



# **Entraînement d'un modèle supervisé pour la détection du plaisir en contexte de jeu vidéo à partir de signaux physiologiques et d'indices comportementaux**

**Mémoire**

**Nicolas Beaudoin-Gagnon**

**Maîtrise en génie mécanique - avec mémoire**  
Maître ès sciences (M. Sc.)

Québec, Canada

**Entraînement d'un modèle supervisé pour la  
détection du plaisir en contexte de jeu vidéo à partir  
de signaux physiologiques et d'indices  
comportementaux**

**Mémoire**

**Nicolas Beaudoin-Gagnon**

Sous la direction de:

Alexandre Campeau-Lecours, directeur de recherche  
Philip L. Jackson, codirecteur de recherche

# Résumé

La modélisation de l'expérience de jeu présente un intérêt considérable pour la conception de jeux vidéo adaptatifs. Les jeux vidéo adaptatifs utilisent l'information émotionnelle contenue dans les signaux physiologiques et les indices comportementaux pour personnaliser l'expérience de jeu vidéo, et ce dans le but de générer une expérience optimale de jeu. Afin de modéliser l'expérience de jeu, le présent projet de recherche s'est penché sur la détection du plaisir d'un joueur à partir de signaux physiologiques (électrocardiogramme, activité électrodermale, activité respiratoire et électromyogramme) et d'indices comportementaux (expressions faciales, mouvements de la tête et entrées d'un contrôleur Xbox). Dans ce travail, des modèles supervisés (SVM, Forêt d'arbres décisionnels et  $k$ NN) ont été entraînés sur un jeu de données construit à partir de la base de données FUNii, qui contient les données physio-comportementales de 219 joueurs réparties sur 362 séances de jeu de la franchise *Assassin's Creed*. Une méthode pour la création de classes de plaisir à partir du facteur-fun, un outil d'annotation continue du plaisir, à également été proposée. Le meilleur modèle entraîné a permis de distinguer trois classes de plaisir avec un taux de classement de 53,5% sur un jeu de test, une amélioration de 12,5% par rapport au meilleur résultat obtenu dans des travaux antérieurs.

# Abstract

Modeling the gaming experience is of considerable interest for designing adaptive video games. Adaptive video games use the emotional information contained in physiological signals and behavioral cues to personalize the video game experience, in order to generate an optimal gaming experience. With the purpose of modeling the gaming experience, this research project has focused on the detection of a player's fun using physiological signals (electrocardiogram, electrodermal activity, respiratory activity and electromyogram) and behavioral cues (facial expressions, head movements and facial expressions and inputs from an Xbox controller). In this work, supervised machine learning models (SVM, Random Forest and  $k$ NN) were trained on a dataset built from the FUN*ii* database, which contains the physio-behavioral data of 219 players spread over 362 game sessions of the *Assassin's Creed* franchise. A method for creating fun classes from the fun factor, a tool for continuous annotation of fun, has also been proposed. The best model trained allowed to distinguish three classes of pleasure with an accuracy of 53,5% on a test dataset, an improvement of 12,5% compared to the best result obtained in previous works.

# Table des matières

<b>Résumé</b>	<b>iii</b>
<b>Abstract</b>	<b>iv</b>
<b>Table des matières</b>	<b>v</b>
<b>Liste des tableaux</b>	<b>vii</b>
<b>Liste des figures</b>	<b>viii</b>
<b>Remerciements</b>	<b>xi</b>
<b>Introduction</b>	<b>1</b>
L'expérience de jeu . . . . .	3
Les signaux physiologiques et les indices comportementaux : indicateurs de l'état affectif . . . . .	5
Modélisation de l'expérience de jeu à partir des signaux physiologiques et des indices comportementaux par apprentissage automatique : revue des travaux présents dans la littérature . . . . .	16
Présentation de la problématique de recherche . . . . .	23
Objectifs . . . . .	25
Organisation du mémoire . . . . .	25
<b>1 Extraction de caractéristiques à partir des signaux physiologiques et des indices comportementaux des joueurs de la base de données FUNii</b>	<b>27</b>
1.1 Mise en contexte : la base de données FUNii . . . . .	28
1.2 Prétraitement des signaux physiologiques et des indices comportementaux contenus dans la base de données FUNii . . . . .	30
1.3 Extraction de caractéristiques pour apprentissage automatique supervisé . . . . .	42
<b>2 Création des classes de plaisir à partir du facteur-fun</b>	<b>48</b>
2.1 Le facteur-fun . . . . .	49
2.2 Utilisation des changements de facteur-fun comme indicateurs du plaisir du joueur . . . . .	50
2.3 Mise en contexte : approches proposées dans les travaux antérieurs	54

2.4	Approche proposée dans le présent travail . . . . .	58
<b>3</b>	<b>Entrainement des classificateurs</b>	<b>65</b>
3.1	Méthode . . . . .	66
3.2	Résultats . . . . .	72
3.3	Discussion . . . . .	79
	<b>Conclusion</b>	<b>84</b>
	<b>Bibliographie</b>	<b>85</b>
	<b>Annexes</b>	<b>101</b>
<b>A</b>	<b>Participants et missions sélectionnés pour l'extraction de caractéristiques</b>	<b>102</b>
<b>B</b>	<b>Concepts préliminaires d'apprentissage automatique supervisé</b>	<b>105</b>
<b>C</b>	<b>Détection des changements de facteur-fun</b>	<b>112</b>
<b>D</b>	<b>Classe Python implémentée pour la détection et pour la correction des pics de facteur-fun</b>	<b>114</b>

# Liste des tableaux

0.1	Mesures fréquentielles typiques utilisées pour l'analyse de la variabilité cardiaque. . . . .	8
0.2	Mesures extraites de la mesure de la respiration . . . . .	12
0.3	Exemples d'unités d'action selon le FACS. . . . .	14
0.4	Émotions de base et unités d'action associées . . . . .	14
1.1	Contenu de la base de données FUNii. . . . .	29
1.2	Questionnaires de la base de données FUNii. . . . .	29
1.3	Mesures brutes de la base de donnée FUNii utilisées dans le cadre de ce projet. . . . .	32
1.4	Mesures extraites à partir des données brutes de la base de données FUNii. . . . .	33
1.5	Tableau des AUs disponibles avec le modèle de régression d'OpenFace. . . . .	39
1.6	Modèle des émotions basé sur la moyenne géométrique des unités d'action . . . . .	40
1.7	Caractéristiques extraites des signaux physiologiques et des indices comportementaux. . . . .	46
3.1	Espaces des hyperparamètres explorés durant la recherche aléatoire . . . . .	70
3.2	Meilleurs résultats obtenus par recherche aléatoire avec validation croisée pour les classes créées avec les équations 2.1 et 2.8 selon les trois longueurs d'époques testées . . . . .	72
3.3	Valeurs p des tests T entre les performances des meilleurs classificateurs et celles des classificateurs naïfs pour les trois longueurs d'époque testées. . . . .	74
3.4	Précision, rappel, score $F_1$ et support des résultats de classification du modèle $k$ NN-60-B sur le jeu de test. . . . .	75
A.1	Participants sélectionnés pour l'extraction des caractéristiques ayant joué au jeu ACU. . . . .	103
A.2	Participants sélectionnés pour l'extraction des caractéristiques ayant joué au jeu ACS. . . . .	104

# Liste des figures

0.1	Exemple d'un signal ECG . . . . .	8
0.2	Exemple d'un signal EDA . . . . .	10
0.3	Exemple d'un signal RSP . . . . .	11
0.4	Exemple d'un signal EMG . . . . .	13
0.5	Le système de coordonnées décrivant les différentes positions de la tête.	16
0.6	Jeu de <i>Pong</i> . . . . .	17
0.7	Le facteur-fun et l'interface USB utilisée pour sa mesure. . . . .	21
1.1	Exemple de signal EDA problématique. Plusieurs parties du signal montrent un niveau de conductance nul causé par une déconnexion des électrodes. . . . .	31
1.2	Détermination des périodes d'inspiration et d'expiration à partir du signal RSP . . . . .	35
1.3	Contrôleur Xbox et les actions associées à chaque touche dans ACU et ACS. . . . .	41
1.4	Exemple de segmentation en époques à durée fixe . . . . .	43
1.5	Distribution temporelle des changements successifs du facteur-fun et sa somme cumulative. . . . .	45
2.1	Exemple de facteur-fun. . . . .	49
2.2	Deux paradigmes de cotation du plaisir observés dans les facteurs-fun des participants retenus. . . . .	51
2.3	Approche mixte de cotation du plaisir . . . . .	52
2.4	Le modèle à trois composantes binaires proposé par Clerico et collab. (2016). . . . .	54
2.5	Comparaison des approches proposées par Fortin-Cote et collab. (2018)	56
2.6	Pics dans le facteur-fun . . . . .	58
2.7	Étapes de la détection des changements de facteur-fun. . . . .	60
2.8	Correction des pics de facteur-fun. . . . .	62
2.9	Facteur-fun original et transformé selon l'approche proposée. . . . .	63
2.10	Classes créées à partir du facteur-fun selon la valeur de $FT_n$ telles que déterminées à l'équation 2.8. . . . .	64
3.1	Distributions des instances pour les ensembles de classes $C_A$ et $C_B$ dans les 3 jeux de données créés. . . . .	67



3.2	Taux de performance moyen dans les 3 plis durant la recherche aléatoire pour les 3 modèles testés ( <i>k</i> NN, RF, SVM) selon différentes longueurs d'époques et pour 2 approches utilisées pour la création des classes de plaisir. . . . .	73
3.3	Matrice de confusion du modèle <i>k</i> NN-60-B avec un taux de classement de 53,5% sur le jeu de test. . . . .	75
3.4	Courbe ROC du modèle <i>k</i> NN-60-B sur le jeu de test . . . . .	76
3.5	Importance relative des 57 caractéristiques sélectionnées pour l'entraînement des modèles <i>k</i> NN-60-B et RF-60-B. . . . .	77
3.6	Importance relative de chaque modalité physiologique et comportementale. . . . .	78
B.1	Séparation typique du jeu de données en trois sous-ensembles : les jeux d'entraînement, de validation et de test. . . . .	108
B.2	Exemple d'une validation croisée à 3-plis. . . . .	109
B.3	Exemples de matrices de confusion pour des problèmes à 2, 3 et 4 classes. . . . .	110

Pour l'homme absurde, il ne s'agit plus d'expliquer et de résoudre, mais d'éprouver et de décrire.

---

Albert Camus

# Remerciements

Plusieurs personnes ont contribué à ce mémoire, qui est la résultante de beaucoup de questionnements, de grattements de tête et de discussions de corridor. Je tiens à les remercier comme il se doit.

Tout d’abord, je voudrais remercier Philip Jackson pour son soutien incroyable durant tout le cours de ma maîtrise. Philip, bien qu’il soit la personne la plus occupée de la planète, est toujours parvenu à faire de la place dans son horaire pour une discussion impromptue, quasi philosophique, sur la nature du plaisir du joueur, pour m’éclairer de sa lanterne quand l’incertitude me frappait, ou pour m’écouter me plaindre quand les choses allaient moins bien. C’est difficile de démontrer ici toute ma reconnaissance, alors –comme il est un grand (immense) fan de Star Wars– je dirai simplement qu’il a été un maître Jedi pour le jeune padawan que j’étais.

Merci à Alexandre-Campeau Lecours pour les nombreuses relectures des ébauches de ce qui est devenu ce mémoire, pour tous les conseils, les discussions et les coups de pouce qui m’ont permis de mener à terme cette maîtrise.

Merci également à tous les étudiants du laboratoire de neurosciences cognitives et sociales : Frédéric Grondin, Marie-Pier B. Tremblay, Josianne Jauniaux, Elsa Massicotte, Audrey Marcoux, Chloé Gingras, Sarah-Maude Deschênes, Sophie Bélanger-LeBel et Marie-Hélène Tessier. Vous êtes tous des personnes incroyables et ce fut un réel plaisir d’apprendre à vous connaître ces deux dernières années. Merci également à Alexis Fortin-Côté : grand réceptacle de connaissances infini, pour son aide inestimable tout au cours de mon parcours.

Merci à Alicia, Cédric, Charles, Jean-Félix, Mathieu, Vincent et Xavier. J’ai toujours cru que les liens les plus forts étaient tissés dans l’adversité, quand tout un chacun devait porter sur son dos sa part du fardeau commun. Alors que nos vertèbres et nos genoux craquaient à l’unisson dans ce long hiver de l’esprit, vous avez été cette

lanterne qui à la fois réchauffe et éclaire le chemin. Merci pour les longues discussions dans l'herbe du grand axe, les tirs de frisbee toujours plus précis et plus loin, les brassages d'idées et les changements de référentiel. Puisse les sapins « de Valvan-dry » vous protéger des intempéries futures, mes amis.

Finalement, un merci tout particulier à ma conjointe et complice, Kathleen Bédard-Daigle, pour sa patience inébranlable, son aide inestimable et son support indéfectible durant les deux dernières années. Ce mémoire porte les traces de ta bienveillance et de ton amour.

# Introduction

Selon un rapport publié en 2018 par l'Association canadienne du logiciel de divertissement (ALD), l'industrie canadienne du jeu vidéo contribue annuellement 3.7 milliards de dollars au PIB du Canada (Association canadienne du logiciel de divertissement, 2018). Celle-ci emploie également 21 700 Canadiens à temps plein, qui sont répartis à travers les 596 studios de jeux vidéo présentement en activité au Canada. Les jeux vidéo sont aussi très présents dans la culture populaire. En effet, toujours selon l'ALD, 61% des Canadiens se considèrent comme des joueurs, ce qui représente environ 23 millions de personnes. Cette popularité des jeux vidéo est reflétée par l'avènement des sports électroniques (« *E-Sports* ») et du « *streaming* »<sup>1</sup>, qui prennent place sur des plateformes comme *Twitch.TV* et *YouTube* (Kaytoue et collab., 2012). Les jeux vidéo occupent donc une place importante dans la société actuelle, et ce autant au niveau économique que culturel.

Picard (2000a,b) s'est intéressée à la place des émotions dans l'interaction entre humain et ordinateur. Celle-ci a proposé qu'un ordinateur connaissant l'état émotionnel de son utilisateur pourraient également s'y adapter, ce qui rendrait l'interaction plus organique et donc plus semblable à une interaction humaine. Transposant cette idée à la sphère des jeux vidéo, il a été proposé que l'expérience de jeu pourrait être améliorée par la création de « jeux émotionnellement intelligents » (JVEI), c'est-à-dire des jeux qui peuvent s'adapter aux différents états émotionnels du joueur (Sykes et Brown, 2003; Gilleade et Dix, 2004; Hudlicka, 2008a). À cet égard, il a été montré que les signaux physiologiques et les indices comportementaux pouvaient être utilisés pour détecter les états émotionnels d'un joueur en contexte de jeu vidéo (Mandryk et Atkins, 2007; Drachen et collab., 2010; Chanel et collab., 2011). Les signaux physiologiques englobent des mesures électriques de l'activité cardiaque, respiratoire, électrodermale et musculaire, tandis que les indices comportementaux désignent,

---

1. Pratique durant laquelle un joueur diffuse en temps réel sa partie de jeu, la décrit et offre des commentaires instructifs ou divertissants.

entre autres, les expressions faciales et les mouvements de la tête.

S’inspirant de ce courant de recherche sur les JVEI, le projet FUNii –une collaboration entre l’Université Laval (Philip Jackson, Sébastien Tremblay et Alexandre Campeau-Lecours) et le studio de jeu vidéo d’Ubisoft Québec et Conseil de recherches en sciences naturelles et en génie du Canada (CRSNG)– s’est intéressé à l’utilisation du plaisir pour le développement de jeux vidéo adaptatifs. Les jeux adaptatifs, qui englobent les JVEI, sont « capables de modifier de manière dynamique leur conception [(c.-à-d. leur « *design* »)] à la lumière de l’interaction continue entre le joueur et le jeu » (Gilleade et Dix, 2004).

Le projet FUNii vise à créer un jeu vidéo adaptatif utilisant en temps réel les variations de plaisir du joueur afin de personnaliser l’expérience de jeu. Un tel jeu pourrait par exemple reconnaître que le niveau de plaisir du joueur diminue dans certains contextes de jeu (p. ex. les batailles avec des ennemies) et pourrait réduire l’occurrence de certains de ces contextes (p. ex. réduire le nombre de batailles).

S’inspirant d’études similaires utilisant les émotions dans des jeux adaptatifs, les chercheurs impliqués dans le projet de recherche FUNii ont souhaité déterminer s’il était possible de mettre en place un système capable de prédire le plaisir d’un joueur à partir de mesures physiologiques et comportementales, et ce indépendamment du joueur. Dans une phase antérieure du projet, un outil de cotation permettant d’obtenir une représentation continue du plaisir du joueur –nommée « facteur-fun »– a d’abord été développé (Chamberland et collab., 2015). Dans la phase suivante, des mesures physiologiques et comportementales ont ensuite été récoltées en laboratoire sur plus de 200 participants jouant à *Assassin’s Creed : Unity* (Ubisoft, 2014) et *Assassin’s Creed : Syndicate* (Ubisoft, 2015), deux jeux d’action/aventure (Clerico et collab., 2016; Fortin-Cote et collab., 2018). Durant cette expérience, les joueurs ont coté leur plaisir sous forme de facteur-fun pour chaque séance de jeu.

Le présent projet de recherche, qui s’inscrit dans une nouvelle phase du projet FUNii, a comme objectif d’évaluer la faisabilité de la détection du plaisir à partir de données physio-comportementales et vise à développer un algorithme de détection du plaisir pouvant être utilisé dans un jeu adaptatif. Pour ce faire, ce projet s’appuie sur les données physio-comportementales et les facteurs-fun recueillis dans le cadre du projet FUNii.

Le reste de ce chapitre définit les notions importantes et justifie les objectifs de re-

cherche du présent projet. Tout d'abord, les différentes définitions de l'expérience de jeu sont présentées. Puis, les signaux physiologiques et indices comportementaux sont introduits et leurs liens avec l'état affectif sont présentés. Ensuite, une revue de littérature des différents travaux utilisant les signaux physiologiques et les indices comportementaux pour modéliser l'expérience de jeu est présentée. Finalement, ce chapitre se termine par l'exposition des différents objectifs de recherche du présent projet.

## L'expérience de jeu

Plusieurs concepts ont été proposés pour tenter de décrire l'expérience de jeu. L'engagement est lié à une sensation d'immersion et de présence dans le jeu, et celui-ci est défini par Charlton et Danforth (2007); Boyle et collab. (2012) comme un niveau élevé d'implication dans l'utilisation d'un ordinateur. L'immersion, quant à elle, est un état psychologique caractérisé par l'impression d'être enveloppé, inclus dans et en interaction avec un environnement virtuel (Brown et Cairns, 2004; Jennett et collab., 2008). De manière analogue à l'immersion, la présence décrit un sentiment de se trouver en un endroit même si on se trouve en réalité dans un autre. En ce qui le concerne, le plaisir se rapporte aux concepts de *flow* et d'émotions, et est décrit comme une réaction positive durant une séance de jeu (Caroux et collab., 2015). Le *flow* correspond, quant à lui, à l'état atteint lorsque les compétences du joueur sont en équilibre avec le *challenge* du jeu (tel que perçu par le joueur) (Csikszentmihalyi, 1990; Chen, 2007). Plus difficiles à définir, les émotions sont essentiellement des états momentanés qui reflètent une évaluation affective et qui sont associés à des tendances comportementales et des biais cognitifs Hudlicka (2008b).

Différents auteurs ont tenté de décrire l'expérience de jeu en s'appuyant sur les concepts d'engagement, de présence, de plaisir, d'immersion, d'émotions ou de *flow*. Takatalo et collab. (2015) ont proposé un cadre théorique pour rendre compte de l'expérience de jeu : le PIFF<sup>2</sup> (« *Presence-Involvement-Flow Framework* »). Le PIFF tente de capturer les déterminants de l'expérience utilisateur, notamment sa qualité, son intensité, sa signification, sa valeur et son étendue. Caroux et collab. (2015) ont décrit l'expérience de jeu comme ce que le joueur recherche ou vit durant l'interaction joueur-jeu, soit l'engagement et le plaisir. Selon ces derniers, l'expérience de jeu est un concept multidimensionnel qui englobe une interaction complexe entre les émotions, le plaisir, le sentiment d'immersion et de présence du joueur lors de l'inter-

action avec le jeu. S'appuyant sur le concept de *flow*, Sweetser et Wyeth (2005) ont proposé *GameFlow*, un modèle du plaisir en contexte de jeu vidéo. Les composantes de ce modèle sont la concentration, le *challenge*, les compétences, le contrôle, les buts clairs définis dans le jeu, la rétroaction, l'immersion et l'interaction sociale. Selon les auteurs, bien que *GameFlow* soit en réalité un modèle du plaisir en contexte de jeu vidéo, « il y a un chevauchement entre [les éléments de *GameFlow*] et les composantes de la théorie du *flow* » (Sweetser et collab., 2012). Poels et collab. (2008) ont proposé un modèle pour rendre compte du plaisir d'un joueur de jeu vidéo. Ce modèle est basé sur l'immersion, le stress, la compétence, le *flow*, les émotions à valence positive et négative ainsi que le *challenge* (tels que rapportés par Wiemeyer et collab. (2016)). Calvillo-Gámez et collab. (2015) ont proposé le modèle CEGE (« *Core Elements of the Gaming Experience* »). Selon ce modèle, une expérience positive associée à du plaisir est la conséquence de la perception du jeu vidéo qu'a le joueur et de l'interaction avec ce dernier. Selon les auteurs, ce plaisir découle de deux éléments centraux : le jeu vidéo et ce que les auteurs ont nommé les « marionnettes » (« *puppetry* »). Les marionnettes sont les éléments qui permettent de créer un sentiment de contrôle et de possession, qui eux même provoque du plaisir. Les éléments associés à la perception du jeu vidéo par le joueur regroupent l'environnement et la jouabilité, qui eux aussi provoque du plaisir.<sup>2</sup>

Plusieurs modèles du plaisir (« fun ») ont également été proposés. Desmet (2003) suggère que ce dernier ne doit pas être vu comme une émotion, mais plutôt comme la résultante d'une combinaison d'émotions. Le modèle de Lazzaro (2004) distingue 4 différents types de plaisir (« *Hard Fun* », « *Easy Fun* », « *Altered States* » et « *The People Factor* »), tandis que Poels et collab. (2007) incluent le plaisir dans la dimension de l'amusement (« *enjoyment* »). Finalement, Blythe et Hassenzahl (2003) propose une distinction entre les concepts de « *fun* » et de « *pleasure* ». D'ailleurs, dans la suite de ce mémoire, le terme « plaisir » sera utilisé exclusivement au sens de « *fun* » tel que proposé par ces auteurs.

L'évaluation de l'expérience de jeu présente des défis considérables. D'une part, l'interaction entre les différents facteurs impliqués dans l'expérience de jeu est encore mal comprise. D'une autre part, l'expérience de jeu est une expérience subjective, inobservable directement et, au mieux, indirectement mesurable.

---

2. Pour une introduction plus complète aux différents modèles de l'expérience de jeu (« *Player Experience* »), voir le travail de Wiemeyer et collab. (2016). Pour une revue complète des différents travaux concernant l'expérience de jeu, voir Schaffer et Fang (2019)



Afin de quantifier ou d'utiliser l'expérience de jeu dans le contexte de jeux adaptatifs, plusieurs chercheurs se sont donc intéressés aux signaux physiologiques et aux indices comportementaux. En effet, les émotions produisent des réponses physiologiques (Kreibig, 2010) et comportementales caractéristiques (notamment au niveau des expressions faciales (Ekman et Friesen, 1983)). Par exemple, la peur est accompagnée à la fois d'une augmentation du rythme cardiaque, mais également d'une expression faciale caractérisée par l'ouverture des yeux et l'élévation et la contraction des sourcils (Larsen et collab., 2008; Ekman et Friesen, 1978). À l'inverse des émotions, ces réponses physiologiques et comportementales ont l'avantage d'être objectivement mesurables, et peuvent donc être utilisées comme indicateurs de celles-ci.

S'appuyant sur le principe que les émotions sont corrélées à des réponses physiologiques et comportementales, plusieurs chercheurs ont tenté de modéliser l'expérience de jeu à partir des signaux physiologiques, faisant ainsi le pari que certains construits impliqués dans l'expérience de jeu (présence, engagement, immersion, plaisir, etc.) pourraient également présenter des signatures physio-comportementales caractéristiques. À la section suivante, les différents signaux physiologiques et indices comportementaux pertinents pour le présent projet de recherche sont présentés, et leurs liens avec les différentes émotions sont discutés.

## **Les signaux physiologiques et les indices comportementaux : indicateurs de l'état affectif**

*Psychophysiology is based on the dual assumptions that human perception, thought, emotion, and action are embodied and embedded phenomena; and that the measures of the processes of the corporeal brain and body contain information can shed light on the human mind.*<sup>3</sup>

— Cacioppo et collab. (2007)

Les signaux physiologiques regroupent un ensemble de mesures informatives de l'état physiologique d'un individu. Ceux-ci sont la plupart du temps basés sur des mesures des propriétés électriques (différences de potentiel, conductance, résistance) de différentes parties du corps.

---

3. « La psychophysologie est basée sur la double hypothèse selon laquelle la perception humaine, la pensée et l'émotion sont des phénomènes intégrés et incarnés ; et que les mesures des processus du cerveau et du corps contiennent de l'information qui peut permettre de comprendre l'esprit humain ». Traduction libre.

Le système nerveux autonome (SNA) contrôle les différents signaux physiologiques. Ce dernier est composé du système nerveux sympathique (SNS) et du système nerveux parasympathique (SNP). L'activité du SNS et du SNP est modulée par les stimuli affectifs. Le SNP et le SNS sont souvent mis en opposition pour leurs rôles antagonistes : le SNP est responsable « d'exciter » l'organisme, tandis que le SNS s'occupe rôle de « calmer » l'organisme. Dans une analogie bien connue, le SNS est impliqué dans les réponses physiologiques du type « *fight or flight* »<sup>4</sup>, alors que le SNP est davantage impliqué dans les réponses du type « *rest and digest* »<sup>5</sup>. Par exemple, l'activation du SNS produit (entre autres) une augmentation de la taille des pupilles, une augmentation du rythme cardiaque et une dilatation des voies respiratoires. Ces réponses permettent de préparer l'organisme à faire face aux situations stressantes. À l'inverse, l'activation du SNP engendre (entre autres) une diminution de la taille des pupilles, une diminution du rythme cardiaque et une constriction des voies respiratoires, qui permettent à l'organisme d'économiser de l'énergie et d'entrer dans une phase de digestion<sup>6</sup>.

Tel que souligné par Kivikangas et collab. (2010), l'utilisation des signaux physiologiques présente trois avantages importants dans l'étude de l'expérience de jeu. Premièrement, les signaux physiologiques sont pour la plupart involontaires et, en conséquence, ceux-ci (à l'inverse d'un questionnaire, par exemple) ne sont pas contaminés par « le style de réponse, la désirabilité sociale, l'interprétation de la formulation des questions, la limite de la mémoire du participant, ni par le biais des observateurs ("*observer bias*") ». Deuxièmement, les signaux physiologiques « peuvent être enregistrés automatiquement et en temps réel, sans affecter les habitudes naturelles du participant »<sup>7</sup>. Troisièmement, et toujours selon Kivikangas et collab. (2010), « les signaux physiologiques sont suffisamment sensibles pour détecter des variations subtiles, qui ne pourraient pas être détectées à l'oeil nu ».

Dans le cadre du présent projet, quatre mesures des signaux physiologiques ont été utilisées : l'électrocardiographie, l'activité électrodermale, l'activité respiratoire et l'électromyographie.

---

4. « Combattre ou fuir » ; traduction libre.

5. « Se reposer et digérer » ; traduction libre.

6. Pour davantage de détails concernant le système autonome, voir l'excellent livre de Tortora et Derrickson (2008).

7. Notons que ceci est valide si les appareils de mesures ne sont pas encombrants, comme certains appareils sans fils. Les appareils utilisés en laboratoire (Biopac MP150) limitent considérablement les mouvements du joueur, qui doit demeurer assis et relativement immobile durant l'expérience.

Dans le présent travail, les indices comportementaux font référence aux expressions faciales et aux mouvements de la tête. Ces derniers sont hautement informatifs de l'état affectif d'un individu, comme il sera discuté dans les sections suivantes. Les indices comportementaux considérés ici demandent un système d'enregistrement vidéo (p. ex. une webcaméra), ainsi qu'un système de reconnaissance des mouvements faciaux et des mouvements de la tête. Le fait que les indices comportementaux dépendent principalement d'un appareil d'enregistrement vidéo implique que ces derniers sont non intrusifs, ce qui signifie qu'ils peuvent être utilisés sans troubler l'expérience du joueur.

Dans ce travail, nous avons également testé l'ajout d'un autre indice comportemental : les entrées d'un contrôleur Xbox. Malgré que la littérature soit muette à ce sujet (le seul article recensé étant le travail de Sykes et Brown (2003)), il est possible que celles-ci puissent potentiellement être utilisées comme indicateurs de l'état affectif du joueur. Conséquemment, les entrées du contrôleur sont traitées dans le présent travail comme une modalité supplémentaire potentiellement indicative de l'expérience de jeu.

Utilisés conjointement, les signaux physiologiques et les indices comportementaux sont des indicateurs puissants de l'état affectif du joueur. Dans cette section, les différentes modalités physiologiques et comportementales utilisées dans ce travail sont introduites, et leurs liens avec l'état affectif sont présentés.

## **Les signaux physiologiques**

### **Électrocardiographie**

L'électrocardiogramme (ECG) est la mesure de l'activité électrique du coeur, associée aux ondes de dépolarisation et de polarisation qui se succèdent lors du cycle cardiaque. La figure 0.1 présente deux battements cardiaques tels que mesurés par un ECG typique. L'ECG permet d'imager les ondes P, Q, R, S, T et U, qui correspondent aux différentes étapes de polarisation et de dépolarisation du muscle cardiaque. Dans la mesure du rythme cardiaque et de sa variabilité, présentée ci-dessous, l'onde R du ECG est utilisée comme point de comparaison entre les battements.

Plusieurs mesures caractéristiques de l'activité cardiaque peuvent être extraites de l'ECG, notamment le rythme cardiaque et sa variabilité. Le rythme cardiaque (HR) correspond au nombre de battements cardiaque par unité de temps et est tradition-

nellement exprimé en battement par minute (BPM). Sa réciproque, la période cardiaque, correspond quant à elle au temps entre deux battements (voir figure 0.1).




FIGURE 0.1 – Exemple de l'électrocardiogramme (ECG) pour 2 battements cardiaques consécutifs mesuré dans une configuration d'électrodes II. Le complexe QRS correspond à la contraction des ventricules droit et gauche (Berntson et col-lab., 2007).<sup>8</sup>

L'analyse de la variabilité du rythme cardiaque (HRV) concerne les variations dans la durée des périodes cardiaques. Celle-ci est généralement effectuée dans les domaines d'analyse statistique et fréquentielle (Task Force, 1996). Quelques mesures fréquentielles typiques utilisées pour l'analyse de la HRV sont rapportées au tableau 0.1.

Tableau 0.1 – Mesures fréquentielles typiques utilisées pour l'analyse de la variabilité cardiaque et les bandes de fréquences associées. Tableau adapté du tableau 2 de Task Force, 1996.

Mesure	Unités	Description	Bande de fréquences
VLF	ms <sup>2</sup>	Puissance spectrale dans la bande VLF	≤ 0,04 Hz
LF	ms <sup>2</sup>	Puissance spectrale dans la bande LF	0,04 – 0,15 Hz
HF	ms <sup>2</sup>	Puissance spectrale dans la bande HF	0,15 – 0,5 Hz
LF/HF	–	Ratio de LF et HF	–

Bien que la HRV soit utilisée dans beaucoup de travaux (voir ci-dessous), celle-ci n'a pas été utilisée dans le présent projet. La raison est que la HRV nécessite des segments de signal d'une durée minimale de 1, 2 ou 5 minutes dépendamment des bandes de fréquences étudiées (Task Force, 1996), tandis que la durée des segments de signaux ECG est limitée, dans le cadre du présent projet, à une durée maximale de 1 minute (voir la section 1.3.1). En conséquence, comme une seule bande (c.-à-d. la bande HF) aurait pu être étudiée, les mesures associées à la HRV ont simplement été laissées de côté. Le lien entre la HRV et l'état affectif est tout de même présenté

8. Adaptation d'une image du domaine public récupérée sur <https://commons.wikimedia.org/wiki/File:Qrs.svg>

ci-dessous afin de rendre un portrait complet de l'utilisation de l'ECG dans la littérature.

Les changements d'activité cardiaque par rapport à un état de base (« baseline »), autant au niveau du rythme cardiaque que de sa variabilité, ont été associés à différentes émotions. Plusieurs études rapportent une augmentation du rythme cardiaque pour certaines émotions à valence négative, telles que la gêne (Hofmann et collab., 2006; Herral et Tomaka, 2002), l'anxiété (Croft et collab., 2004) ou la peur (Larsen et collab., 2008). Une augmentation du rythme cardiaque est également observée pour la surprise (Boiten, 1996), une émotion sans valence précise, et dans les émotions de joie et de bonheur, des émotions à valence positive. À l'inverse, une diminution du rythme cardiaque est observée pour des émotions de satisfaction (Nyklíček et collab., 1997) et de tristesse (Christie et Friedman, 2004). De façon intéressante, la relation observée entre le rythme cardiaque et l'amusement est ambiguë, plusieurs études rapportant des augmentations, des diminutions ou aucun changement du rythme cardiaque (Kreibig, 2010).

Certaines mesures statistiques et fréquentielles de la HRV ont également été étudiées lors de la provocation d'émotions. Notamment, la HRV diminue pour les émotions d'anxiété (Murakami et Ohira, 2007), de colère (Christie et Friedman, 2004; Marci et collab., 2007) ou de peur (Christie et Friedman, 2004; Gilissen et collab., 2007, 2008) et augmente avec l'amusement (Christie et Friedman, 2004).

Les changements d'activité cardiaque ne semblent pas permettre de différencier les émotions selon leur valence. En effet, dans sa revue systématique, Kreibig (2010) suggère plutôt que le rythme cardiaque pourrait permettre de différencier les émotions selon qu'elles engendrent ou non une réponse motrice : certaines émotions impliquant des éléments de passivité – comme la tristesse, le soulagement et la satisfaction – et d'autres menant plutôt à l'action – comme la colère, la peur et l'anxiété. Cette idée est également reliée à l'activation émotionnelle, qui correspond à l'intensité d'une émotion donnée (Russell, 1980; Lang, 1995).

### **Activité électrodermale**

L'activité électrodermale (EDA) décrit l'ensemble des phénomènes reliés aux modulations des propriétés électriques de la peau. Bien qu'il existe plusieurs méthodes pour mesurer l'EDA, ce terme sera utilisé à travers ce mémoire pour décrire la mesure exosomatique par courant direct de la conductivité dermale (voir (Boucsein,

2012), notamment le tableau 1.1 pour plus d'informations).

Un signal de l'EDA peut être divisé en deux composantes : le niveau tonique de conductivité dermale (SCL) et les réponses phasiques de conductivité dermale (SCR). Le SCL correspond au niveau global de conductivité de la peau alors que les SCRs sont associées à des événements ponctuels d'augmentation de conductivité. La figure 0.2 montre un exemple de décomposition d'un signal de l'EDA en SCL et SCR. Les SCRs peuvent ne pas être spécifiques à certains événements, et dans ce cas, elles sont appelées SCRs non spécifiques (nSCR). Les SCRs et nSCRs sont en pratique non distinguables dans un contexte de jeu vidéo, car chaque élément du jeu a le potentiel de causer une ou plusieurs SCRs. De plus, les nSCRs doivent être déterminées une à une en visionnant conjointement les séances de jeu et les signaux de l'EDA. Pour ces raisons, les SCRs spécifiques et non spécifiques n'ont pas été distinguées dans la suite de ce projet.




FIGURE 0.2 – Exemple d'un signal EDA et de ses composantes SCL et SCR.

Il a été proposé par Fredrikson et collab. (1998) que l'EDA pourrait être un indicateur d'une préparation motrice conditionnée par des processus cognitifs ou émotionnels. De la même manière, dans sa revue systématique sur les réponses du système nerveux autonome à 22 émotions différentes<sup>9</sup>, Kreibig (2010) remarque qu'une diminution de l'activité électrodermale accompagne les émotions de grande tristesse, de tristesse sans pleurs, de satisfaction et de soulagement, et rapporte une augmentation de l'EDA pour les 18 autres émotions. Pour expliquer cette observation, celle-ci suggère qu'une diminution de l'EDA pourrait être associée à une baisse de prépara-

9. Les 22 émotions revues par (Kreibig, 2010, tableau 2, p.401) sont les suivantes : colère, anxiété, dégoût (contamination), dégoût (blessure), gêne, peur, peur d'une menace imminente, tristesse sans pleurs, tristesse avec pleurs, tristesse anticipative, grande tristesse, affection, amusement, satisfaction, bonheur, joie, plaisir anticipatif visuel, plaisir anticipatif évoqué, fierté, soulagement, surprise et appréhension.

tion motrice, qui serait retrouvée dans les émotions qui n’engendrent pas d’actions, mais qui sont plutôt passives.

Le SCL permet d’étudier les états généraux d’activation (« arousal ») et de vigilance (« alertness ») (Dawson et collab., 2007). Par exemple, l’EDA a fréquemment été utilisée comme mesure du stress, définie comme un état de haute activation et de valence négative (Boucsein, 2012). Plus précisément, plusieurs recherches ont permis de montrer que des stimuli stressants évoqués en laboratoire (anticipation d’une décharge électrique, films montrant des accidents) étaient accompagnés (ou précédés) d’une augmentation du SCL (Lazarus, 1966; Nomikos et collab., 1968; Folkins, 1970). Finalement, la magnitude des SCRs a aussi été associée à l’activation émotionnelle rapportée (Cuthbert et collab., 1996).

### Activité respiratoire

L’activité respiratoire (RSP) est la mesure de la variation du volume pulmonaire lors des périodes d’inspiration et d’expiration. Celle-ci peut être mesurée notamment par une ceinture extensible placée au niveau de l’abdomen couplée à un capteur de tension. Cette technique a été utilisée dans le cadre de ce projet. Un exemple de signal de la RSP est présenté à la figure 0.3. Le tableau 0.2 contient les mesures pouvant être extraites à partir du RSP.




FIGURE 0.3 – Exemple d’une mesure de l’activité respiratoire (RSP) avec une ceinture extensible. L’amplitude est donnée en unités standardisées selon la déviation standard du signal et le signal est centré sur la moyenne.

Plusieurs travaux rapportent une influence de l’état émotionnel sur le rythme et le volume respiratoires. En effet, le niveau d’anxiété (Masaoka et Homma, 1999, 2001) et la peur (Rainville et collab., 2006; Stemmler, 2004; Etzel et collab., 2006) sont tous deux corrélés avec une augmentation du rythme respiratoire, alors que ce dernier diminue avec la tristesse (Kunzmann et Grünh, 2005; Etzel et collab., 2006). Quant

Tableau 0.2 – Mesures dérivées de la mesure de la respiration. Tableau adapté du tableau 10.1 de Lorig (2007).

Mesure	Unités	Description
RR	Respiration/minute	Rythme respiratoire
$V_{in}$	L	Volume inspiratoire (relatif)
$V_{ex}$	L	Volume expiratoire (relatif)
$\frac{V_{in}}{V_{ex}}$	-	Rapport entre $V_{in}$ et $V_{ex}$
$t_{in}$	s	Temps d'inspiration
$t_{ex}$	s	Temps d'expiration
$\frac{t_{in}}{t_{ex}}$	-	Rapport entre $t_{in}$ et $t_{ex}$

à lui, le volume respiratoire (inspiratoire et expiratoire) diminue avec la peur (Ritz et collab., 2005; Van Diest et collab., 2009), mais augmente avec une émotion de tristesse (Kunzmann et Grün, 2005; Etzel et collab., 2006).

Dans le même ordre d'idées, Boiten et collab. (1994) dégage quatre profils respiratoires associés à différents états émotionnels. Selon lui, une respiration rapide et profonde est associée à de l'excitation (Boiten et collab., 1994) et une respiration lente et profonde, à de la relaxation (Boiten, 1993). À l'inverse, une respiration rapide et peu profonde est une conséquence de tâches mentales stressantes (Carroll et collab., 1986; Turner et collab., 1987; Boiten, 1993) et finalement, une respiration lente et peu profonde est associée à une tristesse passive ou à du bonheur (calme) (Averill, 1969; Nakamura, 1984).

Il a été soulevé par Boiten et collab. (1994) que bien que l'activité respiratoire soit influencée par le niveau d'activation émotionnelle, une relation réciproque n'a pas été observée pour la valence émotionnelle. En conséquence, l'activité respiratoire pourrait ne pas être suffisante pour déterminer le caractère positif ou négatif d'un état émotionnel donné.

## Électromyographie

L'électromyographie de surface est une mesure de l'activité électrique causée par la contraction d'un muscle. L'électromyogramme (EMG) est mesuré via des électrodes placées à la surface de la peau, au-dessus du muscle d'intérêt. La figure 0.4 présente un exemple de signal de l'EMG pour le muscle long abducteur du pouce de la main droite, seul muscle étudié dans le cadre de ce projet<sup>10</sup>.

10. Ce dernier permet d'actionner les contrôles pour positionner la caméra et activer les touches A, B, X et Y du contrôleur Xbox (voir section 1.2.2)






FIGURE 0.4 – Exemple d’un signal EMG pour le muscle long abducteur du pouce.

L’amplitude de l’EMG peut permettre d’estimer la force exercée par un muscle (Staudenmann et collab., 2010), cette relation étant même linéaire pour certains muscles comme le muscle adducteur du pouce ou le muscle soléaire, par exemple (Woods et Bigland-Ritchie, 1983). Il a été démontré par Maier et Hepp-Reymond (1995) que l’EMG et la force étaient peu linéaire dans le cas du muscle long abducteur du pouce. Notons que certaines relations non linéaires – une relation parabolique par exemple comme cela a été observé pour certains muscles (Farina et collab., 2016) – pourraient tout de même permettre d’extraire une approximation correcte de la force.

Pour caractériser le niveau d’activation du muscle sur lequel l’EMG a été mesuré, il est recommandé de travailler avec l’EMG rectifié moyen (« Average Rectified EMG ») (Merletti et Di Torino, 1999). Ce dernier correspond à la moyenne, sur un intervalle temporel  $T$ , de la valeur absolue de l’EMG.

## Les indices comportementaux

### Reconnaissance des expressions faciales et mesure des contractions musculaires faciales

Les expressions faciales peuvent être caractérisées à l’aide du « Facial Action Coding System » (FACS), un système d’annotation des expressions faciales largement utilisé mis au point par Ekman et Friesen (1976, 1978). Le FACS utilise 44 unités d’action (AU) rendant compte des mouvements particuliers à chaque expression faciale. Les AUs forment un ensemble complet décrivant toutes les mouvements possibles du visage (Ekman, 1997) et sont basés sur l’anatomie musculaire de ce dernier<sup>11</sup>. Le tableau 0.3 contient quelques exemples d’AUs ainsi que les muscles impliqués dans leur production.

Tableau 0.3 – Exemples d’unités d’action selon le FACS de Ekman et Friesen (1978).  
Tableau adapté de Ekman et Friesen (1976, p.65).

AU	Muscle(s) impliqué(s)	Nom FAC
1	<i>Frontalis, Pars medialis</i>	Remontée de la partie interne des sourcils
6	<i>Orbicularis oculi, Pars orbitalis</i>	Remontée des joues
12	<i>Zygomaticus major</i>	Étirement du coin des lèvres
27	Ptérygoides; muscle digastrique	Bâillement
44	<i>Corrugator supercilii</i>	Rapprochement des sourcils

Traditionnellement, les AUs sont extraites à partir d’images fixes ou de vidéos par un annotateur certifié. Cependant, certains logiciels de reconnaissance d’expressions faciales, tels qu’*OpenFace* (Baltrusaitis et collab., 2018), permettent désormais d’effectuer cette tâche de manière automatique.

Le lien entre les expressions faciales et les émotions a été étudié notamment par Paul Ekman, pionnier du domaine (voir p. ex. Ekman (1993)). Dans ses travaux, ce dernier a soulevé l’existence d’émotions de base pour lesquelles il existerait des familles d’expressions faciales distinctes et universelles (Ekman, 1992). Ces émotions de base (joie, tristesse, peur, colère et dégoût) sont associées à des combinaisons d’AUs particulières. Celles-ci sont présentées au tableau 0.4.

Tableau 0.4 – Émotions de base et unités d’action associées (tableau adapté de Ekman et Friesen (1983)).

Émotion	AUs impliqués
Joie	6, 12
Tristesse	1, 4, 15
Surprise	1, 2, 5, 26
Peur	1, 2, 4, 5, 20, 26
Colère	4, 5, 7, 23
Dégoût	9, 15, 16

La contraction de certains muscles faciaux est informative de la valence émotionnelle. En effet, Lang et collab. (1993) ont observé que l’activation du zygomatique majeur<sup>12</sup> (ZM) et du corrugateur du sourcil<sup>13</sup> (CS) – impliqués respectivement dans la production du sourire et du froncement des sourcils – étaient corrélées avec la

11. Pour la liste complète des AUs et les muscles associés, voir les travaux de Ekman et Friesen (1976); Ekman et collab. (2002), tableau 1, page 65.

12. *Zygomaticus major*

13. *Corrugator supercilii*

valence d'émotions rapportées. Plus spécifiquement, ces derniers ont rapporté que la contraction du CS était inversement proportionnelle à la valence, indiquant une activité du CS moindre pour les émotions à valence positive (sourcils détendus) et accrue pour celles à valence négative (sourcils froncés). Inversement, les auteurs ont rapporté que la contraction du ZM était liée à la valence selon une relation quadratique, signifiant une plus grande activité du ZM pour des émotions à valence faible ou très grande, ainsi qu'une plus faible activité pour les émotions à valence neutre. Les résultats de Lang et collab. (1993) ont été reproduits dans plusieurs travaux ultérieurs (Larsen et collab., 2003; Larsen et Norris, 2009; Tan et collab., 2012), ce qui semble indiquer que le ZM et le CS sont des indicateurs fiables de la valence émotionnelle.

### **Captation des mouvements de la tête**

Les mouvements de la tête peuvent être mesurés à l'aide d'une webcam et d'un logiciel approprié Baltrusaitis et collab. (2018). Ce dernier utilise la position des yeux et de la bouche pour construire un modèle de la tête, qui permet ensuite de déterminer la position de celle-ci.

La position de la tête peut-être un décrite dans un système de coordonnées à 6 degrés de liberté (3 en translation et 3 en rotation). Celui utilisé dans le cadre de ce projet est illustré à la figure 0.5.

Les mouvements de la tête sont importants dans un contexte conversationnel, car « ceux-ci marquent la structure du discours et permettent de réguler l'interaction » (McClave, 2000). Par exemple, certains mouvements de la tête sont associés avec des expressions verbales exprimant « l'inclusivité, l'intensification et l'incertitude » (McClave, 2000).

Quelques chercheurs ont utilisé les mouvements de la tête pour déterminer différents états émotionnels. Gunes et Pantic (2010) ont utilisé les mouvements de la tête lors d'une conversation pour prédire le niveau d'attention d'un utilisateur selon un modèle à cinq dimensions émotionnelles : l'activation, l'anticipation, l'intensité, la domination (« power ») et la valence. Asteriadis et collab. (2009) ont utilisé la position de la tête, conjointement à de l'oculométrie, pour déterminer le niveau d'attention d'un utilisateur. Caridakis et collab. (2010) ont extrait différents indices d'expressivité à partir des mouvements de la tête. Ces derniers ont conclut que ces indices d'expressivité permettaient d'améliorer les performances d'un système de détection

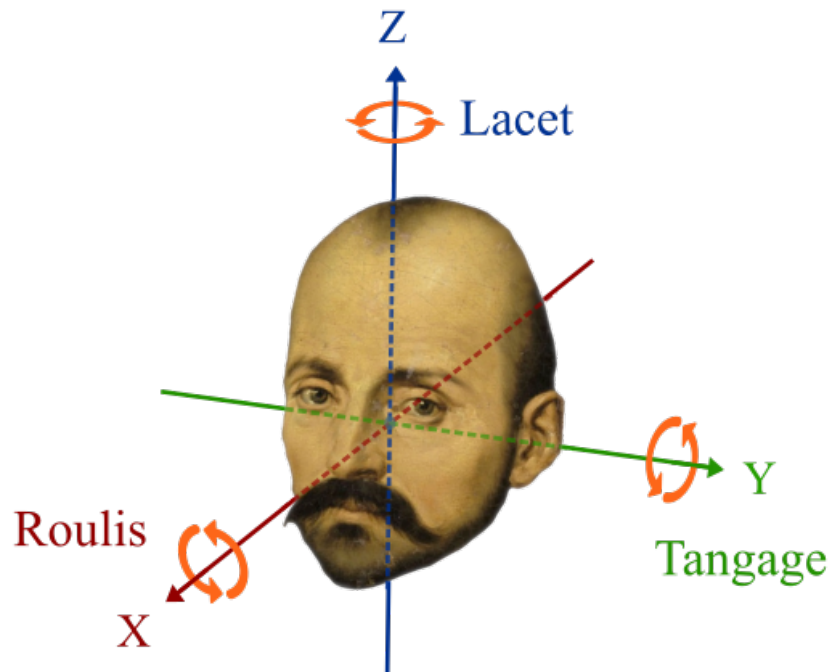


FIGURE 0.5 – Le système de coordonnées décrivant les différentes positions de la tête<sup>14</sup>. Ce dernier compte 6 degrés de liberté : 3 degrés en translation (X, Y, Z) et 3 degrés rotationnels (roulis, tangage, lacet).

des émotions comportant déjà d'autres modalités (p.ex. des expressions faciales).

## **Modélisation de l'expérience de jeu à partir des signaux physiologiques et des indices comportementaux par apprentissage automatique : revue des travaux présents dans la littérature**

Cette section propose un bref survol des travaux utilisant des techniques d'apprentissage automatique pour modéliser l'expérience de jeu à partir de signaux physiologiques et/ou d'indices comportementaux.

Bien que toutes les études présentées ici aient des objectifs de recherche et des méthodes similaires, celles-ci abordent l'expérience de jeu sous des angles différents. Pour cette raison et dans le but de faciliter la lecture, les études présentées ci-dessous

<sup>14</sup>. La tête en question est tirée d'un portrait de Michel de Montaigne, célèbre philosophe et essayiste.

ont été regroupées selon les trois conceptions de l'expérience de jeu les plus utilisées dans la littérature relevée : le *flow*, les états émotionnels et le plaisir.

## Le *flow*

Liu et collab. (2009) se sont intéressés à l'utilisation du stress pour adapter la difficulté d'un jeu. Ceux-ci ont recueilli les signaux physiologiques (ECG, EMG, cardiographie de l'impédance, PPG, EDA et ST) de 15 participants dans le but d'entraîner un classificateur capable de déterminer le niveau de stress d'un joueur. Les jeux *Pong* (Atari, 1972) et *Anagram* (voir Pecchinenda (1996)), tous deux sur ordinateur, ont été utilisés pour l'étude, car il était facile de les modifier pour moduler le niveau de stress du joueur (par exemple, augmenter la vitesse de la balle dans le jeu de *Pong*).




FIGURE 0.6 – Jeu de *Pong*. Image tirée du domaine public.

Les niveaux de stress étaient périodiquement rapportés par les joueurs, à un intervalle variant entre 2 et 4 minutes, sous forme d'une cote sur une échelle de Likert à 9 niveaux. Les auteurs ont obtenu un taux de classement de 88,9% avec un SVM pour 3 classes de stress (faible, moyenne et élevée).

Dans une étude similaire, Chanel et collab. (2011) ont fait l'acquisition des signaux physiologiques (EEG, EDA, ST, RSP et BVP) de 20 participants alors qu'ils jouaient à une version sur ordinateur du jeu *Tetris* (Pajitnov, 1984). Durant l'expérience, les joueurs devaient rapporter le niveau de difficulté perçu du jeu (facile, moyen et difficile). Chaque niveau de difficulté était alors associé à un état émotionnel : ennui (facile), engagement (difficulté moyenne) et anxiété (difficile). En effectuant une fu-

sion des décisions de trois classificateurs – c.-à-d. LDA, QDA et SVM – les auteurs ont obtenu un taux de classification de 63% pour les 3 niveaux de difficulté.

À la différence des travaux présentés précédemment, Shaker et collab. (2013) ont utilisé seulement des indices comportementaux (actions et interactions du joueur avec le jeu et mouvements de la tête) pour modéliser l'expérience de jeu. Pour ce faire, 58 joueurs (28 H, 30 F) âgés de 22 et 48 ans ont joué au jeu *Infinite Marios Bros*, une version publique du jeu classique *Super Mario Bros* (Nintendo, 1985). Après chaque séance de jeu, les joueurs devaient noter leur expérience de jeu sur une échelle de Likert à 5 niveaux pour 3 états émotionnels (engagement, frustration et « *challenge* »). En utilisant un MLP et de l'apprentissage de préférence (« preference learning »), les auteurs ont obtenu des taux de réussite de 91%, 92% et 88% pour les états d'engagement, de frustration et de *challenge* respectivement.

Les travaux de Liu et collab. (2009) et Chanel et collab. (2011) ont tenté de modéliser un même aspect de l'expérience de jeu, soit la manière dont le joueur perçoit et réagit à la difficulté du jeu. L'évaluation de la difficulté perçue (ou son estimation informée par l'évaluation du stress du joueur) permet d'adapter le niveau de difficulté du jeu afin que l'expérience de jeu demeure optimale, en évitant l'ennui si le jeu est trop facile ou la frustration s'il est trop difficile. Ceci n'est pas sans rappeler la théorie de l'expérience optimale : la théorie du *flow* (Csikszentmihalyi, 1990, 1997, 2014; Chen, 2007). L'état de *flow* décrit, entre autres, un état d'absorption complète durant lequel la perception du temps et la conscience de soi sont altérées, ce qui provoque un engagement complet dans la tâche entreprise. Selon Csikszentmihalyi (1990), cet état est atteint lorsqu'un individu effectue une tâche dont le niveau de difficulté est en équilibre avec ses propres capacités. La conception de l'expérience de jeu retrouvée dans le travail de Shaker et collab. (2013) semble également référer à des éléments de la théorie *flow*. En effet, le concept de « *challenge* » utilisé par ces derniers fait partie intégrante de l'expérience du *flow* (Nakamura et Csikszentmihalyi, 2014), tandis que la « frustration » s'apparente au concept d'« apathie », qui émerge lorsque les capacités du sujet sont trop faibles par rapport au degré de difficulté de la tâche. En ce qui concerne l'« engagement », celui-ci est parfois perçu comme une conséquence du *flow*, parfois comme une cause, toutefois, il n'y a pas vraiment de consensus à ce sujet considérant la ressemblance entre ces deux construits (Rupayana, 2008).

Cependant, tel que remarqué par Caroux et collab. (2015), il est possible que le concept de *flow* puisse ne pas être applicable à la sphère des jeux vidéo, puisque

le *flow* a été défini et étudié en dehors de celle-ci. Par exemple, le fait que l'échec soit une composante importante des jeux vidéo pourrait être en contradiction avec la théorie du *flow*, dans laquelle les actions sont orientées vers des buts et non vers l'échec de ces buts (Juul, 2013). En effet, l'échec peut être perçu positivement par les joueurs comme un élément important d'une expérience de jeu agréable (Ravaja et collab., 2008). Les difficultés et les échecs sont caractéristiques des moments de victoire, de succès, d'apprentissage et d'amélioration, ce qui explique en grande partie l'expérience positive associée aux jeux à très grande difficulté (Petralito et collab., 2017). En somme, quoique le concept de *flow* puisse être important pour modéliser l'expérience de jeu, certaines études pointent vers d'autres directions. .

## Les états émotionnels

L'expérience de jeu est également reliée à l'expérience émotionnelle du joueur (Caroux et collab., 2015). Vachiratamporn et collab. (2013) se sont intéressés aux réactions de peur des joueurs alors qu'ils jouaient à *Slender : The Eight Pages* (Parsec Productions, 2012), un jeu d'horreur dans lequel les joueurs doivent récupérer les 8 pages d'un carnet et en même temps éviter d'être attrapé par le *Slender Man*, une créature paranormale. Pour étudier la peur des joueurs durant la partie, les auteurs ont mesuré les signaux physiologiques (ECG et EEG) des joueurs et ont monitoré l'utilisation de la souris et du clavier. Au total, 11 participants (6 H, 5 F) âgés de 21 à 32 ans ont été recrutés. Après chaque séance de jeu, les joueurs devaient indiquer leur état émotionnel selon 3 classes avant (neutre, anxiété ou suspense) et après (peur faible, moyenne ou élevée) un évènement provoquant de la peur (c.-à-d. une apparition de *Slender Man*). En utilisant les caractéristiques extraites de l'ECG pour prédire les 6 états émotionnels, les auteurs ont obtenu un taux de classement de 90,8% avec un classificateur C4.5.

Dans le même ordre d'idées, Nogueira et collab. (2014) ont extrait les signaux physiologiques (EDA, BVP et EMG<sup>15</sup>) provenant de 24 participants âgés entre 19 et 28 ans lors de 72 séances de jeu. Le jeu d'horreur *Vanish* (3DrunkMen, 2012) a été utilisé pour l'étude. Les auteurs ont d'abord utilisé le modèle à logique floue développé par Mandryk et Atkins (2007) pour obtenir les réponses émotionnelles des joueurs à certains évènements du jeu dans l'espace valence-activation (voir Russell (1980); Posner et collab. (2005)). Ceux-ci ont ensuite utilisé un MLP pour prédire les ré-

---

15. Zygomaticus major et corrugator supercilii.

ponses émotionnelles à divers évènements du jeu. Leur meilleur modèle a atteint un taux d'erreur de 23,09% sur l'activation et de 31,2% sur la valence.

Modéliser et détecter les états émotionnels est une pratique directement en lien avec le domaine de l'informatique affective (« *affective computing* »). Ce domaine soutient que les systèmes informatiques devraient être capables de reconnaître et de mettre à profit les états émotionnels de leurs utilisateurs (Picard, 2000b). Les émotions sont définies comme des états courts (quelques secondes à quelques minutes), reflétant une évaluation émotionnelle d'un état interne ou externe et étant associées à des tendances comportementales et des biais cognitifs (Hudlicka, 2008b). Les émotions sont communément représentées selon les dimensions de la valence et de l'activation (Kotsia et collab., 2016). La valence est associée au caractère positif ou négatif des émotions, tandis que l'activation est reliée à leur caractère calme ou excité (Russell, 1980).

Dans les études présentées ci-dessus, Nogueira et collab. (2014) ont étudié les réponses émotionnelles de joueurs sous forme de la valence et d'activation, tandis que Vachiratamporn et collab. (2013) ont plutôt tenté de reconnaître les manifestations physiologiques de différents niveaux de suspense et de peur. Dans les deux cas, les états émotionnels étaient associés à des évènements précis et l'objectif était de connaître la manière dont les joueurs réagissaient à ceux-ci. Les émotions sont assurément nécessaires pour mieux comprendre l'expérience de jeu, car elles sont notamment informatives de la réaction du joueur à différents éléments du jeu. D'ailleurs, le domaine de « *affective gaming* » a pour objectif d'intégrer les émotions aux jeux vidéo afin d'assurer une expérience de jeu qui comporte une certaine part de « *challenge* » tout en étant agréable (Hudlicka, 2008b). À ce sujet, plusieurs études ont été menées pour comprendre comment les émotions pourraient être intégrées à la conception de jeux vidéo adaptatifs (voir par exemple la synthèse de Karpouzis et Yannakakis (2016)), ce qui semble être une avenue prometteuse.

## **Le plaisir**

Une autre approche pour modéliser l'expérience de jeu est d'utiliser le plaisir rapporté par le joueur. Celle-ci a été proposée et explorée par Chamberland et collab. (2015), Clerico et collab. (2016) et Fortin-Cote et collab. (2018) dans le contexte du projet FUNii.






FIGURE 0.7 – Le facteur-fun et l’interface USB utilisée pour sa mesure. Le facteur-fun se situe entre -100 et 100, les valeurs positives étant associées à du plaisir et les valeurs négatives, à du non-plaisir. Image adaptée de Chamberland et collab. (2015).

Chamberland et collab. (2015) ont été les premiers à suggérer et tester une méthode pour mesurer en continu le plaisir d’un joueur dans un contexte de jeu vidéo, nommé le facteur-fun (« *funmeter* » ; Fortin-Cote et collab. (2018)). Le facteur-fun est une mesure auto rapportée et continue du niveau de plaisir d’un joueur. Celui-ci est mesuré après une séance de jeu, durant un visionnement de cette dernière par le joueur. Le joueur note en continu sur une échelle de -100 à 100, via un contrôleur rotatif, son niveau de plaisir durant la séance de jeu. La figure 0.7 montre un exemple du facteur-fun ainsi que le contrôleur rotatif utilisé pour sa mesure.

Clerico et collab. (2016) ont mesuré les signaux physiologiques (ECG, RSP, EMG<sup>16</sup> et EDA) de 62 participants alors qu’ils jouaient au jeu vidéo *Assassin’s Creed : Unity*. Lors d’un visionnement de leur séance, les joueurs devaient rapporter, sous forme de facteur-fun, leur niveau de plaisir ressenti lors de la partie. Les auteurs ont ensuite créé des classes à partir de la dérivée du facteur-fun (pour détecter les changements de plaisir) et de la valeur absolue du facteur-fun. Les auteurs ont utilisé une fusion de 3 classificateurs binaires SVM afin de déterminer le plaisir du joueur à partir des différents signaux physiologiques. Les auteurs n’ont pas obtenu des taux de classements significativement différents de ceux d’un classificateur aléatoire dans le cas où les classificateurs étaient testés sur les données inter participantes, tandis que ces résultats étaient significatifs dans le cas intra participant. Il est cependant difficile de conclure sur les performances du modèle complet, puisque les résultats de classification pour la cascade des 3 classificateurs n’ont pas été fournis par les

16. Longus abductor pollicis.

auteurs. Or, comme les classificateurs sont interdépendants, il est fort probable que la performance combinée des 3 classificateurs soit très faible.

Dans un travail connexe effectué par le même groupe, Fortin-Cote et collab. (2018) ont recueilli les signaux physiologiques (ECG, RSP, EMG<sup>17</sup> et EDA) et les indices comportementaux (événements dans le jeu, oculométrie, mouvements de la tête et unités d'action du visage) de 218 participants âgés de 18 à 35 ans. Ces données ont été recueillies alors que les participants jouaient aux jeux *Assassin's Creed : Unity* (Ubisoft, 2014) ou *Assassin's Creed : Syndicate* (Ubisoft, 2015). Utilisant encore une fois le plaisir ressenti les facteurs-fun, les auteurs ont testé divers classificateurs (kNN, MLP, SVM, RF, LR, AB et XGB) pour obtenir un taux de classement final de 41,5% (kNN) sur 3 classes extraites de la mesure de plaisir (plaisir faible, neutre et élevé).

Parallèlement au projet FUNii, la modélisation du plaisir en contexte de jeu vidéo à partir de signaux physiologiques a également été exploré par Čertický et collab. (2019). À partir des données physiologiques (HR, RSP, GSR) et comportementales (mesures de l'attention, de la méditation et de la fréquence de clignement des yeux) de 31 participants (26 H, 5 F) âgés entre 20 et 40 ans, les auteurs ont entraîné un modèle supervisé afin de prédire le plaisir d'un joueur de *Dota 2* (Valve, 2013). Dans cette étude, le plaisir des joueurs est représenté sur une échelle de Likert à 5 points, une valeur de 1 représentant un plaisir faible et une valeur de 5, un plaisir élevé. Avec un classificateur RF, Čertický et collab. (2019) ont obtenu un taux de classement de 96,04%. Ce résultat, quoique surprenant, doit être considéré avec réserve. En effet, la méthodologie proposée par Čertický et collab. (2019) pour l'entraînement du modèle laisse à penser que ce dernier ait pu sur apprendre le jeu de données. En effet, ceux-ci ne semblent pas avoir pris les précautions nécessaires pour éviter qu'il y ait des fuites d'information entre les jeux d'entraînement et de test (ou du moins la méthodologie proposée ne l'indique pas), ce qui pourrait avoir eu comme conséquence des résultats trop optimistes. De plus, il est attendu qu'une certaine erreur irréductible empêche le classificateur d'atteindre un niveau de performance aussi élevé. Cette erreur serait explicable par le caractère hautement subjectif du « plaisir » tel que noté par les participants, mais également par le fait qu'on peut s'attendre à des variations dans la manière d'utiliser l'échelle de Likert proposée par les auteurs. Bref, il est raisonnable de s'attendre à un certain niveau de bruit dans le jeu de données, ce qui se traduirait par une erreur irréductible sur les performances d'un modèle supervisé. Or, les résultats obtenus par Čertický et collab. (2019) semblent

---

17. Longus abductor pollicis.

trop optimistes considérant la tâche de classification proposée et la méthodologie suivie. La validité de leur résultats nous apparaît donc discutable.

Dans les travaux de Clerico et collab. (2016) et Fortin-Cote et collab. (2018), le plaisir a été représenté à l'aide du facteur-fun. Selon ces auteurs, l'utilisation des facteurs-fun permet d'obtenir une résolution temporelle très fine de l'expérience des joueurs, qui n'est pas réduite à un questionnaire en fin de partie, mais qui s'échelonne sur la séance de jeu entière. De plus, sa mesure ne perturbe pas l'expérience de jeu, puisque celle-ci est effectuée après que la partie soit terminée.

## Présentation de la problématique de recherche

Cette section présente la problématique de recherche qui fait l'objet de ce mémoire. Comme il en est question ci-dessous, celle-ci émerge des limites des travaux de Clerico et collab. (2016) et Fortin-Cote et collab. (2018), qui ont été menés dans le cadre du projet FUNii.

L'objectif de Clerico et collab. (2016) et Fortin-Cote et collab. (2018) était de proposer un modèle d'apprentissage automatique supervisé permettant de déterminer le plaisir d'un joueur à partir des signaux physiologiques et des indices comportementaux. Bien que Clerico et collab. (2016) aient atteint des taux de classement de 70% pour un des 3 classificateurs, les performances des autres classificateurs de l'étude ne dépassent pas significativement la chance dans plusieurs cas. On retrouve une situation semblable dans les travaux de Fortin-Cote et collab. (2018), qui n'ont obtenu qu'un taux de classement de 8% supérieur à un classificateur aléatoire.

Plusieurs facteurs pourraient expliquer ces performances modestes. Tout d'abord, au niveau des classes extraites à partir du facteur-fun pour la tâche de classification, celles extraites par Clerico et collab. (2016) sont basées exclusivement sur la valeur absolue et les changements du facteur-fun. Il en est de même chez Fortin-Cote et collab. (2018), où les meilleurs résultats ont été obtenus en utilisant la valeur absolue du facteur-fun. Dans un contexte d'annotation continue d'émotion, certains auteurs ont souligné que des annotateurs avaient plus de facilité à annoter des émotions de manière relative plutôt qu'absolue (Metallinou et Narayanan, 2013; Martínez et collab., 2014). Cela signifie qu'il serait plus facile, par exemple, d'identifier une augmentation d'activation émotionnelle que d'évaluer la valeur exacte de cette activation en un point donné. Il est fort probable que ce phénomène se transpose également au

facteur-fun, qui est un protocole d’annotation continue, et donc que les variations du facteur-fun soient plus informatives du plaisir que sa valeur absolue<sup>18</sup>.

De plus, Clerico et collab. (2016) et Fortin-Cote et collab. (2018) n’ont pas tenu compte des artefacts présents dans le facteur-fun –les pics de facteur-fun– qui sont causés par une cotation temporellement très précise de la part du participant<sup>19</sup>. Or, cet artefact de la cotation en continu du plaisir peut induire des associations données-classe erronées, affectant directement les performances des classificateurs utilisés. En conséquence, tenir compte de cet artefact lors de la création de classes de plaisir pourrait permettre d’identifier des classes plus informatives de l’expérience de jeu et, par le fait même, de faciliter la tâche de classification.

Finalement, les caractéristiques extraites des signaux physiologiques et des indices comportementaux utilisées pour la tâche de classification du plaisir par Clerico et collab. (2016) et Fortin-Cote et collab. (2018) montrent un certain décalage avec ce qui est présent dans la littérature. En effet, dans ces travaux, les caractéristiques extraites s’inspiraient davantage de méthodes de traitement de signal classiques (analyse spectrale, notamment) que des différentes approches d’extraction de caractéristiques proposée dans les travaux similaires ayant utilisé des signaux physiologiques et des indices comportementaux (Picard, 2000b; Chanel et collab., 2011; Vachiratamporn et collab., 2013; Nogueira et collab., 2014; Chanel et collab., 2017). Donc, une extraction de caractéristique s’appuyant davantage sur des travaux similaires pourraient permettre d’augmenter les capacités prédictives du modèle supervisé.

En somme, le présent projet vise donc à proposer un modèle supervisé permettant de discriminer les différents états de plaisir d’un joueur de jeu vidéo à partir de ses signaux physiologiques et indices comportementaux. Ce travail de recherche se distingue des travaux antérieurs effectués dans le cadre du projet FUNii au niveau des points suivants :

- seules les variations du facteur-fun sont considérées informatives du plaisir du joueur ;
- les pics de facteur-fun sont pris en compte durant la création des classes ;
- l’extraction de caractéristiques des signaux physiologiques et des indices com-

---

18. À travers ce mémoire, nous avons utilisé le terme « valeur absolue » du facteur-fun pour décrire la valeur du facteur-fun. Ce terme est mis en opposition avec la « valeur relative » du facteur-fun, qui se rapporte aux changements de facteur-fun (dérivée).

19. Cet artefact est traité en détail au chapitre 2

portementaux s'appuient sur des travaux similaires présents dans la littérature.

- la longueur des époques pour l'extraction de caractéristiques est justifiée par une analyse approfondie des facteurs-fun et des signaux physiologiques utilisés.

## Objectifs

L'objectif global de ce projet de recherche est d'évaluer d'implémenter un système de détection du plaisir à partir de données physio-comportementales, qui pourrait être utilisé dans un jeu adaptatif. Plus précisément, l'objectif global de ce projet de recherche est d'entraîner et de tester les performances d'un classificateur permettant de reconnaître différents états de plaisir à partir des signaux physiologiques et des indices comportementaux en contexte de jeu vidéo, et ce à partir des données recueillies dans le cadre du projet FUNii.

L'objectif global du projet peut être divisé en cinq objectifs spécifiques :

1. extraire des caractéristiques des signaux physiologiques et les indices comportementaux et identifier une longueur d'époque optimale ;
2. créer des classes à partir de la valeur continue de plaisir pour la tâche de classification tenant compte des artefacts dans le facteur-fun ;
3. entraîner différents classificateurs (SVM, *k*NN et RF) sur les caractéristiques et les classes extraites de la base de données du projet FUNii ;
4. déterminer les signaux physiologiques et les indices comportementaux les plus informatifs pour la tâche de classification du plaisir ;
5. tester les performances en généralisation de différents modèles d'apprentissage automatique supervisé en faisant varier la longueur des époques et les classes de plaisir utilisées, et identifier le modèle le plus performant.

## Organisation du mémoire

Le reste de ce mémoire est organisé selon trois chapitres. Le deuxième chapitre présente la base de données FUNii, dont les données ont été utilisées tout au long de ce

mémoire. Les mesures dérivées des signaux physiologiques et des indices comportementaux retrouvées dans la littérature y sont décrites en détail, et les différentes caractéristiques extraites pour chaque mesure y sont également détaillées. Différentes longueurs d'époques possibles y sont considérées pour l'entraînement des classificateurs, basées notamment sur des propriétés de certains signaux physiologiques et sur l'analyse des changements dans le facteur-fun.

Le troisième chapitre concerne quant à lui la création de classes à partir du facteur-fun. Une revue des classes créées à partir du facteur-fun dans les travaux antérieurs (du projet FUNii) y est effectuée et une discussion concernant les caractéristiques générales des facteurs-fun y est proposée. De plus, deux propositions concernant le plaisir du joueur y sont établies et une méthode originale pour la création de classes à partir du facteur-fun y est détaillée.

Finalement, le quatrième chapitre présente la création des différents jeux de données ainsi que la méthodologie d'entraînement pour les trois classificateurs considérés, soit les modèles  $k$ NN, SVM et RF. On y présente la manière dont les classificateurs ont été entraînés pour diverses longueurs d'époques ainsi qu'avec deux types de classes, incluant les classes créées avec la méthode originale proposée au troisième chapitre. Les résultats de l'entraînement, l'importance des différentes modalités physio-comportementales, la création de classes à partir du facteur-fun ainsi que les limites du présent travail y sont également discutés.

# Chapitre 1

## **Extraction de caractéristiques à partir des signaux physiologiques et des indices comportementaux des joueurs de la base de données FUN*ii***

Dans ce chapitre, la méthodologie suivie pour l'extraction de caractéristiques à partir de la base de données FUN*ii* est décrite. Afin d'établir le contexte ayant mené au présent projet de recherche, la base de données FUN*ii* est d'abord présentée. Les différentes mesures extraites des signaux physiologiques et des indices comportementaux sont ensuite détaillée et le processus d'extraction des caractéristiques utilisées lors de l'entraînement du modèle supervisé est décrit.

## 1.1 Mise en contexte : la base de données FUNii

Ici, un bref survol de la méthodologie suivie pour la collecte de données de la base de données FUNii est effectué. La mise en place de cette dernière étant antérieure au présent projet, une description exhaustive de la méthodologie utilisée par Clerico et collab. (2016); Fortin-Cote et collab. (2018); Beaudoin-Gagnon et collab. (2019) sortirait du cadre de ce mémoire. Le lecteur intéressé pourra cependant se référer à ces articles pour davantage de détails.

Dans le cadre du projet FUNii, 219 participants (183H, 36F) âgés entre 18 et 35 ans ( $M. = 25,4$ ;  $E.T. = 4,6$ ) ont joué à deux missions de l'un ou l'autre des jeux *Assassin's Creed : Unity* (ACU; 103 participants) et *Assassin's Creed : Syndicate* (ACS; 116 participants). Durant chaque séance de jeu (d'une durée de 5 à 15 minutes), les signaux physiologiques (ECG, EDA, RSP et EMG<sup>1</sup>) et les indices comportementaux (oculométrie, pupillométrie, mouvements faciaux et position de la tête) étaient enregistrés. Les signaux physiologiques ont été mesurés à l'aide d'un *Biopac M150* (fréquence d'échantillonnage de 1000 Hz), tandis que les indices comportementaux ont été recueillis avec un système de suivi du regard *Smart Eye Pro* (120 Hz) et une webcaméra (24 images/seconde). La webcaméra, attachée à l'écran de l'ordinateur du participant, filmait le haut du corps des participants durant la séance de jeu (de la taille à la tête). Les vidéos produites ont permis d'extraire les unités d'action (AU) et les mouvements de la tête en six degrés de liberté de chaque participant à l'aide du logiciel OpenFace (Baltrusaitis et collab., 2018).

Afin d'établir un niveau de base pour les signaux physiologiques, ceux-ci ont été enregistrés durant 3 minutes avant de débiter l'expérience. Durant ce temps, les participants devaient demeurer immobiles, fixer une croix à l'écran et écouter un bruit blanc avec des écouteurs pour éviter les distractions sonores<sup>2</sup>.

Après l'expérience ou après chaque mission<sup>3</sup>, les participants devaient compléter une série de questionnaires visant à évaluer le niveau d'expertise, le degré d'immersion dans le jeu, les motivations pour les jeux vidéo, le niveau d'exigence mentale,

---

1. *Longus abductor pollicis* pour tous les participants ainsi que *corrugator supercilli* et *zygomaticus major* pour 48 des 218 participants.

2. Ces signaux physiologiques de référence seront utilisés par la suite pour standardiser les signaux physiologiques acquis durant la séance de jeu.

3. Certains questionnaires ont été administrés après l'expérience, c'est-à-dire après que le participant ait joué aux deux missions des jeux ACU ou ACS (p. ex. les habitudes de jeu). D'autres ont été administrés après chaque mission, c.-à-d. qu'ils étaient administrés deux fois durant l'expérience (p. ex. le niveau d'exigence mental).



l'expérience générale durant la séance de jeu ainsi que les habitudes de jeu. Par la suite, après chaque séance de jeu, les participants devaient visionner l'enregistrement de cette dernière afin d'annoter en continu le plaisir ressenti durant la partie sur une échelle de -100 à 100 (facteur-fun, voir le chapitre 2). Le contenu complet de la base de données FUN*ii* est rapporté aux tableaux 1.1 et 1.2.

Tableau 1.1 – Contenu de la base de données FUN*ii*. Tableau adapté de Beaudoin-Gagnon et collab. (2019).

Source	Mesure	Contenu
Signaux physio.	ECG	Signal brut et prétraité, rythme cardiaque, positions des ondes R
	EDA	Signal brut et prétraité, composantes phasique et tonique, SCR
	RSP	Signal brut et prétraité, rythme respiratoire, périodes d'inspirations
	EMG	Signal brut et prétraité pour les muscles APL, ZM et CS <sup>1</sup>
Oculométrie	Mvt. oculaires	Fixations, saccades, clignement et position du regard à l'écran.
	Pupillométrie	Taille de la pupille
Webcaméra	Position de la tête	Position de la tête en 6 degrés de liberté (3 en translation et 3 en rotation)
	Mvt. faciaux	Unité d'action
Contrôleur Xbox	Entrées	Entrées activées par le participant durant la séance de jeu
Expérience de jeu	Facteur-fun	Évaluation continue du plaisir du joueur
	Questionnaires	Plaisir et difficulté perçue, charge de travail, immersion et expérience de jeu
Démographie	Questionnaires	Âge, sexe, habitude de jeu, expertise et motivations pour les jeux vidéo

<sup>1</sup> Respectivement muscle long abducteur du pouce (APL), muscle zygomatique majeur (ZM) et muscle corrugateur du sourcil (CS).

Tableau 1.2 – Questionnaires présents dans la base de données FUN*ii*. Tableau adapté de Beaudoin-Gagnon et collab. (2019).

Questionnaire	Description	# Éléments	Disponibilité
NASA-TLX	Charge mentale perçue par le joueur	6	ACU / ACS
Motivation	Motivations pour les jeux vidéo	28	ACS
Complétion AC	% de complétion de chaque jeu <i>Assassin's Creed</i>	9 / 10	ACU / ACS
Expérience de jeu	Expérience de jeu globale durant l'expérience	16	ACU / ACS
Expertise	Expertise générale avec les jeux vidéo	5	ACS
Post-mission	Plaisir et difficulté perçus durant la séance de jeu	2	ACU / ACS
Immersion	Immersion du participant durant la séance de jeu	31	ACU / ACS
Habitude de jeu	Temps et ressources monétaires consacrés aux jeux vidéo	1 / 6	ACU / ACS
Démographie	Âge et sexe du participant	2	ACU / ACS

## 1.2 Prétraitement des signaux physiologiques et des indices comportementaux contenus dans la base de données FUNi

### 1.2.1 Sélection des mesures et des séances de jeu

Certaines mesures contenues dans la base de données n'ont pas été utilisées dans ce projet. Tout d'abord, l'EMG facial a été mis de côté, car il n'a été mesuré que pour 48 des 219 participants, et était donc inutilisable à moins de considérer uniquement ces 48 participants pour l'entraînement des classificateurs, réduisant considérablement, par le fait même, la taille du jeu de données. Ensuite, à la suite d'une erreur récurrente avec la détermination de la position de la tête dans les données extraites du *Smart Eye Pro*, aucune donnée provenant du *Smart Eye* n'a été utilisée. Ceci inclut les saccades oculaires, la position du regard à l'écran, les clignements des yeux et les périodes de fixation. Bien qu'il ne soit pas certain que les données fournies par le système *Smart Eye* aient toutes été affectées par cette erreur, les données provenant de l'oculométrie ont été entièrement écartées afin d'éviter d'introduire du bruit dans le jeu de données<sup>4</sup>.

Ensuite, certaines séances de jeux comportent des problèmes importants concernant l'EDA. En effet, les signaux de l'EDA de 192 séances de jeux sont parsemés de périodes suggérant une perte de signal (déconnexions). La figure 1.1 montre un exemple d'un tel signal. Ce problème avec l'EDA a été causé par le fait que les électrodes qui servaient à l'acquisition de l'EDA étaient situées sur une partie très déformable et humide de la paume. Il arrivait donc, durant l'expérience, que les électrodes décollent si le joueur transpirait abondamment ou s'il bougeait trop sa main. Le contrôleur Xbox étant tenu avec les deux mains, il arrivait également que les électrodes entrent en contact avec le contrôleur Xbox, ce qui provoquait la déconnexion des électrodes de l'EDA.

Afin de limiter les sources de bruit, seules les séances de jeux avec EDA non problématiques ont été conservées pour l'entraînement du modèle supervisé. De plus, les données des participants pour lesquels l'EDA était fautif lors de l'acquisition des signaux physiologiques de référence, ainsi que les données des participants qui présentaient des EDA fautifs lors des deux séances de jeux ont été exclues pour la suite.

---

4. De plus, la récupération de ces données représente une somme de travail qui, si elle avait été entreprise, aurait dépassé le cadre de ce mémoire.




FIGURE 1.1 – Exemple de signal EDA problématique. Plusieurs parties du signal montrent un niveau de conductance nul causé par une déconnexion des électrodes.

Les données des participants qui comportaient des bogues repérées par l’expérimentateur durant l’expérience ont également été laissées de côté.

Contrairement à l’EMG facial et à l’oculométrie, le signal EDA a été conservé malgré les problèmes qu’il comportait. En effet, l’EDA est une modalité très informative de l’état du joueur, puisque celle-ci constitue une importante mesure de l’activation émotionnelle. L’appareillage sur lequel s’appuie l’EDA est également très simple, peu encombrant (deux électrodes au niveau du poignet suffisent), et facilement intégrable à une interface de jeu vidéo conventionnel (p. ex. un contrôleur Xbox). À l’inverse, l’EMG facial nécessite le positionnement d’électrodes sur le visage –ce qui peut-être hautement invasif pour le joueur– tandis que les systèmes d’oculométrie disponibles sur le marché sont coûteux et requièrent la plupart du temps un appareillage complexe devant être calibré à chaque utilisation. En somme, il semblait nécessaire d’intégrer l’EDA au nombre des modalités étudiées dans le cadre de ce mémoire, malgré le travail nécessaire pour identifier les signaux problématiques.

Les données de 78 participants, dont seulement 3 femmes, répondaient aux critères mentionnés ci-dessus. Les données de ces 3 participantes ont également été exclues, car le nombre limité de participants de sexe féminin n’aurait, en fin de compte, pas permis de conclure en l’applicabilité du modèle à des joueurs de sexe féminin. Il était donc préférable d’écarter les données de ces participantes afin d’éviter d’introduire une variabilité non informative dans le jeu de données.

En somme, les données physiologiques et comportementales de 75 participants âgés de 18 à 35 ans (M. 25,56; É.T. 4,60) de sexe masculin ayant joué aux jeux ACU ou ACS ( $n_{ACU} = 40$ ,  $n_{ACS} = 35$ ) ont été conservées pour l’extraction des caractéristiques. Ces données sont réparties sur 126 séances de jeu (une séance de jeu constituant

une mission de ACU ou de ACS). Les identifiants des participants et des missions associées sont présentés à l'Annexe A, aux tableaux A.1 et A.2.

De plus, les mesures brutes utilisées dans le cadre de ce projet sont présentées au tableau 1.3. Les mesures extraites à partir de celles-ci permettront d'extraire des caractéristiques pour l'entraînement des modèles. Plus précisément, les caractéristiques seront extraites à partir des signaux physiologiques, des données de la webcaméra et du contrôleur Xbox. Le facteur-fun sera quant à lui utilisé au chapitre 2 pour la création de classes de plaisir.

Tableau 1.3 – Mesures brutes de la base de données FUN*ii* utilisées dans le cadre de ce projet.

Modalité	Mesure brute
Signaux physiologiques	ECG
	EDA
	RSP
	EMG
Webcaméra	Position de la tête
	Mouvements faciaux
Contrôleur Xbox	Entrées activées
Expérience de jeu	Facteur-fun

## 1.2.2 Mesures extraites des signaux physiologiques et des indices comportementaux

À partir des signaux physiologiques et des indices comportementaux contenus dans la base de données FUN*ii*, 21 mesures ont été obtenues. Celles-ci découlent de la revue de littérature présentée à l'introduction et sont représentatives de l'état émotionnel du joueur. Ces mesures sont résumées au tableau 1.4 et la méthode suivie pour les extraire est décrite en détail ci-dessous.

### Électrocardiogramme

Un filtre passe-bande à réponse impulsionnelle finie (FIR; « Finite Impulse Response ») d'ordre 300 entre 13 Hz et 45 Hz a été appliqué au signaux ECG bruts (Cacioppo et collab., 2007). Un segmenteur de Hamilton a ensuite été utilisé pour détecter la position des complexes QRS<sup>5</sup> (Hamilton, 2002), et donc la position des

5. voir (Canento et collab., 2012) pour une revue des différentes méthodes de segmentation.

Tableau 1.4 – Mesures extraites à partir des données brutes de la base de données FUNii. Les mesures extraites de l’ECG, du RSP et de l’EDA ont été standardisées avec les signaux de référence.

Mesure	Description	Équation
$HR$	rythme cardiaque	1.1
$RR$	rythme respiratoire	1.4
$t_{in}, t_{ex}$	périodes inspiratoire et expiratoire	1.5
$\frac{t_{in}}{t_{ex}}$	rapport des périodes inspiratoire et expiratoire	
$V_{in}, V_{ex}$	volumes inspiratoire et expiratoire	1.6, 1.7
$\frac{V_{in}}{V_{ex}}$	rapport des volumes inspiratoire et expiratoire	
$EDA_t$	composante EDA tonique	1.9
$EDA_p$	composante EDA phasique	1.10
$EREMG$	enveloppe de réponse EMG	1.13
$VRI$	vitesse rotationnelle instantanée de la tête	1.14
$VTI$	vitesse translationnelle instantanée de la tête	1.15
$ARI$	accélération rotationnelle instantanée de la tête	1.16
$ATI$	accélération translationnelle instantanée de la tête	1.17
$J$	expression faciale de joie	1.19
$T$	expression faciale de tristesse	1.20
$S$	expression faciale de surprise	1.21
$P$	expression faciale de peur	1.22
$C$	expression faciale de colère	1.23
$D$	expression faciale de dégoût	1.24
$AICC$	activation instantanée du contrôleur Xbox en combat	1.25
$AICI$	activation instantanée du contrôleur Xbox en interaction	1.26

ondes R. Les positions des ondes R ont été corrigées pour correspondre à la valeur maximale dans une fenêtre de 100 ms autour des valeurs déterminées par le segmenteur.

À partir de la position des ondes R, le rythme cardiaque instantané (HR) en battement par minute a été extrait selon

$$HR(t_i) = \frac{1}{P_i} \cdot 60000, \quad [\text{bpm}] \quad (1.1)$$

où le rythme cardiaque en un point donné  $t_i$  (ms) donné correspond à l’inverse de la période  $P_i$  entre deux ondes R successives, soit

$$P_i = t_j - t_i, \quad [\text{ms}] \quad (1.2)$$

où  $t_i$  correspond à la position temporelle des ondes  $R_i$  et  $t_j$ , à la position de l’onde suivant  $R_j = R_{i+1}$ . Comme les valeurs du HR obtenues sont discrètes, celles-ci

doivent être interpolées. Pour ce faire, nous utilisons une interpolation de « projection vers l'avant » (« forward fill »), où les valeurs manquantes sont fixées à la plus récente valeur. Le rythme cardiaque ainsi obtenu a été lissé avec une fonction noyau carrée d'une largeur de 3 ms.

Finalement, le rythme cardiaque a été standardisé à partir de l'ECG de référence suivant l'équation

$$HR(t_i) = \frac{HR(t_i) - \mu_{ref}}{\sigma_{ref}}, \quad [-] \quad (1.3)$$

où  $\mu_{ref}$  et  $\sigma_{ref}$  représentent respectivement le HR moyen et l'écart-type du HR durant l'acquisition des signaux de référence.

### Activité respiratoire

Un filtre passe-bande Butterworth d'ordre 2 entre 0,1 Hz et 0,35 Hz<sup>6</sup> a été appliqué aux signaux du RSP bruts. Par la suite, les passages au niveau zéro (« zero crossings ») de la dérivée première du RSP ont été utilisés pour calculer le rythme respiratoire instantané (RR) en cycle par minute.

À partir des positions temporelles des débuts d'inspiration et d'expiration, déterminées à l'aide des passages au niveau zéro de la dérivée première du RSP, le rythme respiratoire instantané (RR) en battement par minute a été extrait selon

$$RR(t_i) = \frac{1}{P_i} \cdot 60000, \quad [\text{bpm}] \quad (1.4)$$

où le rythme respiratoire en un point donné  $t_i$  (ms) donné correspond à l'inverse de la période  $P_i$  entre deux points de passage au niveau zéro successifs, soit

$$P_i = t_j - t_i, \quad [\text{ms}] \quad (1.5)$$

où  $t_i$  correspond à la position temporelle du début de l'inspiration et  $t_j$ , à la position du début de l'expiration subséquente. Les équations 1.4 et 1.5 pour calculer le RR sont identiques à 1.1 et 1.2, à l'exception que ce sont les positions temporelles des passages au niveau zéro qui sont utilisés, et non les positions des ondes R. Le rythme respiratoire ainsi obtenu a également été lissé avec une fonction noyau carrée d'une largeur de 3 ms.

---

6. Cette plage de fréquence couvre les rythmes respiratoires entre 6 et 21 cycles par minute, la respiration normale d'un adulte au repos étant d'environ 18 cycles par minute (Cacioppo et collab., 2007).

En ce qui concerne les périodes d'inspirations et d'expirations, celles-ci ont été identifiées en utilisant les positions temporelles des passages au niveau zéro de la dérivée première du RSP filtré. En effet, lorsque la dérivée du RSP filtré est nulle et que le RSP est inférieur à la moyenne, cela signifie que les poumons du sujet sont en expansion et donc qu'il s'agit d'une période d'inspiration. À l'inverse, lorsque la dérivée est nulle et le RSP est supérieur à la moyenne, les poumons du sujet sont en contraction et donc il s'agit d'une période d'expiration. Le début et la fin des périodes d'inspiration et d'expiration sont établis avec les positions temporelles des passages au niveau zéro, qui marquent toujours le début d'une inspiration ou d'une expiration. La figure 1.2 illustre la méthode utilisée pour identifier les périodes d'inspiration et d'expiration.




FIGURE 1.2 – Détermination des périodes d'inspiration (bleu) et d'expiration (rouge) à partir du signal RSP. Les périodes d'inspiration et d'expiration sont déterminées à partir des passages au niveau zéro de la dérivée première du RSP, qui représente le début d'une inspiration et la fin d'une expiration et vice-versa.

Les temps d'inspiration ( $t_{in}$ ) et d'expiration ( $t_{ex}$ ) ont également été déterminés avec l'équation 1.5. Ces derniers ont ensuite permis de calculer le rapport entre le temps d'inspiration et d'expiration, soit  $\frac{t_{in}}{t_{ex}}$  (tel qu'introduit au tableau 0.2). Finalement, les volumes inspiratoire ( $V_{in}$ ) et expiratoire ( $V_{ex}$ ) ont été calculés. Ceux-ci ont été calculés avec

$$V_{in}(t_i) \sim RSP(t_j) - RSP(t_i) , \quad [-] \quad (1.6)$$

et

$$V_{ex}(t_j) \sim |RSP(t_k) - RSP(t_j)| , \quad [-] \quad (1.7)$$

où  $t_i$  correspond à la position temporelle du début de l'inspiration ;  $t_j$  à la position du début de l'expiration subséquente et  $t_k$ , la position du début de l'inspiration suivant l'expiration en  $t_j$ . Notons que les équations 1.6 et 1.7 ne représentent pas le volume

respiratoire directement, mais plutôt la variation de la circonférence de la cage thoracique<sup>7</sup>. Ici, nous faisons l'hypothèse que cette dernière sera aussi informative de l'état du joueur que le volume respiratoire réel. Le rapport des volumes inspiratoire et expiratoire est quant à lui donné par  $\frac{V_{in}}{V_{out}}$ , tel que présenté au tableau 0.2.

Finalement, le rythme respiratoire ainsi que les temps et les volumes d'inspiration et d'expiration (et les rapports correspondants; c.-à-d.  $\frac{t_{in}}{t_{ex}}$  et  $\frac{V_{in}}{V_{out}}$ ) ont été standardisés à partir du signal RSP de référence, selon le même principe qu'utilisé à l'équation 1.3.

### Activité électrodermale

Les parties phasique et tonique des signaux de l'EDA ont été extraites à l'aide de modèle *cvxEDA*<sup>8</sup> proposé par Greco et collab. (2016). L'avantage du modèle *cvxEDA* est qu'il ne nécessite pas de prétraitement des signaux EDA et il peut donc être utilisé directement sur les signaux de l'EDA bruts pour l'extraction des parties tonique et phasique. Ce modèle traite le signal EDA comme l'addition des parties tonique ( $EDA_t$ ) et phasique ( $EDA_p$ ), et d'un bruit gaussien ( $\epsilon$ ), soit

$$EDA = EDA_t + EDA_p + \epsilon . \quad [\mu S] \quad (1.8)$$

La composante tonique du signal est représentée par une somme de fonctions B-spline cubiques et d'une tendance linéaire. Celle-ci est donnée par

$$EDA_t = Bl + Cd , \quad [\mu S] \quad (1.9)$$

où  $B$  est une matrice contenant les vecteurs de base des fonctions B-spline cubiques,  $l$  est un vecteur contenant les coefficients splines,  $C$  est une matrice  $N \times 2$  et  $d$  est un vecteur déterminant la pente et l'ordonnée à l'origine de la tendance linéaire présente dans l'EDA. En ce qui concerne la composante phasique, celle-ci est modélisée par

$$EDA_p = A^{-1}pq , \quad [\mu S] \quad (1.10)$$

où  $p$  représente l'activité du nerf moteur activant les glandes sudoripares<sup>9</sup>,  $A$  est une matrice contenant les paramètres permettant de modéliser la forme des SCRs par des fonctions de Bateman et  $q$ , une variable auxiliaire utilisée pour déterminer  $p$ . Tel que mentionné par Greco et collab. (2016), la fonction de Bateman correspond

7. Il est à noter que comme le signal RSP a été standardisé, les volumes inspiratoire et expiratoire sont sans unité.

8. Abbréviation de « Convex-optimization-based EDA model ».

9. Traduction libre de « Sudomotor nerve activity » (Greco et collab., 2016).



à la solution d'un « modèle pharmacocinétique bicompartimental » représentant la diffusion de la sueur à travers les glandes sudoripares et ayant été développé par Schneider (1987).

L'implémentation de *cvxEDA* utilisée dans le cadre de ce mémoire est celle proposée par Greco et collab. (2016)<sup>10</sup>. Les paramètres du modèle ont été fixés aux valeurs proposées par les auteurs ( $\tau_0=2.$ ,  $\tau_1=0.7$ ,  $\alpha = 8 \cdot 10^{-4}$ ,  $\gamma = 10^{-2}$  et un temps entre les noeuds des fonctions B-splines de 10 secondes).

Les composantes tonique et phasique ont été standardisées avec l'EDA de référence selon l'équation 1.3.

### Électromyogramme du muscle long abducteur du pouce

Un filtre passe-bande Butterworth d'ordre 1 entre 20 Hz et 400 Hz a été appliqué sur le signal EMG brute (Boxtel, 2001). Le signal EMG a ensuite été transformé en enveloppe de réponse représentant l'activation du muscle abducteur long du pouce. Pour ce faire, le « Teager-Kaiser Energy Operator » (TKEO) a été utilisé (Li et collab., 2007). Le TKEO ( $\Psi$ ) est défini comme

$$\Psi[x_n] = x_n^2 - (x_{n+1} \cdot x_{n-1}), \quad [\text{mV}^2] \quad (1.11)$$

où  $x_n$  est la valeur du signal EMG au point  $n$ . Après avoir appliqué le TKEO, la valeur obtenue avec ce dernier est rectifiée avec à l'aide de la fonction valeur absolue. Finalement, le signal obtenu est lissé avec une fonction « Root Mean Square » (RMS) mobile avec une largeur de 100 ms, c'est-à-dire

$$RMS(x_i) = \left( \sum_{j=0}^{N=99} x_{i+j}^2 \right)^{\frac{1}{2}}. \quad (1.12)$$

L'enveloppe de réponse EMG (EREMG) peut donc être finalement exprimée comme

$$EREMG_n = RMS(|\Psi[x_n]|), \quad [\text{mV}^2] \quad (1.13)$$

### Position de la tête en 6 degrés de liberté et mouvements faciaux

La position de la tête en 6 degrés de liberté (3 en translation et 3 en rotation) a été extraite à l'aide du logiciel OpenFace (Baltrusaitis et collab., 2018), à partir des vidéos originales des participants. Celle-ci n'a pas nécessité de filtrage ou de lissage.

10. Disponible à l'adresse suivante : <https://github.com/lciti>.

Afin de caractériser le mouvement de la tête, la vitesse rotationnelle instantanée de la tête (VRI), telle que proposée<sup>11</sup> par Caridakis et collab. (2010) et Shaker et collab. (2013) a été calculée. Bien que l’VRI soit définie comme une somme de  $T$  valeurs par Shaker et collab. (2013), dans le cadre de ce projet cette dernière est plutôt définie de manière instantanée, soit

$$VRI_n = \frac{dy_n}{dt} + \frac{dp_n}{dt}, \quad [\text{rad/ms}] \quad (1.14)$$

où  $y_n$  correspond à la valeur de lacet et  $p_n$ , à la valeur de tangage associées au temps  $t_n$ . S’inspirant des auteurs mentionnés ci-haut, une mesure semblable de la vitesse translationnelle instantanée (VTI) a également été calculée. Celle-ci est donnée par l’équation

$$VTI_n = \frac{dy_n}{dt} + \frac{dp_n}{dt} + \frac{dr_n}{dt}, \quad [\text{ms}^{-1}] \quad (1.15)$$

où les valeurs  $y$ ,  $p$  et  $r$  correspondent aux axes translationnels présentés à la figure 0.5 de l’introduction. En plus du VRI et du VTI, deux autres mesures ont également été calculées à partir de la position de la tête, soit les accélérations rotationnelle (ARI) et translationnelle instantanées (ATI). Ces dernières visent à capturer les accélérations de la tête et ont également été adaptées de Caridakis et collab. (2010) et Shaker et collab. (2013)<sup>12</sup>. Celles-ci sont définies comme

$$ARI_n = \frac{d^2y_n}{dt^2} + \frac{d^2p_n}{dt^2}, \quad [\text{ms}^{-2}] \quad (1.16)$$

et

$$ATI_n = \frac{d^2y_n}{dt^2} + \frac{d^2p_n}{dt^2} + \frac{d^2r_n}{dt^2}. \quad [\text{ms}^{-2}] \quad (1.17)$$

## Unités d’action

Les unités d’action ont été extraites à l’aide du logiciel OpenFace (Baltrusaitis et collab., 2018), à partir des vidéos originales des participants. Les valeurs obtenues n’ont pas nécessité de filtrage ou de lissage.

OpenFace fournit deux modèles pour détecter les unités d’action. Le premier est un classificateur binaire qui indique la présence ou l’absence d’une AU donnée. Le second est un modèle de régression, qui retourne l’intensité de l’AU. Les unités d’action fournies par le modèle de régression sont présentées au tableau 1.5. Pour ce

11. Dans les travaux originaux, celle-ci est plutôt nommée « Head Pose Overall Activation ».

12. Dans ces travaux, celle-ci est nommée « Power of Head movement » (PO). Comme la division par la valeur  $T$  n’est pas effectuée ici, la résultante a davantage les unités d’une accélération que d’une puissance, d’où l’utilisation du terme « accélération ».

projet, seul le modèle de régression de OpenFace a été utilisé. La raison étant qu'à l'inverse du modèle binaire qui détecte seulement la présence ou l'absence des unités d'action, le modèle de régression permet également de mesurer l'intensité des mouvements faciaux. Or, en plus de permettre de déterminer la présence ou l'absence –une intensité nulle signifiant que l'AU est absente– l'intensité des mouvements faciaux pourrait possiblement s'avérer informative de l'état du joueur.

Tableau 1.5 – Tableau des AUs disponibles avec le modèle de régression d'OpenFace. Traduction libre des noms FACS tels que définis par Ekman et collab. (2002).

AU	Nom FACS
1	Remontée de la partie interne des sourcils
2	Remontée de la partie externe des sourcils
4	Abaissement et rapprochement des sourcils
5	Ouverture entre la paupière supérieure et les sourcils
6	Remontée des joues
7	Tension de la paupière
9	Plissement de la peau du nez vers le haut
10	Remontée de la partie supérieure de la lèvre
12	Étirement du coin des lèvres
14	Plissement externe des lèvres
15	Abaissement des coins externes des lèvres
17	Élévation du menton
20	Étirement externe des lèvres
23	Tension refermante des lèvres
25	Lèvres pressées
26	Ouverture de la mâchoire
45	Clignotement

S'inspirant de la relation entre les émotions et expressions faciales, les unités d'action obtenues par OpenFace ont été utilisées pour déterminer l'intensité de certaines émotions. Au vu des unités d'action fournies par le modèle de régression d'OpenFace –telles que décrites au tableau 1.5, un modèle simple associant une émotion à un groupe d'unités d'action a été mis en place. Ce dernier est basé sur les unités d'action impliquées dans les émotions de base, telles que présentées au tableau 0.4 de l'introduction.

Le tableau 1.6 contient les différentes expressions utilisées pour modéliser les émotions à partir des unités d'action. Les émotions de base du tableau 0.4 ont été représentées comme la moyenne géométrique des unités d'action impliquées, celle-ci

étant définie comme

$$\left( \prod_{i=1}^n x_i \right)^{\frac{1}{n}} = \sqrt[n]{x_1 x_2 \cdots x_n} . \quad (1.18)$$

Tableau 1.6 – Modèle des émotions basé sur la moyenne géométrique des unités d’action présentées au tableau 0.4.

Émotion	Équation
Joie	$J_n = \left( AU_n^6 \cdot AU_n^{12} \right)^{1/2} \quad (1.19)$
Tristesse	$T_n = \left( AU_n^1 \cdot AU_n^4 \cdot AU_n^{15} \right)^{1/3} \quad (1.20)$
Surprise	$S_n = \left( AU_n^1 \cdot AU_n^2 \cdot AU_n^5 \cdot AU_n^{26} \right)^{1/4} \quad (1.21)$
Peur	$P_n = \left( AU_n^1 \cdot AU_n^2 \cdot AU_n^4 \cdot AU_n^5 \cdot AU_n^{20} \cdot AU_n^{26} \right)^{1/6} \quad (1.22)$
Colère	$C_n = \left( AU_n^4 \cdot AU_n^5 \cdot AU_n^7 \cdot AU_n^{23} \right)^{1/4} \quad (1.23)$
Dégoût	$D_n = \left( AU_n^9 \cdot AU_n^{15} \cdot AU_n^{16} \right)^{1/3} \quad (1.24)$

Pour les 6 émotions mentionnées, toutes les AUs doivent être présentes pour pouvoir considérer que l’émotion a été exprimée. L’utilisation de la moyenne géométrique permet d’assurer que cette contrainte est respectée, puisqu’un seul terme nul dans l’équation 1.18 rend la moyenne géométrique égale à zéro.

Bien que ce modèle soit simple – la relation entre les émotions et les unités d’action étant plus subtile que ce que le modèle admet – celui-ci offre deux avantages non négligeables. Premièrement, malgré sa simplicité, le modèle permet d’induire des *a priori* sur les relations entre certaines unités d’action (p. ex., les AUs 6 et 12 sont toutes deux impliquées dans l’expression faciale de joie). Ce genre d’*a priori* peut permettre de souligner une relation importante et ainsi faciliter l’entraînement du modèle supervisé. Deuxièmement, ce modèle des émotions permet de diminuer la complexité du problème en réduisant le nombre de variables d’entrée. En effet, ce dernier permet de passer de 17 unités d’action à 6 variables représentant chacune une émotion de base. On peut ainsi réduire l’espace d’entrée et donc, par le fait même, le bruit dans les données.

## Entrées du contrôleur Xbox

Dans les données brutes, les touches du contrôleur Xbox activées par le joueur durant la séance de jeu ont été enregistrées comme des événements ponctuels. Afin de faciliter l'extraction des caractéristiques, ces entrées ont été transformées en séries temporelles. Sous cette forme, chaque touche du contrôleur Xbox prend une valeur binaire indiquant si la touche a été activée (1) ou non (0).




FIGURE 1.3 – Contrôleur Xbox et les actions associées à chaque touche. Les entrées directionnelles sont indiquées par un connecteur bleu. Les entrées non directionnelles sont divisées en deux catégories : les entrées de combat et les entrées d'interactions avec l'environnement. Les entrées de combat sont indiquées par des connecteurs rouges, les entrées d'interaction avec l'environnement, par des connecteurs verts et les entrées directionnelles par des connecteurs bleus.<sup>13</sup>

Le contrôleur Xbox comporte des entrées directionnelles (c.-à-d. qui permettent d'orienter le personnage et la caméra) et non directionnelles (qui permettent d'interagir avec l'environnement). Ici, seules les entrées non directionnelles ont été conservées tandis que les entrées directionnelles ont été laissées de côté. Ce choix repose sur l'observation que les entrées directionnelles sont activées de manière uniforme, indifféremment des situations dans le jeu et qu'elles ne sont pas reliées à des interactions précises avec le jeu (elles ne servent qu'au positionnement de la caméra et au déplacement du personnage)<sup>14</sup>. À l'inverse, les entrées non directionnelles sont directement reliées à des interactions précises avec le jeu (p. ex. : combat, interaction avec les personnages non-joueurs ou interaction avec l'environnement virtuel). La

13. Image adaptée de <https://upload.wikimedia.org/wikipedia/commons/9/91/XboxControllerAllDPad.svg> par Jishenaz. Fichier sous licence *Creative Commons CC0 1.0*.

14. Les entrées directionnelles sont parfois impliquées dans des manœuvres de combat. Cependant, ces manœuvres impliquent aussi d'autres entrées, qui elles sont plutôt non directionnelles.

figure 1.3 présente les différentes touches du contrôleur Xbox ainsi que les actions qui leurs sont associées.

Les entrées restantes ont été regroupées en 2 catégories : les entrées de combat et les entrées d'interaction avec l'environnement. La première catégorie comprend les entrées RB, LB, LT et RT. Ces dernières permettent d'effectuer des tirs à l'arc ainsi que de porter ou parer des coups durant les combats rapprochés. La seconde catégorie comprend les entrées A, B, X et Y<sup>15</sup>. Celles-ci permettent notamment d'escalader une paroi, d'interagir avec un personnage non joueur et d'effectuer une roulade.

Dans le but de quantifier le degré d'utilisation du contrôleur Xbox pour les deux catégories d'entrées mentionnées ci-dessus, deux mesures ont été développées : l'activation instantanée du contrôleur en combat (AICC) et l'activation instantanée du contrôleur en interaction (AICI). Celles-ci sont définies comme

$$AICC_n = RB_n + LB_n + LT_n + RT_n , \quad [-] \quad (1.25)$$

et

$$AICI = A_n + B_n + X_n + Y_n , \quad [-] \quad (1.26)$$

où les valeurs des entrées ( $RB_n, LB_n, A_n, B_n, \dots$ ) sont binaires ( $\{0, 1\}$ ). Il importe de souligner que les valeurs des gâchettes (LT et RT), ont été transformées pour correspondre aux valeurs binaires mentionnées, celles-ci couvrant à l'origine une plage de 256 valeurs (de 0 à 255). Dans ce cas précis, toutes les valeurs plus grandes que 0 se sont vu attribuer une valeur de 1.

## 1.3 Extraction de caractéristiques pour apprentissage automatique supervisé

### 1.3.1 Segmentation des données temporelles en époques

Afin d'extraire les caractéristiques utilisées pour accomplir la tâche de classification, les mesures extraites précédemment doivent d'abord être divisées en *époques*. Les époques sont des segments de signal de durée fixe auxquels sont associées des classes. Pour ensemble de  $S$  mesures, une époque  $e_i$  correspond donc à

$$e_i = \{X_i, y_i\} = \{\{\mathbf{x}_t, \mathbf{x}_{t+1}, \dots, \mathbf{x}_{t+(n-1)} | t + (n-1) < N\}, y_i\} , \quad (1.27)$$

15. Les entrées de la croix directionnelle (« directional pad »; « D-pad ») n'ont pas été pris en compte, car elles étaient rarement activées durant la séance de jeu comparativement aux autres entrées d'interaction avec l'environnement.

où  $X_i$  est une matrice  $N \times S$  contenant les  $S$  mesures de longueur  $N$ ,  $y_i$  est la classe associée à l'époque  $e_i$ ,  $\mathbf{x}_t$  est la valeur des  $S$  signaux à l'échantillon  $t = in \in \mathbb{N}$  et  $n \in \mathbb{N}$  est le nombre d'échantillons contenus dans l'époque  $e_i$ . La figure 1.4 présente le type de segmentation utilisée dans ce projet, soit les époques à durée fixe. Le processus d'extraction des caractéristiques à partir des  $X_i$  est décrit à la section 1.3.2, tandis que la création des classes  $y_i$  est détaillée au chapitre 2.




FIGURE 1.4 – Exemple de la segmentation en époques à durée fixe. À chaque époque est associée une classe ( $C_1$  ou  $C_2$  dans cet exemple) représentée par une couleur (bleu ou rouge).

### Détermination de la durée des époques

La durée des époques – c'est-à-dire  $n$  dans l'équation 1.27 – est une variable déterminante. En effet, il est attendu que la durée des segments de signaux choisie ait un impact à la fois sur les performances du modèle supervisé, mais également sur l'utilité du modèle dans le mécanisme d'un jeu adaptatif. Dans le cadre du présent travail, trois différentes durées d'époque ont été testées, soit 10, 30 et 60 secondes. L'argumentaire sur lequel reposent ces trois valeurs est présenté ci-dessous.

Différentes longueurs d'époque ont été utilisées dans des travaux antérieurs. Par exemple, Vachiratamporn et collab. (2013) ont testés des époques de 2, 5 et 10 secondes avec l'EEG, l'ECG et des indices comportementaux reliés à l'utilisation de la souris durant le Jeu *Slender : The Eight Pages* (Parsec Productions, 2012). Nogueira et collab. (2014) ont extrait des caractéristiques sur des époques de 5 s de l'EDA, du HR et de l'EMG facial centrés sur des évènements du jeu d'horreur *Vanish* (3DrunkMen, 2012). De manière semblable, Fortin-Cote et collab. (2018) ont utilisé des époques de 5 s sur des signaux physiologiques de la base de donnée FUNii. De plus, Chanel et collab. (2011) ont testé des époques variant entre 30 s et 300 s avec les signaux

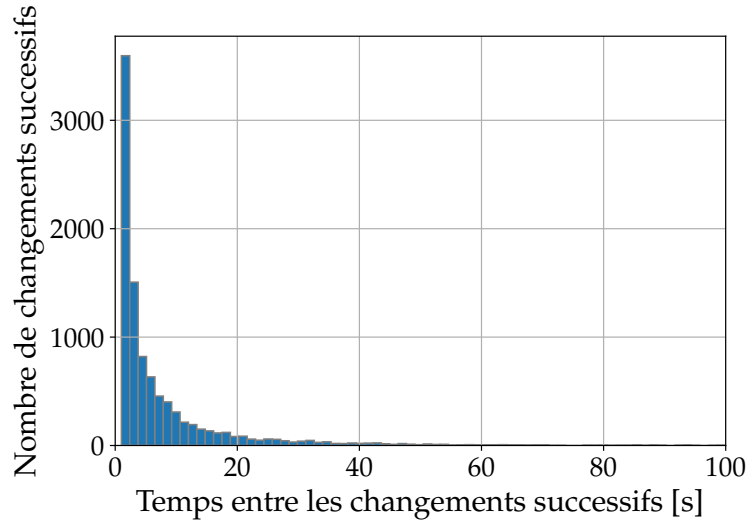
physiologiques périphériques EDA, BVP, HR, RSP et ST mesurés durant des parties de *Tetris* (Pajitnov, 1984). De façon intéressante, ces derniers ont observé qu'un classificateur entraîné sur des époques de 300 s était plus performant qu'un entraîné sur des époques de 30-50 s, ceux-ci obtenant respectivement des taux de classement de 57 % et de 47 % pour la prédiction de 3 classes de difficulté. Ce dernier résultat semble indiquer que des époques plus longues permettent d'obtenir une meilleure performance de classification que des époques plus courtes.

En effet, les époques doivent être suffisamment longues pour être informatives de l'état du joueur, c'est-à-dire pour permettre aux réponses physiologiques de prendre place. Le temps de réponse à un stimulus externe – la latence – diffère selon le signal physiologique considéré. Par exemple, l'EDA est considéré comme ayant une latence élevée comparativement aux autres signaux physiologiques, le déclenchement d'un SRC prenant en moyenne de 1 à 2 s et pouvant aller jusqu'à 5 s (Wilcott, 1967). Un SCR typique, de son déclenchement jusqu'au retour à la moitié de son amplitude maximale, s'étend sur environ 6.2 s (Boucsein, 2012). Cela signifie qu'une réponse EDA typique nécessite entre 7.2 s et 11.2 s de signal suivant la présentation du stimulus pour être enregistrée convenablement. Notons également que le rythme respiratoire minimum d'un sujet puisse être aussi bas que 6 cycles par minute, et donc une durée de 10 s est nécessaire pour capturer un seul cycle respiratoire. Conséquemment, les époques doivent avoir une durée minimale approximative de 12 s afin de permettre de capturer les valeurs extrêmes à la fois de l'EDA et du rythme respiratoire. Ce résultat semble aller à l'encontre des valeurs retrouvées dans la littérature, comme les époques de 5 s (particulièrement les travaux de Chanel et collab. (2011) et de Fortin-Cote et collab. (2018), qui utilisent tous deux l'EDA), ce qui semble indiquer que des durées d'époque sous optimales ont été utilisées dans ces travaux.

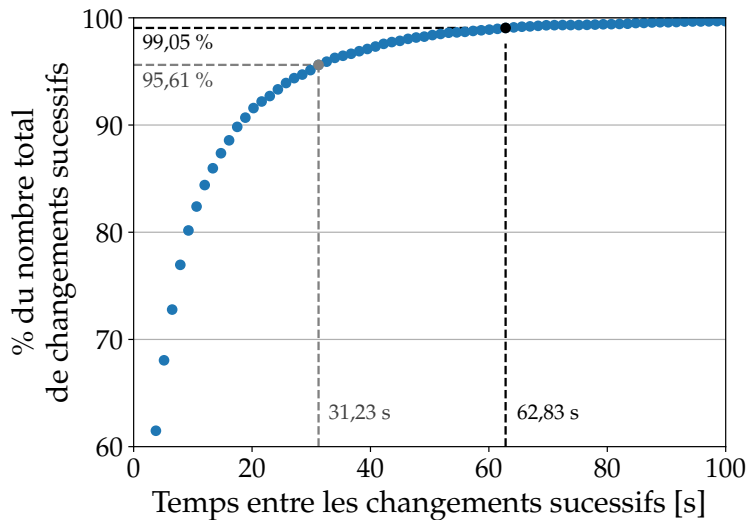
Ensuite, les époques doivent également avoir une durée limitée pour permettre l'évaluation du plaisir du joueur. En effet, des époques trop longues pourraient englober plusieurs variations de plaisir à l'intérieur d'une même époque, ce qui aurait pour effet de réduire la résolution temporelle du modèle, et ainsi sa capacité à discriminer les différents états de plaisir. Sous un autre angle, les époques courtes sont également à privilégier, car avoir un temps de détection du plaisir le plus court possible permet également d'assurer que les périodes critiques (p. ex. lorsque le plaisir diminue sous un certain seuil et qu'une adaptation soit nécessaire pour garder le joueur engagé dans le jeu) soient détectées rapidement. Une piste de solution pour déterminer la durée maximale des époques consiste à déterminer la fréquence des variations



de plaisir en contexte de jeu vidéo. Bien que la littérature soit muette à ce sujet, les facteurs-fun recueillis dans le cadre du projet FUNii peuvent être utilisés pour déterminer la distribution temporelle des changements de plaisir.



(a) Distribution temporelle des changements successifs du facteur-fun.



(b) Somme cumulative de la distribution présentée en (a).

FIGURE 1.5 – (a) Distribution temporelle des changements successifs du facteur-fun et (b) sa somme cumulative. Les changements de facteur-fun proviennent de l’ensemble des séances de jeu sélectionnés à la section 1.2.1. En (b), 95.61% des changements de facteur-fun prennent place entre 0 – 31,23 s après le changement précédent, et 99.05% entre 0 – 62,83 s.

La figure 1.5a présente la distribution temporelle des changements de plaisir telle que mesurée à partir des facteurs-fun. La somme cumulative de cette distribution,

présentée à la figure 1.5b, nous permet de constater que 95,61% ( $\approx 2\sigma$ ) des changements de plaisir surviennent entre 0 et 31,23 secondes après un changement antérieur, tandis que 99,05% ( $\approx 3\sigma$ ) surviennent entre 0 et 62,83 secondes après un même changement.

En conséquence, dans le présent travail trois durées d'époque ont été testées : 10, 30 et 60 secondes. La valeur de 10 secondes s'approchent des valeurs utilisées dans la littérature, tandis que les valeurs de 30 et 60 secondes découlent de l'utilisation du facteur-fun, tel que présenté ci-dessus. Ici, les valeurs obtenues précédemment ont été arrondies à la dizaine pour simplifier la segmentation des données en époques.

### 1.3.2 Extraction de caractéristiques à partir des époques

Après avoir segmenté les mesures extraites en époques, des caractéristiques peuvent en être extraites. Une caractéristique d'une époque permet de représenter une partie de l'information contenue dans celle-ci. Dans ce travail, les caractéristiques proposées par Picard et collab. (2001) ont été extraites des époques. Ces caractéristiques ont été utilisées par un grand nombre de travaux utilisant des signaux physiologiques et des indices comportementaux (p. ex. Picard et collab. (2001); Yannakakis et Hal-lam (2008); Colomer Granero et collab. (2016); Chen et collab. (2017)). Celles-ci sont présentées au tableau 1.7.

Tableau 1.7 – Caractéristiques extraites des signaux physiologiques et des indices comportementaux. Ces caractéristiques sont calculées pour chaque époque du jeu de données.

Description	Caractéristique
Minimum	$\min_x = \max_{x_n \in X} x_n$
Maximum	$\max_x = \min_{x_n \in X} x_n$
Moyenne	$\mu_X = \frac{1}{N} \sum_{n=1}^N x_n$
Écart-type (non biaisé)	$\sigma_X = \left( \frac{1}{N-1} \sum_{n=1}^N (x_n - \mu_X)^2 \right)^{1/2}$
Asymétrie (« Skewness »)	$S_X = \frac{1}{N-1} \sum_{n=1}^N \left( \frac{x_n - \mu_X}{\sigma_X} \right)^3$
Kurtosis	$\mathcal{K}_X = \frac{1}{N-1} \sum_{n=1}^N \left( \frac{x_n - \mu_X}{\sigma_X} \right)^4$
Valeurs absolues moyennes des 1 <sup>ères</sup> différences	$\delta_X = \frac{1}{N-1} \sum_{n=1}^{N-1}  x_{n+1} - x_n $
Valeurs absolues moyennes des 2 <sup>èmes</sup> différences	$\delta_X^2 = \frac{1}{N-2} \sum_{n=1}^{N-2}  x_{n+2} - x_n $

La méthode proposée par [Martinez et collab. \(2013\)](#) pour l'extraction de caractéristiques à partir de signaux physiologiques a également été explorée dans le cadre de ce projet. Ces derniers ont utilisé un auto-encodeur à réduction de bruit (« denoising autoencoder ») ([Vincent et collab., 2008](#)) pour construire une représentation dans un « espace latent » de moindre dimension que l'espace d'entrée. Cet espace latent permet d'exprimer les signaux d'entrée sous une forme « compressée », qui est l'analogie des caractéristiques présentées ci-haut. En utilisant des signaux physiologiques (BVP, EDA), il a été démontré que cette méthode permet d'obtenir des résultats semblables ou supérieurs aux techniques présentées précédemment et permet également de gérer facilement de multiples modalités. En effet, la représentation latente obtenue est une combinaison non-linéaire de toutes les modalités se trouvant dans l'espace d'entrée. Cependant, l'inconvénient de cette méthode est que les caractéristiques obtenues (c.-à-d. la représentation latente), en plus d'être des combinaisons non linéaires de toutes les modalités en entrée, sont difficilement interprétables.

En conséquence, il est difficile de connaître la signification précise de chaque caractéristique, et donc de déterminer leur importance relative dans la tâche de classification. Or, dans le cadre du présent projet, il est nécessaire de pouvoir déterminer les caractéristiques et les modalités importantes ou non pour la tâche de classification. En effet, afin que le modèle puisse être utilisé dans des applications « en dehors du laboratoire », il est capital d'utiliser un nombre de signaux physiologiques et d'indices comportementaux minimal. Pour cette raison, la méthode de [Martinez et collab. \(2013\)](#) pour l'extraction de caractéristiques a donc été laissée de côté.

## Chapitre 2

# Création des classes de plaisir à partir du facteur-fun

Dans ce chapitre, le facteur-fun est présenté et l'utilisation des changements de facteur-fun pour l'évaluation du plaisir du joueur est étudiée. Les approches précédentes pour la création de classes de plaisir sont revues. Deux propositions sont faites pour modéliser le plaisir du joueur à partir des changements de facteur-fun et une nouvelle approche pour la création de classes de plaisir est présentée.

## 2.1 Le facteur-fun

Le plaisir des joueurs de la base de données FUNii a été évalué à partir des facteurs-fun. Comme il en a été question plus tôt, le facteur-fun est une mesure autorapportée et continue du niveau de plaisir du joueur. Celui-ci est obtenu après une séance de jeu, durant le visionnement de cette dernière. Durant le visionnement, le joueur cote en continu, sur une échelle de -100 à 100 à l'aide un contrôleur rotatif, son niveau de plaisir durant la séance de jeu. Les valeurs négatives représentent les différents degrés de « non-plaisir » (« displeasure »), tandis que les valeurs positives représentent les différents degrés de plaisir (« fun »). Un exemple de facteur-fun est présenté à la figure 2.1.

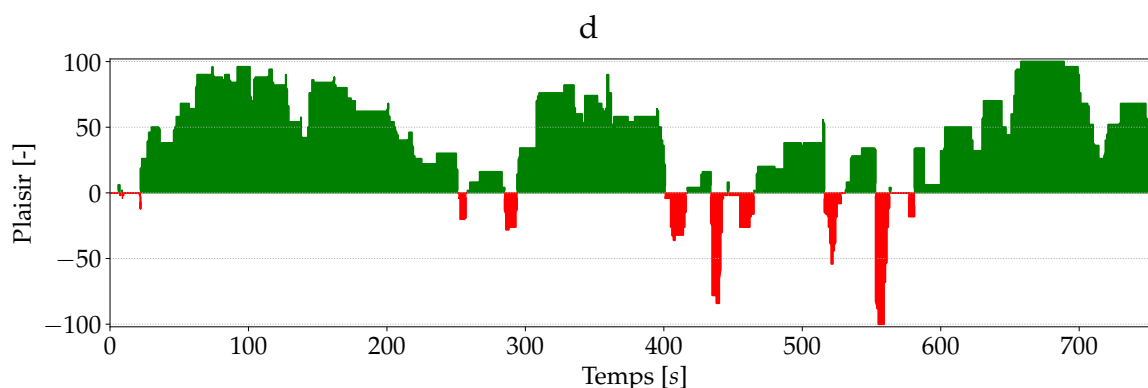


FIGURE 2.1 – Exemple de facteur-fun. (P38, S9M3)<sup>1</sup>

Des méthodes alternatives pour l'évaluation du plaisir du joueur peuvent être utilisée, comme des échelles ordinales de type « Likert » par exemple. Bien que celles-ci permettent de déterminer le niveau global de plaisir d'un joueur, leur résolution temporelle est habituellement limitée à une seule mesure par séance de jeu, ce qui ne permet pas de capturer l'évolution du plaisir durant la partie. À l'inverse, l'utilisation du facteur-fun permet d'obtenir une évaluation continue du plaisir du joueur durant la séance de jeu, ce qui ouvre aussi la porte à l'étude des mécanismes physiologiques et comportementaux impliqués dans les changements de plaisir

1. Entre parenthèses, la provenance du facteur-fun est présentée. Dans ce cas, il s'agit de celui du participant 38 durant la mission S9M3.

## 2.2 Utilisation des changements de facteur-fun comme indicateurs du plaisir du joueur


À partir des facteurs-fun des séances de jeux retenues, il est possible de discerner qualitativement deux « paradigmes » de cotation du plaisir suivis par les participants. Ces paradigmes indiquent des utilisations différentes du facteur-fun, et donc une signification variable du facteurs-fun d'un joueur à l'autre. Ceux-ci découlent d'observations qualitatives étendue sur toute la durée de ce projet de maîtrise et constituent un outil permettant d'orienter notre réflexion quant à l'utilisation du facteur-fun par les différents joueurs. Plus bas, ceux-ci permettront de faire deux propositions concrètes quant à l'utilisation du facteur-fun nous permettant d'extraire des classes de plaisir à partir de ces derniers.

Le premier paradigme ( $P_A$ ) est une cotation générale du plaisir durant la séance de jeu et est illustré à la figure 2.2a. Dans ce cas, le participant augmente ou diminue la valeur du facteur-fun de façon plutôt espacée (c.-à-d. que le temps entre les changements est grand). Dans ce paradigme, la valeur du facteur-fun semble être interprétée, par le participant, comme le « niveau de plaisir » (plus celui-ci est élevé, plus le plaisir réel du joueur l'est aussi). Notons qu'il est plus probable que le facteur-fun « sature » sous ce paradigme, c'est-à-dire qu'il atteigne une ou l'autre des valeurs minimale (-100) ou maximale (+100), si plusieurs augmentations ou diminutions ont lieu successivement.


Le second paradigme ( $P_B$ ) est associé à une cotation plus précise du plaisir, qui est illustrée à la figure 2.2b. Dans ce paradigme, le joueur augmente ou diminue la valeur du facteur-fun pour certains évènements précis du jeu, en procédant relativement rapidement. Ici, le facteur-fun semble être traité comme le « changement de plaisir », et chaque augmentation ou diminution est habituellement suivie d'un retour au niveau initial (c.-à-d. que chaque changement dans une direction est habituellement suivi d'un autre dans la direction opposée). Dans ce paradigme, le facteur-fun a tendance à osciller autour d'une valeur moyenne.

En somme, un participant qui suit le paradigme  $P_A$  effectue la cotation selon le « niveau de plaisir », tandis qu'un participant qui suit le paradigme  $P_B$  effectue la cotation selon la « dérivée du niveau de plaisir » (c.-à-d. selon le taux de variation du niveau de plaisir).

Bien que certains participants suit parfois l'un ou l'autre des paradigmes, la plu-



(a)  $P_1$  : cotation selon le niveau de plaisir. ( $P147, S4M1$ )




(b)  $P_2$  : cotation selon les changements de plaisir. ( $P173, S4M1$ )

FIGURE 2.2 – Deux paradigmes de cotation du plaisir observés dans les facteurs-fun des participants retenus.


part des participants suivent davantage une approche mixte. Dans ces approches mixtes, en plus de coter leur niveau de plaisir, les participants cotent également les changements de plaisir pour des événements précis. La figure 2.3 contient quelques exemples illustrant ceci.

Ces différences dans les techniques de cotation semblent indiquer que la signification de la valeur absolue du facteur-fun varie selon le participant, et qu'elle change même à l'intérieur d'une même cotation (c.-à-d. le cas de l'approche mixte). En conséquence, la valeur absolue du facteur-fun ne semble pas constituer une source d'information fiable du plaisir du joueur, puisqu'elle semble parfois référer au niveau global de plaisir, parfois au changement de plaisir.


Cependant, à l'inverse de la valeur du facteur-fun, les changements dans le facteur-fun semblent contenir une information similaire entre les joueurs et à l'intérieur d'une même cotation. En effet, les changements du facteur-fun semblent toujours être associés aux différents événements du jeu perçus comme plaisants ou déplai-




(a) (P20, S9M3)



(b) (P36, S9M3)



(c) (P43, S5M3)



(d) (P68, S5M3)

FIGURE 2.3 – Approche mixte de cotation du plaisir : quelques exemples de facteurs-fun.



sants par le joueur. En ce sens, les changements dans le facteur-fun semblent être, à la base, une cotation du degré d'appréciation d'un évènement du jeu.

En conséquence, il est proposé que les changements du facteur-fun sont des indicateurs plus fiables du plaisir du joueur que la valeur du facteur-fun elle-même, et donc que les classes de plaisir doivent s'appuyer sur les changements du facteur-fun et non sur la valeur de celui-ci. Ce qui précède est résumé dans la proposition 1 :

**Proposition 1 (P1)** *Seuls les changements du facteur-fun sont représentatifs du plaisir du joueur.*

Durant une partie, le joueur est exposé à certains évènements de jeu<sup>2</sup> qu'il interprète comme neutres, plaisants ou déplaisants. Les évènements plaisant produisent des augmentations de plaisir, les évènements déplaisants, des diminutions de plaisir, et que les évènements neutres ne modifient pas le niveau de plaisir du joueur.

Il est raisonnable de penser que l'effet de l'augmentation de plaisir causée par les évènements plaisants s'atténuera alors que le jeu progresse. En effet, en l'absence d'évènements qui éveillent l'intérêt du joueur et maintiennent son engagement, l'expérience commune suggère que le plaisir du joueur diminuera progressivement. À l'inverse, il est attendu qu'un évènement déplaisant ne minera pas complètement le plaisir du joueur, et que ce dernier reviendra à une position d'équilibre (neutre) après un certain temps. Cette réflexion est résumée dans la proposition 2

**Proposition 2 (P2)** *En l'absence d'évènements plaisants ou déplaisants, le plaisir du joueur croit ou décroît progressivement jusqu'à atteindre une valeur neutre.*

---

2. Ici, le terme « évènement de jeu » réfère à tout ce qui peut se produire dans le jeu. Bien que ce terme englobe ce qui se passe dans le jeu indépendamment de la volonté du joueur (p.ex. une explosion), celui-ci inclut également le résultat d'une interaction entre le joueur et le jeu (p. ex. un combat entre le joueur et un personnage non-joueur).

## 2.3 Mise en contexte : approches proposées dans les travaux antérieurs

Ici, les approches pour la création de classes de plaisir proposées dans les travaux de Clerico et collab. (2016) et Fortin-Cote et collab. (2018) sont présentées et les problématiques de ces approches sont discutées dans le contexte des propositions 1 et 2.

### 2.3.1 Classes proposées par Clerico et collab. (2016)

Afin de créer des classes de plaisir, Clerico et collab. (2016) ont proposé l'approche à 3 composantes représentée en figure 2.4. Dans cette dernière, chaque composante du modèle est un classificateur binaire qui prend en entrée des caractéristiques extraites des signaux physiologiques. En premier lieu, le classificateur A détermine si le plaisir du joueur est en changement ou s'il est stable. Ensuite, selon la valeur obtenue par le classificateur A, l'un ou l'autre des classificateurs B ou C est utilisé. Dans le cas où un changement de plaisir est détecté, le classificateur B détermine si le plaisir augmente ou diminue. Dans le cas où aucun changement de plaisir n'est détecté, le classificateur C détermine si le plaisir est au-dessus ou en dessous de la moyenne globale.

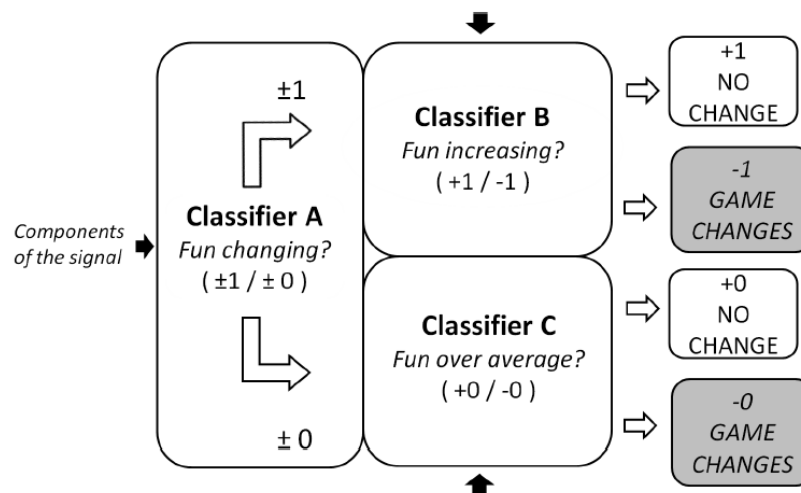


FIGURE 2.4 – Le modèle à trois composantes binaires proposé par Clerico et collab. (2016). Image tirée de Clerico et collab. (2016).

Cette cascade de classificateurs permet de discriminer quatre cas de figure (4 classes) : le plaisir augmente (+1), diminue (-1), est stable et sous la moyenne (-0) ou est stable

et au-dessus de la moyenne (+0). Selon les auteurs, seulement deux de ces cas de figure indiquent qu'une adaptation du jeu est nécessaire, alors que les deux autres indiquent qu'aucune adaptation du jeu n'est nécessaire, puisque le plaisir du joueur augmente ou est stable.

### 2.3.2 Classes proposées par Fortin-Cote et collab. (2018)

Fortin-Cote et collab. (2018) ont proposé deux approches pour la création de classe de plaisir. La première approche utilise la valeur du facteur-fun pour créer 3 classes nommés respectivement « plaisir faible », « plaisir neutre » et « plaisir élevé ». L'équation 2.1 présente la définition de chaque classe :

$$\text{classe}(f_i) = \begin{cases} \text{Plaisir faible} & \text{si } (f_i - \mu_F) < -\frac{1}{3}\sigma_F \\ \text{Plaisir neutre} & \text{si } |f_i - \mu_F| < \frac{1}{3}\sigma_F \\ \text{Plaisir élevé} & \text{si } (f_i - \mu_F) > \frac{1}{3}\sigma_F \end{cases}, \quad (2.1)$$


où  $f_i$  est la valeur du facteur-fun au temps  $i$  et  $F = \{f_i, \dots, f_N\}$ ,  $N$  étant le nombre d'échantillons, et  $\mu_F$  et  $\sigma_F$  sont respectivement la moyenne et l'écart-type du facteur-fun considéré.

Dans la seconde approche, le rang (« rank ») du facteur-fun est calculé avec l'équation<sup>3</sup>


$$\text{rang}(f_i) = \begin{cases} \max(-1, \text{rang}(f_{i-1}) - 1) & \text{si } f_i - f_{i-1} < -T \\ \min(1, \text{rang}(f_{i-1}) + 1) & \text{si } f_i - f_{i-1} > T \\ 0 & \text{si } i = 0 \\ \text{rang}(f_{i-1}) & \text{autrement} \end{cases}, \quad (2.2)$$

où  $T$  est la tolérance, un paramètre qui est utilisé pour balancer la distribution des classes. Le rang du facteur-fun est calculé avec la première différence du facteur-fun et s'appuie donc sur les changements du facteur-fun. Les trois classes possibles (-1, 0, et +1) décrivent si le plaisir du joueur diminue, est stable ou augmente. La figure 2.5 illustre les résultats des équations 2.1 et 2.2 pour un même facteur-fun.

3. L'équation (2) proposée par Fortin-Cote et collab. (2018) contenait des erreurs qui ont été corrigées dans l'équation 2.2.



(a) Selon la valeur du facteur-fun (éq. 2.1).



(b) Selon le rang (éq. 2.2 pour  $T = 0$ ).

FIGURE 2.5 – Comparaison des approches proposées par Fortin-Cote et collab. (2018) selon la valeur du facteur-fun et selon le rang pour un même facteur-fun. Les couleurs rouge, jaune et vert représentent en respectivement les classes « plaisir faible » (« plaisir diminuant »), « plaisir neutre » (« plaisir stable ») et « plaisir élevé » (« plaisir augmentant »). (P213, S4M1)

Pour les deux approches de Fortin-Cote et collab. (2018), la classe assignée à une époque donnée correspond à la valeur majoritaire dans l'époque. Par exemple, si l'équation 2.2 indique que 60% des échantillons de l'époque ont obtenu une valeur nulle, alors la classe de l'époque sera « 0 » (« plaisir stable »).

### 2.3.3 Problèmes avec les approches précédentes

Basé sur les propositions présentées à la section 2.2, deux problèmes se dégagent des approches de Clerico et collab. (2016) et Fortin-Cote et collab. (2018) quant à la création de classes à partir des facteurs-fun.

Tout d'abord, deux des approches proposées par les auteurs dépendent de la valeur absolue du facteur-fun pour la création de classes de plaisir. Or, tel que proposé à la section précédente, il existe une grande variabilité interparticipant et intraparti-

cipant quant à la signification de la valeur du facteur-fun. Cette variabilité dans la signification de la valeur du facteur-fun rend celle-ci inutilisable pour la création de classe. En effet, il est possible que l'introduction de cette dernière dans la définition des classes de plaisir produise des classes non représentatives de l'état de plaisir réel du joueur, introduisant par le fait même une quantité non négligeable de bruit dans le jeu de données.

À l'inverse, l'équation 2.2 est la seule qui utilise strictement la valeur des changements pour la création de classe (le modèle de Clerico et collab. (2016) utilise à la fois la valeur et les changements du facteur-fun) et est donc la seule approche qui respecte P1. Cependant, contrairement à ce qui est affirmé par les auteurs, l'approche du rang ne permet pas réellement de balancer les 3 classes (« plaisir diminuant », « plaisir stable », « plaisir augmentant »). En effet, indépendamment de la tolérance choisie, la classe « plaisir stable » n'apparaît que comme transition entre les deux autres classes et est de durée infinitésimale ( $\approx 1$  ms). Cela a pour conséquence que cette classe n'est pas représentée dans le jeu de donnée (c.-à-d. qu'elle n'est assignée à aucune époque). Or, nous soutenons que cette classe est nécessaire pour l'entraînement du modèle, puisque la proposition 2 indique que le plaisir du joueur tend vers un état neutre.

D'ailleurs, parmi les trois approches présentées, aucune ne propose de mécanisme pour tenir compte des considérations soulevées par P2, c'est-à-dire que le plaisir du joueur devrait décroître ou croître de manière à tendre vers un état de plaisir neutre. Dans le cas de l'équation 2.2, par exemple, ceci a pour conséquence que certains segments « stables » du facteur-fun (c.-à-d. des segments où il n'y a aucun changement dans le facteur-fun) sont associés à des diminutions ou des augmentations constantes, alors que P2 suggère que l'inverse se produit (si le facteur-fun est positif et constant, alors le plaisir réel du joueur est, en fait, en décroissance jusqu'à atteindre un plaisir neutre).

Finalement, aucune des approches ne tient compte des pics de fun-facteur. Comme illustré à la figure 2.6, les pics de facteur-fun sont des variations qui sont suivies d'un retour au niveau initial. Il est raisonnable de supposer que ces pics (ceux de la figure 2.6) indiquent des augmentations ponctuelles du plaisir du joueur, plutôt qu'une augmentation rapide suivie d'une diminution tout aussi rapide du plaisir (ce point sera discuté plus en détail à la section 2.4.2). Or, ceci doit être pris en compte lors du calcul des changements de facteur-fun, car autrement les augmentations pourraient

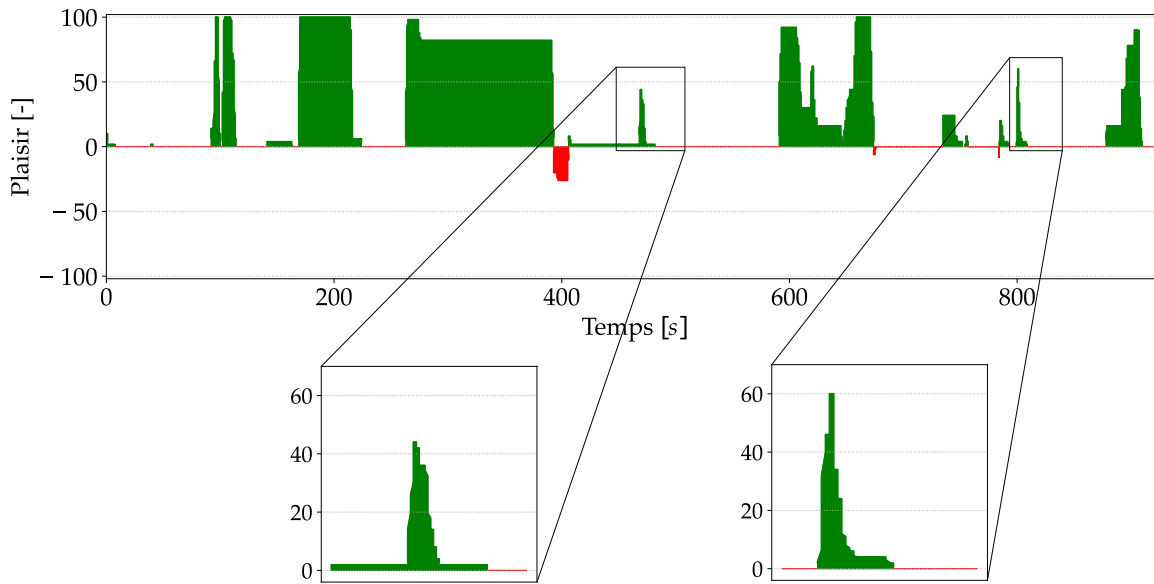


FIGURE 2.6 – Pics dans le facteur-fun. (*P188, S5M3*)

être confondues avec des diminutions et vice-versa.

## 2.4 Approche proposée dans le présent travail

Pour remédier aux problèmes des approches précédentes, une nouvelle approche est proposée pour créer des classes à partir des facteurs-fun. Celle-ci repose sur les propositions 1 et 2 soulevées à la section 2.2 ainsi que sur les points abordés à la section 2.3.3.

Cette méthode se divise en 4 étapes. Premièrement, les changements de facteur-fun sont détectés. Deuxièmement, les changements sont corrigés pour tenir compte des pics de facteur-fun. Troisièmement, les changements de facteur-fun sont modifiés pour intégrer la proposition 2, soit que le plaisir du joueur tende vers un état de plaisir neutre en l'absence d'évènements plaisants ou déplaisants. Finalement, les classes sont associées à des époques par un vote de majorité, de la même manière que proposé dans le travail de Fortin-Cote et collab. (2018).

### 2.4.1 Détection des changements de facteur-fun

Afin de détecter les changements de facteur-fun, une méthode utilisée dans Fortin-Côté et collab. (2019) est reprise et développée ici. Cette méthode utilise la première différence du facteur-fun ( $\Delta f_n$ ), qui est proportionnelle à la dérivée du facteur-fun et est définie au temps  $n$  comme

$$\Delta f_n = f_{n+1} - f_n . \quad (2.3)$$

La première différence est informative des variations de facteur-fun, mais celle-ci est bruitée, ce qui rend la détection précise de la position des changements difficile. Afin de contourner ce problème, le produit de convolution entre  $\Delta f_n$  et une fonction fenêtre de Hanning est calculé afin d'obtenir une version lissée de  $\Delta f_n$ , soit

$$F_n = \Delta f_n * H_n = \sum_{k=-\infty}^{\infty} \Delta f_k H_{n-k} , \quad (2.4)$$

avec la fenêtre de Hanning  $H_n$  définie comme


$$H_n = \frac{1}{2} \left[ 1 - \cos \left( \frac{2\pi n}{M} \right) \right] \quad 0 \leq n \leq M - 1 , \quad (2.5)$$

où  $M$  est la largeur de  $H_n$ . Dans le présent travail, une fenêtre de Hanning de 5 secondes a été utilisée. Cette valeur a été déterminée empiriquement. De plus,  $F_n$  a été calculée en faisant attention à ce que le produit de convolution soit centré sur la fonction originale<sup>4</sup>.


Ensuite, un algorithme simple de détection des maxima et des minima est utilisé pour déterminer les positions précises des changements de facteur-fun à partir de  $F_n$ . La figure 2.7 résume les étapes présentées ci-dessus pour la détection des changements de facteur-fun, tandis que le code Python implémenté pour cette tâche est présenté à l'annexe C.

---


4. Le produit de convolution avec la fenêtre de Hanning proposée devrait normalement être décalé par rapport à  $\Delta f_n$ , cependant celle-ci peut-être recentré pour imiter une fonction noyau centrée à l'origine. La fonction `numpy.convolve` avec le paramètre `mode='same'`, qui a été utilisée pour calculer le produit de convolution, effectue cette opération automatiquement.




(a) Facteur-fun original.



(b) Première différence du facteur-fun (éq. 2.3).



(c) Convolution par une fenêtre de Hanning de 5 secondes (éq. 2.4).



(d) Détection des maxima et des minima.

FIGURE 2.7 – Étapes de la détection des changements de facteur-fun. (*P188, S5M3*)



## 2.4.2 Corrections des changements de facteurs-fun pour la prise en compte des pics de fun

Comme il en a été question à la section 2.3.3, les pics de facteur-fun doivent être pris en compte pour éviter de confondre les diminutions et les augmentations de facteur-fun. À cette fin, un algorithme de détection des pics de facteur-fun a été mis en place. Ce dernier s'appuie sur la méthode de détection des changements de facteur-fun présentée à la section précédente.

Dans cet algorithme, les changements de facteur-fun obtenus précédemment sont parcourus en ordre chronologique. Lorsqu'un changement dans une direction est suivi d'un changement dans la direction opposée, le second changement est ignoré. Dans ce projet, le temps maximum entre 2 changements de facteur-fun opposés, à l'intérieur duquel ceux-ci sont considérés comme des pics, a été réglé à 6 secondes de manière empirique. La figure 2.8 illustre la correction des changements de facteur-fun pour la prise en compte des pics. La classe Python implémentée pour effectuer cette correction est présentée à l'annexe D. Afin de simplifier la notation, les changements de facteur-fun avec correction seront notés  $CF_n$  pour la suite.


## 2.4.3 Intégration de la proposition 2

Cette étape a pour but d'intégrer la proposition 2 dans la création des classes. La proposition 2 indique que le plaisir du joueur tend vers une valeur neutre en l'absence d'évènement plaisant ou déplaisant.


Dans le cadre de ce projet, cette proposition est modélisée par une fonction qui décroît exponentiellement, soit

$$g_n = e^{-t_n} , \tag{2.6}$$

où  $t_n$  est la  $n$ -ième valeur d'une variable  $t$ .



(a) Facteur-fun original.




(b) Détection des changements de facteur-fun avec correction des pics. Les changements en gris sont ignorés.

FIGURE 2.8 – Correction des pics de facteur-fun. (P188, S5M3)


Afin d'intégrer la proposition 2 à la création des classes de facteur-fun, nous proposons que le plaisir du joueur puisse être modélisé par un produit de convolution entre la fonction exponentielle  $g_n$  et les changements de facteur-fun corrigés ( $CF_n$ ). Le nouveau facteur-fun obtenu, nommé facteur-fun transformé ( $FT_n$ ), correspond à l'équation

$$FT_n = CF_n * g_n = \sum_{k=0}^{\infty} CF_n \cdot e^{-t_k}, \quad (2.7)$$

où  $t_k = 0, \dots, 5$   $k \in \mathbb{N}$  est la  $k$ -ième échantillon de  $t_k$ . Dans notre cas, la fonction exponentielle s'étend sur 30 secondes. Ce choix est justifié par le fait que 95% des changements de facteur-fun surviennent entre 0 et 30 secondes après un changement précédent (tel qu'illustré à la figure 1.5). Et donc, si aucun changement de facteur-fun n'est détecté dans les 30 secondes suivant le changement de facteur-fun précédent, ce doit être que le plaisir du joueur est revenu à un niveau neutre (selon P2). La figure 2.9 illustre le facteur-fun transformé.



(a) Facteur-fun original.



(b) Facteur-fun transformé ( $FT_n$ ).


FIGURE 2.9 – Facteur-fun original et transformé selon l’approche proposée. (P188, S5M3)

#### 2.4.4 Assignation des classes aux époques par vote de majorité


Trois classes de plaisir sont définies à partir du facteur-fun transformé ( $FT_n$ ) : « non-plaisir », « neutre » et « plaisir ». Ces dernières représentent le plaisir du joueur durant la séance de jeu et sont définies à l’équation 2.8 et la figure 2.10 illustre les classes des échantillons d’un facteur-fun selon la méthode proposée.

Finalement, la classe associée à une époque donnée est déterminée par un vote de majorité, où la classe majoritaire est assignée à l’époque.

$$\text{classe}(FT_n) = \begin{cases} \text{Plaisir diminuant} & \text{si } FT_n < 0 \\ \text{Plaisir neutre} & \text{si } FT_n = 0 \\ \text{Plaisir augmentant} & \text{si } FT_n > 0 \end{cases} , \quad (2.8)$$



(a) Classes projetées sur le facteur-fun original.



(b) Classes projetées sur le facteur-fun transformé ( $FT_n$ ).

FIGURE 2.10 – Classes créées à partir du facteur-fun selon la valeur de  $FT_n$  telles que déterminées à l'équation 2.8. (P188, S5M3)

# Chapitre 3

## Entraînement des classificateurs

Dans ce chapitre, les méthodologies suivies pour la création des jeux de données, la sélection des caractéristiques, l'entraînement et l'optimisation des hyperparamètres des classificateurs sont présentées. Les résultats de l'entraînement sont également présentés et un modèle final est proposé. Finalement, les résultats et les limites du présent travail sont discutés.

## 3.1 Méthode

La méthode proposée dans cette section vise à adresser les objectifs spécifiques 3, 4 et 5 de ce projet de recherche. En premier lieu, le processus de création des jeux de données est présenté. Pour l'entraînement des modèles, 3 jeux de données avec des longueurs d'époques de 10, 30 et 60 secondes ont été créés et 2 types de classes de plaisir ont été joints aux jeux de données. En second lieu, la méthode utilisée pour sélectionner et standardiser les caractéristiques physio-comportementales est détaillée. Dans cette partie, la statistique F d'une ANOVA univariée a été utilisée comme mesure de corrélation entre les caractéristiques physio-comportementales et les classes de plaisir. En troisième lieu, les différents classificateurs entraînés sont présentés. Trois modèles ( $k$ NN, SVM et RF) ont été entraînés sur chaque jeu de données, et ce pour les deux types de classes testés, totalisant ainsi 9 conditions d'entraînement pour chaque classificateur. Finalement, la méthode pour l'entraînement des différents classificateurs et l'optimisation de leurs hyperparamètres est présentée. Ici, une recherche aléatoire a été menée pour déterminer les valeurs optimales des hyperparamètres.

Cette méthode a été élaborée afin de répondre aux questions suivantes, qui découlent des objectifs spécifiques du présent projet :

- quelle longueur d'époque utilisée pour calculer les différentes caractéristiques physio-comportementales permet d'obtenir la meilleure performance de classification ?
- quelles classes parmi celles mises en place par Fortin-Cote et collab. (2018) et celles proposées dans ce mémoire permettent d'obtenir les meilleures performances de classification ?
- quelles modalités physio-comportementales sont les plus informatives de l'expérience de jeu ?

### 3.1.1 Création des jeux de données

Afin de vérifier l'effet de la longueur des époques sur les performances des classificateurs, 3 longueurs d'époques ont été testées, soit 10, 30 et 60 secondes. Pour chaque longueur d'époque, un jeu de données a été créé, ce qui a permis d'obtenir 3 jeux de données distincts.

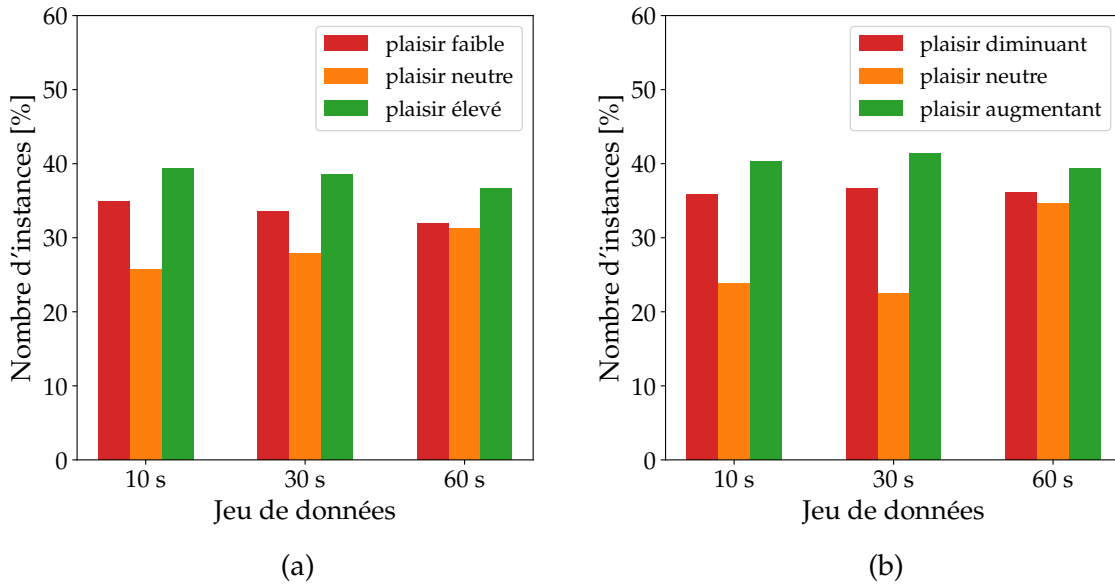


FIGURE 3.1 – Distributions des instances pour les ensembles de classes (a)  $C_A$  et (b)  $C_B$  dans les 3 jeux de données créés. Les 3 jeux de données contiennent des caractéristiques calculées sur des longueurs d'époque différentes, soit 10, 30 et 60 secondes. De plus, les jeux de données avec des époques de 10, 30 et 60 secondes contiennent respectivement 7366, 2481 et 1266 instances.

Les jeux de données obtenus pour chaque longueur d'époque contenaient respectivement 7366, 2481 et 1266 instances de 192 caractéristiques. Les caractéristiques extraites ont été présentées à la section 1.3.2 et proviennent des signaux physiologiques et des indices comportementaux de la base de données FUNii. De plus, deux types de classes de plaisir ont été ajoutés aux jeux de données, soit les classes créées à partir des équations 2.1 ( $C_A$ ) et 2.8 ( $C_B$ ). Les classes  $C_A$  correspondent aux classes proposées par Fortin-Cote et collab. (2018) et s'appuient sur la valeur absolue du facteur-fun. À l'inverse, les classes  $C_B$  ont été obtenues avec l'approche proposée au chapitre 2.1 et s'appuient sur les changements de facteur-fun. La distribution des classes dans les 3 jeux de données est présentée à la figure 3.1.

Chaque jeu de données a été divisé en deux parties : le jeu d'entraînement et de validation, et le jeu de test. Comme son nom l'indique, le jeu d'entraînement et de validation est utilisé pour l'entraînement des classificateurs ainsi que pour la validation de leur performance durant la validation croisée à 3 plis. Le jeu de test est, quant à lui, utilisé pour déterminer les performances du classificateur final et permet d'estimer ses capacités de généralisation.

Afin d'éviter que les performances du modèle entraîné ne montrent un biais optimiste, il importe que les données d'un même participant ne soient pas utilisées à la fois pour l'entraînement et pour les tests. En conséquence, le jeu de test est exclusivement construit à partir des données de nouveaux participants, qui sont absents du jeu d'entraînement. À cette fin, les données de 80% des participants ont été utilisées pour construire les jeux d'entraînement et de validation, tandis que les 20% restants ont été utilisées pour construire les jeux de tests.

### 3.1.2 Sélection et standardisation des caractéristiques

Pour chaque classificateur entraîné, une partie des caractéristiques a été sélectionnée à partir des 192 caractéristiques initialement extraites des signaux physiologiques et des indices comportementaux.

La sélection des caractéristiques a été effectuée à l'aide de la statistique F d'une ANOVA univariée entre chaque caractéristique et les classes de plaisir. La statistique F mesure le rapport entre la variabilité entre les groupes et la variabilité à l'intérieur des groupes. Concrètement, la statistique F teste l'hypothèse que les moyennes de différents ensembles de données suivant des lois normales avec les mêmes écarts-types sont égales. La valeur de la statistique F est donnée par l'équation

$$F = \frac{(K - 1) \sum_{i=1}^K n_i (\bar{Y}_i - \bar{Y})^2}{(N - K) \sum_{i=1}^K \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2}$$

où  $K$  est le nombre de classes,  $N$  est le nombre total d'observations,  $n_i$  est le nombre d'observations dans le groupe  $i$ ,  $\bar{Y}_i$  est la moyenne de  $Y$  pour le groupe  $i$ ,  $\bar{Y}$  est la moyenne globale du jeu de données,  $Y_{ij}$  est la  $j$ -ième observation du groupe  $i$  (St et collab., 1989). Pour les trois jeux de données créés, les caractéristiques pour lesquelles  $p < 0.05$  ont été sélectionnées et les autres ont été rejetées. Les données associées à chaque caractéristique ont ensuite été standardisées selon la valeur moyenne et l'écart-type calculés sur le jeu d'entraînement et de validation complet.

### 3.1.3 Classificateurs testés

Trois classificateurs ont été testés pour l'entraînement du modèle : un  $k$  plus proche voisin («  $k$  Nearest Neighbors »;  $k$ NN), un séparateur à vaste marge (SVM) et une forêt d'arbres décisionnels (« Random Forest »; RF). Ces classificateurs ont été sélectionnés pour leur présence dans les travaux présentés à la section (tout particulièrement le classificateur SVM, qui a été utilisé dans plusieurs travaux), mais également



pour leur simplicité. De plus, pour l'entraînement des classificateurs nous avons utilisé *Scikit-Learn*<sup>1</sup>, une librairie d'apprentissage automatique avec une interface Python (Pedregosa et collab., 2011).

Les trois modèles et les hyperparamètres testés durant la recherche aléatoire sont présentés ci-dessous,

### ***k* plus proches voisins**

Le *k*NN<sup>2</sup> est une méthode non paramétrique pour laquelle les classes de nouveaux exemples sont déterminées à partir des classes de leurs *k* plus proches voisins, suivant un vote de majorité parmi les *k* voisins. Autrement dit, un exemple donné se verra attribuer la classe majoritaire associée aux *k* exemples qui en sont le plus près.

En conséquence, le *k*NN dépend principalement de deux hyperparamètres : le choix du nombre de voisins à considérer (*k*) et la métrique permettant de mesurer les distances entre les exemples.

### **Séparateur à vaste marge**

Le SVM<sup>3</sup> est une méthode paramétrique qui s'appuie sur des vecteurs de support pour déterminer la frontière de décision entre les classes. Ces vecteurs de supports sont des instances choisies afin de maximiser la marge, c'est-à-dire la distance entre la frontière de décision et les instances les plus près de celle-ci. Le SVM classique est un classificateur binaire, mais il est possible d'en faire un classificateur multi-classes en suivant un paradigme de comparaison un-contre-un.

Le SVM avec un noyau gaussien utilisé ici dépend de deux hyperparamètres principaux : *C* et  $\gamma$ . L'hyperparamètre *C* est une pénalité sur les erreurs de classification durant l'entraînement, tandis que  $\gamma$  est un paramètre du noyau gaussien qui module l'influence des vecteurs de support.

### **Forêt d'arbres décisionnels**

Le modèle RF<sup>4</sup> est une méthode d'ensemble qui utilise plusieurs arbres de décisions sur des sous-ensembles du jeu d'entraînement pour construire la frontière de dé-

---

1. La documentation de *Scikit-Learn* (v0.21.3) est disponible à l'adresse : <https://scikit-learn.org/dev/versions.html>.

2. Implémentation utilisée : `sklearn.neighbors.KNeighborsClassifier`

3. Implémentation utilisée : `sklearn.svm.SVC`

4. Implémentation utilisée : `sklearn.ensemble.RandomForestClassifier`

cision. Ces sous-ensembles, déterminés aléatoirement par tirage avec remise, sont utilisés pour entraîner des arbres de décision. Ceux-ci sont ensuite mis en commun par une méthode d'ensemble afin de déterminer la classe d'une nouvelle instance.

Le modèle RF dépend de plusieurs hyperparamètres : le nombre d'estimateurs ( $n\_estimator$ ), la profondeur maximale des arbres ( $max\_depth$ ), le nombre minimum d'échantillons requis pour scinder un noeud ( $max\_samples\_split$ ), ainsi que le nombre minimum d'échantillons requis pour former une feuille ( $max\_samples\_leaf$ ).

Le tableau 3.1 présente l'espace des hyperparamètres testés pour chaque modèle. Les hyperparamètres qui sont demeurés constants durant tous les tests ne sont pas représentés au tableau 3.1, et correspondent à ceux proposés par défaut dans *Scikit-Learn*. Pour plus d'informations, le lecteur pourra se référer à la documentation de *Scikit-Learn*.

Tableau 3.1 – Espaces des hyperparamètres explorés durant la recherche aléatoire. Les noms des hyperparamètres sont les mêmes que ceux des implémentations utilisées, c.-à-d. qu'ils correspondent à l'interface de *Scikit-Learn*.

Modèle	Hyperparamètres
kNN	$k \in \{1, 2, 3, \dots, 38, 39\}$ $p \in \{1, 2\}$ $weights \in \{'uniform', 'distance'\}$
SVM	$C \in [2 \cdot 10^{-5}, 2 \cdot 10^{15}]$ $\gamma \in [2 \cdot 10^{-15}, 2 \cdot 10^3]$
RF	$bootstrap \in \{True, False\}$ $max\_depth \in \{10, 20, 30, \dots, 100, \} \cup \{\infty\}$ $min\_samples\_leaf \in \{1, 2, 4\}$ $min\_samples\_split \in \{2, 5, 10\}$ $n\_estimators \in \{200, 400, 600, \dots, 1800, 2000\}$

### 3.1.4 Entraînement et optimisation des hyperparamètres des modèles

Les modèles ont été entraînés à l'aide d'une recherche aléatoire des hyperparamètres avec validation à 3 plis<sup>5</sup>. Durant la recherche aléatoire, chaque hyperparamètre est choisi au hasard parmi un ensemble prédéfini de valeurs ou une distribution continue lorsque cela est possible. Comparativement à une autre méthode populaire, la recherche en grille (« grid search »), la recherche aléatoire permet généralement d'ob-

5. implémentation utilisée : `sklearn.model_selection.RandomizedSearchCV`

tenir de meilleurs modèles en moins de temps de calcul (Bergstra et Bengio, 2012). De plus, la recherche aléatoire est stratifiée, c'est-à-dire que la distribution des données dans chaque pli est la même que dans le jeu d'entraînement complet. Pour plus de détail concernant le processus d'entraînement des modèles supervisés, se référer à l'annexe B.

Lors de la recherche aléatoire, chaque jeu d'hyperparamètres est utilisé pour entraîner un modèle avec une validation croisée à 3-plis. Ceci permet d'obtenir 3 estimations de la performance du modèle sur le jeu de validation. Ces 3 mesures sont utilisées pour calculer la valeur moyenne et l'écart-type du taux de classement, qui sont des approximations du biais et de la variance du modèle entraîné. Le biais est associé aux erreurs d'hypothèses à l'intérieur du modèle, tandis que la variance est associée aux erreurs causées par la mauvaise capacité de généralisation du modèle à de nouvelles données (Bishop, 2006). En conséquence, un modèle avec un taux de classement moyen élevé (c.-à-d. un biais faible) et un écart-type faible (c.-à-d. une variance faible) parvient à classer correctement les exemples et ses performances dépendent peu des données utilisées (bonne capacité de généralisation à de nouvelles données).

Durant la recherche aléatoire menée dans ce chapitre, 200 configurations d'hyperparamètres ont été testées pour chacun des modèles entraînés (à l'exception du modèle  $k$ NN, pour lequel l'espace des hyperparamètres testés ne comptait que 169 jeux d'hyperparamètres). Au terme de ces 200 itérations, les hyperparamètres ayant permis d'obtenir les plus grands taux de classement ont été retenus pour chaque classificateur entraîné.

Pour chaque classificateur testé, la recherche aléatoire a été menée pour les 3 jeux de données (avec des époques de 10, 30 et 60 secondes). Au total, 9 classificateurs ont donc été obtenus, ceux-ci ayant obtenu les meilleures performances en validation croisée. Dans le reste de ce mémoire, ces modèles seront identifiés par le classificateur utilisé, par la longueur d'époque du jeu de données sur lequel ils ont été obtenus et par les classes qui ont été utilisées pour entraîner le modèle. Par exemple, on référera au meilleur SVM obtenu sur le jeu de données avec des époques de 10 secondes et entraîné avec les classes  $C_A$  par « SVM-10-A ».

## 3.2 Résultats

### 3.2.1 Performances des différents modèles durant l'entraînement

Afin de déterminer les jeux d'hyperparamètres optimaux pour chaque modèle, une recherche aléatoire avec validation croisée à 3 plis a été menée. Pour les modèles SVM et RF, 200 jeux d'hyperparamètres ont été testés, tandis que le modèle  $k$ NN a été testé pour 160 jeux d'hyperparamètres. Un classificateur naïf, qui classifie aléatoirement les instances selon la distribution du jeu d'entraînement, a également été testé sur les 3 jeux de données. Les performances de ce dernier ont servi de point de départ pour estimer les performances des modèles entraînés. La figure 3.2 présente les résultats des entraînements des modèles sur les jeux de données pour chaque jeu d'hyperparamètres et pour les classes  $C_A$  et  $C_B$ . Le tableau 3.2 présente quant à lui les plus grands taux de classement moyens obtenus pour chaque classificateur selon la longueur des époques.

Tableau 3.2 – Meilleurs résultats obtenus par recherche aléatoire avec validation croisée pour les classes  $C_A / C_B$  selon les trois longueurs d'époques testées. Les résultats représentent la moyenne (écart-type) du pourcentage de classification parmi les 3 plis du jeu d'entraînement pour  $C_A / C_B$ .

Classificateur	10 s	30 s	60 s
$k$ NN	39,2 (1,2) / 42,8 (0,6)	39,3 (2,1) / 48,3 (1,7)	39,7 (2,1) / 49,9 (1,5)
SVM	41,4 (1,2) / 40,3 (1,4)	40,3 (0,8) / 50,3 (2,0)	41,9 (1,0) / 47,5 (2,8)
RF	42,6 (1,2) / 44,2 (0,6)	41,2 (0,8) / 49,7 (2,9)	39,7 (0,9) / 48,8 (1,1)
Naïf	39,4 (1,8) / 40,3 (1,4)	38,5 (2,1) / 41,4 (2,1)	36,6 (2,5) / 35,6 (3,0)

Afin de déterminer si les différents classificateurs entraînés permettaient d'obtenir des performances significativement supérieures à celles des classificateurs naïfs, des tests T pour échantillons indépendants ont été menés entre les résultats des meilleurs modèles entraînés et les résultats des classificateurs naïfs. Le tableau 3.3 présente les valeurs p obtenues pour les 9 tests T menés. Les résultats indiquent qu'aucune des performances obtenues par les modèles entraînés avec les classes  $C_A$  ne permet d'obtenir des performances significativement différentes d'un classificateur naïf.

Les résultats de ces tests T ont également été utilisés afin de déterminer quel était le modèle le plus performant parmi les 9 modèles obtenus. Ici, le test T permet de déterminer les performances de quel classificateur sont les plus distinctes de celles

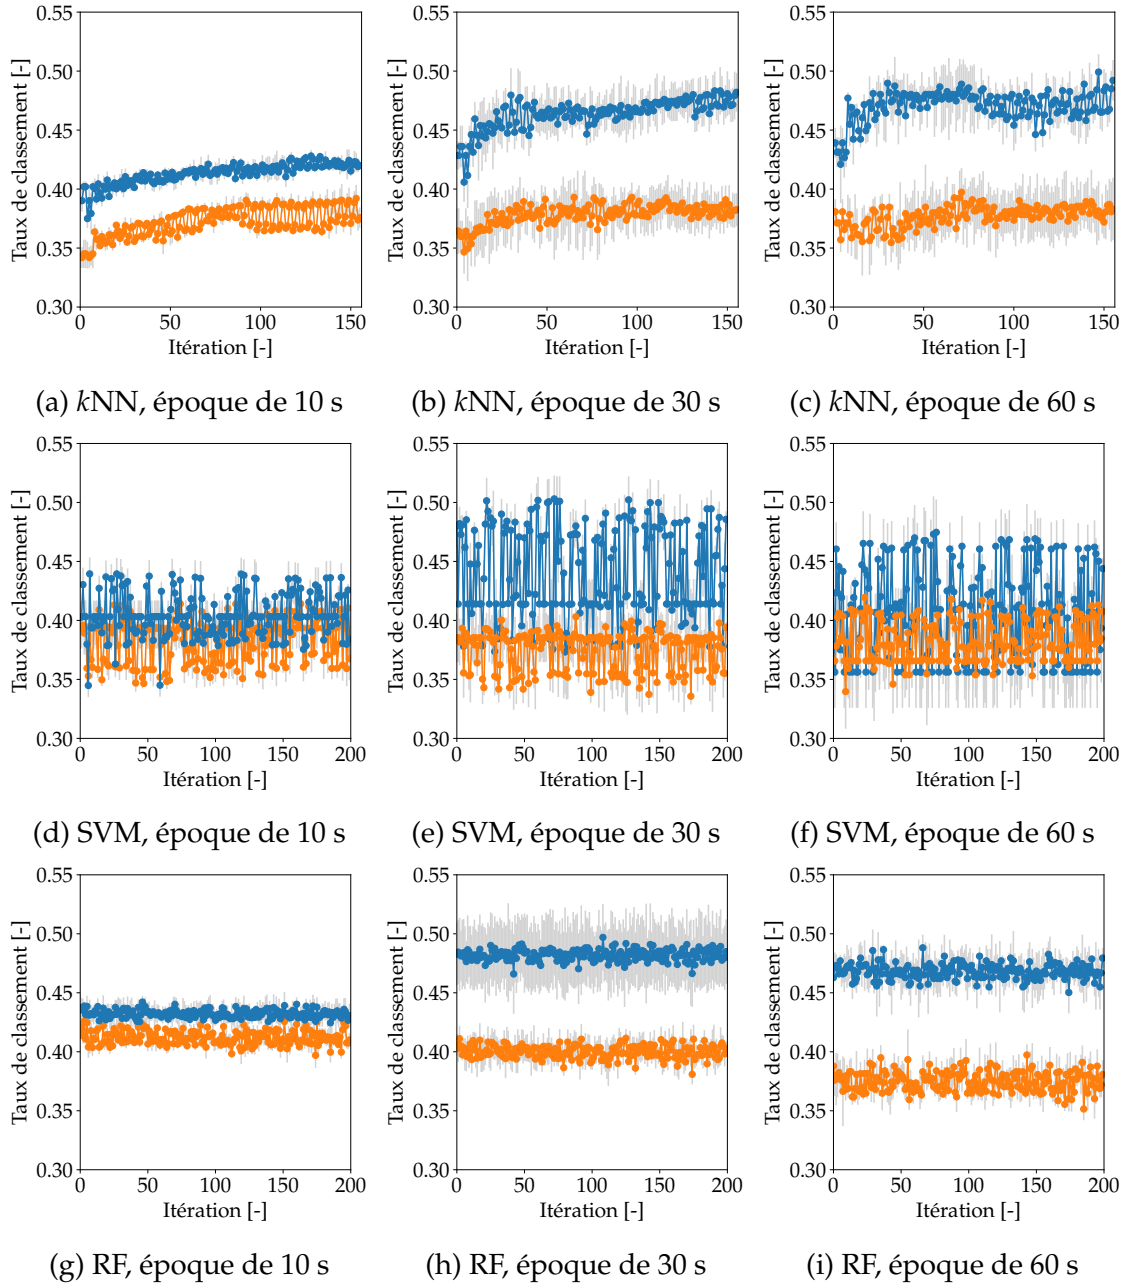


FIGURE 3.2 – Taux de performance moyen dans les 3 plis durant la recherche aléatoire pour les 3 modèles testés (*k*NN, RF, SVM) selon différentes longueurs d'époques et pour 2 approches utilisées pour la création des classes de plaisir. Les valeurs en bleu correspondent aux performances obtenues avec les classes produites par l'équation 2.8, et celles en orange, aux performances obtenues avec l'équation 2.1. La déviation standard calculée sur les 3 plis de chaque itération est indiquée en gris. Les graphiques a-c, d-f et g-i représentent les résultats obtenus pour les classificateurs *k*NN, RF et SVM, respectivement.

Tableau 3.3 – Valeurs p des tests T entre les performances des meilleurs classificateurs et celles des classificateurs naïfs pour les trois longueurs d’époque testées et pour les deux ensembles de classes. Ici, les valeurs p pour les classes  $C_A / C_B$  sont présentées.

Classificateur	10 s	30 s	60 s
<i>k</i> NN	0,92 / 0,11	0,72 / 0,024*	0,24 / 0,010*
SVM	0,25 / 0,058	0,36 / 0,012*	0,076 / 0,015*
RF	0,10 / 0,043*	0,21 / 0,033*	0,21 / 0,016*

d’un classificateur naïf. Pour ce faire, nous avons considéré que le modèle ayant obtenu une valeur-p la plus faible était également le plus performant. Les résultats indiquent donc que le modèle *k*NN-60-B, qui a obtenu un taux de classement moyen de 49,9% durant l’optimisation des hyperparamètres, est le plus performant. Remarquons que, bien que le modèle RF-30-B ait obtenu un taux de classement supérieur au modèle *k*NN-60-B, ce dernier a obtenu un taux de classement très semblable (−0.4%) et avait un écart-type inférieur au modèle RF-30-B. Ceci signifie que le taux de classement du modèle *k*NN-60-B est demeuré plus constant à travers les 3 plis de la validation croisée que celui du modèle RF-30-B.

### 3.2.2 Performances du modèle *k*NN-60-B sur le jeu de test

Afin de déterminer les capacités de généralisation du modèle *k*NN-60-B (c.à-d. notre meilleur modèle) les performances de ce dernier ont été évaluées sur le jeu de test. Le jeu de test comporte 357 instances provenant toutes de participants non présents dans le jeu d’entraînement. La figure 3.3 présente la matrice de confusion du classificateur *k*NN-60-B sur le jeu de test. Ce modèle a obtenu un taux de classement 53,5 % sur le jeu de test. La matrice de confusion du classificateur *k*NN-60-B a été utilisée pour déterminer la précision, le rappel et le score  $F_1$ , ainsi que la courbe ROC (« receiver operating characteristic ») pour chaque classe, qui sont présentés au tableau 3.4 et à la figure 3.4, respectivement. Les résultats indiquent que le modèle prédit avec moins de précision les classes « plaisir augmentant » et « plaisir diminuant », mais prédit avec plus de précision la classe « plaisir neutre ». Les résultats indiquent également que le modèle confond la plupart du temps les deux classes « plaisir augmentant » et « plaisir diminuant ».

Étiquette réelle	P. diminuant	45	3	86
	P. neutre	11	46	26
	P. augmentant	34	6	100
		P. diminuant	P. neutre	P. augmentant
		Prédiction		

FIGURE 3.3 – Matrice de confusion du modèle *k*NN-60-B avec un taux de classement de 53,5% sur le jeu de test.

Tableau 3.4 – Précision, rappel, score F1 et support des résultats de classification du modèle *k*NN-60-B sur le jeu de test.

Classe	précision	rappel	score F1	support
Plaisir diminuant	0,50	0,34	0,40	134
Plaisir neutre	0,84	0,55	0,67	83
Plaisir augmentant	0,47	0,71	0,57	140

### 3.2.3 Importances relatives des caractéristiques dans la prise de décision du meilleur modèle

Afin de déterminer quelles caractéristiques étaient les plus importantes pour la tâche de classification, la métrique d'importance des caractéristiques du modèle RF-60-B, qui a obtenu des performances similaires au modèle *k*NN-60-B, a été utilisé. En effet, les modèles *k*NN ne disposent d'aucune métrique de l'importance des caractéristiques, et il est possible d'utiliser un modèle similaire (c.-à-d. un modèle RF) possédant une telle métrique afin d'obtenir une évaluation de l'importance des caractéristiques. Pour plus de détail sur la détermination de l'importance des caractéristiques dans les modèles RF, voir la revue de Louppe (2014). La figure 3.5 présente l'impor-




FIGURE 3.4 – Courbe ROC du modèle  $k$ NN-60-B sur le jeu de test

tance relative de chacune des 57 caractéristiques sélectionnées pour l’entraînement du modèle  $k$ NN-60-B.

Afin de déterminer si certaines modalités physiologiques et comportementales étaient plus utilisées que d’autres par le modèle, les importances relatives des caractéristiques présentées à la figure 3.5 ont été regroupées selon leurs modalités respectives. Par exemple, les importances relatives de toutes les caractéristiques extraites de l’activité respiratoire ont été dans la catégorie « RSP ». La figure 3.6 présente l’importance relative de chaque modalité utilisée pour l’entraînement du modèle. Les résultats indiquent que les 3 modalités les plus importantes, soit l’expression faciale (36,31%), le RSP (25,02%) et les entrées du contrôleur Xbox (17,62%), représentent 78,94% de l’importance totale des caractéristiques, tandis que les 4 modalités restantes, soit l’ECG (7,29%) les mouvements de la tête (6,61%) l’EMG (4,95%) et l’EDA



(2,21%) représentent conjointement 21,06% de l'importance des caractéristiques.




FIGURE 3.5 – Importance relative des 57 caractéristiques sélectionnées pour l'entraînement des modèles *k*NN-60-B et RF-60-B. La métrique d'importance relative provient du modèle RF-60-B.

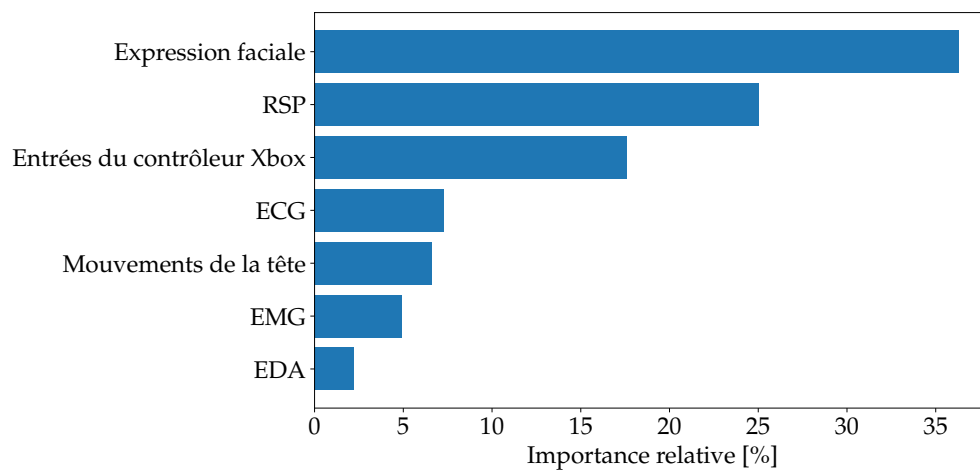


FIGURE 3.6 – Importance relative de chaque modalité physiologique et comportementale.

### 3.3 Discussion

Le présent projet de recherche consistait à entraîner et à tester les performances d'un classificateur permettant de reconnaître différents états de plaisir en contexte de jeu vidéo à partir de signaux physiologiques et d'indices comportementaux. Ce projet visait également à proposer une méthode de création de classes de plaisir à partir des facteurs-fun et à déterminer les modalités physio-comportementales essentielles à la classification par le meilleur modèle obtenu.

Pour ce faire, des caractéristiques des signaux physiologiques et des indices comportementaux ont été extraites suite à une recension des écrits. Une nouvelle méthode pour créer des classes à partir des facteurs-fun a été proposée et trois types de classificateurs ( $k$ NN, SVM et RF) ont été entraînés à reconnaître deux types de classes décrivant le plaisir d'un joueur de jeu vidéo de la base de données FUNii, incluant les classes obtenues avec la nouvelle méthode et celles proposées dans un travail antérieur. Aussi, afin de déterminer la longueur d'époque optimale et de quantifier l'effet de cette dernière sur les performances du classificateur, trois longueurs d'époques ont été testées pour chaque classificateur, soit 10, 30 et 60 secondes.

Le modèle le plus performant, un modèle  $k$ NN avec des époques de 60 secondes et avec les classes de plaisir proposées dans le cadre de ce projet, permet de déterminer les différentes classes de plaisir avec un taux de classement de 53,5% sur le jeu de test. Ce résultat dépasse les performances atteintes par Fortin-Cote et collab. (2018), qui étaient de 41,0% sur un jeu de test avec un classificateur XGBoost et des époques de 5 secondes.

Dans ce qui suit, trois sujets importants pour la mise en place d'un système de détection du plaisir en contexte de jeu vidéo sont discutés à la lumière des résultats obtenus : l'importance relative des caractéristiques physio-comportementales pour la détection des changements de plaisir ; l'utilisation du facteur-fun pour la détection des changements de plaisir ; l'effet de la longueur des époques sur les performances de classification. Ces derniers découlent des objectifs spécifiques 1, 2 et 4 de ce projet de recherche.

### **3.3.1 Importance relative des caractéristiques physio-comportementales pour la détection des changements de plaisir**

Dans un premier temps, le présent projet visait à déterminer les signaux physiologiques et les indices comportementaux les plus informatifs pour la tâche de classification du plaisir. À cette fin, différentes caractéristiques extraites des signaux physiologiques et des indices comportementaux ont été incluses aux jeux de données utilisés pour entraîner les différents modèles, et l'importance relative de celles-ci a été déterminée. Les résultats obtenus suggèrent que certaines caractéristiques, comme celles provenant de l'expression faciale, de la respiration ou des entrées du contrôleur Xbox, sont plus importantes que d'autres pour mener à bien la tâche de classification.

Les résultats indiquent également que certaines modalités physiologiques pourraient ne pas être nécessaires pour mener à bien la classification. En effet, bien que le RSP et l'ECG soient importants pour la décision du modèle, les caractéristiques extraites de l'EDA et l'EMG sont peu utilisées par ce dernier et sont donc potentiellement superflues. À l'inverse, un grand nombre de caractéristiques extraites de l'expression faciale et des entrées du contrôleur Xbox sont utiles à la classification.

Ceci suggère que le présent modèle pourrait être entraîné avec un nombre réduit de modalités sans affecter significativement ses performances. Un nombre réduit de modalités est nécessaire afin de minimiser la complexité du système de traitement de données et de tenir au minimum le nombre d'appareils de mesures nécessaires, ce qui facilite par le fait même son implémentation dans un engin de jeu vidéo.

### **3.3.2 Utilisation du facteur-fun pour la détection des changements de plaisir**

Dans un second temps, le présent projet visait à proposer une méthode de création de classes de changements de plaisir à partir des facteurs-fun. À cette fin, des classes capturant les variations de facteur-fun ont été proposées et testées. Celles-ci s'appuient sur deux propositions soulevées au cours de ce mémoire. La première proposition était que seuls les changements du facteur-fun sont représentatifs du plaisir du joueur, tandis que la seconde était que le plaisir du joueur croît ou décroît jusqu'à atteindre une valeur neutre. Quoique les performances du meilleur modèle

(*k*NN-60-B) demeure modestes, les classes dérivées de ces heuristiques ont tout de même permis d'augmenter de 12,5% le taux de classement du plaisir sur la base de données FUN*ii*, ce qui constitue un gain significatif par rapport au résultat obtenu par Fortin-Cote et collab. (2018). Les performances du modèle *k*NN-60-B dépassent également celles d'un classificateur naïf, et sont donc significativement supérieures à ceux d'un résultat aléatoire.

Les performances obtenues avec cette méthode de création de classes suggèrent qu'il existe bel et bien un lien entre le facteur-fun et les mesures physio-comportementales. En effet, si ce n'était pas le cas, les performances de classification obtenues pour les nouvelles classes n'auraient pas dépassé significativement celles proposées dans les travaux antérieurs (Clerico et collab., 2016; Fortin-Cote et collab., 2018; Fortin-Côté et collab., 2019). Les résultats suggèrent cependant que le facteur-fun doit être transformé dans une représentation alternative pour que ce lien puisse être exploité par un modèle supervisé, et que cette transformation (non triviale) doit être basée sur une connaissance approfondie de l'interaction entre les utilisateurs du facteur-fun et ce dernier. Ceci semble expliquer, du moins en partie, pourquoi les résultats obtenus dans les travaux antérieurs n'ont pas permis de discriminer les différentes classes créées à partir des facteurs-fun jusqu'à maintenant.

D'ailleurs, il importe de souligner que l'écart entre les performances obtenues avec les deux types de classes testées ne peut être attribuable à la longueur des époques, car les classes proposées par Fortin-Cote et collab. (2018) produisent des performances systématiquement inférieures à celles obtenues avec les classes proposées ici et ce, pour des longueurs d'époques identiques.

### **3.3.3 Effet de la longueur des époques sur les performances de classification**

Dans un troisième temps, le présent projet visait à déterminer la longueur d'époque optimale pour l'extraction des caractéristiques physio-comportementales. Les résultats obtenus pour les nouvelles classes proposées dans ce mémoire montrent que les classificateurs entraînés avec des époques de 30 secondes et 60 secondes obtiennent des taux de classement systématiquement supérieurs à ceux entraînés sur des époques de 10 secondes. Ceci suggère que des époques d'une longueur supérieure à 10 secondes permettent d'obtenir de meilleures performances en classification avec les nouvelles classes proposées.

Ce résultat semble concorder avec les travaux de la littérature concernant les divers signaux physiologiques. Par exemple, une réponse EDA moyenne nécessite entre 7,2 et 11,2 secondes pour être enregistrée complètement (Wilcott, 1967; Boucsein, 2012). Aussi, un seul cycle respiratoire peut nécessiter jusqu'à 10 secondes de signal pour être complètement enregistré (Cacioppo et collab., 2007).

Bien que les époques de 60 secondes aient permis d'obtenir les meilleures performances dans notre cas, il importe de souligner que les époques de 30 secondes ont permis d'obtenir des résultats très similaires. En conséquence, il est peu probable que des longueurs d'époques plus grandes que 60 secondes aient permis d'obtenir de meilleures performances, bien que davantage de tests avec des longueurs d'époques plus grandes seraient nécessaires pour conclure définitivement.

### **3.3.4 Limites et travaux futurs**

Le présent projet de recherche comporte plusieurs limites qui doivent être prises en compte.

Premièrement, dans ce projet nous avons considéré que le facteur-fun était une représentation plus ou moins fidèle du plaisir du joueur, ce qui implique que le plaisir du joueur puisse être représenté sur une seule dimension. Dans les faits, le plaisir est un état complexe, et il est probable que plusieurs dimensions soient nécessaires pour le décrire correctement (Desmet, 2003; Lazzaro, 2004; Poels et collab., 2007; Blythe et Hassenzahl, 2003). Dans le même ordre d'idée, il n'est pas dit qu'un protocole d'annotation continue (c.-à-d. le facteur-fun) permette de capturer adéquatement le plaisir du joueur. À ce sujet, davantage d'études devraient être menées afin de déterminer la validité réelle d'une annotation continue du plaisir (Metallinou et Narayanan, 2013). La cohérence interne d'un même participant pourrait par exemple être étudiée en lui demandant d'annoter plusieurs fois une même séance de jeu.

Deuxièmement, les jeux utilisés pour l'entraînement des modèles n'incluaient aucune donnée provenant de participantes de sexe féminin. En conséquence, il est fort probable que les résultats obtenus ici ne soient pas transférables à celles-ci, considérant les différences physiologiques et comportementales entre les deux sexes déjà relevées dans la littérature (Rukavina et collab., 2016; Cacioppo et collab., 2007).

Troisièmement, aucune information contextuelle du jeu vidéo –c'est-à-dire tout ce qui se produit dans l'univers virtuel du jeu durant l'interaction avec le joueur – n'a

été utilisée pour aider la prédiction du plaisir. Or, des travaux récents indiquent que la capacité humaine à reconnaître les émotions dépend grandement du contexte dans lequel celles-ci prennent place (Barrett et collab., 2011, 2019). À cet égard, un futur travail pourrait tenter d'extraire des caractéristiques contextuelles à partir d'un enregistrement d'une séance de jeu et tester l'influence de celles-ci sur les performances d'un modèle de prédiction des changements de plaisir.

Tel qu'utilisé dans le présent texte, les informations contextuelles englobent (mais ne sont pas limitées à) les éléments narratifs, l'environnement virtuel, les relations avec les personnages du jeu, les mécanismes du jeu, l'interface utilisateur (p. ex. une carte de navigation), etc. Il est donc évident que la tâche de déterminer précisément ce qui est entendu par « informations contextuelles » représente un travail de recherche en soi. Cependant, cette tâche pourrait potentiellement être facilitée par l'utilisation de techniques de vision numérique modernes (segmentation sémantique et détection d'objets) combinées à l'utilisation de prises d'écrans de la vue du joueur (« *screen-shots* »).

Finalement, dans le présent travail aucune tentative n'a été faite pour identifier des sous-groupes de joueurs dans les données obtenues, ce qui aurait pu permettre de tenir compte des différences et des ressemblances entre les participants de l'étude lors de l'entraînement du modèle, et ce notamment au niveau des préférences des joueurs<sup>6</sup>. En ce qui a trait à Fortin-Cote et collab. (2018), ceux-ci ont tenté d'intégrer les réponses aux questionnaires d'immersion et d'expérience de jeu comme des caractéristiques pour la classification. Comme ceci ne s'est pas traduit en des augmentations significatives du taux de classement, une analyse préliminaire des questionnaires (semblable à celle menée par Bergeron-Boucher (2016)) pourrait permettre de déterminer les types de joueurs<sup>7</sup> dans la base de données FUNii et d'entraîner des modèles spécifiques à chaque type de joueur.

---

6. Par préférence, nous entendons le type de jeu préféré par le joueur. Par exemple, dans le contexte des jeux *Assassin's Creed*, certains joueurs apprécient davantage les combats contre des ennemis, tandis que d'autres préfèrent simplement explorer l'environnement virtuel.

7. Les typologie des joueurs décrit les différentes motivations intrinsèques pour le jeu vidéo. Par exemple, certains joueurs retirent plus de plaisir de l'interaction social avec les autres joueurs et d'autres, de l'aspect compétitif de certains jeux.

# Conclusion

Le présent travail visait à proposer une méthode permettant de prédire les changements de facteur-fun à partir des signaux physiologiques et des indices comportementaux d'un joueur dans un contexte de jeu vidéo. À cette fin, un classificateur *kNN* a été entraîné à reconnaître des classes de plaisir à partir de caractéristiques physio-comportementales et une nouvelle méthode a été proposée pour la création de classe de plaisir à partir du facteur-fun. Les performances obtenues surpassent celles retrouvées dans des travaux antérieurs, ce qui souligne la pertinence de l'approche proposée. De plus, parmi les modalités étudiées, il a été établi que les expressions faciales, l'activité respiratoire et les entrées du contrôleur Xbox sont les plus importantes pour la prédiction du facteur-fun. De plus, il a été établi que des époques de 30 ou 60 secondes permettaient d'obtenir de meilleures performances que des époques de 10 secondes. D'autres travaux seraient nécessaires afin de déterminer comment les performances du modèle pourraient être améliorées, en intégrant par exemple des informations contextuelles du jeu ou en utilisant les questionnaires de la base de données FUNii pour construire des modèles spécifiques aux différents types de joueurs.



# Bibliographie

3DrunkMen. 2012, «Vanish», [Ordinateur].

Alpaydin, E. 2010, *Introduction to machine learning*, 2<sup>e</sup> éd., Adaptive computation and machine learning, MIT Press, Cambridge, Mass, ISBN 978-0-262-01243-0. OCLC : ocn317698631.

Association canadienne du logiciel de divertissement. 2018, «Faits essentiels sur le secteur canadien du jeu vidéo», .

Asteriadis, S., P. Tzouveli, K. Karpouzis et S. Kollias. 2009, «Estimation of behavioral user state based on eye gaze and head pose—application in an e-learning environment», *Multimedia Tools and Applications*, vol. 41, n<sup>o</sup> 3, doi : 10.1007/s11042-008-0240-1, p. 469–493, ISSN 1573-7721. URL <https://doi.org/10.1007/s11042-008-0240-1>.

Atari. 1972, «Pong», [Arcade].

Averill, J. R. 1969, «Autonomic response patterns during sadness and mirth», *Psychophysiology*, vol. 5, n<sup>o</sup> 4, doi :10.1111/j.1469-8986.1969.tb02840.x, p. 399–414, ISSN 1469-8986(Electronic),0048-5772(Print).

Baltrusaitis, T., A. Zadeh, Y. C. Lim et L. Morency. 2018, «OpenFace 2.0 : Facial Behavior Analysis Toolkit», dans *2018 13th IEEE International Conference on Automatic Face Gesture Recognition (FG 2018)*, p. 59–66.

Barrett, L. F., R. Adolphs, S. Marsella, A. M. Martinez et S. D. Pollak. 2019, «Emotional expressions reconsidered : Challenges to inferring emotion from human facial movements», *Psychological science in the public interest*, vol. 20, n<sup>o</sup> 1, p. 1–68.

Barrett, L. F., B. Mesquita et M. Gendron. 2011, «Context in emotion perception», *Current Directions in Psychological Science*, vol. 20, n<sup>o</sup> 5, p. 286–290.

- Beaudoin-Gagnon, N., A. Fortin Côté, C. Chamberland, L. Lefebvre, J. Bergeron-Boucher, A. Campeau-Lecours, S. Tremblay et P. L. Jackson. 2019, «The FUNii Database : A Physiological, Behavioral, Demographic and Subjective VideoGame Database for Affective Gaming and Player Experience Research», IEEE, Cambridge, Royaume-Unis.
- Bergeron-Boucher, J. 2016, *Identification des motivations pour le jeu vidéo : revue des typologies des joueurs*, mémoire de maîtrise, Université Laval, Québec, Canada. URL <https://corpus.ulaval.ca/jspui/handle/20.500.11794/26941>.
- Bergstra, J. et Y. Bengio. 2012, «Random search for hyper-parameter optimization», *Journal of Machine Learning Research*, vol. 13, n° Feb, p. 281–305. URL <http://www.jmlr.org/papers/v13/bergstra12a.html>.
- Berntson, G. G., K. S. Quigley et D. Lozano. 2007, *Cardiovascular Psychophysiology*, 3<sup>e</sup> éd., Cambridge University Press, p. 182–210.
- Bishop, C. M. 2006, *Pattern recognition and machine learning*, Information science and statistics, Springer, New York, ISBN 978-0-387-31073-2.
- Blythe, M. et M. Hassenzahl. 2003, «The Semantics of Fun: Differentiating Enjoyable Experiences», dans *Funology*, Human-Computer Interaction Series, Springer, Dordrecht, ISBN 978-1-4020-2966-0 978-1-4020-2967-7, p. 91–100, doi : 10.1007/1-4020-2967-5\_9. URL [https://link.springer.com/chapter/10.1007/1-4020-2967-5\\_9](https://link.springer.com/chapter/10.1007/1-4020-2967-5_9).
- Boiten, F. 1993, «Component analysis of task-related respiratory patterns», *International Journal of Psychophysiology*, vol. 15, n° 2, doi :10.1016/0167-8760(93)90067-Y, p. 91–104, ISSN 0167-8760. URL <http://www.sciencedirect.com/science/article/pii/016787609390067Y>.
- Boiten, F. 1996, «Autonomic response patterns during voluntary facial action», *Psychophysiology*, vol. 33, n° 2, p. 123–131, ISSN 0048-5772.
- Boiten, F. A., N. H. Frijda et C. J. E. Wientjes. 1994, «Emotions and respiratory patterns : review and critical analysis», *International Journal of Psychophysiology*, vol. 17, n° 2, doi :10.1016/0167-8760(94)90027-2, p. 103–128, ISSN 0167-8760. URL <http://www.sciencedirect.com/science/article/pii/0167876094900272>.
- Boucsein, W. 2012, *Electrodermal activity*, 2<sup>e</sup> éd., Springer, New York, ISBN 978-1-4614-1125-3 978-1-4614-1126-0.

- Boxtel, A. v. 2001, «Optimal signal bandwidth for the recording of surface EMG activity of facial, jaw, oral, and neck muscles», *Psychophysiology*, vol. 38, n° 1, doi :10.1111/1469-8986.3810022, p. 22–34, ISSN 1469-8986. URL <http://onlinelibrary.wiley.com/doi/abs/10.1111/1469-8986.3810022>.
- Boyle, E. A., T. M. Connolly, T. Hainey et J. M. Boyle. 2012, «Engagement in digital entertainment games : A systematic review», *Computers in human behavior*, vol. 28, n° 3, p. 771–780.
- Brown, E. et P. Cairns. 2004, «A grounded investigation of game immersion», dans *CHI'04 extended abstracts on Human factors in computing systems*, ACM, p. 1297–1300.
- Cacioppo, J. T., L. G. Tassinary et G. G. Berntson. 2007, *Handbook of psychophysiology*, Cambridge University Press, Cambridge [England]; New York, ISBN 978-0-511-27907-2 978-0-511-27729-0 978-0-511-48116-1 978-0-511-27788-7 978-0-511-27847-1 978-0-511-54639-6 978-0-511-32073-6. URL <http://www.dawsonera.com/depp/reader/protected/external/AbstractView/S9780511320736>, oCLC : 166506595.
- Calvillo-Gómez, E. H., P. Cairns et A. L. Cox. 2015, «Assessing the Core Elements of the Gaming Experience», dans *Game User Experience Evaluation*, édité par R. Bernhaupt, Human-Computer Interaction Series, Springer International Publishing, Cham, ISBN 978-3-319-15985-0, p. 37–62, doi :10.1007/978-3-319-15985-0\_3. URL [https://doi.org/10.1007/978-3-319-15985-0\\_3](https://doi.org/10.1007/978-3-319-15985-0_3).
- Canento, F., A. Lourenço, H. Silva et A. L. N. Fred. 2012, «Review and Comparison of Real Time Electrocardiogram Segmentation Algorithms for Biometric Applications», .
- Caridakis, G., S. Asteriadis et K. Karpouzis. 2010, «User modeling via gesture and head pose expressivity features», dans *2010 Fifth International Workshop Semantic Media Adaptation and Personalization*, p. 19–24, doi :10.1109/SMAP.2010.5706868.
- Caroux, L., K. Isbister, L. Le Bigot et N. Vibert. 2015, «Player–video game interaction : A systematic review of current concepts», *Computers in Human Behavior*, vol. 48, doi :10.1016/j.chb.2015.01.066, p. 366–381, ISSN 0747-5632. URL <http://www.sciencedirect.com/science/article/pii/S0747563215000941>.
- Carroll, D., J. R. Turner et J. C. Hellawell. 1986, «Heart Rate and Oxygen Consumption during Active Psychological Challenge: The Effects of Level of Difficulty»,

- Psychophysiology*, vol. 23, n° 2, doi :10.1111/j.1469-8986.1986.tb00613.x, p. 174–181, ISSN 1469-8986. URL <http://onlinelibrary.wiley.com/doi/abs/10.1111/j.1469-8986.1986.tb00613.x>.
- Chamberland, C., M. Grégoire, P.-E. Michon, J.-C. Gagnon, P. L. Jackson et S. Tremblay. 2015, «A Cognitive and Affective Neuroergonomics Approach to Game Design», *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 59, n° 1, doi :10.1177/1541931215591301, p. 1075–1079, ISSN 1541-9312. URL <https://doi.org/10.1177/1541931215591301>.
- Chanel, G., S. Avry, G. Molinari, M. Bétrancourt et T. Pun. 2017, «Multiple users' emotion recognition : Improving performance by joint modeling of affective reactions», dans *2017 Seventh International Conference on Affective Computing and Intelligent Interaction (ACII)*, p. 92–97, doi :10.1109/ACII.2017.8273584.
- Chanel, G., C. Rebetez, M. Betrancourt et T. Pun. 2011, «Emotion Assessment From Physiological Signals for Adaptation of Game Difficulty», vol. 41, doi :10.1109/TSMCA.2011.2116000, p. 1052–1063, ISSN 1083-4427.
- Charlton, J. P. et I. D. W. Danforth. 2007, «Distinguishing addiction and high engagement in the context of online game playing», *Computers in Human Behavior*, vol. 23, n° 3, doi :10.1016/j.chb.2005.07.002, p. 1531–1548, ISSN 0747-5632. URL <http://www.sciencedirect.com/science/article/pii/S074756320500049X>.
- Chen, J. 2007, «Flow in games (and everything else)», *COMMUNICATIONS OF THE ACM*, vol. 50, n° 4, p. 4.
- Chen, J., B. Hu, Y. Wang, P. Moore, Y. Dai, L. Feng et Z. Ding. 2017, «Subject-independent emotion recognition based on physiological signals: a three-stage decision method», *BMC Medical Informatics and Decision Making*, vol. 17, n° S3, doi :10.1186/s12911-017-0562-x, ISSN 1472-6947. URL <https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-017-0562-x>.
- Christie, I. C. et B. H. Friedman. 2004, «Autonomic specificity of discrete emotion and dimensions of affective space : a multivariate approach», *International Journal of Psychophysiology*, vol. 51, n° 2, doi :10.1016/j.ijpsycho.2003.08.002, p. 143–153, ISSN 0167-8760. URL <http://www.sciencedirect.com/science/article/pii/S0167876003001946>.

- Clerico, A., C. Chamberland, M. Parent, P.-E. Michon, S. Tremblay, T. H. Falk, J.-C. Gagnon et P. Jackson. 2016, «Biometrics and classifier fusion to predict the fun-factor in video gaming», dans *Computational Intelligence and Games (CIG), 2016 IEEE Conference on*, IEEE, p. 1–8. URL <http://ieeexplore.ieee.org/abstract/document/7860418/>.
- Colomer Granero, A., F. Fuentes-Hurtado, V. Naranjo Ornedo, J. Guixeres Provinciale, J. M. Ausín et M. Alcañiz Raya. 2016, «A Comparison of Physiological Signal Analysis Techniques and Classifiers for Automatic Emotional Evaluation of Audiovisual Contents», *Frontiers in Computational Neuroscience*, vol. 10, doi :10.3389/fncom.2016.00074, ISSN 1662-5188. URL <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4945646/>.
- Croft, R. J., C. J. Gonsalvez, J. Gander, L. Lechem et R. J. Barry. 2004, «Differential relations between heart rate and skin conductance, and public speaking anxiety», *Journal of Behavior Therapy and Experimental Psychiatry*, vol. 35, n° 3, doi :10.1016/j.jbtep.2004.04.012, p. 259–271, ISSN 0005-7916. URL <http://www.sciencedirect.com/science/article/pii/S0005791604000473>.
- Csikszentmihalyi, M. 1990, «FLOW: The Psychology of Optimal Experience», *Harper Perennial*, p. 6.
- Csikszentmihalyi, M. 1997, *Finding flow : The psychology of engagement with everyday life*, Finding flow : The psychology of engagement with everyday life, Basic Books, New York, NY, US, ISBN 978-0-465-04513-6.
- Csikszentmihalyi, M. 2014, «Toward a Psychology of Optimal Experience», dans *Flow and the Foundations of Positive Psychology : The Collected Works of Mihaly Csikszentmihalyi*, Springer Netherlands, Dordrecht, ISBN 978-94-017-9088-8, p. 209–226, doi :10.1007/978-94-017-9088-8\_14. URL [https://doi.org/10.1007/978-94-017-9088-8\\_14](https://doi.org/10.1007/978-94-017-9088-8_14).
- Cuthbert, B. N., M. M. Bradley et P. J. Lang. 1996, «Probing picture perception: activation and emotion», *Psychophysiology*, vol. 33, n° 2, p. 103–111, ISSN 0048-5772.
- Dawson, M. E., A. M. Schell et D. L. Filion. 2007, *The Electrodermal System*, 3<sup>e</sup> éd., Cambridge University Press, p. 159–181.
- Desmet, P. 2003, «Measuring Emotion: Development and Application of an Instrument to Measure Emotional Responses to Products», dans *Funology*, Human-

- Computer Interaction Series, Springer, Dordrecht, ISBN 978-1-4020-2966-0 978-1-4020-2967-7, p. 111–123, doi :10.1007/1-4020-2967-5\_12. URL [https://link.springer.com/chapter/10.1007/1-4020-2967-5\\_12](https://link.springer.com/chapter/10.1007/1-4020-2967-5_12).
- Drachen, A., L. E. Nacke, G. Yannakakis et A. L. Pedersen. 2010, «Correlation between heart rate, electrodermal activity and player experience in first-person shooter games», dans *Proceedings of the 5th ACM SIGGRAPH Symposium on Video Games - Sandbox '10*, ACM Press, Los Angeles, California, ISBN 978-1-4503-0097-1, p. 49–54, doi :10.1145/1836135.1836143. URL <http://portal.acm.org/citation.cfm?doid=1836135.1836143>.
- Ekman, P. 1992, «An argument for basic emotions», *Cognition and Emotion*, vol. 6, n° 3-4, doi :10.1080/02699939208411068, p. 169–200, ISSN 0269-9931. URL <https://doi.org/10.1080/02699939208411068>.
- Ekman, P. 1993, «Facial expression and emotion», *American Psychologist*, vol. 48, n° 4, doi :10.1037/0003-066X.48.4.384, p. 384–392, ISSN 1935-990X(Electronic),0003-066X(Print).
- Ekman, P. et W. Friesen. 1978, *Facial Action Coding System : A Technique for the Measurement of Facial Movement*, Consulting Psychologists Press.
- Ekman, P. et W. Friesen. 1983, «Emfacs-7 : Emotional facial action coding system», *Unpublished manual*, University of California, San Francisco.
- Ekman, P. et W. V. Friesen. 1976, «Measuring facial movement», *Environmental psychology and nonverbal behavior*, vol. 1, n° 1, doi :10.1007/BF01115465, p. 56–75, ISSN 1573-3653. URL <https://doi.org/10.1007/BF01115465>.
- Ekman, P., W. V. Friesen et J. C. Hager. 2002, «Facial action coding system : The manual on cd rom», *A Human Face*, Salt Lake City, p. 77–254.
- Ekman, R. 1997, *What the Face Reveals: Basic and Applied Studies of Spontaneous Expression Using the Facial Action Coding System (FACS)*, Oxford University Press, ISBN 978-0-19-510446-2.
- Čertický, M., M. Čertický, P. Sinčák, G. Magyar, J. Vaščák et F. Cavallo. 2019, «Psychophysiological Indicators for Modeling User Experience in Interactive Digital Entertainment», *Sensors*, vol. 19, n° 5, doi :10.3390/s19050989, p. 989, ISSN 1424-8220. URL <http://www.mdpi.com/1424-8220/19/5/989>.

- Etzel, J. A., E. L. Johnsen, J. Dickerson, D. Tranel et R. Adolphs. 2006, «Cardiovascular and respiratory responses during musical mood induction», *International Journal of Psychophysiology : Official Journal of the International Organization of Psychophysiology*, vol. 61, n° 1, doi :10.1016/j.ijpsycho.2005.10.025, p. 57–69, ISSN 0167-8760.
- Farina, D., D. F. Stegeman et R. Merletti. 2016, *Biophysics of the Generation of EMG Signals*, chap. 2, Wiley-Blackwell, ISBN 9781119082934, p. 1–24, doi : 10.1002/9781119082934.ch02. URL <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781119082934.ch02>.
- Folkins, C. H. 1970, «Temporal factors and the cognitive mediators of stress reaction», *Journal of Personality and Social Psychology*, vol. 14, n° 2, doi :10.1037/h0028688, p. 173–184, ISSN 1939-1315(Electronic),0022-3514(Print).
- Fortin-Cote, A., C. Chamberland, M. Parent, S. Tremblay, P. Jackson, N. Beaudoin-Gagnon, A. Campeau-Lecours, J. Bergeron-Boucher et L. Lefebvre. 2018, «Predicting Video Game Players’ Fun from Physiological and Behavioural Data.», , p. 8.
- Fortin-Côté, A., N. Beaudoin-Gagnon, C. Chamberland, F. Desbiens, L. Lefebvre, J. Bergeron, A. Campeau-Lecours, S. Tremblay et P. L. Jackson. 2019, «FUNii : The Physio-Behavioural Adaptive Video Game», dans *Augmented Cognition, Lecture Notes in Artificial Intelligence, HCII (International Conference on Human-Computer Interaction)*, vol. 15, Springer International Publishing, Orlando, Florida.
- Fredrikson, M., T. Furmark, M. T. Olsson, H. Fischer, J. Andersson et B. Långström. 1998, «Functional neuroanatomical correlates of electrodermal activity: a positron emission tomographic study», *Psychophysiology*, vol. 35, n° 2, p. 179–185, ISSN 0048-5772.
- Gilissen, R., M. J. Bakermans-Kranenburg, M. H. van IJzendoorn et R. van der Veer. 2008, «Parent-child relationship, temperament, and physiological reactions to fear-inducing film clips : Further evidence for differential susceptibility», *Journal of Experimental Child Psychology*, vol. 99, n° 3, doi :10.1016/j.jecp.2007.06.004, p. 182–195, ISSN 1096-0457(Electronic),0022-0965(Print).
- Gilissen, R., C. M. Koolstra, M. H. van IJzendoorn, M. J. Bakermans-Kranenburg et R. van der Veer. 2007, «Physiological reactions of preschoolers to fear-inducing film clips : Effects of temperamental fearfulness and quality of the parent-child relationship», *Developmental Psychobiology*, vol. 49, n° 2, doi :10.1002/dev.20188, p. 187–195, ISSN 1098-2302(Electronic),0012-1630(Print).

- Gilleade, K. M. et A. Dix. 2004, «Using frustration in the design of adaptive videogames», ACM Press, ISBN 978-1-58113-882-5, p. 228–232, doi :10.1145/1067343.1067372. URL <http://portal.acm.org/citation.cfm?doid=1067343.1067372>.
- Greco, A., G. Valenza, A. Lanata, E. P. Scilingo et L. Citi. 2016, «cvxEDA : A Convex Optimization Approach to Electrodermal Activity Processing», *IEEE Transactions on Biomedical Engineering*, vol. 63, n° 4, doi :10.1109/TBME.2015.2474131, p. 797–804, ISSN 0018-9294.
- Gunes, H. et M. Pantic. 2010, «Dimensional Emotion Prediction from Spontaneous Head Gestures for Interaction with Sensitive Artificial Listeners», dans *Intelligent Virtual Agents*, édité par J. Allbeck, N. Badler, T. Bickmore, C. Pelachaud et A. Safonova, Lecture Notes in Computer Science, Springer Berlin Heidelberg, ISBN 978-3-642-15892-6, p. 371–377.
- Hamilton, P. 2002, «Open source ECG analysis», dans *Computers in Cardiology*, IEEE, Memphis, TN, USA, ISBN 978-0-7803-7735-6, p. 101–104, doi :10.1109/CIC.2002.1166717. URL <http://ieeexplore.ieee.org/document/1166717/>.
- Herrald, M. M. et J. Tomaka. 2002, «Patterns of emotion-specific appraisal, coping, and cardiovascular reactivity during an ongoing emotional episode», *Journal of Personality and Social Psychology*, vol. 83, n° 2, p. 434–450, ISSN 0022-3514.
- Hofmann, S. G., D. A. Moscovitch et H.-J. Kim. 2006, «Autonomic correlates of social anxiety and embarrassment in shy and non-shy individuals», *International Journal of Psychophysiology*, vol. 61, n° 2, doi :10.1016/j.ijpsycho.2005.09.003, p. 134–142, ISSN 0167-8760. URL <http://www.sciencedirect.com/science/article/pii/S0167876005002229>.
- Hudlicka, E. 2008a, «Affective computing for game design», dans *Proceedings of the 4th Intl. North American Conference on Intelligent Games and Simulation*, McGill University Montreal, Canada, p. 5–12.
- Hudlicka, E. 2008b, «AFFECTIVE COMPUTING FOR GAME DESIGN», , p. 8.
- Jennett, C., A. L. Cox, P. Cairns, S. Dhoparee, A. Epps, T. Tijs et A. Walton. 2008, «Measuring and defining the experience of immersion in games», *International Journal of Human-Computer Studies*, vol. 66, n° 9, doi :10.1016/j.ijhcs.2008.04.



- 004, p. 641–661, ISSN 1071-5819. URL <http://www.sciencedirect.com/science/article/pii/S1071581908000499>.
- Juul, J. 2013, *The Art of Failure : An Essay on the Pain of Playing Video Games*, The MIT Press, ISBN 978-0-262-01905-7.
- Karpouzis, K. et G. N. Yannakakis, éd.. 2016, *Emotion in Games, Socio-Affective Computing*, vol. 4, Springer International Publishing, Cham, ISBN 978-3-319-41314-3 978-3-319-41316-7, doi :10.1007/978-3-319-41316-7. URL <http://link.springer.com/10.1007/978-3-319-41316-7>.
- Kaytoue, M., A. Silva, L. Cerf, W. Meira, Jr. et C. Raïssi. 2012, «Watch Me Playing, I Am a Professional : A First Study on Video Game Live Streaming», dans *Proceedings of the 21st International Conference on World Wide Web, WWW '12 Companion*, ACM, New York, NY, USA, ISBN 978-1-4503-1230-1, p. 1181–1188, doi : 10.1145/2187980.2188259. URL <http://doi.acm.org/10.1145/2187980.2188259>, event-place : Lyon, France.
- Kivikangas, J. M., I. Ekman, G. Chanel, S. Järvelä, B. Cowley, P. Henttonen et N. Ravaja. 2010, «Review on psychophysiological methods in game research», dans *Proc. of 1st Nordic DiGRA, DiGRA*.
- Kotsia, I., S. Zafeiriou, G. Goudelis, I. Patras et K. Karpouzis. 2016, «Multimodal Sensing in Affective Gaming», dans *Emotion in Games*, vol. 4, édité par K. Karpouzis et G. N. Yannakakis, Springer International Publishing, Cham, ISBN 978-3-319-41314-3 978-3-319-41316-7, p. 59–84, doi :10.1007/978-3-319-41316-7\_4. URL [http://link.springer.com/10.1007/978-3-319-41316-7\\_4](http://link.springer.com/10.1007/978-3-319-41316-7_4).
- Kreibig, S. D. 2010, «Autonomic nervous system activity in emotion: A review», *Biological Psychology*, vol. 84, n° 3, doi :10.1016/j.biopsycho.2010.03.010, p. 394–421, ISSN 03010511. URL <http://linkinghub.elsevier.com/retrieve/pii/S0301051110000827>.
- Kunzmann, U. et D. Grühn. 2005, «Age differences in emotional reactivity: the sample case of sadness», *Psychology and Aging*, vol. 20, n° 1, doi :10.1037/0882-7974.20.1.47, p. 47–59, ISSN 0882-7974.
- Lang, P. J. 1995, «The emotion probe. Studies of motivation and attention», *The American Psychologist*, vol. 50, n° 5, p. 372–385, ISSN 0003-066X.

- Lang, P. J., M. K. Greenwald, M. M. Bradley et A. O. Hamm. 1993, «Looking at pictures : Affective, facial, visceral, and behavioral reactions», *Psychophysiology*, vol. 30, n° 3, doi :10.1111/j.1469-8986.1993.tb03352.x, p. 261–273, ISSN 0048-5772. URL <http://onlinelibrary.wiley.com/doi/abs/10.1111/j.1469-8986.1993.tb03352.x>.
- Larsen, J. T., G. G. Berntson, K. M. Poehlmann, T. A. Ito et J. T. Cacioppo. 2008, «The psychophysiology of emotion», dans *Handbook of emotions, 3rd ed*, Guilford Press, New York, NY, US, ISBN 978-1-59385-650-2, p. 180–195.
- Larsen, J. T., C. J. Norris et J. T. Cacioppo. 2003, «Effects of positive and negative affect on electromyographic activity over zygomaticus major and corrugator supercilii», *Psychophysiology*, vol. 40, n° 5, doi :10.1111/1469-8986.00078, p. 776–785, ISSN 1469-8986. URL <http://onlinelibrary.wiley.com/doi/abs/10.1111/1469-8986.00078>.
- Larsen, J. T. et J. I. Norris. 2009, «A facial electromyographic investigation of affective contrast», *Psychophysiology*, vol. 46, n° 4, doi :10.1111/j.1469-8986.2009.00820.x, p. 831–842, ISSN 1469-8986. URL <http://onlinelibrary.wiley.com/doi/abs/10.1111/j.1469-8986.2009.00820.x>.
- Lazarus, R. 1966, *Psychological stress and the coping process*, Psychological stress and the coping process, McGraw-Hill, New York, NY, US.
- Lazzaro, N. 2004, «Why We Play Games: Four Keys to More Emotion Without Story», , p. 8.
- Li, X., P. Zhou et A. S. Aruin. 2007, «Teager-Kaiser energy operation of surface EMG improves muscle activity onset detection», *Annals of Biomedical Engineering*, vol. 35, n° 9, doi :10.1007/s10439-007-9320-z, p. 1532–1538, ISSN 0090-6964.
- Liu, C., P. Agrawal, N. Sarkar et S. Chen. 2009, «Dynamic Difficulty Adjustment in Computer Games Through Real-Time Anxiety-Based Affective Feedback», *International Journal of Human-Computer Interaction*, vol. 25, n° 6, doi : 10.1080/10447310902963944, p. 506–529, ISSN 1044-7318, 1532-7590. URL <http://www.tandfonline.com/doi/abs/10.1080/10447310902963944>.
- Lorig, T. S. 2007, *The Respiratory System*, 3<sup>e</sup> éd., Cambridge University Press, p. 231–244.

- Louppe, G. 2014, «Understanding Random Forests : From Theory to Practice», *arXiv :1407.7502 [stat]*. URL <http://arxiv.org/abs/1407.7502>, arXiv : 1407.7502.
- Maier, M. A. et M. C. Hepp-Reymond. 1995, «EMG activation patterns during force production in precision grip. I. Contribution of 15 finger muscles to isometric force», *Experimental Brain Research*, vol. 103, n° 1, p. 108–122, ISSN 0014-4819.
- Mandryk, R. L. et M. S. Atkins. 2007, «A fuzzy physiological approach for continuously modeling emotion during interaction with play technologies», *International Journal of Human-Computer Studies*, vol. 65, n° 4, doi :10.1016/j.ijhcs.2006.11.011, p. 329–347, ISSN 10715819. URL <http://linkinghub.elsevier.com/retrieve/pii/S1071581906001881>.
- Marci, C. D., D. M. Glick, R. Loh et D. D. Dougherty. 2007, «Autonomic and pre-frontal cortex responses to autobiographical recall of emotions», *Cognitive, Affective, & Behavioral Neuroscience*, vol. 7, n° 3, doi :10.3758/CABN.7.3.243, p. 243–250, ISSN 1531-135X. URL <https://doi.org/10.3758/CABN.7.3.243>.
- Martinez, H. P., Y. Bengio et G. N. Yannakakis. 2013, «Learning deep physiological models of affect», *IEEE Computational Intelligence Magazine*, vol. 8, n° 2, doi :10.1109/MCI.2013.2247823, p. 20–33, ISSN 1556-603X.
- Martínez, H. P., G. N. Yannakakis et J. Hallam. 2014, «Don't Classify Ratings of Affect; Rank Them!», *IEEE Transactions on Affective Computing*, vol. 5, n° 3, doi : 10.1109/TAFFC.2014.2352268, p. 314–326, ISSN 1949-3045.
- Masaoka, Y. et I. Homma. 1999, «Expiratory time determined by individual anxiety levels in humans», *Journal of Applied Physiology (Bethesda, Md. : 1985)*, vol. 86, n° 4, doi :10.1152/jappl.1999.86.4.1329, p. 1329–1336, ISSN 8750-7587.
- Masaoka, Y. et I. Homma. 2001, «The effect of anticipatory anxiety on breathing and metabolism in humans», *Respiration Physiology*, vol. 128, n° 2, p. 171–177, ISSN 0034-5687.
- McClave, E. Z. 2000, «Linguistic functions of head movements in the context of speech», *Journal of pragmatics*, vol. 32, n° 7, p. 855–878.
- Merletti, R. et P. Di Torino. 1999, «Standards for reporting emg data», *J Electromyogr Kinesiol*, vol. 9, n° 1, p. 3–4.

- Metallinou, A. et S. Narayanan. 2013, «Annotation and processing of continuous emotional attributes : Challenges and opportunities», dans *2013 10th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG)*, p. 1–8, doi :10.1109/FG.2013.6553804.
- Murakami, H. et H. Ohira. 2007, «Influence of Attention Manipulation on Emotion and Autonomic Responses», *Perceptual and Motor Skills*, vol. 105, n° 1, doi :10.2466/pms.105.1.299-308, p. 299–308, ISSN 0031-5125. URL <https://doi.org/10.2466/pms.105.1.299-308>.
- Nakamura, H. 1984, «Effects of musical emotionality upon GSR and respiration rate : The relationship between verbal reports and physiological responses. [Effects of musical emotionality upon GSR and respiration rate : The relationship between verbal reports and physiological responses.]», *Japanese Journal of Psychology*, vol. 55, n° 1, doi :10.4992/jjpsy.55.47, p. 47–50, ISSN 1884-1082(Electronic),0021-5236(Print).
- Nakamura, J. et M. Csikszentmihalyi. 2014, «The Concept of Flow», dans *Flow and the Foundations of Positive Psychology : The Collected Works of Mihaly Csikszentmihalyi*, Springer Netherlands, Dordrecht, ISBN 978-94-017-9088-8, p. 239–263, doi :10.1007/978-94-017-9088-8\_16. URL [https://doi.org/10.1007/978-94-017-9088-8\\_16](https://doi.org/10.1007/978-94-017-9088-8_16).
- Nintendo. 1985, «Super mario bros.», [NES].
- Nogueira, P. A., R. Aguiar, R. Rodrigues et E. Oliveira. 2014, «Computational Models of Players' Physiological-Based Emotional Reactions : A Digital Games Case Study», dans *2014 IEEE/WIC/ACM International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT)*, vol. 3, p. 278–285, doi :10.1109/WI-IAT.2014.178.
- Nomikos, M. S., E. Opton Jr. et J. R. Averill. 1968, «Surprise versus suspense in the production of stress reaction», *Journal of Personality and Social Psychology*, vol. 8, n° 2, Pt.1, doi :10.1037/h0025274, p. 204–208, ISSN 1939-1315(Electronic),0022-3514(Print).
- Nyklíček, I., J. F. Thayer et L. J. P. Van Doornen. 1997, «Cardiorespiratory differentiation of musically-induced emotions», *Journal of Psychophysiology*, vol. 11, n° 4, p. 304–321, ISSN 2151-2124(Electronic),0269-8803(Print).

- Pajitnov, A. 1984, «Tetris», [Ordinateur].
- Parsec Productions. 2012, «Slender : The Eight Pages», [Ordinateur].
- Pecchinenda, A. 1996, «The affective significance of skin conductance activity during a difficult problem-solving task», *Cognition & Emotion*, vol. 10, n° 5, p. 481–504.
- Pedregosa, F., G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot et E. Duchesnay. 2011, «Scikit-learn : Machine learning in Python», *Journal of Machine Learning Research*, vol. 12, p. 2825–2830.
- Petralito, S., F. Brühlmann, G. Iten, E. D. Mekler et K. Opwis. 2017, «A Good Reason to Die : How Avatar Death and High Challenges Enable Positive Experiences», dans *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*, CHI '17, ACM, New York, NY, USA, ISBN 978-1-4503-4655-9, p. 5087–5097, doi : 10.1145/3025453.3026047. URL <http://doi.acm.org/10.1145/3025453.3026047>.
- Picard, R. W. 2000a, *Affective computing*, MIT press.
- Picard, R. W. 2000b, «Toward computers that recognize and respond to user emotion», *IBM Systems Journal*, vol. 39, n° 3.4, doi :10.1147/sj.393.0705, p. 705–719, ISSN 0018-8670.
- Picard, R. W., E. Vyzas et J. Healey. 2001, «Toward machine emotional intelligence : analysis of affective physiological state», *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 23, n° 10, doi :10.1109/34.954607, p. 1175–1191, ISSN 0162-8828.
- Poels, K., Y. de Kort et W. IJsselsteijn. 2008, «Fuga-the fun of gaming : measuring the human experience of media enjoyment», *Deliverable D3*, vol. 3.
- Poels, K., D. Y. A.W. Kort et W. A. IJsselsteijn. 2007, «"It is always a lot of fun!" : exploring dimensions of digital game experience using focus group methodology», dans *Proceedings of the International Academic Conference on the Future of Game Design and Technology : Future-Play 2007, November 15-17, 2007, Toronto, Canada*, Association for Computing Machinery, Inc, p. 83–89. URL <https://research.tue.nl/en/publications/it-is-always-a-lot-of-fun-exploring-dimensions-of-digital-game-ex>.

- Posner, J., J. A. Russell et B. S. Peterson. 2005, «The circumplex model of affect : An integrative approach to affective neuroscience, cognitive development, and psychopathology», *Development and psychopathology*, vol. 17, n° 3, doi :10.1017/S0954579405050340, p. 715–734, ISSN 0954-5794. URL <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2367156/>.
- Rainville, P., A. Bechara, N. Naqvi et A. R. Damasio. 2006, «Basic emotions are associated with distinct patterns of cardiorespiratory activity», *International Journal of Psychophysiology*, vol. 61, n° 1, doi :10.1016/j.ijpsycho.2005.10.024, p. 5–18, ISSN 0167-8760. URL <http://www.sciencedirect.com/science/article/pii/S0167876005002801>.
- Ravaja, N., M. Turpeinen, T. Saari, S. Puttonen et L. Keltikangas-Järvinen. 2008, «The psychophysiology of James Bond : Phasic emotional responses to violent video game events», *Emotion*, vol. 8, n° 1, doi :10.1037/1528-3542.8.1.114, p. 114–120, ISSN 1931-1516(Electronic),1528-3542(Print).
- Ritz, T., M. Thöns, S. Fahrenkrug et B. Dahme. 2005, «Airways, respiration, and respiratory sinus arrhythmia during picture viewing», *Psychophysiology*, vol. 42, n° 5, doi :10.1111/j.1469-8986.2005.00312.x, p. 568–578, ISSN 0048-5772.
- Rukavina, S., S. Gruss, H. Hoffmann, J.-W. Tan, S. Walter et H. C. Traue. 2016, «Affective Computing and the Impact of Gender and Age», *PLOS ONE*, vol. 11, n° 3, doi :10.1371/journal.pone.0150584, p. e0150584, ISSN 1932-6203. URL <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0150584>.
- Rupayana, D. D. 2008, *Flow and Engagement: Different Degrees of the Same?*, mémoire de maîtrise, Kansas State University.
- Russell, J. A. 1980, «A circumplex model of affect», *Journal of Personality and Social Psychology*, vol. 39, n° 6, doi :10.1037/h0077714, p. 1161–1178, ISSN 1939-1315(Electronic),0022-3514(Print).
- Schaffer, O. et X. Fang. 2019, «Digital Game Enjoyment: A Literature Review», dans *HCI in Games*, édité par X. Fang, Lecture Notes in Computer Science, Springer International Publishing, ISBN 978-3-030-22602-2, p. 191–214.
- Schneider, R. 1987, «A Mathematical Model Of Human Skin Conductance», *Psychophysiology*, vol. 24, n° 5, p. 610.

- Shaker, N., S. Asteriadis, G. N. Yannakakis et K. Karpouzis. 2013, «Fusing Visual and Behavioral Cues for Modeling User Experience in Games», *IEEE Transactions on Cybernetics*, vol. 43, n° 6, doi :10.1109/TCYB.2013.2271738, p. 1519–1531, ISSN 2168-2267.
- St, L., S. Wold et collab.. 1989, «Analysis of variance (anova)», *Chemometrics and intelligent laboratory systems*, vol. 6, n° 4, p. 259–272.
- Staudenmann, D., K. Roeleveld, D. F. Stegeman et J. H. van Dieën. 2010, «Methodological aspects of SEMG recordings for force estimation – A tutorial and review», *Journal of Electromyography and Kinesiology*, vol. 20, n° 3, doi :10.1016/j.jelekin.2009.08.005, p. 375–387, ISSN 10506411. URL <http://linkinghub.elsevier.com/retrieve/pii/S1050641109001229>.
- Stemmler, G. 2004, «Physiological processes during emotion», dans *The regulation of emotion*, Lawrence Erlbaum Associates Publishers, Mahwah, NJ, US, ISBN 978-0-8058-4201-2, p. 33–70.
- Sweetser, P., D. M. Johnson et P. Wyeth. 2012, «Revisiting the GameFlow model with detailed heuristics», *Journal : Creative Technologies*, vol. 2012, ISSN 2230-2115. URL <http://journal.colab.org.nz/article/21>.
- Sweetser, P. et P. Wyeth. 2005, «GameFlow : A model for evaluating player enjoyment in games», dans *ACM Computers in Entertainment*, ACM Press.
- Sykes, J. et S. Brown. 2003, «Affective Gaming : Measuring Emotion Through the Gamepad», dans *CHI '03 Extended Abstracts on Human Factors in Computing Systems*, CHI EA '03, ACM, New York, NY, USA, ISBN 978-1-58113-637-1, p. 732–733, doi :10.1145/765891.765957. URL <http://doi.acm.org/10.1145/765891.765957>, event-place : Ft. Lauderdale, Florida, USA.
- Takatalo, J., J. Häkkinen et G. Nyman. 2015, «Understanding Presence, Involvement, and Flow in Digital Games», dans *Game User Experience Evaluation*, édité par R. Bernhaupt, Human–Computer Interaction Series, Springer International Publishing, Cham, ISBN 978-3-319-15985-0, p. 87–111, doi :10.1007/978-3-319-15985-0\_5. URL [https://doi.org/10.1007/978-3-319-15985-0\\_5](https://doi.org/10.1007/978-3-319-15985-0_5).
- Tan, J.-W., S. Walter, A. Scheck, D. Hrabal, H. Hoffmann, H. Kessler et H. C. Traue. 2012, «Repeatability of facial electromyography (EMG) activity over corrugator supercilii and zygomaticus major on differentiating various emotions»,

*Journal of Ambient Intelligence and Humanized Computing*, vol. 3, n° 1, doi : 10.1007/s12652-011-0084-9, p. 3–10, ISSN 1868-5145. URL <https://doi.org/10.1007/s12652-011-0084-9>.

Task Force of the European Society of Cardiology the North American Society of Pacing and Electrophysiology. 1996, «Heart Rate Variability: Standards of Measurement, Physiological Interpretation, and Clinical Use», *Circulation*, vol. 93, n° 5, doi :10.1161/01.CIR.93.5.1043, p. 1043–1065, ISSN 0009-7322, 1524-4539. URL <http://circ.ahajournals.org/content/93/5/1043>.

Tortora, G. J. et B. H. Derrickson. 2008, *Principles of anatomy and physiology*, John Wiley & Sons.

Turner, J. R., J. Sims, D. Carroll, R. K. Morgan et J. K. Hewitt. 1987, «A comparative evaluation of heart rate reactivity during MATH and a standard mental arithmetic task», *International Journal of Psychophysiology*, vol. 5, n° 4, doi : 10.1016/0167-8760(87)90061-4, p. 301–303, ISSN 0167-8760. URL <http://www.sciencedirect.com/science/article/pii/0167876087900614>.

Ubisoft. 2014, «Assassin's Creed : Unity», [Ordinateur].

Ubisoft. 2015, «Assassin's Creed : Syndicate», [Ordinateur].

Vachiratamporn, V., R. Legaspi, K. Moriyama et M. Numao. 2013, «Towards the Design of Affective Survival Horror Games : An Investigation on Player Affect», dans *2013 Humaine Association Conference on Affective Computing and Intelligent Interaction*, p. 576–581, doi :10.1109/ACII.2013.101.

Valve. 2013, «Dota 2», [Ordinateur].

Van Diest, I., M. M. Bradley, P. Guerra, O. Van den Bergh et P. J. Lang. 2009, «Fear conditioned respiration and its association to cardiac reactivity», *Biological psychology*, vol. 80, n° 2, doi :10.1016/j.biopsycho.2008.09.006, p. 212–217, ISSN 0301-0511. URL <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2670487/>.

Vincent, P., H. Larochelle, Y. Bengio et P.-A. Manzagol. 2008, «Extracting and Composing Robust Features with Denoising Autoencoders», dans *Proceedings of the 25th International Conference on Machine Learning, ICML '08*, ACM, New York, NY, USA, ISBN 978-1-60558-205-4, p. 1096–1103, doi :10.1145/1390156.1390294. URL <http://doi.acm.org/10.1145/1390156.1390294>, event-place : Helsinki, Finland.



- Wiemeyer, J., L. Nacke, C. Moser et F. 'Floyd' Mueller. 2016, «Player Experience», dans *Serious Games : Foundations, Concepts and Practice*, édité par R. Dörner, S. Göbel, W. Effelsberg et J. Wiemeyer, Springer International Publishing, Cham, ISBN 978-3-319-40612-1, p. 243–271, doi :10.1007/978-3-319-40612-1\_9. URL [https://doi.org/10.1007/978-3-319-40612-1\\_9](https://doi.org/10.1007/978-3-319-40612-1_9).
- Wilcott, R. C. 1967, «Arousal sweating and electrodermal phenomena», *Psychological Bulletin*, vol. 67, n° 1, doi :10.1037/h0024140, p. 58–72, ISSN 1939-1455(Electronic),0033-2909(Print).
- Woods, J. J. et B. Bigland-Ritchie. 1983, «Linear and non-linear surface EMG/force relationships in human muscles. An anatomical/functional argument for the existence of both», *American Journal of Physical Medicine*, vol. 62, n° 6, p. 287–299, ISSN 0002-9491.
- Yannakakis, G. N. et J. Hallam. 2008, «Entertainment modeling through physiology in physical play», *International Journal of Human-Computer Studies*, vol. 66, n° 10, doi :10.1016/j.ijhcs.2008.06.004, p. 741–755, ISSN 1071-5819. URL <http://www.sciencedirect.com/science/article/pii/S107158190800075X>.

## **Annexe A**

# **Participants et missions sélectionnés pour l'extraction de caractéristiques**

Les tableaux A.1 et A.2 présentent les participants restants dans la base de données après l'application des critères d'exclusion, pour ACU et ACS respectivement. Ce sont les données provenant de ces participants qui ont été utilisées pour l'extraction de caractéristique.

Tableau A.1 – Participants sélectionnés pour l’extraction des caractéristiques ayant joué au jeu ACU. Certaines séances de jeu (mission) ont été exclues pour les raisons mentionnées à la section 1.2.1. Les sigles « S5M3 » et « S9M3 » signifient « Séquence 5, Mémoire 3 » et « Séquence 9, Mémoire 3 », respectivement. Celles-ci réfèrent à des missions précises du jeu ACU.

Participant	S5M3 (« The Prophet »)	S9M3 (« The Escape »)
8	✓	
9	✓	✓
11	✓	
12	✓	✓
14		✓
15	✓	✓
16	✓	✓
17	✓	✓
20	✓	✓
22	✓	✓
23	✓	✓
24	✓	
26	✓	✓
28	✓	✓
32	✓	✓
33	✓	✓
34	✓	✓
35	✓	✓
36	✓	✓
38	✓	✓
39	✓	✓
43	✓	✓
44	✓	✓
45		✓
46	✓	✓
48	✓	✓
50	✓	✓
53	✓	
58	✓	✓
62	✓	
66	✓	✓
67	✓	✓
68	✓	✓
69	✓	✓
73	✓	✓
78	✓	✓
82	✓	✓
84	✓	✓
88		✓
100	✓	

Tableau A.2 – Participants sélectionnés pour l’extraction des caractéristiques ayant joué au jeu ACS. Certaines séances de jeu (mission) ont été exclues pour les raisons mentionnées à la section 1.2.1. Les sigles « S4M1 » et « S5M3 » signifient « Séquence 4, Mémoire 1 » et « Séquence 5, Mémoire 3 », respectivement. Celles-ci réfèrent à des missions précises du jeu ACS.

Participant	S4M1 (« A Spoonful of Syrup »)	S5M3 (« Survival of the Fittest »)
114	✓	
115	✓	✓
120	✓	✓
130	✓	✓
135	✓	✓
147	✓	✓
151	✓	✓
153	✓	✓
162	✓	
168	✓	✓
169	✓	✓
173	✓	✓
177	✓	✓
178	✓	✓
184	✓	✓
188	✓	✓
190	✓	✓
191	✓	✓
193	✓	✓
194	✓	✓
196	✓	✓
198	✓	
199	✓	✓
200	✓	✓
201	✓	
203	✓	
205	✓	✓
213	✓	✓
214	✓	
219	✓	✓
220	✓	✓
221	✓	✓
222	✓	✓
224	✓	✓
226	✓	✓

# Annexe B

## Concepts préliminaires d'apprentissage automatique supervisé

Comme la classification par apprentissage supervisé occupe une place importante dans ce projet de recherche, il convient d'en survoler les principes de base et d'établir la terminologie qui y est associée.

### B.1 Classification par apprentissage automatique supervisé

L'apprentissage automatique supervisé est un champ d'étude de l'intelligence artificielle regroupant des méthodes qui permettent à un programme d'« apprendre »<sup>1</sup> à résoudre des problèmes difficilement solubles par des méthodes conventionnelles. L'apprentissage supervisé utilise des données<sup>2</sup> étiquetées, c'est-à-dire des données appartenant à des classes.

La classification est une application très répandue de l'apprentissage supervisé. Celle-ci consiste à déterminer les classes auxquelles appartiennent des données à partir de

---

1. Le verbe « apprendre » est utilisé métaphoriquement. Dans le contexte de l'apprentissage automatique, cela signifie simplement qu'un modèle est construit à partir des données qui lui sont présentées.

2. Les termes « exemples » et « données » ont le même sens en apprentissage automatique. Ils réfèrent tous deux aux données utilisées pour construire le modèle, ou à celles sur lesquelles est appliqué le modèle.

caractéristiques. Les caractéristiques sont quant à elles des variables qui contiennent de l'information pertinente à l'accomplissement de la tâche de classification. Les caractéristiques dépendent grandement de l'objet de la classification (ex : des images, des mots, des objets, etc.) et prennent habituellement la forme de valeurs numériques réelles ou discrètes (ex : intensités des pixels, lettres composants chaque mot, taille des objets, etc.). Finalement, un classificateur est un modèle utilisant des techniques d'apprentissage supervisé pour effectuer une tâche de classification.

### B.1.1 Principes de la classification

Ici, le problème de la classification est explicité en détail. Supposons un jeu de données  $\mathcal{X}$  contenant  $N$  exemples tel que<sup>3</sup>

$$\mathcal{X} = \{\mathbf{x}^t, y^t\}_{t=1}^N. \quad (\text{B.1})$$

Chaque exemple  $t$  est composé d'un vecteur de caractéristiques  $\mathbf{x}^t \in X$ , qui contient les variables d'entrée du modèle, et d'une étiquette de classe  $y^t \in Y$ , qui représente la classe à laquelle la donnée  $\mathbf{x}^t$  est associée. Formellement, la tâche de classification revient à déterminer, parmi l'espace des hypothèses possibles  $\mathcal{H}$ , la fonction  $h : X \rightarrow Y$  qui offre la meilleure approximation de la fonction réelle de classification  $c$ . Concrètement, la fonction  $c$  permet de déterminer la classe  $y^t$  d'une donnée  $\mathbf{x}^t$ , c'est-à-dire  $C(\mathbf{x}^t) = y^t$ . Par exemple, dans un problème à 2 classes, disons  $C_1$  et  $C_2$ ,  $c$  serait

$$c(\mathbf{x}^t) = \begin{cases} 0, & \text{si } \mathbf{x}^t \in C_1 \\ 1, & \text{si } \mathbf{x}^t \in C_2 \end{cases}. \quad (\text{B.2})$$

Cependant,  $c$  étant inconnue, un critère est nécessaire pour déterminer l'hypothèse  $h$  qui s'en approche le plus. En général, l'erreur empirique  $E$  est utilisée. Celle-ci est calculée sur le jeu de donnée entier et peut s'écrire de manière générale comme

$$E(h|\mathcal{X}) = \frac{1}{N} \sum_{t=1}^N \mathcal{L}(h(\mathbf{x}^t), y^t), \quad (\text{B.3})$$

où  $\mathcal{L}$  est une fonction de perte qui peut prendre plusieurs formes.  $E$  correspond à l'erreur de classification et dépend de la performance de  $h$ , c'est-à-dire la capacité de  $h$  à déterminer les classes réelles des données. La plupart du temps  $h$  sera une fonction dépendant de paramètres  $\theta$ , et donc l'erreur empirique prendra plutôt la

---

3. la notation mathématique utilisée dans cette section est inspirée de celle de Alpaydin (2010)

forme

$$E(\theta|\mathcal{X}) = \frac{1}{N} \sum_{t=1}^N \mathcal{L}(h(\mathbf{x}^t|\theta), y^t). \quad (\text{B.4})$$

Sous cette forme, la tâche de classification devient un problème de minimisation, où il faut déterminer l'ensemble de paramètres  $\theta'$  de la fonction  $h$  tels que l'erreur empirique sur  $\mathcal{X}$  est minimale, c'est-à-dire :

$$\theta' = \operatorname{argmin}_{\theta} E(\theta|\mathcal{X}). \quad (\text{B.5})$$

Ceci est effectué différemment selon le modèle choisi. Par exemple, un SVM (« Support Vector Machine »), qui tente de maximiser la séparation entre certains exemples clés (les vecteurs de support), utilisera une descente du gradient pour minimiser l'erreur empirique, tandis qu'un modèle bayésien utilisera plutôt par une estimation du maximum de vraisemblance. Quoiqu'une revue en profondeur des modèles utilisés en apprentissage supervisé sorte du cadre de ce projet, le lecteur intéressé pourra consulter les ouvrages de [Alpaydin \(2010\)](#) et [Bishop \(2006\)](#) pour plus de détails sur le sujet.

À chaque modèle supervisé correspond un ensemble de paramètres qui doivent être ajustés lors de l'entraînement (l'entraînement est expliqué à la sous-section suivante). Ces paramètres sont différents des paramètres  $\theta$  utilisés dans l'équation B.4 pour paramétrer la fonction  $h$ . Pour éviter toute confusion, ceux-ci sont appelés « hyperparamètres ». Les hyperparamètres sont propres à chaque modèle, au sens où ceux d'un classificateur SVM diffèrent de ceux d'un classificateur « Random Forest » par exemple. Le réglage des hyperparamètres est un aspect important de l'entraînement du classificateur, car les performances de ce dernier en dépendent grandement.

### B.1.2 Entraînement, validation et test d'un classificateur

La mise en place d'un classificateur se fait en trois étapes : l'entraînement, la validation et le test du classificateur. L'objectif de ces trois étapes est d'obtenir un classificateur capable de trouver les étiquettes de nouvelles données dont les classes sont inconnues, et ce, avec le moins d'erreurs possible. Puisque chaque étape nécessite un ensemble de données différent, une manière simple de procéder est d'utiliser un sous-ensemble du jeu de données pour chacune des trois étapes (voir figure B.1).

Tout d'abord, l'entraînement est le processus par lequel un classificateur détermine la fonction lui permettant de classer les données. Durant l'entraînement, le classi-




FIGURE B.1 – Séparation typique du jeu de données en trois sous-ensembles : les jeux d’entraînement, de validation et de test. Les jeux d’entraînement et de validation sont utilisés conjointement pour l’entraînement et l’ajustement des hyperparamètres, tandis que le jeu de test ne doit être utilisé qu’à la toute fin pour évaluer les performances du classificateur. Un exemple de partitionnement pourrait être 80/10/10, soit 80% des données pour l’entraînement, 10% pour la validation et le test.

ficateur utilise des exemples étiquetés afin de mettre au point une fonction lui permettant de retrouver les étiquettes de ces exemples. L’entraînement est effectué avec un certain jeu d’hyperparamètres.

Ensuite, l’étape de validation consiste à vérifier les performances du classificateur entraîné avec un certain ensemble d’hyperparamètres. Cette étape permet d’ajuster les hyperparamètres du classificateur afin d’optimiser les capacités de généralisation du modèle. Dans un partitionnement du jeu de données en 3 sous-ensembles, il est fréquent d’utiliser plusieurs fois le jeu de validation pour tester différents agencements d’hyperparamètres. Bien que ceci permette de mettre au point un modèle plus performant, cela a aussi l’inconvénient de faire passer de l’information du jeu de validation au jeu d’entraînement. En effet, le jeu de validation devient progressivement intégré à l’entraînement, au sens où ce dernier est utilisé pour augmenter les performances du classificateur en passant par le réglage de ses hyperparamètres. C’est pour cette raison qu’un jeu de test, qui n’a jamais été utilisé lors de l’entraînement, est nécessaire pour évaluer les performances du modèle final.

Mentionnons que les étapes d’entraînement et de validation sont souvent effectuées conjointement lors de la sélection d’un modèle. Cela est notamment le cas lors d’une validation croisée à  $k$ -plis. Un exemple de partitionnement pour une validation croisée à 3-plis est illustrée à la figure B.2. L’avantage de cette méthode est qu’en plus d’obtenir une estimation du biais du classificateur, il est également possible d’obtenir une estimation de sa variance, ce que ne permet pas le partitionnement entraînement-validation-test.






FIGURE B.2 – Exemple d’une validation croisée à 3-plis. L’entraînement et la validation sont effectués à 3 reprises avec un partitionnement différent. Cela permet d’obtenir une estimation plus précise du biais et de la variance du classificateur. À noter que le jeu de test demeure intouché jusqu’au test du modèle final.

Finalement, l’étape de test permet d’évaluer les capacités du classificateur à généraliser à de nouvelles données. Cette étape est effectuée sur le jeu de test, dont les données n’ont pas été utilisées durant l’entraînement et la validation.

Suite à ceci, le classificateur final est entraîné à nouveau sur tout le jeu de données. Cela permet de maximiser le nombre de données présentées au classificateur, et donc d’améliorer la validité statistique de son modèle.

### B.1.3 Matrice de confusion

La matrice de confusion est une matrice contenant les comptes des prédictions correctes et incorrectes d’un classificateur. La figure B.3 contient des exemples de matrices de confusion. Les valeurs sur la diagonale de cette matrice correspondent aux données ayant été correctement classées – c’est-à-dire celles pour lesquelles la prédiction du classificateur correspond à la classe réelle – tandis que les éléments hors diagonales correspondent aux données incorrectement classées par le classificateur.

### B.1.4 Métriques de performances des classificateurs

À partir de la matrice de confusion, il est possible de calculer plusieurs métriques pour déterminer les performances d’un classificateur.

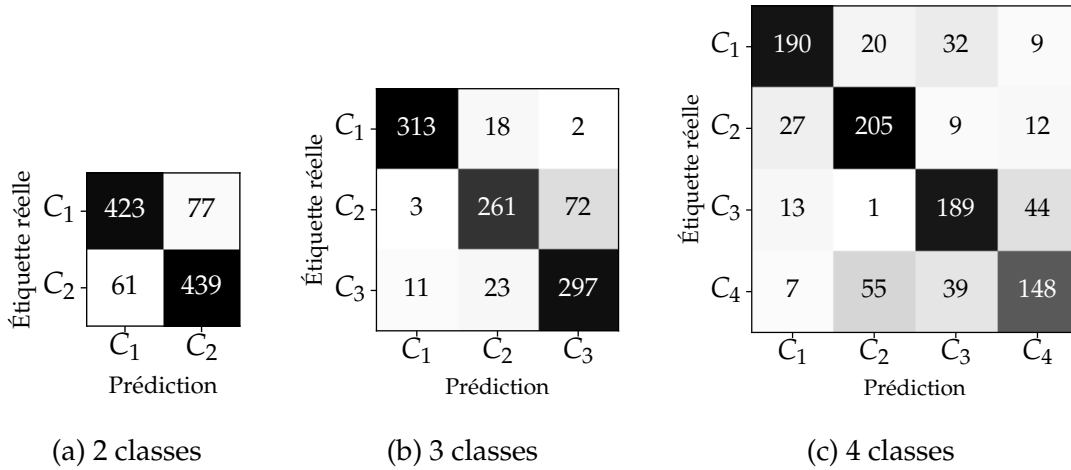


FIGURE B.3 – Exemples de matrices de confusion pour des problèmes à 2, 3 et 4 classes. Dans tout les cas, le nombre de données est  $N = 1000$  et les classes sont balancées.

### Taux de classement

Le taux de classement (« accuracy »), correspond à la proportion des données correctement classifiées selon le nombre total de données, soit

$$ACC = \frac{\sum_{i=1}^K C_{ii}}{\sum_{i=1}^K \sum_{j=1}^K C_{ij}} = \frac{Tr(C)}{N}, \quad (B.6)$$

où  $C_{ij} \in \mathbb{N}$  sont les éléments d'une matrice de confusion  $C_{K \times K}$ . De plus,  $ACC \in [0, 1]$ . Lorsque  $ACC = 0$ , cela signifie qu'aucune donnée n'a été correctement classée, tandis que pour  $ACC = 1$  toutes les données ont été classées correctement.

### Précision, rappel et score F1

La précision ( $P_i$ ) et le rappel ( $R_i$ ) pour une classe  $i$  sont définis comme

$$P_i = \frac{VP_i}{VP_i + FP_i} \quad (B.7)$$

et

$$R_i = \frac{VP_i}{VP_i + FN_i} \quad (B.8)$$

où  $VP_i$ ,  $FP_i$  et  $FN_i$  correspondent respectivement à la quantité de vrais positifs, de faux positifs et de faux négatifs pour la classe  $i$ . Étant donnée une matrice de confusion  $C$ , ces derniers sont définis comme

$$VP_i = C_i , \quad (\text{B.9})$$

$$FP_i = \sum_{i \neq j}^K C_{ji} , \quad (\text{B.10})$$

$$FN_i = \sum_{j \neq i}^K C_{ij} . \quad (\text{B.11})$$

Enfin, le score  $F1_i$  pour la classe  $i$  est défini comme la moyenne géométrique de la précision et du rappel, soit

$$F1 = 2 \cdot \frac{P \cdot R}{P + R} . \quad (\text{B.12})$$

# Annexe C

## Détection des changements de facteur-fun

Méthode utilisée dans Fortin-Côté et collab. (2019). Proposée par Alexis Fortin-Côté et adaptée et implémentée par Nicolas Beaudoin-Gagnon.

```
0 def increases_detection_in_array(arr, window_len_in_seconds,
  sampling_rate, n_changes_to_keep=1.0, return_increases_amplitude=
  False):
  1     """Detects increases in array with auto threshold. If
  n_changes_to_keep is smaller than or equal to 1.0, it's treated
  2     as a percentage of total number of peaks (biggest peaks are selected
  first). Hence, all peaks are kept if it's equal to 1.0."""
  import scipy.signal
  4     import numpy as np
  def average_diff(arr, hanning_window_width):
  6         arr = np.array(arr) # subsampling to reduce computation time
  new_arr = arr.copy()
  8         arr_len = len(arr)
  new_arr[:-1] = np.convolve(np.diff(arr), scipy.signal.hanning(
  hanning_window_width), mode='same')
  10     return new_arr

  12     window_len = window_len_in_seconds*sampling_rate

  14     # Subsampling signals with sampling rate > 10hz to 10hz
  subsampling_factor = sampling_rate//10
  16     arr_1000hz = arr
```

```

18 arr = arr[:, :subsampling_factor]
   hanning_window_width = window_len//subsampling_factor

20 arr = average_diff(arr, hanning_window_width)
   arr_len = len(arr)

22
   new_arr = np.zeros_like(arr_1000hz)

24
   ## Peak detection
26   # Detect peaks only, not valleys.
   for i in np.arange(arr_len):
28       if not np.any((arr[max(i-hanning_window_width//2, 0):min(i+
hanning_window_width//2, arr_len)] - arr[i]) > 0):
           if arr[i] > 0:
30               new_arr[i*subsampling_factor] = arr[i]

32   # First and last 30 seconds of fun are removed.
   time_not_to_consider = 30 * sampling_rate
34   new_arr[:time_not_to_consider] = 0
   new_arr[-time_not_to_consider:] = 0

36
   # finds n_changes_to_keep based on total number of peaks.
38   if n_changes_to_keep <= 1:
       n_peaks = np.sum((new_arr>0).astype(int))
40       n_changes_to_keep = int(n_changes_to_keep*n_peaks)

42   # Keeping only n biggest peaks.
   try:
44       thresh = np.sort(new_arr)[-(n_changes_to_keep + 1)]

46   except:
       thresh = np.sort(new_arr)[0]

48
   new_arr = np.array([i if i>thresh else 0 for i in new_arr])

50
   if return_increases_amplitude:
52       pass
   else:
54       new_arr = new_arr.astype(np.int32)

56   return new_arr

```

## Annexe D

# Classe Python implémentée pour la détection et pour la correction des pics de facteur-fun

```
0 import sys
import numpy
2 import pandas as pd
import numpy as np
4 from .funii_utils import increases_detection_in_array
from scipy.stats import linregress
6
class FunLabelCreator():
8     def __init__(self, fun, time_range_in_sec=6,
hanning_window_len_in_seconds=5, n_fun_changes_to_keep=1,
sampling_rate=1000):
    """ Classe used for fun-factor change detection
10
    Parameters:
12     fun (Numpy array): The fun-meter rating.
14
    time_range_in_sec (int): Time range [seconds] to consider
when looking for peaks of fun.
    Default has been empirically set to 6 seconds.
16
    hanning_window_len_in_seconds (int): = Length [seconds] of
the Hanning window used to detect fun changes.
18     Default has been empirically set to 5 seconds.
```

```

20         n_fun_changes_to_keep (int of float): Number of fun changes
to keep track of. If n_fun_changes_to_keep > 1,
        n biggest increases and n biggest decreases are
22     considered (hence, 2 x n_fun_changes_to_keep in total).
        If 0.0 < n_fun_changes_to_keep <= 1.0, it is treated as a
ratio of total fun increases/decreases.

24     sampling_rate (int): Sampling rate [Hz] of fun-meter rating.

26     """
    self.fun = fun
28     self.fun_length = len(fun)
    self.hanning_window_len_in_seconds =
hanning_window_len_in_seconds

30     self.fun_increases = increases_detection_in_array(fun,
n_changes_to_keep=n_fun_changes_to_keep, window_len_in_seconds=self.
hanning_window_len_in_seconds, sampling_rate=sampling_rate,
return_increases_amplitude=True)
32     self.fun_decreases = increases_detection_in_array(-fun,
n_changes_to_keep=n_fun_changes_to_keep, window_len_in_seconds=self.
hanning_window_len_in_seconds, sampling_rate=sampling_rate,
return_increases_amplitude=True)
    self.fun_changes = self.fun_increases + self.fun_decreases

34     self.increases_idx = np.array(range(len(self.fun))[self.
fun_increases>0])
36     self.decreases_idx = np.array(range(len(self.fun))[self.
fun_decreases>0])
    self.changes_idx = np.array(range(len(self.fun))[self.
fun_changes>0])
38     self.time_range = time_range_in_sec*sampling_rate
    self.sampling_rate = sampling_rate

40

42     # Fun increases/decreases with peak handling
    # here, idx of fun peaks are mean position of peaks.
    self.fun_increases_peaks_handled_mean_idx, self.
fun_decreases_peaks_handled_mean_idx = self.
extract_fun_changes_with_peak_handling()
44     self.increases_idx_peaks_handled_mean = np.array(range(len(self.
fun_increases_peaks_handled_mean_idx)))[self.
fun_increases_peaks_handled_mean_idx>0]

```

```

    self.decreases_idx_peaks_handled_mean = np.array(range(len(self.
fun_decreases_peaks_handled_mean_idx)))[self.
fun_decreases_peaks_handled_mean_idx>0]
46
    # but here, idx of fun peaks are start position of peaks.
48
    self.fun_increases_peaks_handled_start_idx, self.
fun_decreases_peaks_handled_start_idx = self.
extract_fun_changes_with_peak_handling(use_mean_peak_idx=False)
    self.increases_idx_peaks_handled_start = np.array(range(len(self.
fun_increases_peaks_handled_start_idx)))[self.
fun_increases_peaks_handled_start_idx>0]
50
    self.decreases_idx_peaks_handled_start = np.array(range(len(self.
fun_decreases_peaks_handled_start_idx)))[self.
fun_decreases_peaks_handled_start_idx>0]
52
def get_standardized_fun_changes(self):
54
    std = np.std(self.fun_changes[self.fun_changes>0])
    fun_increases_standardized = self.fun_increases/std
56
    fun_decreases_standardized = self.fun_decreases/std
    return fun_increases_standardized, fun_decreases_standardized
58
def extract_fun_changes_with_peak_handling(self, use_mean_peak_idx=
True):
60
    new_fun_increases = np.zeros_like(self.fun_increases)
    new_fun_decreases = np.zeros_like(self.fun_decreases)
62
    idx_to_skip =[]
64
    for change_idx in self.changes_idx[:-1]: # skipping last event
        if change_idx not in idx_to_skip:
66
            # wheter fun change is an increase or a decrease
            idx_is_increase = self.is_fun_change_idx_an_increase(
change_idx)
68
            if idx_is_increase:
                is_peak_start = self.is_idx_fun_increase_peak_start
70
            else:
                is_peak_start = self.is_idx_fun_decrease_peak_start
72
            # wheter increase or decrease is a peak start or not
74
            if is_peak_start(change_idx):
                peak_mean_idx = self.find_fun_peak_mean_idx(
change_idx)
76
                nearest_fun_change_idx = self.

```



```

78     find_nearest_fun_change_idx_within_time_range(change_idx)
           idx_to_skip.append(nearest_fun_change_idx)

80         if use_mean_peak_idx:
           if idx_is_increase:
               new_fun_increases[peak_mean_idx] = self.
fun_increases[change_idx]

82         elif not idx_is_increase:
           new_fun_decreases[peak_mean_idx] = self.
84 fun_decreases[change_idx]

86         else:
           if idx_is_increase:
88               new_fun_increases[change_idx] = self.
fun_increases[change_idx]

90         elif not idx_is_increase:
           new_fun_decreases[change_idx] = self.
92 fun_decreases[change_idx]

94         else:
           if idx_is_increase:
               new_fun_increases[change_idx] = self.
fun_increases[change_idx]

96         elif not idx_is_increase:
           new_fun_decreases[change_idx] = self.
98 fun_decreases[change_idx]

100     return new_fun_increases, new_fun_decreases

102     def get_stable_fun_segments(self,
minimum_window_length_where_fun_is_stable_in_seconds):
        all_fun_increases = increases_detection_in_array(self.fun,
n_changes_to_keep=1.0, window_len_in_seconds=self.
hanning_window_len_in_seconds,
104                                     sampling_rate=
self.sampling_rate, return_increases_amplitude=False)
        all_fun_decreases = increases_detection_in_array(self.fun,
n_changes_to_keep=1.0, window_len_in_seconds=self.
hanning_window_len_in_seconds,
106                                     sampling_rate=

```

```

self.sampling_rate, return_increases_amplitude=False)

108     window_length =
minimum_window_length_where_fun_is_stable_in_seconds*self.
sampling_rate
    stable_fun_segments_idx = (np.convolve(all_fun_increases +
all_fun_decreases, np.ones(window_length), mode='same') == 0).astype(
np.int32)
110
    for i in stable_fun_segments_idx.nonzero()[0]:
112         if np.any(stable_fun_segments_idx[(i - window_length//2):i]):
            stable_fun_segments_idx[i] = 0
114     return stable_fun_segments_idx

116     def find_fun_peak_mean_idx(self, idx_of_peak_start):
        nearest_idx = self.find_nearest_fun_change_idx_within_time_range(
idx_of_peak_start)
118         fun_peak_mean_idx = idx_of_peak_start + (nearest_idx -
idx_of_peak_start)//2
        return fun_peak_mean_idx

120
    def is_idx_fun_decrease_peak_start(self, idx_of_decrease):
122         is_idx_a_decrease = ~self.is_fun_change_idx_an_increase(
idx_of_decrease)
        is_nearest_idx_an_increase = self.
is_nearest_fun_change_within_time_range_an_increase(idx_of_decrease)
124         if is_nearest_idx_an_increase is not None:
            return bool(is_idx_a_decrease * (is_nearest_idx_an_increase))
126         else:
            return None

128
    def is_idx_fun_increase_peak_start(self, idx_of_increase):
130         is_idx_an_increase = self.is_fun_change_idx_an_increase(
idx_of_increase)
        is_nearest_idx_an_increase = self.
is_nearest_fun_change_within_time_range_an_increase(idx_of_increase)
132         if is_nearest_idx_an_increase is not None:
            return bool(is_idx_an_increase * (~is_nearest_idx_an_increase
))
134         else:
            return None

136
    def is_nearest_fun_change_within_time_range_an_increase(self, idx):

```

```

138     nearest_fun_change_idx_within_time_range = self.
find_nearest_fun_change_idx_within_time_range(idx)
140     if nearest_fun_change_idx_within_time_range is not None:
        return self.is_fun_change_idx_an_increase(
nearest_fun_change_idx_within_time_range)
142     else:
        return None

144     def find_nearest_fun_change_idx_within_time_range(self, idx):
        """If there is any fun change within time range, find index of
nearest.
146         Otherwise, if there's no fun change with time range, return None.
        """
        if self.check_if_any_fun_change_within_time_range(idx):
148             fun_change_idx = self.find_nearest_fun_change_idx(idx)
        else:
150             fun_change_idx = None
        return fun_change_idx

152     def is_fun_change_idx_an_increase(self, idx):
154         """Check if idx is an increase (True) or a decrease (False)."""
        if idx in self.increases_idx:
156             is_increase = True
        elif idx in self.decreases_idx:
158             is_increase = False
        else:
160             raise ValueError("idx {} not in in fun_increases nor
fun_decreases.".format(idx))
        return is_increase

162     def find_nearest_fun_change_idx(self, idx):
164         nearest_fun_change_idx = self.find_event_idx_nearest_to_idx(idx,
self.changes_idx)
        return nearest_fun_change_idx

166     def check_if_any_fun_change_within_time_range(self, idx):
168         nearest_idx = self.find_nearest_fun_change_idx(idx)
        return self.is_event_in_idx_time_range(idx, nearest_idx)

170     def find_event_idx_nearest_to_idx(self, idx, idx_values):
172         """Finds idx of nearest event in front of index. Events preceding
idx (an idx itself) are ignored."""
        idx_values_greater_than_idx = idx_values[idx_values > idx]

```

```
174     nearest_event_idx = idx_values_greater_than_idx[np.argmin(abs(
idx_values_greater_than_idx-idx))]
    return nearest_event_idx
176
def is_event_in_idx_time_range(self, idx, idx_event):
178     timestamps_in_time_range = self.get_timestamps_in_time_range(idx)
    return (idx_event in timestamps_in_time_range)
180
def get_timestamps_in_time_range(self, idx):
182     """Get timestamps from idx to idx+self.time_range."""
    timestamps = np.array(range(idx+1, idx+self.time_range))
184     return timestamps
```