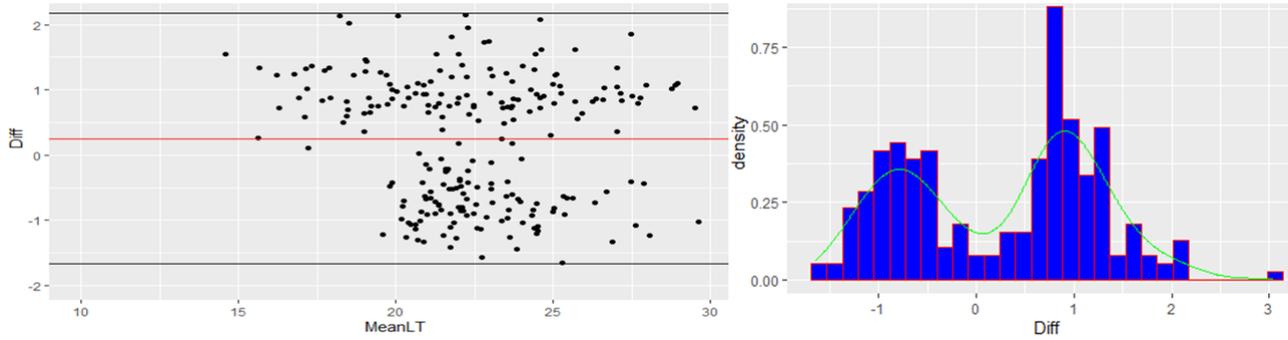


FIGURE 9.11 – Graphique de Bland-Altman et densité de répartition des différences entre *LT* mesurés par *gold-standard* et *centrale inertielle*

## 9.16 Annexe 16 : Preuve de concept pour l'utilisation du coefficient d'autocorrélation pour le compte des coups de bras

Conformément aux travaux de [Zhuang and Xue \(2019\)](#), utiliser le coefficient d'autocorrélation sur les signaux inertiels des phases de nage permet d'exploiter la cyclicité du pattern de nage, se traduisant par un signal accélérométrique et/ou gyroscopique périodique, afin de compter les occurrences de cycle et ainsi monitorer le nombre de coup de bras. En effet un simple *findpeaks* sur l'autocorrélation de l'échantillon permet ce décompte. Bien que cette méthodologie ne soit pas basée *machine learning*, elle permet une reproductibilité et une généralisation certaine dans la mesure où le compte des coups de bras se fonde sur la répétition d'un pattern de signal propre à chaque sujet et sa répétition dans le temps. Nous n'avons pas implémenter cette méthode dans notre algorithme de *post-processing* qui utilise des méthodes plus traditionnelles de la littérature sur signal filtré que nous avons élargies à toutes les nages. Toutefois les figures ci-dessous illustre la démonstration de faisabilité de cette méthodologie pour chaque nage sur des longueurs sélectionnées aléatoirement du sujet LEFEN. Nous avons sélectionné, en fonction de la nage, les signaux les plus pertinents -c'est-à-dire sur lesquels l'autocorrélation est marquée- pour ensuite y appliquer un *findpeaks* avec critère d'espacement temporel propre à la cinématique de chaque pattern de nage.

### Sample autocorrelation use for stroke count in Frontcrawl

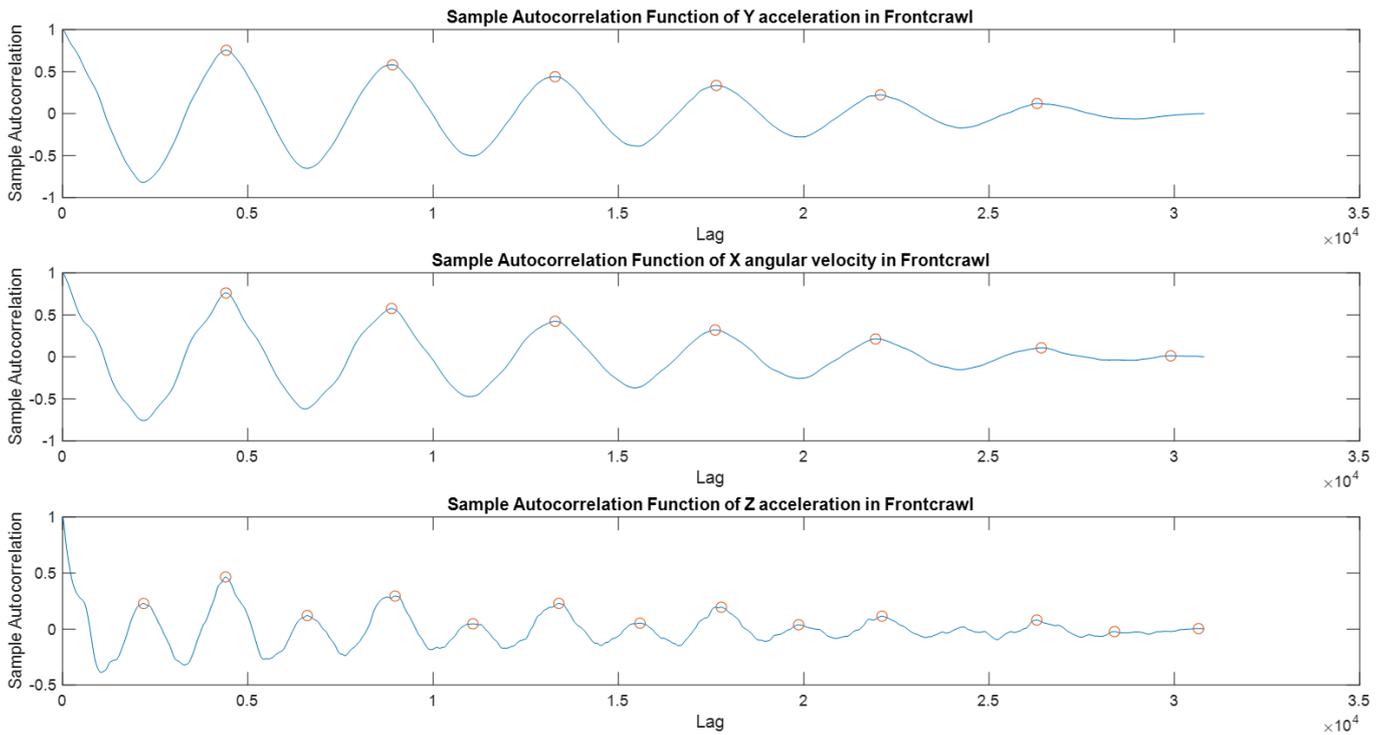


FIGURE 9.12 – Preuve de concept pour l'utilisation du coefficient d'autocorrélation afin de compter le nombre de coups de bras en crawl

### Sample autocorrelation use for stroke count in Backstroke

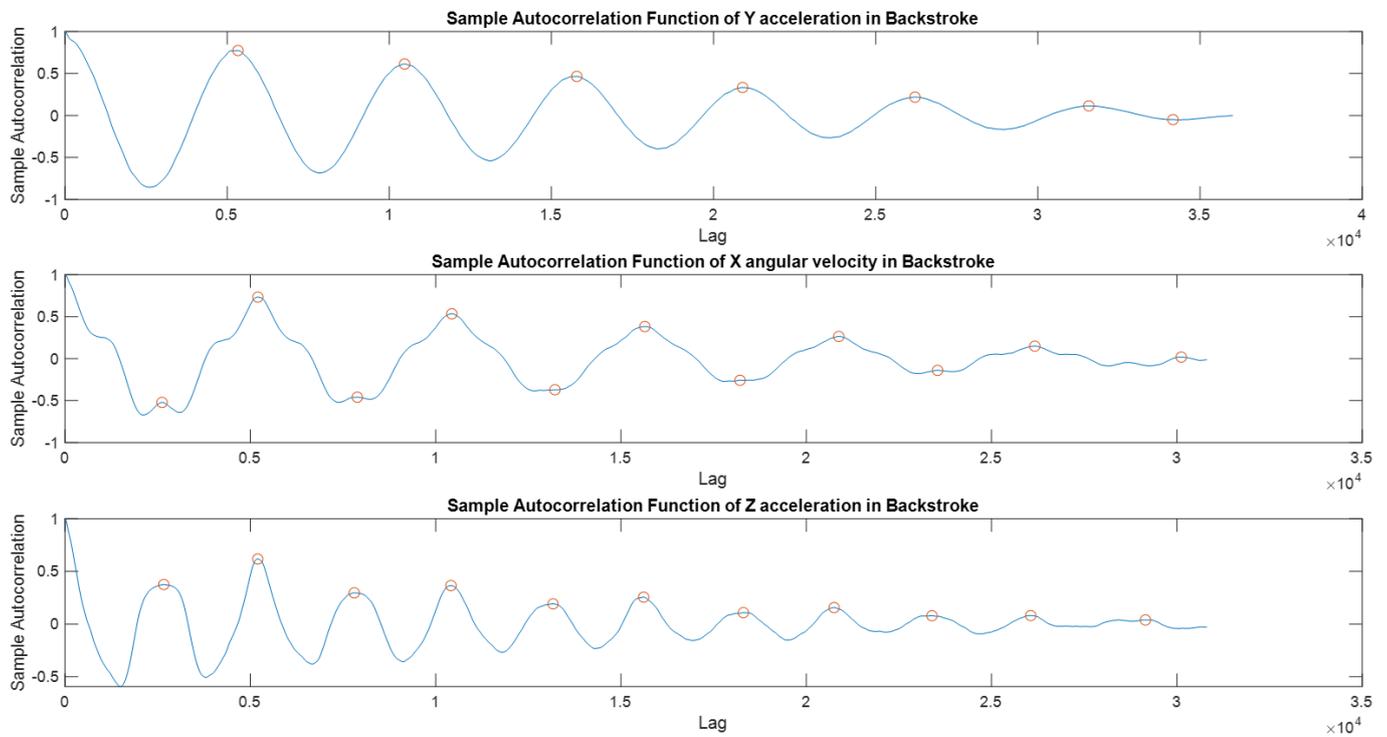


FIGURE 9.13 – Preuve de concept pour l'utilisation du coefficient d'autocorrélation afin de compter le nombre de coups de bras en dos

### Sample autocorrelation use for stroke count in Breaststroke

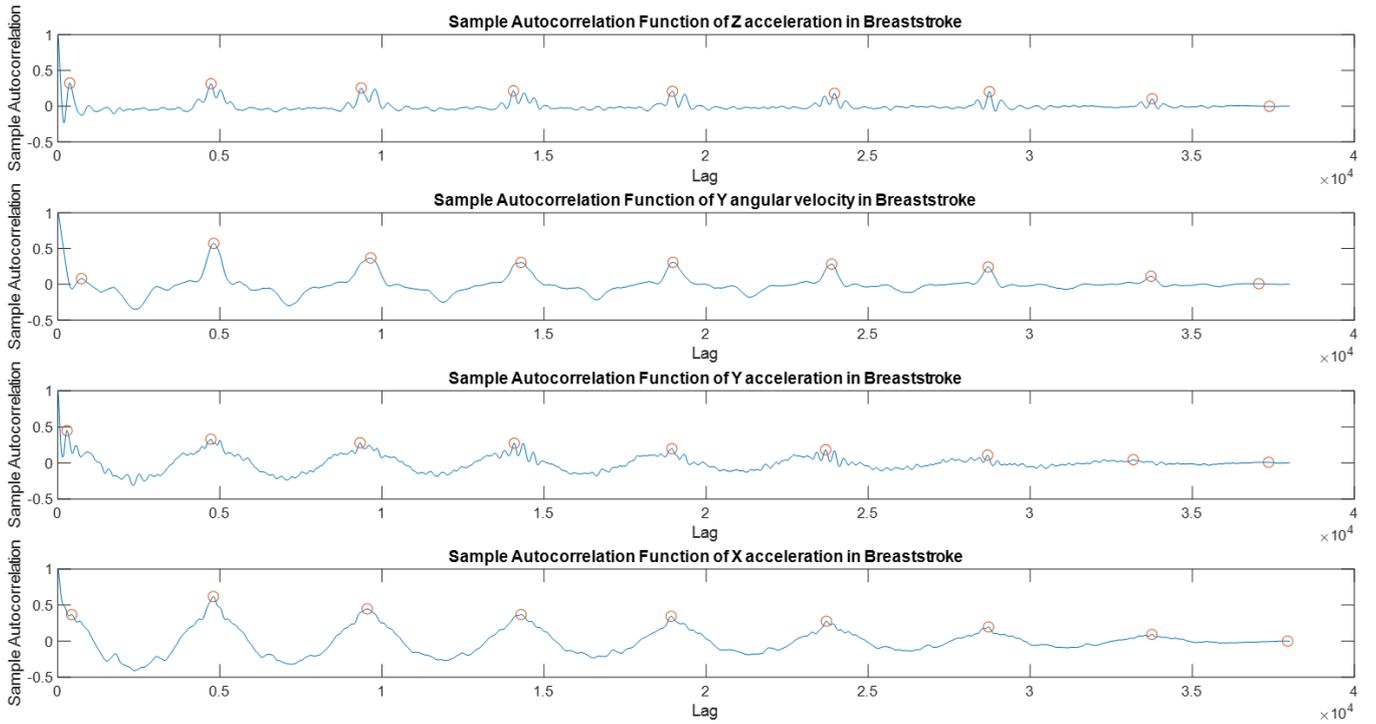


FIGURE 9.14 – Preuve de concept pour l'utilisation du coefficient d'autocorrélation afin de compter le nombre de coups de bras en brasse

### Sample autocorrelation use for stroke count in Butterfly

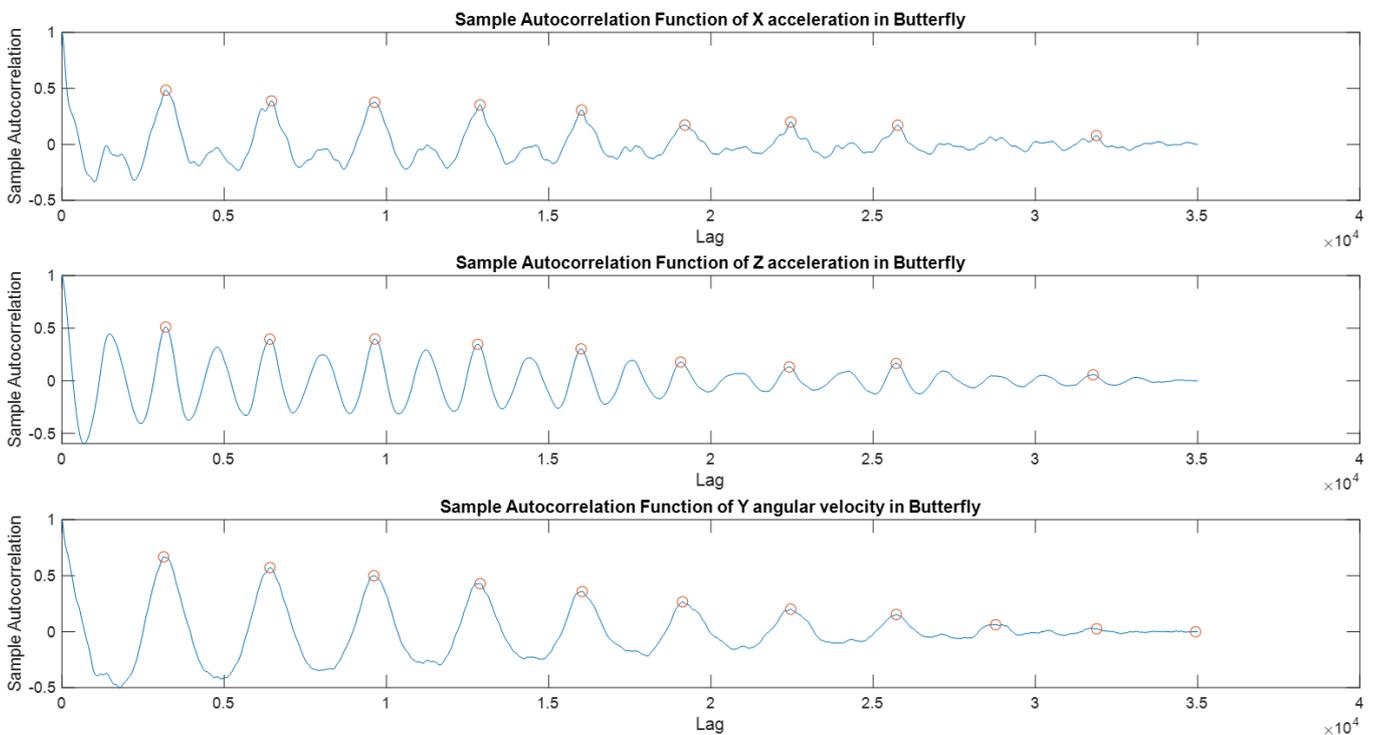


FIGURE 9.15 – Preuve de concept pour l'utilisation du coefficient d'autocorrélation afin de compter le nombre de coups de bras en papillon



# Reconnaissance d'activité humaine en natation : apports du *deep learning* pour le monitoring de l'entraînement basé centrale inertielle

**Présenté par : Antoine BOUVET**

*Sous la direction de : Erwan DELHAYE (ENS Rennes, Laboratoire M2S), Nicolas BIDEAU (Université Rennes 2, laboratoire M2S)*

## RÉSUMÉ

**Objectif :** Cette étude vise le développement d'un outil de reconnaissance d'activité natatoire basé centrale inertielle (IMU) et *deep learning*. Il s'agit, (1) de collecter et labelliser une base de données avec variabilité intra et inter-sujet, (2) d'entraîner un modèle de reconnaissance d'activité généralisable, (3) de l'exploiter pour du monitoring d'entraînement via le calcul de métriques de performances spatio-temporelles et d'efficacité natatoire

**Méthode :** 35 nageurs et triathlètes de niveau récréationnel à national, équipés d'une IMU au sacrum, ont réalisé un protocole filmé incluant toutes les nages et intensités. Après *labelling* manuel des vidéos en 8 classes (repos, poussée au mur, coulée, virage et les quatre nages) un réseau de neurones artificiels basé *long short term memory* bidirectionnel est entraîné sur *training set* et évalué sur *validation et testing set* via un *leave-one-subject-out*. Un algorithme de *post-processing* est développé pour en extraire des variables de performance à partir de la prédiction d'activité du modèle. Leur validation s'effectue par comparaison au *gold-standard* vidéo.

**Résultats :** L'*accuracy* post-entraînement est de 95,14, 94,36 et 93,65% sur *training, validation, et testing set*. Le *F1-score* moyenné par classe est de 0,86 et le pondéré de 0,96. La prédiction d'activité est conforme avec la réalité et permet d'en extraire de nombreux indicateurs de charge et de performance notamment les temps intermédiaires avec une précision de  $\pm 0,42s$ .

**Discussion et conclusion :** Le modèle de classification d'activité présente une bonne généralisation sur des données étrangères à son apprentissage initial et sur un nombre de classes plus important que la littérature disponible. Il permet, en accord avec les exigences de la haute performance et pour la première fois dans la littérature, une collecte de données non-invasive, automatique et en condition écologique, ce qui facilite grandement le monitoring pour les entraîneurs. La validation de toutes les métriques extraites du modèle constitue une piste future de travail. Tout comme l'application et l'enrichissement de l'outil auprès d'athlètes et d'entraîneurs.

**Mots-clefs :** IMU, Intelligence artificielle, Performance, Reconnaissance d'activité humaine

## ABSTRACT

**Objectives :** The aim of this study was to develop an Inertial Measurement Unit (IMU) and deep learning based swim activity recognition system. It must be (1) to collect and labeled a large database with intra et inter-subject variability, (2) to train a generalizable swim activity recognition model, (3) to use it for training monitoring, especially by computation of spatio-temporal performance and swimming efficiency metrics.

**Method :** 35 recreational to national swimmers or triathletes were asked to perform a filmed and sacrum IMU equipped protocol including all swim styles, turn type and intensities. After manual labelling of recorded video in 8 activity class (rest, wallpush, underwater, turn and the fourth swim styles) a neural network based on bi-long short term memory is train on training set and evaluate on validation and testing set with a leave-one-subject-out method. A home-made post processing algorithm was also developed to extract from activity model prediction performance variables. Validation is achieve by video comparison.

**Results :** Post-training accuracy was respectively 95,14, 94,36 and 93,65% on training, validation and testing set. Macro average F1-score by classe was 0,86 and weighted average 0,96. Activity prediction is faithful by real activity and many load and performance metrics could be computed, in particular lap time with a mean absolute error of 0,42s (n=952).

**Discussion and conclusion :** Classification activity model show good generalization on unknow initial training data and with a larger number of activity class than in previous litterature. It enables, in compliance with high performance requirements, a non-invasive and automatic data collection in ecological conditions. This greatly facilitate swim monitoring for coaches. Validation of all the computed metrics is a futur way of work. As well as application and enrichment of the system with athletes and trainers.

**Keywords :** IMU, Artificial intelligence, Performance, Human activity recognition

antoine.bouvet@ens-rennes.fr