



HAL
open science

Observatoire de la tactique en (e-)sport collectif

Alexis Mortelier

► **To cite this version:**

Alexis Mortelier. Observatoire de la tactique en (e-)sport collectif. Intelligence artificielle [cs.AI]. Normandie Université, 2024. Français. NNT : 2024NORMC245 . tel-04902032

HAL Id: tel-04902032

<https://theses.hal.science/tel-04902032v1>

Submitted on 20 Jan 2025

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

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

THÈSE

Pour obtenir le diplôme de doctorat

Spécialité **INFORMATIQUE**

Préparée au sein de l'**Université de Caen Normandie**

Observatoire de la tactique en (e-)sport collectif

Présentée et soutenue par
MORTELIER ALEXIS

Thèse soutenue le 13/12/2024
devant le jury composé de :

M. RIOULT FRANCOIS	Maître de conférences - Université de Caen Normandie (UCN)	Directeur de thèse
MME LE BER FLORENCE	Directeur de recherche - ENGEE STRASBOURG	Président du jury
M. BEN YAHIA SADOK	Maître de conférences - Université de Tunis - Tunisie	Membre du jury
M. GUIGNARD BRICE	Maître de conférences - Université Claude Bernard - Lyon 1	Membre du jury
M. DEVOGELE THOMAS	Professeur des universités - Université de Tours	Rapporteur du jury
M. IODICE PIERPAOLO	Professeur des universités - UNIVERSITE LE MANS	Rapporteur du jury
M. KAYTOUE MEHDI	Maître de conférences HDR - INSA Lyon	Rapporteur du jury

Thèse dirigée par **RIOULT FRANCOIS** (Groupe de recherche en informatique, image et instrumentation de Caen)



REMERCIEMENTS

L'aboutissement de cette thèse intitulée "*Observatoire de la tactique en (e-)sport collectif*" est le fruit de plusieurs années de travail, de réflexions, de recherches, mais surtout, du soutien inestimable de nombreuses personnes que je tiens à remercier chaleureusement.

Tout d'abord, je souhaite exprimer ma profonde gratitude à **François Rioult**, mon directeur de thèse, pour son accompagnement constant tout au long de ce parcours. Ses idées novatrices, son encadrement rigoureux, et surtout la motivation qu'il a su m'insuffler, ont été des piliers essentiels pour la réalisation de ce travail.

Un merci également à **John Komar**, co-encadrant de cette thèse, dont le soutien a été déterminant, notamment pour l'accès aux données et ses réponses éclairées à mes questions sportives. Son accueil lors de mon séjour à Singapour a été une expérience enrichissante et inspirante.

Je tiens à exprimer ma profonde gratitude aux membres du jury qui ont accepté d'évaluer mon travail de thèse. Vos observations et vos commentaires ont été d'une grande richesse, et ils ont permis d'enrichir significativement ce travail.

Je remercie tout particulièrement **Thomas Devogele**, rapporteur de cette thèse, pour l'attention minutieuse portée à mon manuscrit, ainsi que pour les remarques pertinentes et constructives qui ont contribué à améliorer la qualité de ce travail. Votre expertise et vos conseils avisés ont été d'une grande aide.

Je suis également reconnaissant à **Pierpaolo Iodice** et **Medhi Kaytoue** pour avoir accepté d'examiner cette thèse et pour les discussions stimulantes que nous avons eues lors de la soutenance. Vos critiques bienveillantes et vos suggestions ont été précieuses pour approfondir certaines réflexions et affiner mes conclusions.

Enfin, je souhaite exprimer ma reconnaissance à l'ensemble du jury pour le temps consacré à la lecture et à l'évaluation de mon travail. Votre engagement et votre rigueur ont grandement contribué à la valeur scientifique de cette recherche.

Je tiens à remercier **Sébastien Bougleux** pour son rôle dans l'amélioration de mes compétences en apprentissage machine et profond. Son enseignement m'a permis de grandir en tant que chercheur, et j'ai eu la chance de bénéficier de son esprit brillant et de sa personnalité sympathique.

Un remerciement spécial à **Virginie Carreau**, ma gestionnaire, qui a rendu mes missions bien plus agréables grâce à son soutien constant. Elle s'est toujours très bien occupée de moi et a su apporter une touche de sympathie à chaque interaction.

Je souhaite également remercier chaleureusement la DSI pour son soutien tout au long de ma thèse. Un merci tout particulier à **Pierre Blondeau**, **Davy Gigan** et **Renaud Rabeil**, avec qui j'ai partagé de nombreux fous rires lors des pauses cafés et midi. Leur compagnie et leur bonne humeur ont apporté une atmosphère conviviale qui a rendu ces moments de détente d'autant plus agréables.

Je souhaite également exprimer ma reconnaissance envers **Bruno Zanuttini** et **Normandie Université** pour le financement de cette thèse à travers le budget de l'ANR **Haiscode**, ainsi qu'au laboratoire **GREYC** pour m'avoir accueilli et soutenu dans mes missions de recherche. Mais aussi à **Pascal Vanier** et **Florence Leber** pour avoir veillé au bon déroulement de ma thèse en faisant partie de mon CSI.

Un grand merci à Marco Cardinale pour la fourniture précieuse des données de handball.

Mes remerciements vont également à **Matthieu Dien**, qui a su m'intégrer au sein du laboratoire et qui a été un vecteur social important, en particulier durant ma première année de thèse. Nos moments passés à jouer à TowerFall ont grandement contribué à créer un environnement de travail agréable.

Un grand merci à **Julien Clément** pour m'avoir initié aux instruments de musique et pour sa gentillesse contagieuse.

Un grand merci à **Mathias Dehais**, **Antonin Callard**, **Antoine Boiteau**, et **Lise Kastner** pour avoir partagé mon bureau. Votre présence et votre bonne humeur ont rendu cet espace encore plus agréable.

Je ne peux oublier **Étienne Lehembre**, mon co-bureau, qui a non seulement partagé de nombreux moments avec moi mais qui est également devenu un ami cher au cours de cette aventure.

Je souhaite aussi remercier tous les membres du laboratoire, en particulier **Djawad Bekkoucha**, **Aya Sahbi**, et **Marc Souply**, qui ont su rendre cette expérience de thèse plus agréable et sympathique par leur présence et leur amitié.

Je tiens à exprimer ma profonde gratitude à mes parents et à ma petite sœur, dont le soutien inébranlable a été une source inestimable de réconfort tout au long de ces trois années de travail acharné. Leur patience et leur amour m'ont permis de traverser les moments difficiles. Sans leur présence constante et leur encouragement, cette thèse

n'aurait jamais vu le jour. Merci du fond du cœur pour votre compréhension et votre soutien indéfectible.

Enfin, je voudrais conclure en soulignant que la thèse est un véritable marathon, parsemé de nombreuses difficultés, mais aussi riche en enseignements, tant sur le plan professionnel que personnel. Cette expérience m'a permis non seulement d'acquérir des compétences techniques et méthodologiques, mais aussi de mieux me connaître et de grandir en tant qu'individu.

À tous ceux qui ont croisé ma route durant ces années, un grand merci.

TABLE DES MATIÈRES

1	Introduction	2
2	Données et activités	6
2.1	Sport collectif : Handball	6
2.1.1	Les défis tactiques au handball	7
2.1.2	Acquisition de la donnée de handball	8
2.1.3	Les données Qatar 2015	9
2.2	E-sport collectif : les jeux de type MOBA	9
2.2.1	DotA2 (MOBA)	11
2.2.2	OverWatch (FPS stratégique)	12
2.2.3	Acquisition de la donnée de jeux vidéo	13
2.2.4	Jeu de données	15
I	État de l’art	16
3	Analyse du (e-)sport	17
3.1	Engagement du spectateur	17
3.2	Analyse du e-sport	19
3.2.1	Régulation du jeu	20
3.2.2	Résumé de match	21
3.2.3	Indices géométriques	21
3.2.4	Analyse de l’audio de la clameur pour extraire des descripteurs . . .	22
3.3	Analyse du handball	22
3.3.1	Recherche de régularités collectives	23
3.3.2	Analyse de la tactique au handball	24
3.3.3	Recherche de régularités temporelles	24
3.3.4	Discretisation de l’espace 2D	25
3.4	Conclusion	27

4	Éthologie des graphes dynamiques	28
4.1	Graphe statique	28
4.2	Graphe dynamique	29
4.2.1	Représentation par séquences de graphes	30
4.2.2	Graphe différentiel	30
4.3	Base de graphes dynamiques	31
4.4	Extraction de régularités dans les graphes dynamiques	31
4.4.1	Fouille de données transactionnelles	32
4.4.2	Fouille de données séquentielles	32
4.4.3	Isomorphisme de sous-graphes	33
4.4.4	Fouille de graphes statiques	33
4.4.5	Fouille de graphes dynamiques	34
4.5	Conclusion	35
5	Métriologie de la performance	36
5.1	Mesure d'intérêt d'une situation de jeu	36
5.1.1	Expected goal	37
5.1.2	Utilisation de l' $\times G$	38
5.1.3	Apprentissage de l' $\times G$	39
5.2	Pertinence des indicateurs : approche <i>wrapper</i>	40
5.3	<i>Machine learning</i> et mécanisme de l'attention	42
5.4	Conclusion	44
II	Traitement de la trajectoire	45
6	Conception de graphes dynamiques pour le handball	48
6.1	Position	48
6.2	Graphes dynamiques pour le handball	49
6.2.1	Transformation des trajectoires en graphes	49
6.2.2	Encodage par différentiel d'événements	50
6.3	Graphes dynamiques / séquence d'ensemble d'arêtes	52
6.4	Transformation du terrain	52
6.4.1	Détails de la transformation	53
6.4.2	Validation de la transformation de terrain	53

6.5	Conclusion	56
7	Indices tactico-géométriques pour DotA2	58
7.1	Position	59
7.2	Indices géométriques dans DotA2	59
7.3	Approche <i>Wrapper</i> avec RNN	60
7.4	Résultats	64
7.4.1	Apprentissage par phases	65
7.4.2	Apprentissage par fenêtre glissante	67
7.5	Conclusion	69
III	Métrique de performance	71
8	Conception d'un modèle d'<i>expected goal</i> pour le handball	73
8.1	Calculs de l' <i>xG</i> pour le handball	73
8.1.1	Calcul par échantillonnage	74
8.1.2	Calcul d'un modèle	75
8.2	Approche <i>wrapper</i> de sélection d'attributs	75
8.3	Résultats	78
8.4	Conclusion	78
9	Métrique de la performance pour OverWatch	81
9.1	Clameur de la foule, enthousiasme des commentateurs	81
9.1.1	Transformation des données	82
9.1.2	Extraction des descripteurs de l'audio	83
9.2	Expérimentations	84
9.2.1	Résultats	84
9.3	Conclusion	86
IV	Analyse de la tactique	88
10	Handball : Observatoire de la tactique en sport collectif	90
10.1	Observatoire	90
10.2	Représenter les tactiques sous forme de <i>sous-graphes dynamique</i>	91
10.3	Extraction de sous-séquences fréquentes	91

TABLE DES MATIÈRES

10.4 Mesures d'intérêt des tactiques	92
10.5 Interface de visualisation des tactiques	93
10.6 Intérêt pour l'expert	94
10.7 Conclusion	96
11 Attention pour l'analyse de dynamique d'équipe dans DotA2	97
11.1 Méthode	97
11.2 Architecture du modèle	98
11.3 Expérimentations	100
11.3.1 Protocole	100
11.3.2 Pertinence de la couche d'attention	101
11.3.3 Analyse statistique de l'attention	102
11.3.4 Analyse dynamique de l'attention	103
11.4 Conclusion	105
12 Conclusion - Perspectives	107
V Annexes	110
A Modèles d'apprentissage	111
A.1 Régression logistique	111
A.2 Arbre de décision	111
A.3 Forêts aléatoires	112
A.4 Boosting de gradient	113
A.5 CNN	114
A.5.1 1D Séparable CNN	114
A.6 RNN	115
A.6.1 GRU	116
A.6.2 LSTM	117
B Résultats supplémentaires sur l'attention pour l'analyse dynamique d'équipe dans DotA2	119
Bibliographie	125

Introduction

INTRODUCTION

Dans un paysage sportif en constante évolution, où les frontières entre les sports traditionnels et l'e-sport s'estompent, l'analyse de la performance revêt une importance croissante. Les données générées par les matchs offrent un potentiel considérable pour comprendre les schémas de jeu, les tactiques adoptées par les équipes et l'impact de ces tactiques sur les résultats des rencontres. Cette thèse s'inscrit dans ce contexte en explorant les étapes de la construction d'un observatoire de la tactique en (e-)sport collectif, avec une attention particulière portée à deux domaines d'activité : le sport traditionnel (en particulier le handball), et le e-sport (en particulier les jeux *DotA2* et *OverWatch*).

Contexte

Le sport traditionnel et l'e-sport sont des domaines qui partagent de nombreuses similitudes en termes de dynamique de jeu, de tactique d'équipe et d'analyse de performance. Le handball, sport collectif dynamique et stratégique, offre un terrain fertile pour l'analyse des performances et la compréhension des schémas de jeu. De l'autre côté, les jeux de type MOBA (Multiplayer Online Battle Arena), comme *DotA2* et *OverWatch*, sont des exemples emblématiques de la complexité et de la profondeur stratégique de l'e-sport. Ces jeux nécessitent une coordination d'équipe, une prise de décision rapide et une adaptation constante, des éléments également présents dans les sports traditionnels.

L'évolution rapide de l'e-sport et sa popularité croissante ont conduit à une convergence fertile avec les sports traditionnels, en termes d'analyse des performances. Les techniques d'analyse de données développées pour les sports traditionnels commencent à être appliquées à l'e-sport, et *vice versa*, offrent des perspectives inédites pour les chercheurs et les analystes.

Motivations

La motivation principale de cette thèse est de concevoir un cadre analytique qui permette d'explorer les tactiques utilisées dans les sports traditionnels et l'e-sport. Il serait souhaitable de disposer dans ce cadre de méthodes transposables d'un domaine à l'autre : chacun aurait à y gagner. Le champ d'application concerne les aspects collectifs de certaines activités (e-)sportives, pour favoriser les analyses tactiques.

Contributions

En présentant des analyses alternant entre le handball, *DotA2* et *OverWatch*, ce travail vise à segmenter le processus de traitement des données en différentes étapes qui apportent une compréhension spécifique des dynamiques de jeu et des performances collectives. Cette alternance délibérée entre sport et e-sport permet non seulement de dissocier le travail réalisé selon les étapes de traitement de la donnée, mais aussi d'offrir un panorama généraliste sur l'analyse du (e-)sport.

Les contributions de cette thèse sont regroupées selon trois niveaux d'analyse et de méthodologie : traitement de la trajectoire, conception de métrique de performance et enfin analyse de la tactique.

Traitement des trajectoires : la première contribution consiste en le développement de techniques pour représenter les matchs de handball à l'aide de graphes dynamiques et pour simplifier la représentation des trajectoires dans *DotA2* en utilisant des indices géométriques. Ces représentations permettent une meilleure compréhension de la dynamique collective.

Conception de métrique de performance : la deuxième contribution concerne la définition et le calcul de métrique de la performance. Cette étape est essentielle pour l'apprentissage automatique, qui nécessite une cible. Nous élaborons des modèles d'expected goal (xG) pour le handball et des facteurs d'engagement dans *OverWatch*.

Analyse de la tactique : la troisième contribution est la création d'un observatoire de la tactique en sport collectif, dédié au handball, ainsi que l'étude des configurations géométriques dans *DotA2* qui mènent à des événements de jeu importants. Ces travaux favorisent la compréhension des tactiques qui influencent le cours des matchs.

Organisation du Mémoire

Le mémoire est structuré en cinq parties, chacune abordant un aspect spécifique de l'analyse de données en sport et e-sport. La Partie I comporte trois chapitres d'état de l'art : le chapitre 3 *Analyse du (e-)sport* présente les méthodes d'analyse dans ces domaines. Le chapitre 4 *Éthologie des graphes dynamiques* explore les méthodes de représentation, d'analyse et d'extraction de régularités dans les graphes dynamiques et le chapitre 5 *Métriologie de la performance* explore la mesure de la performance dans le cadre de situations de jeu, en utilisant des indicateurs comme l'Expected Goal (xG) et en appliquant des techniques d'apprentissage automatique pour améliorer la pertinence et l'interprétation des données.

La Partie II rassemble nos contributions dans le domaine de l'analyse de la trajectoire : le chapitre 6 se concentre sur la représentation des tactiques dans le handball, en exhibant des schémas tactiques sous forme de graphes dynamiques. Nous discutons de l'importance de la transformation des trajectoires en graphes. Notre approche est adaptée au handball, tenant compte de la topographie du terrain grâce l'introduction d'une transformation *gnomonique* du terrain de jeu.

Le chapitre 7 propose une interprétation géométrique des trajectoires empruntées par les joueurs au cours d'une partie de *DotA2*. L'objectif est de développer une représentation efficace des interactions collectives dans ce jeu complexe en se basant sur des données de trajectoire. En utilisant des indices géométriques calculés à partir des trajectoires des joueurs, nous cherchons à capturer les schémas tactiques clés influençant le déroulement des parties.

La Partie III contribue à la conception de métrique de performance. Le chapitre 8 aborde celle d'un modèle d'expected goal adapté au handball, en mettant en avant une approche qui permet d'économiser la collecte de certaines données.

Le chapitre 9 propose une mesure de la performance dans *OverWatch* en mettant en évidence la corrélation entre les événements du jeu et l'engagement des spectateurs.

La Partie IV est dédiée à l'analyse de la tactique. Le chapitre 10 propose la conception d'un observatoire de la tactique en sport collectif, appliqué au handball. Représentées sous forme de graphes dynamiques, ces tactiques sont découvertes par extraction de séquences récurrentes et évaluées par des métriques d'intérêt.

Le chapitre 11 *Analyse des configurations géométriques dans DotA2* propose enfin une analyse de la dynamique d'équipe dans DotA2, à l'aide du mécanisme de l'attention. Cette dynamique est captée par l'interprétation des poids de la couche d'attention d'un RNN chargé de prédire la survenue d'un événement à partir des caractéristiques géométriques de l'organisation de l'équipe.

DONNÉES ET ACTIVITÉS

Ce chapitre explore les similarités entre les sports traditionnels et l'e-sport, en se concentrant sur les activités (e-)sportives qui constituent notre cadre applicatif : le handball, DotA2 et OverWatch. Nous examinons comment les données sont collectées, analysées et utilisées dans ces domaines, soulignant l'importance croissante de l'analyse des performances.

Nous débutons par le handball, analysant les méthodes d'acquisition et d'enrichissement des données. Ensuite, nous plongeons dans l'e-sport avec DotA2, en examinant les techniques d'extraction de données, notamment à travers des événements majeurs comme The International 2018, équivalent des championnats du monde pour ce jeu. Enfin, nous présentons le jeu OverWatch, mettant en lumière les défis de l'acquisition de données et leur impact sur l'optimisation des tactiques de jeu.

Ce chapitre offre un aperçu de l'effacement des frontières entre les mondes physique et virtuel, ainsi que des opportunités pour l'analyse des performances (e-)sportives.

2.1 Sport collectif : Handball

Le handball est un sport d'équipe dynamique et rapide qui se joue avec un ballon et qui oppose deux équipes de sept joueurs (six joueurs sur le terrain et un gardien de but). L'objectif du jeu est de marquer des buts en lançant le ballon dans le but adverse, tout en empêchant l'équipe adverse de marquer. Les joueurs se déplacent en dribblant avec le ballon à la main et peuvent effectuer un maximum de trois pas sans dribble.

Le handball est réputé pour son action rapide, ses passes précises et ses tirs puissants. Il est populaire dans de nombreux pays à travers le monde et est également pratiqué à différents niveaux, du loisir à la compétition professionnelle.

Le handball se déroule sur un terrain rectangulaire mesurant 40 mètres de long sur 20 mètres de large (voir figure 2.1), avec deux cages situées à chaque extrémité. Ces cages ont une taille réglementaire de 3 mètres de large sur 2 mètres de haut.

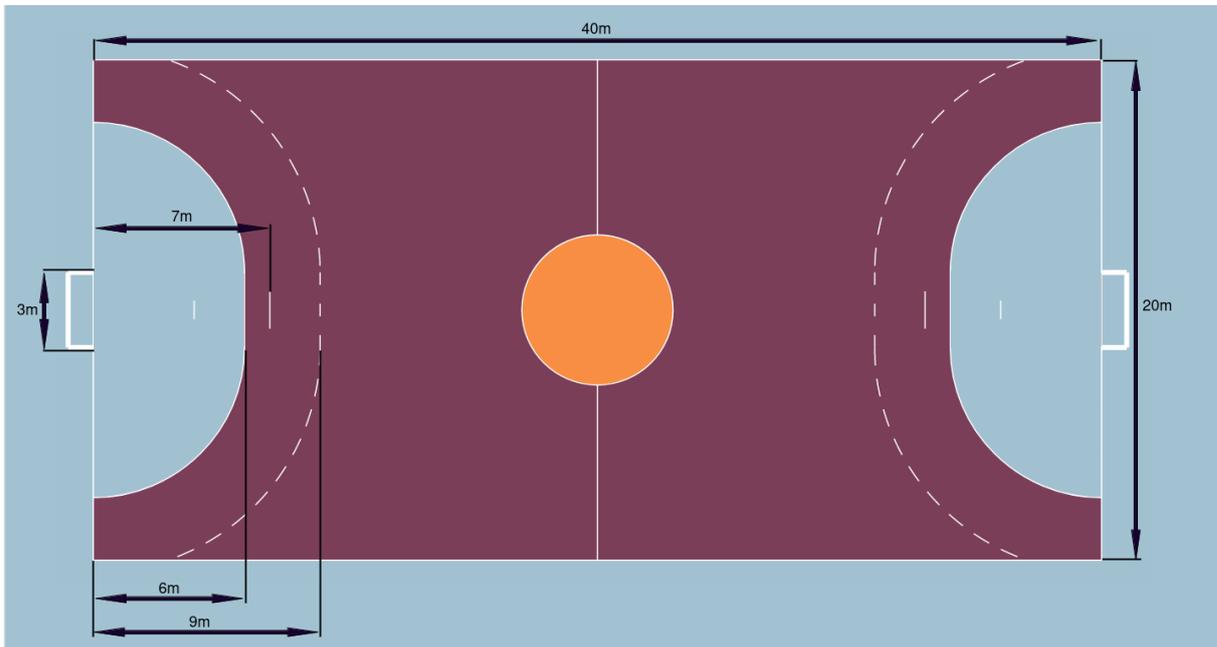


FIGURE 2.1 – Représentation du terrain de handball.

Une fois en possession du ballon, l'équipe attaquante cherche à créer des ouvertures dans la défense adverse en effectuant des passes rapides, en se déplaçant et en essayant de trouver des angles pour tirer au but. Les tirs peuvent être réalisés à partir de différentes positions sur le terrain, mais les joueurs doivent faire attention à ne pas pénétrer dans la zone de tir, où seuls les gardiens de but sont autorisés à se tenir.

Le match se déroule en deux mi-temps de 30 minutes chacune, avec une pause de 10 à 15 minutes entre les deux. L'équipe qui marque le plus de buts à la fin du temps réglementaire remporte la partie.

Le handball est un sport rapide, physique et stratégique qui exige une grande coordination, une excellente condition physique et une bonne compréhension tactique de la part des joueurs.

2.1.1 Les défis tactiques au handball

Au handball, le placement des attaquants et des défenseurs est soigneusement orchestré pour maximiser les opportunités de marquer et minimiser les risques de buts encaissés. Une scène typique sur le terrain révèle cette tactique élaborée : les défenseurs se déploient autour de la zone, formant une ligne défensive solide, tandis que les attaquants se positionnent en face d'eux, disposés sur un cercle concentrique. Cette organisation permet une

circulation fluide de la balle d'un joueur à l'autre, créant des décalages dans la défense et ouvrant des espaces pour des tirs ou des passes décisives. L'objectif est de perturber les défenseurs en les obligeant à se déplacer constamment pour suivre la trajectoire du ballon, tout en cherchant à introduire des intervalles dans leur couverture de la zone.

Cette régularité répétitive dans le placement des joueurs souligne l'importance des schémas tactiques et des mouvements synchronisés au handball, et motive l'analyse minutieuse des récurrences dans les situations. *A contrario*, le football présente des situations de jeu moins régulières à l'échelle globale du terrain, avec des interactions plus locales entre les joueurs et des schémas de jeu qui se concentrent souvent sur des positions spécifiques, concernant un nombre restreint de joueurs.

2.1.2 Acquisition de la donnée de handball

Il existe deux types de jeu de données pour le sport collectif : les données spatio-temporelles et les données événementielles.

Les données *événementielles* fournissent pour un match des journaux d'événements liés aux joueurs (passe, tir, réception, arrêt du gardien, *etc.*) ou d'événements techniques (carton rouge, début du temps, arrêt du temps, faute, *etc.*). Ces données résultent d'annotations manuelles. Chacun de ces événements peut être associé à une position, une durée ou un joueur et possède un horodatage.

Les données événementielles sont intrinsèquement bruitées car sujettes à des erreurs de localisation et d'horodatage. Les événements annotés sont généralement décalés de plusieurs mètres et de plusieurs secondes par rapport à la vérité du terrain. De plus, les données événementielles donnent une vue partielle de ce qui se passe. Elles se concentrent généralement sur les événements liés au ballon, négligeant ainsi les actions des autres joueurs qui ne sont pas directement impliqués dans l'action.

Les données *spatio-temporelles* concernent les trajectoires des joueurs ou du ballon ; elle fournissent des informations de localisation, de direction et de vitesse pour chacune des entités [GUDMUNDSSON et HORTON 2017].

Ces deux façons de voir la donnée induisent des technologies et des moyens techniques ou financiers différents. Par exemple, les capteurs Indoor Position System (IPS) [SERPIELLO et al. 2018] sont peu onéreux mais peu précis, tandis que la vidéo [PETTERSEN et al. 2014 ; SANFORD et al. 2020 ; SCOTT et al. 2022] est précise mais requiert un traitement coûteux.

Une solution est donc de combiner des données événementielles avec les données spatiales, ce qui permet de résoudre ces deux limitations. En utilisant les données spatiales, les erreurs d’annotation manuelle peuvent être corrigées, ce qui améliore la précision des données événementielles et les rend plus utilisables. Avec la synchronisation des événements avec les données spatiales, des caractéristiques de l’activité hors ballon peuvent être déterminées, car la position de chaque joueur est connue au moment d’un événement.

2.1.3 Les données Qatar 2015

Les données analysées au cours de ce travail proviennent de 88 matchs du championnat du monde de Handball 2015 qui se sont déroulés au Qatar. Ces données ont été obtenues par analyse vidéo et annotation manuelle des événements. Elles ont été peu valorisées, et uniquement selon des considérations sur les performances individuelles des joueurs [Marco CARDINALE et al. 2017; HANSEN, SANZ-LOPEZ et al. 2017; HANSEN, WHITELEY et al. 2019].

Ces données combinent des informations spatio-temporelles et événementielles : trajectoire de chaque joueur à 10 Hz (voir un extrait à la table 2.1) et détail des événements du match tel que les passes, les réceptions, les tirs ainsi que les buts (voir table 2.2). Pour chacun des matchs, un tableau récapitulatif statistique de chaque joueur est disponible. Ce tableau communique des informations telles que la distance de marche, de course, le nombre de tirs à 7 m et 9 m ainsi que le rôle et le numéro du joueur (voir table 2.3).

Time	Half	XPos	YPos
0.0	First Half	1156	122
0.1	First Half	1154	124
..
0.9	First Half	1145	119
1.0	First Half	1143	115

TABLE 2.1 – Extrait de données spatio-temporelles pour un joueur.

2.2 E-sport collectif : les jeux de type MOBA

Les MOBA (Multiplayer Online Battle Arena) sont un genre de jeux vidéo compétitifs au cours desquels deux équipes d’au moins cinq joueurs s’affrontent sur un terrain virtuel, dans le but de détruire la base adverse tout en défendant la leur. Ces jeux se

Time	Half	Event	Player1	Player2	Game time	XPos	YPos
00 : 00.0	0	Throw Off	35 Andreas Nilsson		00 : 00.0	0.57	-0.51
00 : 00.6	0	Player Catch	8 Lukas Karlsson		00 : 00.6	2.43	-0.11
00 : 01.5	0	Pass	8 Lukas Karlsson		00 : 01.5	1.22	-0.10
00 : 01.9	0	Player Catch	31 Viktor Ostlund		00 : 01.9	-1.21	3.94
..
00 : 27.8	0	Substitution	2 Magnus Persson	18 Tobias Karlsson	00 : 27.8	2.59	9.10

TABLE 2.2 – Extrait de données événementielles pour un match.

Player	Position	No	Team	Match	Date
Thierry Omeyer	Goalkeeper	16	France	France vs Czech Republic	16.01.15
Xavier Barachet	Right Back	4	France	France vs Czech Republic	16.01.15
Nikola Karabatic	Centre Back	13	France	France vs Czech Republic	16.01.15
Michael Guigou	Left Wing	21	France	France vs Czech Republic	16.01.15
Luka Karabatic	Pivot	22	France	France vs Czech Republic	16.01.15
William Accambray	Left Back	18	France	France vs Czech Republic	16.01.15
Jerome Fernandez	Left Back	2	France	France vs Czech Republic	16.01.15

TABLE 2.3 – Informations sur les joueurs.

déroulent généralement en vue isométrique ou en vue 3D de dessus, offrant aux joueurs une perspective stratégique sur le champ de bataille.

Un élément caractéristique des **MOBA** est que le terrain de jeu est souvent identique d'une partie à l'autre, avec quelques variations mineures. Cette uniformité contribue à une grande reproductibilité des situations, ce qui signifie que les joueurs peuvent apprendre et maîtriser les aspects tactiques et stratégiques du jeu au fil du temps. Cela favorise également le développement de tactiques complexes et la coordination d'équipe.

Les **MOBA** sont des jeux collectifs : le succès dépend non seulement des compétences individuelles des joueurs, mais aussi de leur capacité à travailler ensemble en tant qu'équipe. La communication, la coordination et la compréhension mutuelle des rôles de chaque joueur sont essentielles pour la victoire.

La pratique des **MOBA** nécessite souvent des entraînements similaires à ceux des sports classiques, car les joueurs doivent développer leurs compétences individuelles, leur compréhension du jeu et leur coordination avec leurs coéquipiers. Cela peut impliquer des sessions d'entraînement spécifiques, des analyses de parties, des séances de renforcement de l'équipe et des exercices de réflexes et de prise de décision rapide.

En résumé, les **MOBA** sont des jeux compétitifs en ligne qui offrent une expérience de jeu stratégique et intense, où la coopération d'équipe est un élément déterminant.

Cependant, les jeux MOBA sont particulièrement complexes à analyser : chaque joueur peut choisir l'avatar (ou *héro*) qu'il incarne parmi une centaine, chaque avatar peut lancer quatre sorts exclusifs et progresser dans l'arbre de ses compétences (vitesse de déplacement, fréquence d'attaque, armure, régénération de mana et de points de vie, *etc.*), et enfin être équipé d'items améliorant ses compétences. Ces items procurent des bonus actifs ou passifs. Il est donc souhaitable de réduire cette complexité avant d'entreprendre une analyse tactique ou stratégique.

2.2.1 DotA2 (MOBA)

Nous avons analysé les données du jeu DotA2 (Defense of the Ancients 2), qui est emblématique du type MOBA. Chaque joueur développe son héros au cours du jeu en collectant de l'or et de l'expérience. Grâce à ces ressources, le héros peut obtenir de nouveaux équipements et de nouvelles capacités qui le favoriseront dans la bataille contre les héros de l'équipe adverse. Dans DotA2, les *événements* qui rythment le match surviennent lorsque les héros incarnés par les joueurs sont neutralisés temporairement (*kill*), on parle de mort puis de renaissance ou de *ligne de vie*.

L'objectif de DotA2 est de progresser dans le territoire de l'adversaire et de détruire la forteresse de l'équipe adverse. Chacune des deux forteresses (les étoiles rose en bas à gauche et en haut à droite de la figure 2.2) est accessible par trois voies ou *lignes* (haut, milieu, bas). Ces lignes sont défendues par trois tours, symbolisées par un rond jaune sur la figure 2.2. Afin de détruire les tours et la forteresse adverse, chaque équipe escorte la progression de vagues de serviteurs (*creeps*), des créatures autonomes progressant par groupe dans les lignes, générées toutes les 30 secondes. Lorsque deux vagues de serviteurs opposés se font face, elles se battent pendant une vingtaine de secondes et se neutralisent, ce qui définit une ligne de front. L'objectif du jeu est donc, à l'aide des héros incarnés par les joueurs, de favoriser la progression de ses serviteurs en direction de l'adversaire. Un MOBA pourrait être vu comme une simulation de rugby à cinq sur un terrain très vaste (il faut environ 60 secondes pour aller d'une forteresse à l'autre), avec trois ballons dans trois lignes différentes.

Une partie de DotA2 dure entre 35 mn et 50 mn. On considère généralement qu'une partie se divise en trois grandes phases de jeu : le début de partie (*early-game*), les 15 premières minutes pendant lesquelles les héros sont faibles et cherchent à obtenir de l'or et de l'expérience pour gagner en puissance. C'est au cours de cette phase que l'on tente collectivement des embuscades pour prendre l'avantage et ruiner la progression de



FIGURE 2.2 – Carte de DotA2.

l'adversaire ; le milieu de partie (*mid-game*), de 16 à 35 mn, pendant lequel certains héros sont suffisamment puissants pour rendre possible les combats d'équipe ; la fin de partie (*late-game*), à partir de 36 mn, pendant laquelle les héros ont leur puissance maximale et ne cherchent plus à collecter de l'or ou de l'expérience : les tours et la forteresse ennemie deviennent l'unique objectif.

2.2.2 OverWatch (FPS stratégique)

OverWatch est un jeu vidéo de tir en vue à la première personne (FPS : First Person Shooter), impliquant des équipes de six joueurs. C'est un jeu à mi-chemin entre le FPS, traditionnellement individuel, et le MOBA, jeu collectif en arène fermée. Dans OverWatch, les joueurs choisissent parmi une variété de héros aux compétences uniques qu'ils pourront changer à leur guise au cours de la partie. Les équipes s'affrontent au cours de matchs compétitifs pour remplir divers objectifs, comme capturer des points de contrôle, escorter des charges explosives ou défendre des zones spécifiques. Le jeu est réputé pour son dynamisme, ses graphismes colorés et son univers riche en personnages. OverWatch met l'accent sur la coopération entre les joueurs, chaque héros ayant un rôle spécifique à jouer pour assurer la victoire de son équipe. Il est également célèbre pour ses mises à jour

régulières, ses événements saisonniers et sa communauté active.

2.2.3 Acquisition de la donnée de jeux vidéo

Données de DotA2 Dans le monde de l'e-sport, certaines compétitions officielles offrent des prix très importants, attirant ainsi l'attention des joueurs professionnels et des spectateurs du monde entier. Valve, l'éditeur de DotA2, a été l'un des pionniers dans cette approche. Dès le début, Valve a conçu DotA2 de manière à ce que les données du jeu soient facilement accessibles. DotA2 fournit des traces des activités de jeu sous la forme d'un fichier *replay* qui peut être récupéré après chaque partie. Les 258 parties que nous avons analysées étaient celles d'un tournoi majeur du jeu, The International 2018¹. Pour chaque héros joué par un humain, les informations suivantes sont disponibles à chaque seconde : ses coordonnées, ses points de vie, sa progression dans l'arbre de compétences, les objets de son inventaire, *etc.* L'interface du jeu permet de visualiser les matchs et le format du fichier est ouvert, permettant la récupération de l'intégralité des données. Pour cela, on utilise le *parser* Clarity 2, développé par la communauté. Ces données comprennent une multitude d'informations telles que les actions des joueurs, les statistiques des héros, les objets achetés, les temps d'apparition des monstres neutres, et bien plus encore.

Données de OverWatch On constate une approche de l'e-sport différente de la part de Blizzard, l'éditeur d'OverWatch. Contrairement à DotA2, les données d'OverWatch ne sont pas accessibles et il n'existe pas d'API permettant aux utilisateurs d'extraire des données directement à partir d'un match en cours ou d'une partie récente. Cela a été une source de frustration pour de nombreux joueurs et analystes qui auraient souhaité accéder à des données détaillées, dans le but d'améliorer leur jeu ou pour des analyses approfondies.

Cependant, les vidéos de nombreux matchs d'OverWatch sont enregistrées et déposées sur des plateformes telles que YouTube. Ces vidéos figurent des séquences de jeu capturées avec une sur-couche réservée aux spectateurs (voir figure 2.3). Cette interface offre une vue d'ensemble du match et des différentes actions des joueurs.

Face à ce manque d'accessibilité, nous avons dû créer nos propres outils, y compris un parser de vidéos, pour en extraire les données du jeu. Les données obtenues sont moins complètes que celles fournies par DotA2 ; en particulier, les trajectoires des avatars ne sont pas disponibles.

1. voir <https://www.dota2.com/esports> pour l'édition de cette année

La sur-couche réservée aux spectateurs fournit des informations sur l'ensemble du match (voir figures 2.3 et 2.5). La zone 1 précise le nom des deux équipes et le score. Les compositions d'équipes, le héros de chaque joueur, la vie de ce héros, l'état de sa capacité ultime ainsi que le pseudo du joueur sont affichés en zone 2 (voir Figure 2.5). Le *killfeed* est affiché en zone 3 (voir Figure 2.4) ; il montre les six derniers héros tués et/ou destructions de capacité de héros (méca de D.Va, tourelle de Torbjörn). Les noms des équipes sont affichées selon la couleur de l'équipe et une icône permet d'identifier le héros (voir le cadre vert sur la figure 2.4). Les icônes des héros participant au kill sont affichées à côté (cadres jaunes). Une flèche colorée en jaune indique un kill critique (zone 1). Si c'est une capacité (zone 3) ou une capacité ultime (zone 2) qui tue, son logo est accolé.

Grâce à des techniques d'analyse d'image (OCR, feature matching, pattern matching, érosion et dilatation), ces informations peuvent être captées depuis l'interface spectateur et donnent lieu à une chronologie précise des événements de la partie. L'analyseur de replay est disponible en ligne.²

2.2.4 Jeu de données

Pour le tournoi The International 2018, DotA2 offre une précieuse source de données grâce à son outil de replay, permettant de télécharger 258 matchs où 18 équipes s'affrontent.

OverWatch League

Grâce à l'outil de visualisation de replay que nous avons développé pour **OverWatch**, les vidéos de match ont été transformées en données exploitables, avec extraction des informations visuelles et auditives. Cette technologie a permis une analyse approfondie des matchs des playoffs des stage 1 et 2 de l'**OverWatch League 2020**. Au total, les données de quatorze matchs ont été traitées, engendrant l'étude de plus de soixante cartes différentes sur vingt heures de vidéo. Cette extraction permet de disposer de 60 séquences d'une taille variant entre 900 et 1800 pas de temps. Chacune de ces séquences fournit à chaque pas de temps des descripteurs d'intérêt sur les dégâts, les soins, les morts, le chargement des capacités ultime, l'utilisation des capacités ultime ainsi que les descripteurs audio issus de la bande son des matchs.

2. <https://github.com/Nikkunemufr/Python/tree/master/MetaWatch>

PREMIÈRE PARTIE

État de l'art

ANALYSE DU (E-)SPORT

Le phénomène de l'e-sport en tant que nouvelle ère du sport souligne les opportunités qu'il offre aux scientifiques du sport [HIMMELSTEIN et SHAPIRO 2020]. La manière dont les sports traditionnels et l'e-sport interagissent affecte notamment le public, les sponsors, les revenus, et d'autres aspects économiques et socioculturels. L'e-sport s'inscrit dans le paysage plus large du sport professionnel et peut bénéficier de l'expérience et de l'infrastructure des sports traditionnels [CASTRONOVA 2020].

Ainsi, il est pertinent d'explorer les différentes dimensions de cette interaction, en examinant l'engagement du spectateur. La communauté de l'e-sport n'a en effet rien à envier à celle des sports traditionnels, avec des fans tout aussi fidèles et engagés. Cet engagement se manifeste lors d'événements en direct, sur les plateformes de streaming et les réseaux sociaux. C'est une motivation centrale pour l'analyse de données de cette activité.

Nous explorons ici l'univers de l'e-sport en mettant en lumière ses spécificités, ses défis et ses opportunités uniques. Pour finir, nous étudions le handball, un sport traditionnel avec une base de fans bien établie, afin de comparer les dynamiques tactiques et les méthodes mis en place pour leur analyse. Par cette approche, nous chercherons à comprendre comment l'e-sport et les sports traditionnels peuvent s'enrichir mutuellement.

3.1 Engagement du spectateur

Cette section est le résultat de maintes discussions avec Boris Helleu [MORTELIER, HELLEU et al. 2024].

La complexité de la consommation du spectacle sportif a suscité l'intérêt de diverses disciplines académiques. Des analyses sociologiques, psychologiques, économiques, et de gestion et marketing ont éclairé les multiples facettes de cette pratique, explorant pourquoi et comment les individus s'adonnent au sport. De nombreuses études ont examiné les facteurs influençant l'engagement des spectateurs, tels que la performance de leur équipe

favorite, le talent des joueurs, le coût des billets, les conditions atmosphériques, l'ambiance dans le stade, ou encore l'incertitude du résultat, soulignant ainsi la diversité des modalités de consommation du spectacle sportif.

En mobilisant l'intérêt de nombreux fans, sponsors et médias de par le monde, l'e-sport est devenu un objet scientifique pris au sérieux. En effet, selon le 2022 Global Esports & Live Streaming Market Report de Newzoo, l'audience globale des fans d'e-sport s'élèvera à 640 millions de personnes en 2025, dont 318 millions des fans enthousiastes (ceux qui regardent ce type de contenu au moins une fois par mois). Newzoo estime que le secteur aurait généré un chiffre d'affaires de 1,38 milliards de dollars à la fin de 2022. Ainsi, les questions sur les modalités de consommation du sport ont trouvé des prolongements fertiles dans le domaine de l'e-sport [HAMARI et SJÖBLOM 2017]. De la pratique au spectacle médiatisé, l'e-sport recouvre un large spectre d'expériences si bien qu'on peut parler des publics des e-sports [VOISIN et BESOMBES 2023].

Pour autant, les premiers travaux dédiés aux fans de l'e-sport favorisent la comparaison avec le sport « traditionnel ». [PIZZO et al. 2018] comparent les motivations des spectateurs d'un sport traditionnel (le football) et de deux contextes d'e-sports (FIFA Online 3 et StarCraft II) en Corée du Sud. Les auteurs ont listé 15 motivations pour assister à des événements (l'intérêt, l'excitation, apprécier des joueurs, l'intensité compétitive, rencontrer des gens ou partager un moment en famille, l'habileté des athlètes, *etc.*) [ibid.]. Selon les auteurs, 11 des 15 principales motivations des fans sont communes aux trois événements dénotant une certaine similitude des modalités de consommation sportive et e-sportive [ibid.].

L'e-sport présente pourtant une singularité. Si, à l'instar du sport traditionnel, il parvient à réunir de larges affluences dans des stades et arenas, il mobilise aussi l'intérêt des adeptes sur des plateformes de streaming qui permettent l'interaction à distance. Ainsi de nombreuses études s'intéressent à la consommation en ligne. [JANG et al. 2024] se demandent : "What makes e-sports consumers watch streamers' e-sports live-streaming contents?". [QIAN et al. 2020] ont développé le modèle Scale for Esports Spectator Demand (SESD) qui isole des facteurs spécifiques à l'e-sport : la qualité du stream, la chat room, les récompenses en ligne. Alors que la demande de spectacle sportif s'explique en grande partie par l'incertitude du résultat d'une rencontre en direct, [W. WANG 2023] s'intéresse à la consommation asynchrone en replays. Il s'intéresse plus particulièrement à la popularité et l'habileté (skills) des joueurs.

Les skills sont particulièrement valorisés dans des jeux FPS à la dimension technique

affirmée tandis que la popularité du joueur sera plus estimée dans un jeu de type MOBA laissant place au divertissement et à la socialisation. Les spectateurs des streams étant eux-mêmes des pratiquants de compétitions vidéoludiques, regarder les meilleurs joueurs est aussi un moyen de monter en compétences [HATTINGH, VAN DEN BERG et BEVANDYE 2024; QIAN et al. 2020].

3.2 Analyse du e-sport

L'e-sport est une aubaine pour la recherche en science des données car les traces d'activité sont, la plupart du temps, facilement et massivement disponibles. Contrairement aux sports traditionnels où il est difficile d'obtenir des données précises, chaque match de DotA2 est rendu accessible par l'éditeur du jeu, selon un format retranscrivant parfaitement la suite des interactions entre les joueurs.

La popularité des jeux vidéo en général et du e-sport en particulier a conduit à un certain nombre d'articles étudiant les mécaniques de ces jeux, en utilisant une approche de science des données. Les jeux de type MOBA (voir section 2.2.1) sont très pertinents pour les études comparatives car ils offrent un jeu complexe mais relativement formaté, à la fois en termes de terrain de jeu et de manière de jouer. Les thèmes abordés vont de l'étude du comportement individuel aux résumés de jeu, en passant par la prédiction des résultats, l'utilisation d'indices géométriques et les RNN [MORA-CANTALLOPS et SICILIA 2018].

L'analyse des données dans l'e-sport peut être utilisée pour évaluer les performances individuelles des joueurs. Comprendre les exigences physiques spécifiques des jeux afin d'optimiser la performance des joueurs est important [GOTO et RYNKIEWICZ 2019]. Cela peut inclure des mesures telles que la précision des tirs, la réactivité, les temps de réaction, *etc.* En identifiant les domaines dans lesquels un joueur excelle ou éprouve des difficultés, les entraîneurs peuvent adapter l'entraînement pour renforcer les compétences nécessaires. Par exemple, une étude menée par [SCHULTE et al. 2019] a montré que l'utilisation de données biométriques et de capteurs peut aider à évaluer et à améliorer les performances des joueurs d'e-sport.

Outre les performances individuelles, l'équipe peut être appréhendée selon son caractère collectif. On peut examiner les schémas de jeu, les tactiques utilisées par les adversaires, et les tendances de jeu pour ajuster la tactique [PATEL et LINDLEY 2020]. Par exemple, une recherche menée par [P. WANG et al. 2019] a utilisé l'analyse des données

pour identifier les schémas de jeu et les tactiques utilisées par les équipes de haut niveau de DotA2, ce qui a permis de dégager des éclairages sur les meilleures pratiques et les contre-tactiques possibles.

L'analyse des données dans l'e-sport peut impliquer plusieurs méthodes, l'extraction et l'analyse de données à partir des jeux eux-mêmes [JOHNSON 2020]. Les données transcrivent les actions des joueurs, les résultats des matchs, les mouvements sur la carte, *etc.* Les données peuvent être collectées à l'aide de l'API du jeu ou de logiciels tiers [DRACHEN et al. 2014]. La disposition spécifique de la carte du jeu affecte les tactiques des équipes et l'issue des matchs, en utilisant des données de jeu pour identifier les modèles et les tendances liés à la carte [REIMERS et GOLDMAN 2019].

L'analyse des données historiques des matchs peut fournir des informations précieuses sur les tendances de jeu, les performances des joueurs et des équipes, les tactiques utilisées, *etc.* Par exemple, [SCHUBERT M. 2010] ont examiné le comportement des utilisateurs dans les jeux vidéo en analysant les données de jeu historiques pour comprendre les préférences des joueurs.

3.2.1 Régulation du jeu

Les développeurs de jeux peuvent utiliser les données des joueurs pour améliorer l'expérience de jeu, la conception de jeu, et la rétention des joueurs.

Malgré le fort caractère collectif de la pratique d'un MOBA, les individualités sont beaucoup étudiées. Il est en effet important de catégoriser les joueurs en fonction de leur comportement pendant le jeu, ce qui permet d'obtenir des informations utiles sur le déroulement du jeu mais aussi sur leur comportement en dehors du jeu [SIFA, DRACHEN et BAUCKHAGE 2018]. La télémétrie comportementale peut être utilisée pour cette tâche, produisant des modèles de comportement utilisables. L'analyse du comportement dans le jeu conduit alors à des éléments de co-conception guidée par les données : un comportement exceptionnel est détecté par rapport aux normes établies dans les jeux professionnels [BLOCK et al. 2018]. Un système d'analyse visuelle pour aider les concepteurs de jeux à trouver les événements clés et les paramètres de jeu conduisant à un effet *snowball* (une équipe dominant toujours plus l'autre) est proposé dans [Q. LI, XU et al. 2016].

Comme l'activité de jeu implique parfois des millions de joueurs et des événements compétitifs avec des prix importants, sa régulation est une tâche essentielle. Par exemple, la phase de choix des avatars peut être étudiée, on peut formuler des recommandations

pour gagner et établir des règles pour choisir un personnage plutôt qu'un autre [SUMMERVILLE, COOK et STEENHUISEN 2016; Weiqi WANG 2016]. L'adhésion du public à l'émission générée suscite également l'intérêt. L'analyse des données montre notamment une corrélation entre l'effet snowball et la perte d'audience [Q. LI, WU et al. 2018]. [SCHUBERT, DRACHEN et MAHLMANN 2016] explore le concept de confrontation dans DotA2.

3.2.2 Résumé de match

Effectuée manuellement, la génération automatique de résumés de matchs et leur indexation sont des tâches fastidieuses, comme le montre [AHMAD et al. 2019], qui présente l'étiquetage des actions pour la supervision d'un système de graphe, le tout sur seulement deux matchs. L'objectif ultime est de comprendre les tactiques sous-jacentes, les dynamiques complexes et les décisions stratégiques prises dans des contextes spécifiques. La génération automatique de résumés est souhaitable : au cours d'un jeu MOBA, il y a beaucoup d'événements et de combats, quels sont ceux qui sont particulièrement intéressants? Ces questions concernent également les chercheurs en sport traditionnel (voir par exemple [EKIN, TEKALP et MEHROTRA 2003; STENSLAND et al. 2014; ZAWBAA et al. 2012] pour le football) et plus récemment pour les e-sports [RINGER et NICOLAOU 2018].

Résumer les moments importants ou anticiper les actions essentielles contribue à la disponibilité d'applications compagnons, alimentées par des éléments d'analyse [KOKKINAKIS et al. 2020]. Dans [CHU et CHOU 2015; 2017], les auteurs conçoivent et extraient des caractéristiques propres au jeu en tenant compte du contenu visuel, de la sémantique de l'événement et de la réaction des téléspectateurs. Ils intègrent ensuite les indices de ces trois domaines en se basant sur une approche psychologique et fondée sur des données afin de caractériser les temps forts du jeu.

3.2.3 Indices géométriques

L'analyse d'une pratique collective sur un terrain donné se prête naturellement à l'étude des trajectoires et de la géométrie des organisations de joueurs. Ainsi, pour le football, un travail similaire à celui présenté dans cette thèse au chapitre 7 est proposé dans [FRENCKEN et al. 2011], dans le but de prédire l'issue du match. Pour DotA2, les indices géométriques permettent de prédire correctement le résultat d'un match et cette pertinence est confirmée sur 6 milliards de matchs de League Of Legends (MOBA concurrent de DotA2) via un système RandomForest avec une F-mesure de 92 %. Des

régularités dans les trajectoires, discriminantes pour le gain du match, ont également pu être extraites [CAVADENTI et al. 2016]. Le comportement sur un terrain de MOBA est en effet crucial et les différences entre les niveaux de jeu sont révélées par des indices positionnels : changement de zone, distance entre les joueurs, ce qui permet un regroupement des matchs en fonction de la similarité des mouvements [DRACHEN et al. 2014].

3.2.4 Analyse de l’audio de la clameur pour extraire des descripteurs

Le domaine de l’analyse audio de la clameur des foules est devenu un terrain de recherche fertile. La détection acoustique des dynamiques des rassemblements, par analyse de Fourier, spectroscopie ou réseaux de neurones, fournit des informations pertinentes [PROKSCH et al. 2023]. Il est possible de repérer les comportements anormaux au sein des foules, en mettant en avant des paramètres comme le niveau de pression acoustique et la densité spectrale à l’aide de tactiques de traitement du signal audio [DOSBAYEV et al. 2021]. De même, l’utilisation des signaux audio pour détecter les émotions émergentes dans les foules, à travers des approches telles que l’analyse de l’intensité vocale et des modèles de prosodie est explorée [FRANZONI, BIONDI et MILANI 2020]. Les revues bibliographiques offrent des perspectives précieuses sur l’application de techniques de deep learning et d’analyse prosodique pour extraire de façon automatisée des caractéristiques audio complexes des données de foule [BAŞBUĞ et SERT 2019; CROCCO et al. 2016; KHALIL et al. 2019; LEFÈVRE et al. 2021; RAO, KOOLAGUDI et VEMPADA 2013; SCHULLER 2018]. Dans leur ensemble, ces travaux soulignent l’importance croissante de l’analyse audio pour détecter les variations comportementales et émotionnelles au sein des rassemblements.

3.3 Analyse du handball

Notre point est vue étant l’analyse de la tactique collective, passons sous silence de nombreuses études sur les aspects individuels mis en oeuvre lors de la pratique du handball (voir [WAGNER et al. 2014] pour une revue approfondie des aspects de coordination, d’agilité, de force et de puissance, d’endurance, de constitution, de facteurs sociaux, de cognition).

Sur les aspects collectifs, les contributions sont peu nombreuses. Dans [TILP et SCHRAPP

2015], huit caméras détectent la position du défenseur devant le shooter dans le but de constituer des cartes auto-organisées de Kohonen [KOHONEN 1982], une méthode de clustering qui permet ici de caractériser le comportement en défense. La même technique est utilisée dans [Norbert SCHRAPP et Markus TILP 2013] mais pour l'attaque : des séquences de cinq passes avant le tir sont groupées, ce qui permet de mettre en évidence les huit séquences les plus jouées sur un total de 612, sur 6 matchs. Enfin, [LOPES et al. 2010] analyse une séquence de motifs temporel (T-patterns [JONSSON et al. 2010]) pour caractériser le comportement défensif.

3.3.1 Recherche de régularités collectives

La recherche de régularités collectives est une tâche classique de l'analyse de trajectoires sportives, comme l'atteste [GUDMUNDSSON et HORTON 2017], qui réalise une synthèse très complète des recherches en matière d'analyse temporelle pour les sports collectifs. Cette recherche de régularités nécessite une *discrétisation* (*vector quantization*) du domaine spatial continu vers un domaine *symbolique*. Le problème d'identification de motifs de trajectoire devient alors un problème de fouille de séquences de symboles, sur lesquels un raisonnement qualitatif spatial est possible [J. CHEN et al. 2013]. Par exemple, les relations spatiales sont encodées dans un formalisme logique qui permet la prédiction de la prochaine passe au football à l'aide programmation logique inductive [VERCRUYSSSEN, DE RAEDT et J. DAVIS 2016].

La discrétisation du domaine spatial procède en deux temps : caractérisation / détection d'un objet d'intérêt qui permet d'agréger des données continues de positions (voir section 3.3.3) puis groupement des objets d'intérêt / réduction de la dimension afin de limiter leur nombre.

Pour la deuxième phase de groupement des objets d'intérêt, on peut distinguer l'utilisation de clustering k-means ou EM dans [ANDRIENKO et al. 2016 ; BIALKOWSKI et al. 2014 ; FEUERHAKE 2016 ; FEUERHAKE et SESTER 2013], la réduction de dimension (PCA) dans [RIC et al. 2016] ou réduction optimisée de tenseur [R. LI, CHELLAPPA et ZHOU 2009], l'utilisation de cartes auto-organisées ou de gaz neural [MARTINETZ, BERKOVICH et SCHULTEN 1993] dans [GRUNZ, MEMMERT et PERL 2009 ; 2012 ; HASSAN et al. 2017 ; KEMPE, GRUNZ et MEMMERT 2015 ; PERL 2002 ; Norbert SCHRAPP et Markus TILP 2013 ; TILP et SCHRAPP 2015], et enfin le calcul de voisins par déformation temporelle dynamique [HAASE et BREFELD 2013].

Un troisième temps optionnel pour ce processus de transformation de l'espace des

trajectoires en une série de mouvement concerne la classification du mouvement (une suite de déplacements), souvent par comparaison aux divers représentants des clusters.

3.3.2 Analyse de la tactique au handball

Notre intérêt pour le handball réside dans l'étude des *tactiques* mises en oeuvre, qui désignent l'ensemble des moyens coordonnés que l'on emploie pour parvenir à un résultat. Les tactiques sont des étapes *locales* au sein du déroulement d'un plan d'actions coordonnées. Par exemple, une tactique consistera à provoquer un décalage temporaire de la défense en faisant rentrer un second pivot. La stratégie fournit une vision à plus long terme, par exemple une configuration particulière de la défense.

Les approches tactiques et stratégiques sont mineures dans la littérature. À l'exception de [FEUERHAKE et SESTER 2013; LOPES et al. 2010; Norbert SCHRAPP et Markus TILP 2013; TILP et SCHRAPP 2015], les aspects collectifs du handball sont très peu étudiés. Cependant, c'est un sport où l'aspect collectif domine. De plus, il existe beaucoup de données pour le handball, c'est un sport qui produit un grand nombre de séquences positionnelles stéréotypées et les tactiques de handball sont bien documentées [*Handball playbook* 2021] : chercher des combinaisons récurrentes devrait être fructueux.

L'identification de ces récurrences permettrait une indexation automatique des séquences du match, la génération automatique de résumés (en handball, il y a beaucoup de buts, lesquels sont particulièrement intéressants?) – voir [EKIN, TEKALP et MEHROTRA 2003; STENSLAND et al. 2014; ZAWBAA et al. 2012] pour le football – et *in fine* la détection des routines ou formations caractéristiques [H. KIM et al. 2022] d'une équipe, afin d'obtenir un avantage compétitif.

3.3.3 Recherche de régularités temporelles

La première étape de la recherche de régularités dans des motifs de mouvements collectifs concerne la caractérisation des objets d'intérêt. Cette tâche est bien identifiée, voir par exemple [DODGE, WEIBEL et LAUTENSCHÜTZ 2008] qui fournit une taxonomie extrêmement précise et détaillée des motifs de mouvement collectif.

Les motifs collectifs spatiaux (*generic aggregation patterns* [LAUBE, KREVELD et IMFELD 2005]), bien que classiques dans la communauté d'analyse des trajectoires (flocon, dominance, convergence, confrontation), sont en revanche peu utilisés dans le domaine sportif. On y trouve plutôt les *temporal patterns* (T-patterns [JONSSON et al. 2010]), qui

sont des séquences hiérarchiques d'événements, hiérarchiques au sens d'emboîtement et de relation entre les composants, par exemple dans [LOPES et al. 2010]. Les techniques dérivées des cartes auto-organisées sont également privilégiées, pour leur capacité à effectuer un clustering spatial [GRUNZ, MEMMERT et PERL 2009; 2012; HASSAN et al. 2017; KEMPE, GRUNZ et MEMMERT 2015; PERL 2002; Norbert SCHRAPF et Markus TILP 2013; TILP et SCHRAPF 2015].

On peut enfin noter l'usage de constellations [FEUERHAKE et SESTER 2013], décrivant la position relative des objets les uns par rapport aux autres, selon leur distance. Une constellation est ainsi invariante par rotation et dilatation. Cette approche est appliquée au football dans [FEUERHAKE 2016].

3.3.4 Discrétisation de l'espace 2D

Nous introduisons ici quelques outils fondamentaux pour la discrétisation de l'espace 2D auquel est associé le terrain d'évolution des joueurs que nous analysons. Ces outils sont le diagramme de Voronoï et son dual, le graphe de Delaunay.

Le *diagramme de Voronoï* est une partition de l'espace en cellules, également appelées régions de Voronoï, qui sont définies par des points spécifiques, les *germes*. Chaque cellule comprend l'ensemble des points de l'espace qui sont plus proches du germe associé que de tout autre germe. Les propriétés clés des diagrammes de Voronoï sont leur localité, leur convexité et leur capacité à s'adapter à des formes complexes en fonction de la disposition des germes.

Définition 1 (Diagramme de Voronoï) Soit $G = \{g_1, g_2, \dots, g_n\}$ un ensemble de germes dans un espace euclidien \mathbb{R}^d , le diagramme de Voronoï $V(G)$ est l'ensemble des régions V_i :

$$V_i = \{p \in \mathbb{R}^d \mid \forall j \neq i, \|p - g_i\| \leq \|p - g_j\|\}.$$

La *triangulation de Delaunay* (illustrée en bleu à la Figure 3.1), est l'ensemble de triangles connectant les germes de telle sorte que le cercle circonscrit à chaque triangle ne contient aucun autre germe. Les propriétés clés de la triangulation de Delaunay incluent l'optimalité locale et des propriétés géométriques importantes : encapsulation des triangles plus grands que dans d'autres triangulations, ce qui les rend utiles dans de nombreuses applications telles que la modélisation de terrain, la génération de maillage et l'interpolation.

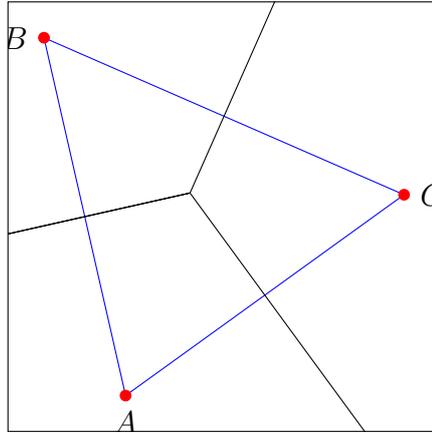


FIGURE 3.1 – Diagramme de Voronoï et triangulation de Delaunay pour un ensemble de points.

Définition 2 (Triangulation de Delaunay) Soit $G = \{g_1, g_2, \dots, g_n\}$ un ensemble de germes. Sa triangulation de Delaunay $D(P)$ est l'ensemble des triangles construits à partir de trois germes et dont le cercle circonscrit ne contient aucun autre germe.

Définition 3 (Graphe de Delaunay) Soit $G = \{g_1, g_2, \dots, g_n\}$ un ensemble de germes. Le graphe de Delaunay est le graphe associé à la triangulation, tel que :

- les sommets désignent les germes de G ;
- il y a une arête entre deux sommets g_i et g_j de G si et seulement s'il existe un triangle dans la triangulation qui a g_i et g_j comme sommets.

Notons que le graphe de Delaunay est dit le *dual* du diagramme de Voronoï, car il rassemble les paires de germes dont les régions de Voronoï sont voisines.

Ces outils de discrétisation prouvent leur utilité dans l'analyse du sport : les diagrammes de Voronoï, utilisés pour analyser la dynamique des joueurs sur le terrain, peuvent servir à identifier les schémas de jeu les plus efficaces en superposant les zones d'influence des joueurs aux mouvements de jeu [W. LIU et al. 2017 ; PAPPALARDO et al. 2019]. Parallèlement, en utilisant les graphes de Delaunay, les analystes peuvent identifier les relations spatiales entre les joueurs, les zones d'interception potentielles et les schémas de jeu [T.-Y. LIN, K.-H. CHEN et LU 2013]. Cette approche permet une analyse fine des schémas de jeu et des tactiques d'équipe.

Ces outils peuvent également être appliqués pour étudier la répartition spatiale des supporters dans un stade ou une arène sportive [KVELADZE, BASU et MANOCHA 2018],

ainsi que pour analyser la répartition spatiale des installations sportives dans une ville [TURO, BLANCO et SOLANA 2016].

Les concepts de *région dominante* [T. TAKI et J. HASEGAWA 2000; Tsuyoshi TAKI, J.-i. HASEGAWA et FUKUMURA 1996] et de zone d'influence, dérivés des diagrammes de Voronoï, jouent un rôle dans l'analyse de la performance des joueurs et l'optimisation des tactiques de jeu, par exemple au football [S. KIM 2004]. La région dominante d'un joueur est la cellule qu'il définit dans le diagramme de Voronoï, elle représente l'espace où le joueur exerce une influence maximale. L'analyse des régions dominantes permet de comprendre les préférences spatiales d'un joueur, ses mouvements typiques sur le terrain et son rôle dans le jeu. On trouve également des contributions à base de modèles probabilistes de mouvement et de zones de contrôle [BREFELD, LASEK et MAIR 2019; FUJIMURA et SUGIHARA 2005].

3.4 Conclusion

Ce chapitre a exploré deux domaines distincts mais intrinsèquement liés : le sport traditionnel et le e-sport. Nous avons synthétisé la littérature sur l'engagement du spectateur et la consommation du e-sport, mettant en lumière l'essor croissant de cette forme de divertissement et ses implications pour l'industrie du sport.

L'analyse du sport et du e-sport suscite un grand intérêt, avec une variété de techniques et méthodes appliquées à des usages diversifiés. Il est cependant difficile de tout présenter, et certains thèmes très spécifiques seront abordés dans les chapitres suivants. Les manques identifiés dans la littérature actuelle suggèrent de mettre l'accent sur l'analyse des dynamiques d'équipe en e-sport et sur une exploration plus poussée des interactions tactiques dans le sport traditionnel. Ces aspects seront approfondis dans les chapitres 10 et 11.

Pour le handball, la littérature pose des pointeurs pour identifier les régularités temporelles et analyser l'espace de jeu. En parallèle, les analyses du e-sport se concentrent sur l'individu, les résumés de matchs et les indices géométriques, permettant ainsi une compréhension plus profonde des tactiques et des performances des joueurs. Cependant, les deux domaines réclament un approfondissement des analyses tactiques sous l'angle du collectif. Nous contribuons à ce domaine dans les chapitres 6 et 7.

ÉTHOLOGIE DES GRAPHES DYNAMIQUES

Pour représenter et étudier les schémas de jeu, il importe de considérer la suite des événements d'un match tel qu'il est retranscrit dans les données à notre disposition. En pratique, nous disposons des trajectoires des joueurs et d'une succession d'événements (passe, tir, faute, *etc.*). La notion de *graphe dynamique* permet de capturer la dynamique de l'évolution du jeu, nous y dédions deux chapitres de contribution, les chapitres 6 et 10.

Ce chapitre introduit les méthodes de conception d'un *graphe dynamique* à partir de trajectoires en 2D, mettant en lumière les différentes propositions pour leur formalisation. C'est également l'occasion d'examiner l'état de l'art sur l'extraction de régularités dans les graphes dynamiques.

4.1 Graphe statique

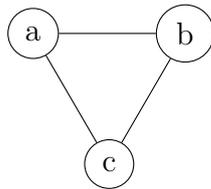


FIGURE 4.1 – Représentation d'un graphe

Un graphe $G = (V, E)$ associe à un ensemble de nœuds V un ensemble d'arêtes E , qui sont des couples ou des paires de nœuds, selon que le graphe est orienté ou pas. Un graphe permet de modéliser les relations entre les entités d'un système. Ce graphe est dit *statique*, par opposition à un *graphe dynamique* dont les arêtes et les nœuds évoluent au cours du temps.

Définition 4 (Graphe statique) Soit $G = (V, E)$ un graphe statique, où :

- V est l'ensemble des sommets du graphe.
- E est l'ensemble des arêtes du graphe :

- dans le cas d'un graphe orienté, les arêtes sont des couples de sommets et $E \subset \{(u, v) \mid (u, v) \in V \times V \wedge u \neq v\}$;
- pour un graphe non orienté, les arêtes sont des paires de sommets et $E \subset \{\{u, v\} \mid (u, v) \in V \times V \wedge u \neq v\}$.

Par exemple, la figure 4.1 présente le graphe $G = (V, E)$ dont l'ensemble des noeuds V est constitué des étiquettes a, b et c ($V = \{a, b, c\}$) et l'ensemble des arêtes est $E = \{(a, b), (b, c), (a, c)\}$.

4.2 Graphe dynamique

Un *graphe dynamique* ou graphe variable dans le temps [CASTEIGTS et al. 2012] $(G_t)_{t=1..T}$ est un graphe dont les arêtes et/ou les sommets peuvent changer au fil du temps. Il peut être défini comme une séquence de graphes statiques (ou *snapshots*) G_1, G_2, \dots, G_T où chaque $G_t = (V_t, E_t)$ représente l'état du graphe dynamique à un instant t . Un graphe dynamique peut également être défini comme une suite de modifications à appliquer au graphe initial [HOLME 2015].

Le temps t indexant le graphe dynamique dépend de la représentation choisie pour les données. Par exemple, pour les données du championnat du monde de handball au Qatar, les trajectoires sont échantillonnées à 10 *Hz*. Le temps t d'indexation pourrait être ici un nombre entier de dixième de secondes. On pourrait également ne considérer que la séquence des graphes correspondant à chaque événement de passe, réception de balle, shoot ou faute. Dans ce cas, t serait un index entier sur le nombre total d'événement.

Un graphe dynamique peut avoir différentes représentations et dénominations équivalentes [ibid.] : graphe temporel, réseau dynamique ou temporel, graphe évolutif, graphe séquence, série chronologique de graphes, *etc.* Les approches classiques utilisent une représentation séquentielle où chaque instant est modélisé par une matrice d'adjacence $(A_t)_{t=1..T}$, décrivant la présence ou l'absence d'arêtes entre les nœuds au temps t [ŠILJAK 2008]. D'autres modèles temporels capturent les évolutions du graphe en attribuant des intervalles de temps aux arêtes, suivant l'évolution des connexions entre les nœuds. Ainsi, chaque arête est caractérisée par un 3-uplet $(v_i, v_j, [t_{\text{start}}, t_{\text{end}}])$, indiquant que l'arête existe entre les nœuds v_i et v_j pendant l'intervalle de temps $[t_{\text{start}}, t_{\text{end}}]$ [FOURNIER-VIGER, HE et al. 2020].

Les graphes évolutifs $(G_t)_{t=1..T}$ intègrent la structure statique d'un graphe G et une fonction d'évolution ϕ telle que $G_t = \phi(G, t)$, cette fonction décrit des changements dans

la topologie du graphe au fil du temps [ROSSI et al. 2013]. Ils sont adaptés pour modéliser des systèmes qui évoluent de manière continue, comme les réseaux sociaux.

4.2.1 Représentation par séquences de graphes

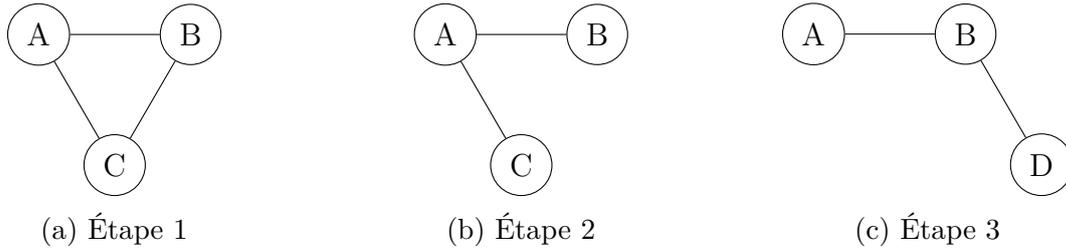


FIGURE 4.2 – Évolution d’un graphe dynamique.

Les séquences de graphes décrivent l’évolution temporelle sous forme de plusieurs graphes successifs (illustration à la Figure 4.2). Cette méthode offre une vision claire de l’évolution, mais peut nécessiter des mécanismes d’alignement pour comparer les états successifs. La séquence de graphes peut être formalisée comme une séquence $\langle G_1, G_2, \dots, G_T \rangle$ où chaque G_t est défini conformément à la représentation d’un graphe statique [HOLME 2015].

4.2.2 Graphe différentiel

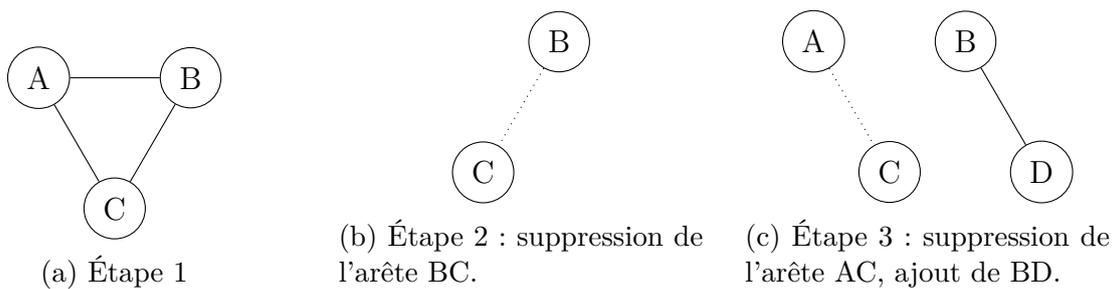


FIGURE 4.3 – Évolution d’un graphe dynamique différentiel.

L’évolution d’un graphe dynamique peut être considérée sous l’angle des différences entre deux snapshots successifs. L’opération de *différence entre deux graphes* exhibe les noeuds et arêtes qu’il convient d’ajouter ou supprimer à un snapshot pour obtenir le suivant. Un exemple de graphe différentiel (ou *difference graph* en anglais [BERGER-WOLF

et SHAVLIK 2007]) est fourni à la figure 4.3 : il s’agit du même graphe dynamique que celui de la figure 4.2 mais seules les modifications de snapshot sont représentées. Cette opération est couramment utilisée en informatique, en théorie des graphes, en analyse de réseaux, et en bio-informatique [SADEGHI et al. 2017].

Dans le domaine de l’apprentissage automatique et de l’analyse de données, la différence de graphe peut être utilisée pour comparer les prédictions de différents modèles ou pour évaluer l’impact des paramètres sur la structure du graphe résultant [ATKINSON, LIPPMANN et VARSHNEY 2013].

4.3 Base de graphes dynamiques

Un graphe dynamique est le résultat de l’évolution temporelle d’un graphe, avec un début et une fin. Par exemple, dans le cas du handball, un graphe dynamique peut gérer la séquence intégrale d’actions démarrant au début de la mi-temps et terminant à la fin de la mi-temps. Une autre vision des données de handball pourrait considérer une *séquence* de graphes dynamiques, rythmés par l’alternance de possession du ballon entre les équipes qui s’opposent.

Nous considérerons donc disposer d’une *base de graphes dynamiques*, au sens d’un *ensemble* de graphes dynamiques. Par exemple, nous serons amené au chapitre 10 à extraire des régularités dans la base des graphes dynamiques constituée à partir de toutes les séquences de cinq passes avant un tir.

Définition 5 (Base de graphes dynamiques) *Une base B de graphes dynamiques est un ensemble de n graphes dynamiques $B = \{(G_{1,t})_{t=1\dots T_1}, \dots, (G_{n,t})_{t=1\dots T_n}\}$. Les snapshots de chaque graphe dynamique sont indicés par des instants temporels de 1 à T_1 , de 1 à T_2 , ..., de 1 à T_n .*

4.4 Extraction de régularités dans les graphes dynamiques

Nous verrons dans les contributions de ce travail que l’extraction de régularités dans les graphes dynamiques est l’une des méthodes que nous avons choisies pour répondre à notre problématique de caractérisation des tactiques dans le sport collectif : les tactiques seront

les sous-graphes dynamiques obtenus à partir des données de trajectoires transformées en base de graphes dynamiques.

L'extraction de régularités est une pratique classique en fouille de données, visant à découvrir des régularités dans les données pour faciliter la prise de décision ou les prédictions en apprentissage automatique. Initialement centrée sur les données transactionnelles (fouille d'itemsets), cette discipline a évolué pour répondre aux besoins de données séquentielles (fouille de séquences d'items ou d'itemsets) et de données représentées par des graphes.

Les algorithmes traditionnels consistent généralement à explorer l'espace de recherche des motifs, selon un principe d'alternance entre des phases de génération de candidats et de mise à l'épreuve de ces candidats (générer puis tester). Cet espace de recherche est structuré, par exemple il est souvent muni d'un ordre partiel, voire d'une structure de treillis. Cette structure permet d'adopter une stratégie pour parcourir l'espace, en bénéficiant de propriétés avantageuses de la mesure d'intérêt choisie, par exemple pour élaguer l'espace.

4.4.1 Fouille de données transactionnelles

Dans les données transactionnelles, chaque transaction est représentée par un ensemble d'items. L'objectif est d'identifier les ensembles d'items fréquents, également appelés motifs fréquents, qui apparaissent ensemble dans un grand nombre de transactions. Cette tâche est couramment abordée à l'aide d'algorithmes tels que Apriori [AGRAWAL et SRIKANT 1994] et FP-Growth [HAN, PEI et YIN 2000], qui utilisent des techniques d'exploration/énumération pour découvrir ces motifs.

Les techniques d'extraction de motifs dans les contextes booléens bénéficient également des apports théoriques relatifs aux représentations condensées et l'analyse formelle de concept [SOULET, RIOULT et CRÉMILLEUX 2022] : l'extraction de motifs maximaux est favorisée, autant parce qu'elle est plus efficace que celle des motifs quelconques, que parce qu'elle fournit des motifs ayant de bonnes propriétés pour résumer un grand nombre de motifs.

4.4.2 Fouille de données séquentielles

Dans des données séquentielles, un motif sera lui-même une séquence d'items ou d'itemsets. Les techniques caractéristiques de l'extraction dans les données transaction-

nelles peuvent être adaptées pour fournir des algorithmes générer et tester [MAHMOOD et SUTTON 2013]. On trouve également des méthodes plus spécifiques qui focalisent leur attention sur les motifs maximaux [FOURNIER-VIGER, J. C.-W. LIN, KIRAN et al. 2017].

À la différence des données transactionnelles, la mesure de fréquence est équivoque dans les séquences : elle peut désigner le nombre de séquences de la base qui contiennent le motif, mais un motif peut apparaître plusieurs fois et donc être répété dans une séquence. La fréquence peut donc également caractériser le nombre total d’occurrences.

4.4.3 Isomorphisme de sous-graphes

Pour l’extraction de régularités dans les graphes dynamiques, il existe plusieurs défis majeurs à relever. Les principaux défis sont la taille de l’espace de recherche et le problème de l’isomorphisme de sous-graphes.

Dans les graphes dynamiques, les structures et les motifs peuvent évoluer rapidement au fil du temps. Cela signifie que l’espace de recherche des motifs potentiels peut devenir extrêmement vaste, ce qui rend la tâche d’extraction de régularités complexe et gourmande en ressources [AKOGLU, TONG et KOUTRA 2015; BERLINGERIO, PINELLI et TIZZONI 2012].

L’isomorphisme de sous-graphes est un problème fondamental en analyse de graphes. Il se pose lorsqu’il faut déterminer si deux sous-graphes sont structurellement identiques, c’est-à-dire s’ils ont la même organisation de nœuds et d’arêtes [GIONIS, MANNILA et TSAPARAS 2007; KAMATH et al. 2014]. La solution de ce problème d’isomorphisme est nécessaire au cours de la phase de test des candidats d’une méthode explorant l’espace de recherche.

Pour surmonter ces défis, des techniques avancées telles que l’échantillonnage efficace des motifs, la compression de données, et l’utilisation de structures de données et d’algorithmes spécifiques peuvent être nécessaires. De plus, des approches hybrides combinant des méthodes symboliques et des techniques d’apprentissage automatique peuvent être explorées pour améliorer l’efficacité et la précision de l’extraction de régularités dans les graphes dynamiques [M. LI, R. ZHANG et Z. LI 2017].

4.4.4 Fouille de graphes statiques

Dans un graphe statique, la recherche de régularités utilise un algorithme générer et tester. Un motif candidat est construit progressivement à partir d’un nœud, puis d’un

deuxième, puis d'une arête, *etc.* Il faut ensuite déterminer le nombre d'occurrence du motif, en déterminant les portions du graphe statique qui sont isomorphes au motif. Ces opérations sont très lourdes algorithmiquement, car le problème de l'isomorphisme de sous-graphe est NP-complet [WEGENER 2005]. Pour le rugby, une étude analyse dynamiquement des graphes statiques en regardant la relation entre la connectivité, l'assortativité, les composantes fortement connectées et le clustering sur le graphe joueur/passe/tacle et cherche une corrélation avec la quantité de progression réalisée [CINTIA, COSCIA et PAPPALARDO 2016].

4.4.5 Fouille de graphes dynamiques

Approche énumérative

L'approche énumérative explore systématiquement toutes les combinaisons de sous-graphes pour extraire des sous-graphes fréquents [INGALALLI, IENCO et PONCELET 2018]. De même, les données spatio-temporelles sont explorées à l'aide d'une approche énumérative pour découvrir des motifs réguliers dans les séquences et les graphes dynamiques attribués. Cette méthode fournit des résultats précis en examinant systématiquement toutes les possibilités de motifs dans les données, ce qui la rend particulièrement adaptée pour la découverte de motifs dans des contextes où la structure des données est complexe et variée [FLOUVAT 2019].

Approche neurale

Les méthodes d'apprentissage profond sont intégrées dans une approche neuronale afin d'extraire des motifs à partir des données en générant des représentations riches et expressives des motifs. Ces techniques explorent un espace d'incorporation ordonné (*ordered embedding space*) pour dégager des motifs de sous-graphes fréquents [YING, A. WANG et al. 2020]. L'embedding, qui projette également la dimension temporelle, est dit en espace ordonné car les projections respectent une relation d'ordre, entre autres temporelle. Cette approche s'applique aux graphes spatio-temporels pour extraire des motifs de sous-graphes fréquents à partir de multiples graphes [ZEGHINA et al. 2023]. Une autre méthode se focalise sur le décompte de sous-graphes de manière généralisable et évolutive en exploitant les techniques d'apprentissage profond [FU et al. 2024]. En complément, une approche explore l'apprentissage de représentations pour l'extraction de motifs de sous-graphes fréquents, favorisant une généralisation et une interprétation

efficaces des motifs découverts [YING, FU et al. 2024].

4.5 Conclusion

Ce chapitre a permis d'explorer différents aspects des graphes dynamiques, notamment les méthodes de représentation puis d'extraction de régularités dans ces graphes, ainsi que les approches de fouille de données associées.

L'approche séquentielle, basée sur la représentation par séquences de graphes, offre une perspective pour analyser l'évolution des graphes. En outre, l'utilisation de graphes différentiels capture les évolutions entre différentes étapes temporelles.

Les méthodes d'extraction de motifs dans les graphes dynamiques, qu'elles soient basées sur des approches énumératives, des techniques de fouille de données transactionnelles ou des approches neuronales, offrent des outils puissants pour identifier des structures récurrentes ou des comportements significatifs dans les données. Ces outils seront exploités au chapitre 10 pour l'extraction de tactiques sous la forme de régularités dans des graphes dynamiques issus de matchs de handball.

MÉTROLOGIE DE LA PERFORMANCE

L'exploration et la compréhension des tactiques sportives ont connu une révolution ces dernières années grâce à l'avènement de l'analyse de données. Au cœur de cette démarche se trouve une méthodologie classique, débutant par la collecte de descripteurs suivie de l'évaluation. Dans le domaine du sport, la mesure et l'évaluation vont bien au-delà des simples nombres et des statistiques. Elles impliquent l'utilisation d'outils spécifiques adaptés à chaque discipline, posant la question fondamentale : qu'est-ce qui définit une situation de jeu efficace ?

Dans cette optique, il est primordial d'accorder une attention particulière à la sélection des descripteurs d'entrées utilisés. Idéalement, ces descripteurs devraient être indépendants de la qualité individuelle des joueurs, qu'ils soient attaquants ou gardiens. L'Expected Goal (xG) émerge comme un indicateur de performance incontournable, offrant cette indépendance en évaluant la probabilité qu'une action mène à un but, tout en prenant en compte divers facteurs contextuels tels que la position du tireur, la distance au but et la pression défensive.

Cependant, la pertinence des descripteurs ne peut être prise pour acquise. Il faut vérifier leur validité et leur fiabilité. Une approche courante pour ce faire est l'utilisation de méthodes de sélections d'attributs telles que l'*approche wrapper*, que nous détaillons à la section 5.2. Cette approche scrute la contribution des différents descripteurs à la prédiction des résultats.

Ce chapitre discute des mesures d'intérêt d'une situation de jeu en se concentrant sur l'xG. Qu'est-ce que l'xG, comment il est utilisé et comment fonctionnent les mécanismes d'apprentissage de l'xG ?

5.1 Mesure d'intérêt d'une situation de jeu

Dans les sports collectifs de ballon, les buts sont les événements les plus importants. Selon les sports, ces événements de but peuvent arriver rarement, comme au football où ils

ont une probabilité faible d'apparition [TENGA, RONGLAN et BAHR 2010]. Les analystes préfèrent donc focaliser leur attention sur les tirs, plus nombreux que les buts. C'est ainsi qu'ont été créées des mesures telles que le *Total Shot Ratio* ou TSR [LAGO-BALLESTEROS et LAGO-PEÑAS 2010], qui évalue la domination des équipes en fonction de leur part de tirs dans les matchs. La limite du TSR est cependant qu'il ne tient pas compte de la qualité d'un tir. Par exemple, un tir dans un but sans gardien a la même valeur qu'un tir du milieu de terrain défendu par toute une équipe.

Avec la démocratisation de l'analyse des données, plusieurs dérivées de cette mesure ont été créées. Le différentiel de tirs, le différentiel de Fenwick [*Fenwick* p. d.] (différentiel de tirs entre les équipes) et le différentiel de Corsi [*Corsi* p. d.] (qui considère différemment les tirs cadrés et les tirs bloqués) sont devenus populaires pour analyser les performances des équipes et des joueurs de hockey [MACDONALD 2012a]. Ces statistiques ont été choisies parce que chacune d'entre elles s'est avérée être un très bon indicateur de la performance au niveau de l'équipe.

Parmi ces outils d'analyse, l'Expected Goal ou but espéré se démarque comme une mesure avancée. L'xG permet de quantifier la probabilité qu'un tir se transforme en but en se basant sur divers facteurs tels que la position du tir, le type de passe, la partie du corps utilisée pour tirer, et bien d'autres.

5.1.1 Expected goal

Tous les tirs n'étant pas égaux, une méthode est nécessaire pour mesurer la qualité d'un tir ou d'une série de tirs donnés, et c'est ainsi que les modèles xG ont été développés. xG est une statistique basée sur la position du tireur afin de calculer une probabilité de transformer un tir en but [*Opta xG* p. d.]. Dans la littérature sur le football, les modèles d'xG utilisent une même base d'attributs : position x et y au moment du tir, angle d'ouverture et distance du but [CAVUS et BIECEK 2022 ; FAIRCHILD, PELECHRINIS et KOKKODIS 2018 ; HEROLD et al. 2019 ; HEWITT et KARAKUŞ 2023 ; MADRERO PARDO 2020a ; UMAMI, D. GAUTAMA et H. HATTA 2021]. Cependant, dans les sports où les évènements de buts surviennent plus fréquemment, comme au handball qui compte environ 40 buts par match, les modèles xG ne sont pas utilisés.

Définition 6 (Expected goal) *L'Expected Goal est une statistique quantifiant la qualité des occasions de but. Pour un ensemble d'occasions de but $O = \{o_1, o_2, \dots, o_n\}$, où chaque occasion de but o_i est caractérisée par un ensemble de descripteurs tels que la position*

du tireur, la position du gardien, la distance au but, l'angle de tir, etc., l'Expected Goal $xG(o_i)$ d'une occasion de but o_i est défini comme suit :

$$xG(o_i) = P(goal(o_i))$$

où $goal(o_i)$ est l'événement réalisé si le but est marqué lors l'occasion de but o_i .

Les modèles d'*expected goal* sont importants car ils constituent un prédicteur précis des performances futures des équipes et des joueurs. Au niveau de l'équipe, ces modèles permettent de mieux prédire les performances que la différence de buts en cours ou que le nombre de tirs, comme le TSR. Les modèles d' xG sont ainsi couramment utilisés pour le football et le hockey [SPEARMAN 2018].

Historiquement les modèles d' xG ont été introduits en football en 2012 par Sam Green pour le site de statistiques Opta¹. Au football, l'entreprise StatsBomb² fournit un service de calcul de l' xG ³ parmi les plus reconnus. StatsBomb utilise de différents façons cette métrique⁴. Dans le milieu du football il s'agit d'une méthode de calcul de référence au même titre que celle fournie par Opta.

5.1.2 Utilisation de l' xG

Dans la littérature, xG peut être utilisé de plusieurs manières. La comparaison de la valeur d' xG au nombre de buts marqués peut indiquer la capacité ou la chance de marquer d'un joueur. Un joueur qui marque régulièrement plus de buts que le score xG qui lui est calculé, a probablement une capacité de tir/finition supérieure à la moyenne [ANZER et BAUER 2021].

Les modèles d' xG sont utilisés pour différentes raisons : prédire le score des matchs [TIIPPANA et al. 2020; UMAMI, D. H. GAUTAMA et H. R. HATTA 2021], mesurer l'efficacité du marquage par l'estimation de l'espérance de but [RUIZ et al. 2015], pour juger de l'efficacité des tirs au football [RATHKE 2017] ou encore pour évaluer la qualité du positionnement sans ballon, précédant les tirs pouvant mener à des buts [SPEARMAN 2018]. Les utilisations de la valeur d' xG sont nombreuses et peuvent être adaptées pour mesurer d'autres qualités, comme celle des passes, de la possession, etc. [MACDONALD 2012b; MADRERO PARDO 2020b; VAN HAAREN 2021].

1. <https://www.statsperform.com/opta/>

2. <https://statsbomb.com/>

3. <https://statsbomb.com/soccer-metrics/expected-goals-xg-explained/>

4. <https://statsbomb.com/what-we-do/soccer-data/>

xG peut donner une mesure de performance collective car il modélise les situations de tir qu'une équipe aurait pu transformer en but ($xG_{infligé}$), ainsi que les occasions qui auraient pu mener à l'encaissement d'un but ($xG_{encaisse}$). Le différentiel xG d'une équipe ($xG_{infligé} - xG_{encaisse}$) peut indiquer comment une équipe doit se comporter : une différence de buts négative mais un différentiel xG positif indiquerait qu'une équipe a eu peu de chance ou a une capacité de finition inférieure à la moyenne [ANZER et BAUER 2021].

xG peut être raffiné pour différencier les capacités d'une équipe selon les situations : jeu ouvert, coup franc, corner, *etc.* Par exemple, une équipe qui a concédé plus de buts sur coups francs que son xG sur coups francs est probablement en-dessous de la moyenne pour défendre ces coups de pied arrêtés.

Enfin, $xG_{encaisse}$ est un indicateur de la capacité de l'équipe à empêcher les occasions de but. Une équipe aura un $xG_{encaisse}$ inférieur à ce qui était prédit si elle se protège des tirs ayant une probabilité élevée d'être marqués.

5.1.3 Apprentissage de l' xG

Les modèles permettant de prédire la probabilité pour un tir de se transformer en but sont entraînés sur un historique de tirs similaires. Par exemple, pour dix tirs à une position, si sept sont transformés en but alors la valeur d' xG de la position sera de 0.7. Cette vérité terrain peut être apprise par un modèle considérant une grande variété de descripteurs, afin de prédire la valeur xG d'un tir particulier. StatsBomb et Opta utilisent jusqu'à 35 descripteurs, chacun avançant une valeur d' xG plus proche de la réalité. Ces modèles partagent une base de descripteurs qui sont l'angle ou la distance de tir par rapport au but, la position du gardien, le nombre de défenseurs exerçant une pression sur le tireur. En général, l'ajout de nouveaux descripteurs ne semble pas améliorer la qualité des modèles d' xG , mais peut être pertinent pour certains cas isolés.

Si la métrique xG indique les positions les plus favorables pour marquer un but, elle ne fournit pas d'information sur la qualité d'un tir : un tir avec une valeur xG importante peut être arrêté par le gardien ou sortir du cadre. xG donne une indication de la position dans laquelle un joueur doit se placer pour tirer afin d'augmenter ses chances de le transformer en but.

Dans l'ensemble, les résultats indiquent que, bien qu'il soit extrêmement difficile de modéliser avec précision les résultats des matchs de football, le modèle d' xG peut donner un aperçu des scores et constitue un outil d'analyse précieux [TIIPPANA et al. 2020].

5.2 Pertinence des indicateurs : approche *wrapper*

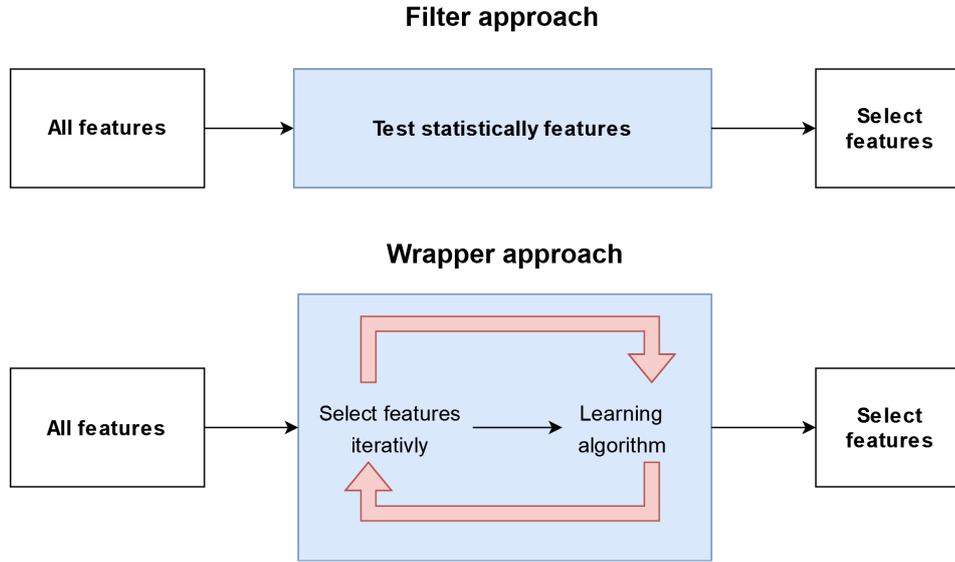
L'évaluation des indicateurs consiste à déterminer leur pertinence et leur performance pour différentes métriques. C'est le rôle de la *sélection d'attributs* : identifier les attributs les plus significatifs ou informatifs parmi un grand ensemble de variables disponibles. Cette étape est essentielle pour simplifier les modèles, réduire la dimensionnalité des données et améliorer l'efficacité de l'apprentissage en éliminant les attributs redondants ou peu pertinents.

En sélection d'attributs, trois approches fondamentales se distinguent : l'approche *filtre* [GERMANO 1992], l'approche *embedded* [TIBSHIRANI 1996], et l'approche *wrapper* [KOHAVI et JOHN 1998]. Chacune propose une manière différente de sélectionner les indicateurs les plus pertinents pour une tâche donnée. Alors que l'approche *filtre* se concentre sur des critères statistiques indépendants du modèle d'apprentissage, l'approche *embedded* intègre la sélection des attributs dans le processus d'apprentissage lui-même. Enfin, l'approche *wrapper* utilise l'apprentissage automatique pour déterminer la pertinence des attributs à l'aune d'une métrique de performance.

L'approche *filtre* évalue chaque attribut individuellement selon des critères statistiques, sans considérer le modèle de prédiction ultérieur. Elle est rapide et peu coûteuse en calcul, mais peut ne pas capturer les interactions entre les attributs. L'approche *embedded* intègre la sélection d'attributs dans le processus d'apprentissage du modèle lui-même, compromis entre efficacité et précision.

Nous avons opté pour l'approche *wrapper*. Cette décision découle de notre besoin d'évaluer non seulement les mesures elles-mêmes, mais également leur pertinence dans le contexte de nos contributions (voir chapitres 7, 8, 9 et 11). L'approche *wrapper* évalue chaque configuration d'indicateurs en mesurant leur performance d'apprentissage. La Figure 5.1 schématise les différences entre les approches *filtre* et *wrapper*.

L'approche *wrapper* favorise le contexte en évaluant les attributs dans le cadre de l'apprentissage des données, ce qui est donc *piloté par la tâche*. Bien que coûteuse en répétition d'apprentissage de modèles, l'approche *wrapper* montre des applications pour la détection d'intrusions [REKIK et BEN HAMADOU 2018], la prédiction de match de football [SARTI et D'AGOSTINO 2019], pour identifier les caractéristiques les plus pertinentes dans un ensemble de données de capteurs [LEONTIDIS et CONSTANTINO 2016] ou encore pour identifier les caractéristiques les plus influentes pour la prise de décision lors de la constitution d'équipes de basketball [Y. ZHANG et Y. LIU 2019].

FIGURE 5.1 – Approche *wrapper*.

Rapport entre corrélation et MSE

L'approche *wrapper* nécessite l'emploi d'un algorithme d'apprentissage et nous utilisons fréquemment des réseaux de neurones. Ces réseaux sont évalués/guidés par une *Mean Square Error* (MSE). La question se pose alors de l'adéquation de la MSE des réseaux de neurones pour mesurer la corrélation entre indicateurs et métrique de performance.

Cette corrélation est traditionnellement mesurée par le coefficient de corrélation de Pearson, qui évalue la relation linéaire entre deux variables non temporelles. Cependant, pour les variables temporelles, des méthodes telles que la corrélation croisée sont souvent plus appropriées [FACULTY 2023].

Lors de l'entraînement d'un réseau de neurones, le coefficient de Pearson possède les qualités nécessaires pour être utilisé comme fonction de perte, mais il est plus courant d'utiliser la Mean Squared Error (MSE). Bien que la corrélation et la MSE mesurent différents aspects de la performance d'un modèle, leur utilisation conjointe peut être complémentaire. Par exemple, un réseau de neurones récurrents (RNN) peut être entraîné avec la MSE pour minimiser l'erreur de prédiction tout en surveillant la corrélation de Pearson pour évaluer la pertinence des prédictions [STHDA 2023].

5.3 *Machine learning* et mécanisme de l'attention

Nous employons ici le terme de *machine learning*, comme référence aux méthodes récentes d'apprentissage de modèles, de la régression logistique aux RNN. Pour ne pas surcharger la lecture de ce chapitre, l'annexe A recense les modèles que nous avons utilisés au cours de notre travail.

Cette section est plutôt dédiée à l'approfondissement du mécanisme de l'attention, spécifique aux réseaux de neurones récurrents. Une utilisation de ce mécanisme, menant à des détections de tactiques, sera proposée dans le chapitre 11.

L'article [VASWANI et al. 2017] introduit une nouvelle architecture de réseau de neurones reposant entièrement sur le *mécanisme d'attention*. Dans ce contexte, l'attention fait référence à la capacité du modèle à se concentrer sur des parties spécifiques de l'entrée lors de l'exécution de tâches telles que la traduction automatique ou la génération de texte. Le mécanisme d'attention permet au modèle de donner plus de poids à certaines parties de la séquence d'entrée, en fonction de leur pertinence pour la prédiction en cours. Contrairement aux modèles précédents qui utilisaient des réseaux récurrents ou des convolutions pour traiter les séquences, l'attention considère simultanément toutes les positions de la séquence.

L'attention utilise les similarités entre les différents éléments de la séquence d'entrée, donnant ainsi plus d'importance aux éléments les plus pertinents pour l'apprentissage en cours. Calculées par produits scalaires, les similarités sont l'objet d'une normalisation *softmax* pour la transformation en probabilité, qui pondère l'importance de l'éléments pour la décision finale.

Les données spatiales, temporelles et spatio-temporelles présentent des défis uniques en matière de modélisation et d'analyse. L'utilisation de la couche d'attention dans les réseaux neuronaux offre une approche prometteuse en analysant l'importance accordée par le modèle aux données d'entrée. Pour la reconnaissance d'entités nommées dans des rapports radiologiques, l'attention temporelle est montrée comme étant capable de capturer les informations les plus pertinentes [N. MEHTA et al. 2019]. La prédiction des flux de foule à l'échelle de la ville [H. YAO et al. 2018] utilise l'attention dans sa capacité à capturer les dépendances spatiales et temporelles complexes entre les différentes régions et les moments dans le temps, améliorant ainsi la précision des prédictions. De même pour l'anticipation des trajectoires de véhicules autonomes, qui exploite les motifs spatiaux et temporels importants dans les données de trajectoire [K. WANG et al. 2020].

Utiliser des RNN avec attention pour apprendre des modèles à partir de trajectoires est une tâche naturelle pour les données chronologiques issues des activités sportives. En particulier, dans le domaine du sport, on trouve de nombreuses approches proposant des modèles pour prédire ou compléter des trajectoires [HAURI et al. 2021 ; MONTI et al. 2021 ; VICTOR et al. 2021 ; ZHAO et al. 2018], modéliser les séquences pour prédire l’issue d’un événement (par exemple un tir au basket [SHAH et ROMIJNDERS 2016]) ou l’issue d’un match [Q. ZHANG et al. 2022]. L’attention favorise la prédiction de mouvement [Y. TANG et al. 2018] ou aide à détecter une similarité entre mouvements [MAO, M. LIU et SALZMANN 2020].

Cet usage de l’attention contribue au design du modèle à apprendre, une tâche classique de l’apprentissage automatique. Cependant, au chapitre 11, nous *interprétons l’attention pour analyser les situations sportives*. Cette démarche, que l’on trouve également dans [ZIYI et al. 2023] pour identifier des portions pertinentes de trajectoires ou comprendre les différences entre des classes et déterminer des corrélations entre les variables et des labels, est peu usuelle dans la littérature.

Attention et explication

Les mécanismes de l’attention dans les réseaux récurrents sont reconnus pour leur capacité à enrichir la contextualisation d’un décodeur, en apprenant une voie complémentaire de dépendance temporelle. L’un des objectifs de notre travail est de montrer que l’analyse des poids d’attention offre une perspective stratégique pour l’étude de matchs de DotA2 (*cf.* chapitre 11).

L’interprétation du mécanisme de l’attention pour obtenir des explications aux décisions prises par le modèle fait débat. Le lecteur intéressé pourra se référer à [BIBAL et al. 2022] qui procure une large synthèse sur le sujet. Ainsi, l’attention ne fournirait pas d’explication et l’utilisation de Total Variation Distance (TVD), de Jensen-Shannon Divergence (JSD) ou de la divergence de Kullback Leibler devrait être préférée [JAIN et WALLACE 2019] car l’attention n’est pas corrélée à des mesures d’importance des attributs fondées sur le gradient, plus traditionnelles [Y. WANG et al. 2024]. Des expérimentations montrent que mélanger les poids d’attention n’affecte pas la décision finale. Cette déclaration est nuancée par [WIEGREFFE et PINTER 2019] qui indique que l’attention fournit *une* explication, mais pas *la seule*. L’utilisation de l’attention sous forme de flux pourrait également conduire à l’émergence d’explications [ABNAR et ZUIDEMA 2020].

5.4 Conclusion

La conception de mesure d'intérêt et l'évaluation de leur pertinence sont des étapes critiques dans l'analyse et la compréhension des situations de jeu. Ce chapitre a introduit l'Expected Goal, qui quantifie les chances de marquer dans une situation de jeu. Nous avons exploré non seulement son utilisation directe mais aussi les méthodes d'apprentissage pour estimer l' xG . L'utilisation et l'apprentissage de l' xG démontrent l'importance de cette mesure pour l'analyse du jeu et comment elle peut être utilisée pour prendre des décisions tactiques et stratégiques. Même si la littérature réserve pour l'instant l' xG au football, notre contribution du chapitre 8 explore un domaine d'application original : le handball.

DEUXIÈME PARTIE

Traitement de la trajectoire

Les trajectoires, qu'elles soient réelles pour un sportif ou virtuelles pour un avatar, renferment des informations fondamentales sur les dynamiques collectives et individuelles. Dans le cadre de notre étude sur les trajectoires au handball et dans les jeux vidéo, nous nous intéressons à la manière dont les mouvements des joueurs peuvent être modélisés et analysés pour prédire des moments clés du jeu. Pour mieux appréhender ces trajectoires, nous adoptons deux approches : la représentation des actions sous forme de graphes dynamiques et la transformation des trajectoires individuelles en indices géométriques collectifs.

Les deux chapitres suivants s'articulent autour de ces deux axes de recherche. Dans le chapitre 6, nous proposons une méthode pour représenter le handball sous forme de graphe dynamique. Cette approche permet de capturer les interactions complexes entre les joueurs et de modéliser les évolutions tactiques au cours du jeu. Nous verrons lors d'une contribution sur la tactique, au chapitre 10, que des graphes dynamiques sont utiles pour analyser les motifs récurrents et identifier les configurations de jeu associées aux moments importants, tels que les opportunités de marquer un but ou les situations critiques de défense. Pour l'instant, nous détaillons la modélisation des interactions entre les joueurs de handball à l'aide de graphes dynamiques. Nous expliquons comment les positions des joueurs et leurs interactions peuvent être traduites en nœuds et arêtes évoluant au fil du temps. Cette représentation permet de visualiser et d'analyser les structures de jeu, offrant une perspective nouvelle sur les stratégies collectives et les transitions entre phases de jeu.

Le chapitre 7 se concentre sur la transformation des trajectoires individuelles des avatars en indices géométriques collectifs. Cette transformation vise à extraire des caractéristiques globales à partir des mouvements des joueurs afin de prédire les moments importants du match. En combinant les informations géométriques avec des techniques d'apprentissage automatique, des modèles sont capables de détecter les instants clés et d'anticiper les actions décisives. Ce chapitre explore la manière dont les trajectoires individuelles des joueurs peuvent être synthétisées en indices géométriques collectifs, une étape cruciale vers l'identification de patterns spécifiques corrélés avec des moments cruciaux du jeu (voir chapitre 11).

Ensemble, ces deux chapitres visent à offrir une compréhension approfondie des dynamiques de jeu collectif et à fournir des outils innovants pour l'analyse et la prédiction des moments importants. Ces contributions peuvent avoir des applications pratiques dans l'entraînement sportif, la stratégie de jeu, et le développement de systèmes intelligents

pour les jeux vidéo.

CONCEPTION DE GRAPHES DYNAMIQUES POUR LE HANDBALL

Dans le domaine de l'analyse de la tactique sportive, le traitement des trajectoires des joueurs et la représentation des situations de jeu revêtent une importance capitale pour déchiffrer les schémas de jeu et les interactions sur le terrain.

Ce chapitre se concentre sur la représentation des interactions entre joueurs de handball par des graphes dynamiques, menant à la définition de schémas tactiques. Nous débutons par une discussion sur l'importance de la transformation des trajectoires en graphes puis rappelons les éléments relatifs à la triangulation de Delaunay et l'encodage de graphes dynamiques par différentiel d'événements.

Notre contribution concerne la définition d'une *transformation gnomonique* de l'espace de jeu, transformant les cercles en droites. Nous montrons que cette transformation caractérise des zones d'influence pertinentes, qui rendent compte de la spécificité du handball.

6.1 Position

Nous avons choisi d'utiliser les techniques des graphes dynamiques pour résoudre notre problème de recherche de mouvements tactiques, à travers les occurrences de séquences d'actions particulières. Les graphes dynamiques permettent de traiter les aspects collectifs de la pratique sportive, car la flexibilité induite par la structure du graphe permet de prendre en compte, outre les joueurs, des sommets particuliers tels que le ballon, les zones, et différents types d'arêtes. Les graphes dynamiques offrent un cadre fécond pour le développement d'algorithmes permettant de détecter des correspondances entre des combinaisons typiques et des situations réelles.

L'accent mis sur les graphes dynamiques est original. Même en football, où il existe de nombreuses études sur l'entraînement des joueurs, en termes d'organisation spatiale, l'état de l'art souligne qu'aucune méthode n'analyse en temps réel la dynamique des tactiques.

La plupart du temps, ce sont des *simples* agrégations sur le temps de possession qui sont analysées.

L'emploi des graphes dynamiques pour analyser le handball est particulièrement pertinent pour plusieurs raisons. Les acteurs du handball sont des entités individuelles : joueurs, ballon, éventuellement des zones spécifiques du terrain. Chaque entité peut être représentée comme un sommet dans un graphe. Les entités entretiennent des relations spécifiques : attaquant/défenseur, relations entre partenaires, possession du ballon. Contrairement à certains autres sports collectifs comme le volley où les relations individuelles entre joueurs sont moins significatives, les relations entre entités au handball sont fondamentales. Un graphe offre la sémantique nécessaire pour la modélisation de ces interactions. Des techniques de recherche de régularités dans des graphes dynamiques existent et peuvent être appliquées pour identifier des schémas tactiques récurrents.

En intégrant les graphes dynamiques, nous pouvons non seulement représenter les positions et les mouvements des joueurs, mais aussi capturer la temporalité des interactions. Cette approche nous permet d'aller au-delà des *simples* statistiques, ouvrant la voie à des analyses sophistiquées, optimisées pour le jeu.

L'approche d'analyse automatique de trajectoires à la recherche de tactiques est complémentaire à l'expertise de l'entraîneur. Les techniques mises en œuvre ici sont *agnostiques* en ce qu'elles ne font pas de présupposition sur l'activité. L'analyse est objective : les trajectoires sont transformées en graphes dynamiques au sein desquels sera appliquée une démarche exploratoire de recherche de régularités (chapitre 10).

6.2 Graphes dynamiques pour le handball

Cette section formalise la modélisation en graphes dynamiques des interactions au handball, en mettant en avant la triangulation de Delaunay et l'encodage par notation d'événements.

6.2.1 Transformation des trajectoires en graphes

La transformation des données en graphes dynamiques requiert d'abord de choisir quelles sont les entités représentées par les sommets et quelles sont les relations entre ces entités, qui seront représentées par les arêtes. Les entités du handball sont naturellement les joueurs et la balle.

Entités - sommets Chaque joueur peut être considéré individuellement ou selon le poste qu’il occupe. Dans le premier cas, une tactique sera personnalisée par un joueur spécifique et l’on pourra constater des tactiques différentes selon les joueurs. Dans le second cas, il ne sera pas tenu compte de l’individu mais de son poste, considérant qu’un mouvement collectif implique des rôles et non des personnes spécifiques.

La balle, comme entité spécifique, peut donner lieu à un son propre sommet dans le graphe. On peut autrement considérer que les entités joueurs possèdent un attribut particulier qui indique la possession de la balle. Nous avons fait le choix d’attribuer un sommet à la balle.

Relations - Arêtes La sémantique des arêtes offre plusieurs choix : définir le voisinage de chaque joueur, considérer les postes, valoriser les positions relatives en attaque/défense, etc..

Pourtant, il serait préférable que la transformation en graphe soit non paramétrique et agnostique. Nous recommandons donc d’utiliser la triangulation de Delaunay (voir section 3.3.4).

6.2.2 Encodage par différentiel d’événements

Le choix de la triangulation de Delaunay pour générer les arêtes de nos graphes dynamiques implique qu’il y aura peu de changements d’un snapshot à l’autre. Par exemple, l’aillier attaquant sera en relation avec l’aillier défenseur tant qu’il n’y aura pas de modification de leur zone d’influence. Ainsi, lors de la recherche de régularités, la relation entre les deux ailiers apparaîtrait, ce qui est peu souhaitable car peu porteur d’information.

Pour encoder le graphe dynamique, nous faisons donc le choix du *différentiel* d’événements. À chaque instant t , nous examinons les changements dans la triangulation de Delaunay relativement à $t - 1$: nous notons quelle arête apparaît ou disparaît. Ainsi, les arêtes persistantes sont ignorées.

Plutôt que $(G_t)_{t=1..T}$, nous considérons donc le graphe dynamique *différentiel* (*difference graph* en anglais dans [NEIGER, CRESPELLE et FLEURY 2012]) $(\Delta G_t)_{t=2..T} = (V_t, E_{t-1} \setminus E_t, E_t \setminus E_{t-1})_{t=2..T}$ où $E_{t-1} \setminus E_t$ est l’ensemble des arêtes qui disparaissent et $E_t \setminus E_{t-1}$ celles qui apparaissent, au passage de $t - 1$ à t . La figure 6.1 fournit un exemple de deux snapshots G_{t-1} et G_t avec leurs ensembles d’arêtes E_{t-1} (Figure 6.1a) et E_t (Figure 6.1b); leur différence $E_{t-1} \setminus E_t$ est à la figure 6.1c.

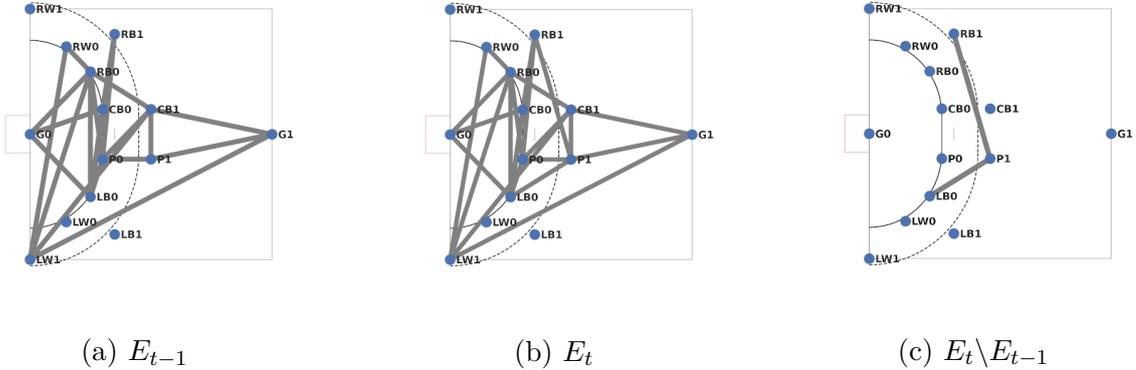


FIGURE 6.1 – Graphe différentiel.

Soit $E(t, e_{i,j})$ une fonction qui indique l'événement associé à l'arête $e_{i,j}$ au temps t . De même, $E(t, v_k)$ représente l'événement associé au sommet v_k au temps t . Ces événements peuvent être définis comme suit :

$$E(t, e_{i,j}) = \begin{cases} 1 & \text{si } e_{i,j} \text{ apparaît au temps } t \\ 0 & \text{si } e_{i,j} \text{ disparaît au temps } t \end{cases}$$

$$E(t, v_k) = \begin{cases} 1 & \text{si } v_k \text{ apparaît au temps } t \\ 0 & \text{si } v_k \text{ disparaît au temps } t \end{cases}$$

L'encodage par différentiel d'événements offre une granularité fine pour capturer les changements dans la structure du graphe dynamique. En contexte sportif, où les interactions entre joueurs évoluent rapidement, cette approche permet de représenter de manière concise les instants où de nouvelles connexions se forment ou se dissipent. L'analyse des moments clés du match, tels que la formation de nouvelles tactiques ou la rupture de l'équipe adverse, en est facilitée. Le différentiel d'événement supprime les arêtes stationnaires, qui généreraient une grande quantité de motifs fréquents inintéressants.

Finalement, comme nos données concernent plusieurs matchs, ayant chacun deux mi-temps voire des prolongations, des arrêts de jeu, *etc.*, nous aurons à gérer une *base de graphes dynamiques*. Plus précisément, nous considérerons disposer d'un graphe dynamique pour chaque série de *cinq* passes précédant un tir. Ce choix est justifié par la volonté de déterminer les tactiques appliquées à l'approche du tir et correspond au rythme du mouvement collectif dans le handball.

6.3 Graphes dynamiques / séquence d'ensemble d'arêtes

Au chapitre 10, nous présentons la réalisation d'un observatoire de la tactique au handball, valorisant des sous-graphes dynamiques fréquents extraits dans nos données. Le chapitre 4 a montré que l'extraction de telles régularités dans les graphes dynamiques était complexe, entre autres pour les phases de matching, nécessitant des isomorphismes de graphes.

Certes, les graphes que nous manipulons sont *petits*, mais nous préférons les considérer comme des *ensembles d'arrêtes* : les graphes dynamiques sont des séquences d'ensembles d'arrêtes.

Cette considération nous donne accès à de nombreux algorithmes d'extraction dans les séquences [FOURNIER-VIGER, J. C.-W. LIN, GOMARIZ et al. 2016]. Certains proposent l'utilisation de contraintes temporelles (gap, size), et se focalisent sur les motifs fermés [FOURNIER-VIGER, NKAMBOU et NGUIFO 2008].

6.4 Transformation du terrain

Un terrain de handball a une topographie atypique : la zone est arrondie et les défenseurs se placent autour pour faire mur devant le but. Cette zone est interdite d'accès, contrairement au football ou au basket-ball par exemple. Emprunter la ligne droite entre deux points n'est pas toujours possible : il faut contourner la zone interdite. Cette interdiction modifie les rapports spatiaux entre les joueurs.

L'objectif d'un diagramme de Voronoï est de rendre compte de l'influence des joueurs sur le terrain, mais la géométrie classique utilisée dans ce but ne tient pas compte de la particularité de la topographie du terrain de handball. Dans l'optique de mieux prendre en compte les rapports spatiaux entre les joueurs, nous proposons de *transformer* le terrain initial (figure 6.2a) en *décourbant* la zone selon une transformation *gnomonique*, de façon à y faire apparaître une géométrie où la ligne droite est le plus court chemin entre deux points (voir figure 6.2b). Le diagramme de Voronoï est alors calculé dans cette transformation. Ensuite, la *transformation inverse* est appliquée, pour obtenir le diagramme de Voronoï pour le terrain initial avec *recourbure* de la zone (voir figure 6.2c). Une interface de visualisation ¹ a été développée pour explorer cette transformation.

1. <https://morteli211.users.greyc.fr/handball/>

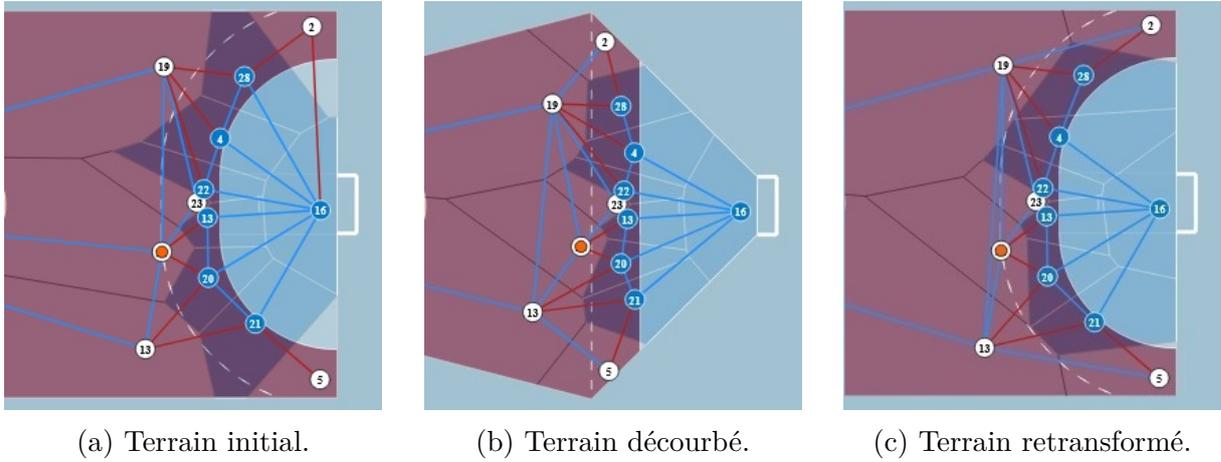


FIGURE 6.2 – Diagramme de Voronoï et triangulation de Delaunay pour les transformations successives du terrain.

6.4.1 Détails de la transformation

Soit M de coordonnées (x, y) . Soit O le centre du quart de cercle de la zone. Soit $r = OM$ et θ l'angle (Ox, OM) (voir Figure 6.3).

La transformation du terrain, qui fait que le quart de cercle de zone devient un segment, a pour équation :

$$\begin{cases} x' = r \\ y' = r \cdot \frac{\theta}{\frac{\pi}{2}} \end{cases} \quad (6.1)$$

Les courbes de niveau présentées à la Figure 6.4 sur le terrain transformé correspondent aux lignes d'abscisse constante sur le terrain décourbé. Ces courbes indiquent les points du terrain où la déformation a provoqué un changement de forme.

6.4.2 Validation de la transformation de terrain

Afin de déterminer l'impact de la transformation de terrain (décourbure puis recourbure), nous comptons les différentiels d'arêtes entre le graphe initial et le graphe transformé. Pour cela, nous avons agrégé chaque situation de jeu selon le poste du joueur : Goalkeeper (G), Left Wing (LW), Right Wing (RW), Center Back (CB), Left Back (LB), Right Back (RB), Pivot (P). L'équipe qui défend est notée 0 et l'équipe qui attaque est notée 1. Par exemple, CB0 indique l'arrière centre en position de défense.

Les tableaux 6.1 et 6.2 indiquent les résultats de comptage, tandis que les figures

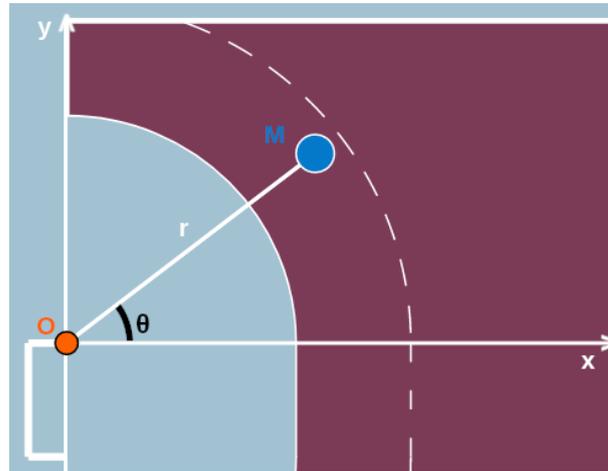


FIGURE 6.3 – Représentation d'un quart de terrain

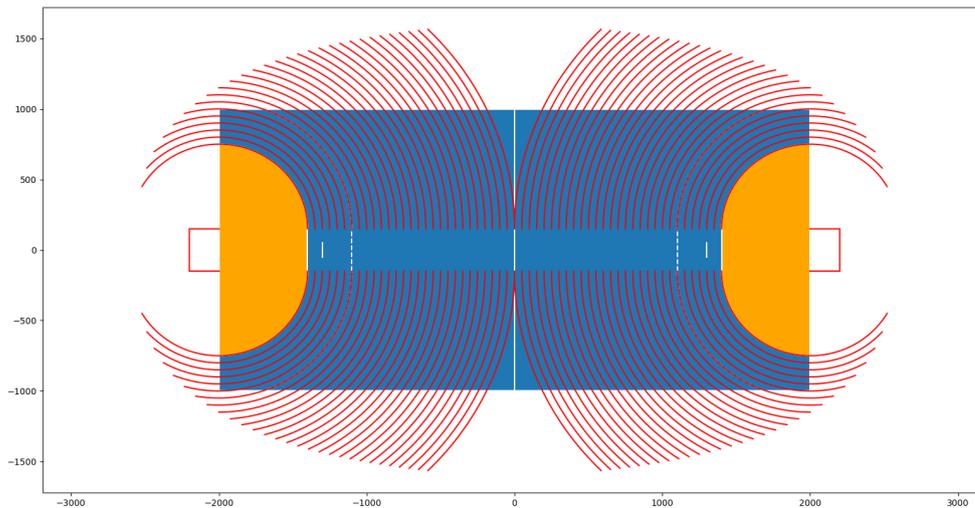


FIGURE 6.4 – Courbe de niveaux.

6.5a et 6.5b donnent une interprétation quantitative. L'analyse comparative des graphes dynamiques générés à partir du jeu de données du Qatar révèle des différences significatives entre les deux approches de modélisation.

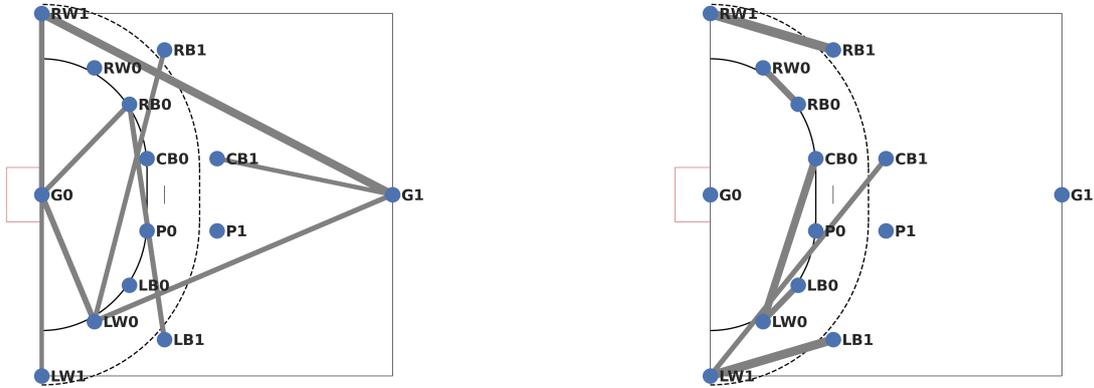
Dans un premier temps, on observe que les arêtes supprimées par notre transformation (présentes dans le graphe initial et absentes du graphe transformé, voir Figure 6.5a) sont peu utiles pour la compréhension du handball. Il s'agit par exemple des liens entre le gardien et ses défenseurs (G0-RB0 et G0-LW0), ou des liens entre le gardien et ses

edges	initial	intersection	initial \ transformé	ratio
(G0, RW1)	1120	192	928	82,86%
(RW0, G1)	1106	216	890	80,47%
(RW1, G0)	1114	357	757	67,95%
(G1, RW1)	3321	1930	1391	41,88%
(RW0, G0)	3993	2999	994	24,89%
(RW0, RB1)	3707	2869	838	22,61%
(CB1, RB0)	5247	4370	877	16,71%
(G1, CB1)	6045	5258	787	13,02%
(RB0, G0)	6850	5975	875	12,77%
(RW1, CB1)	2279	2213	66	2,90%
(RB1, RW1)	2510	2444	66	2,63%
(RW0, CB0)	3230	3153	77	2,38%
(RW0, CB0)	3146	3080	66	2,10%
(RW1, CB1)	3305	3237	68	2,06%
(RB0, RW0)	2064	2034	30	1,45%

TABLE 6.1 – Arêtes perdues par déformation de terrain.

edges	transformé	intersection	transformé \ initial	ratio
(RB1, RW1)	3968	2444	1524	38,41%
(RB0, RW0)	3081	2034	1047	33,98%
(LW1, LB1)	4659	3237	1422	30,52%
(LW0, CB0)	4285	3080	1205	28,12%
(LW1, CB1)	3025	2213	812	26,84%
(LW0, LB0)	4113	3153	960	23,34%
(LW0, RB1)	3255	2869	386	11,86%
(G1, RW1)	2114	1930	184	8,70%
(LW0, G0)	3256	2999	257	7,89%
(LB1, RB0)	4679	4370	309	6,60%
(RB0, G0)	6208	5975	233	3,75%
(LW0, G1)	222	216	6	2,70%
(G1, CB1)	5394	5258	136	2,52%
(LW1, G0)	363	357	6	1,65%
(G0, RW1)	194	192	2	1,03%

TABLE 6.2 – Arêtes gagnées par déformation de terrain.



(a) Arêtes présentes dans le graphe initial mais absentes du graphe déformé.

(b) Arêtes présentes dans le graphe déformé mais absentes du graphe initial.

FIGURE 6.5 – Différenciation des arêtes perdues et gagnées avec la déformation.

attaquants (G1-RW1 et G1-CB1).

La transformation de terrain fait également apparaître des arêtes dans le graphe transformé, qui sont absentes du graphe initial (voir Figure 6.5b). Ces arêtes concernent par exemple les rapports entre ailiers et arrières, mieux prises en compte par la transformation.

Cette nouvelle façon de calculer le diagramme de Voronoï et le graphe de Delaunay permet de mieux appréhender la sémantique du jeu de handball en préservant les relations naturelles entre les joueurs. D'après les experts, elle offre une vision du contrôle du terrain plus proche de la réalité.

6.5 Conclusion

La représentation du handball que nous avons proposée ici donne naissance à une base de graphes dynamiques différentiels qu'il est possible d'explorer à l'aide d'algorithmes dédiés à des séquences de motifs.

La granularité fine de l'encodage par différentiel d'événements offre une vision concise des changements dans la structure du jeu, facilitant ainsi l'identification des moments clés et des tactiques employées. De plus, la transformation du terrain selon une approche gnomonique constitue une contribution significative, car elle prend en compte la topo-

graphie spécifique du terrain de handball. En ajustant la représentation du terrain pour refléter la réalité du jeu, cette transformation améliore la précision et la pertinence de la modélisation des interactions entre les joueurs.

Ce chapitre a fait l'objet d'une publication à ISACE 2024 [MORTELIER, RIOULT et KOMAR 2024].

INDICES TACTICO-GÉOMÉTRIQUES POUR DotA2

Au sein de la deuxième partie de ce travail de thèse, consacrée au traitement de la trajectoire en (e-)sport collectif, ce chapitre s'interroge, dans le cadre du jeu vidéo compétitif, sur l'appréhension du caractère collectif de la pratique à travers les trajectoires dans le cadre du jeu vidéo compétitif.

Notre ambition n'est pas d'optimiser la prédiction de la dynamique du match, mais plutôt d'envisager une transformation des trajectoires, considérant le caractère collectif de la pratique, puis de comparer les performances de cette transformation avec celle des trajectoires.

Nous introduisons ici une représentation géométrique du comportement de chaque équipe dans le jeu d'équipe DotA2. Les indices géométriques que nous considérons ici sont une série de mesures du *polygone défini par l'enveloppe convexe (ou minimale) des positions des avatars*, appelé simplement *polygone des joueurs* dans la suite.

L'objectif de ce chapitre est de montrer que les indices géométriques du polygone sont aussi pertinents pour apprécier l'évolution de la dynamique d'une partie que d'utiliser l'ensemble des trajectoires. La pertinence de ces indices sera utile au cours du chapitre 11, où nous analyserons, pour caractériser les tactiques intéressantes, les poids d'attention conférée par un réseau de neurones récurrent.

Pour montrer la pertinence des indices géométriques, nous utilisons une approche *wrapper* de sélection de variables, qui mesure la contribution de chaque attribut au modèle prédictif. Nous montrons que l'apprentissage du modèle sur les indices géométriques est aussi sinon plus performant que sur les simples trajectoires : les indices géométriques sont informatifs pour l'analyse de la dynamique dans DotA2.

7.1 Position

Par rapport à d'autres travaux dans ce domaine, notre proposition présente deux originalités. Tout d'abord, nous avons centré notre étude sur le caractère *collectif* de la pratique d'un MOBA (voir Section 2.2.1 page 11), car il s'agit fondamentalement d'un jeu d'équipe mettant en avant les actions de groupe plutôt que les actions individuelles [KATONA et al. 2019].

À la recherche d'indices simples à calculer et à exploiter, nous ne souhaitons pas focaliser notre attention sur les comportements et les caractéristiques individuelles (équipement, arbre de compétences). Nous pensons que l'organisation spatiale des joueurs est déterminante pour l'analyse des performances dans ces jeux et il n'est pas nécessaire d'examiner tous les détails d'un jeu pour en caractériser les moments importants.

Nous choisissons d'étudier les caractéristiques géométriques du *polygone* dérivé de l'enveloppe convexe des positions des joueurs d'une même équipe. La pertinence de ces caractéristiques est mesurée par une approche *wrapper* (voir Section 5.2 page 40) : la pertinence d'un descripteur est mesurée par sa contribution au modèle de classification ou de régression.

La cible de notre modèle est une métrique d'intérêt pour chaque équipe : le nombre de héros vivants dans l'équipe adverse. Cette métrique est indicatrice de la performance instantanée. Ce choix est discuté à la section 7.3.

7.2 Indices géométriques dans DotA2

DotA2 est un jeu d'équipe où les mouvements coordonnés et synchronisés sont primordiaux, indépendamment du comportement individuel. Nous pensons (comme [DEJA et MYŚLAK 2015]) que les indices géométriques des trajectoires des joueurs suffisent à la compréhension de la dynamique.

Notre méthode consiste donc à comparer la pertinence de deux types d'indices, *géométriques* ou *positionnels* : (i) les caractéristiques du polygone des joueurs [RIOULT et al. 2014] ou (ii) les trajectoires individuelles. Les indices des trajectoires sont les coordonnées en deux dimensions des positions de chaque avatar.

Pour le polygone défini par l'enveloppe convexe des positions des avatars, répartis en équipes, nous avons calculé les attributs suivants pour chaque seconde de jeu (voir figure 7.1 pour une illustration et figure 7.2 pour une représentation temporelle) :

- la surface du polygone (*area* sur la figure 7.2) ;
- le diamètre : la distance maximale entre deux points du polygone (*diameter* sur la figure 7.2) ;
- la *dispersion géométrique* : moyenne des distances au barycentre, dispersion au sens de l'étalement spatial des avatars (*dispersion* sur la figure 7.2) ;
- l'*inertie* : moment du second ordre des distances au barycentre (*inertia* sur la figure 7.2) ;
- la distance entre le barycentre et la forteresse allié (*friend* sur la figure 7.2) ;
- la distance entre le barycentre et la forteresse adverse (*foe* sur la figure 7.2).

Notons que les deux premiers moments des distances constituent une bonne approximation de leur distribution.

La figure 7.2 montre l'interface que nous avons utilisée¹ pour visualiser nos données. Cette interface représente l'évolution des indices géométriques, visualise les polygones et leur barycentre sur la carte du jeu.

Nous avons souhaité ne travailler que sur des données provenant de parties jouées par des professionnels de l'e-sport, regroupés en équipes renommées. La coordination de groupe étant primordiale dans DotA2, il nous semblait préférable d'étudier des matchs réalisés par des joueurs qui ont l'habitude de jouer ensemble et de produire un haut niveau de performance. Cette position est originale dans la littérature [KATONA et al. 2019 ; MORA-CANTALLOPS et SICILIA 2018]. Afin de privilégier la qualité à la quantité, nous n'avons pas souhaité étudier des millions voire des milliards de parties [DEJA et MYŚLAK 2015]. En effet, l'appariement des joueurs occasionnels est basé sur leur espérance de gain, ce qui conduit à la constitution d'équipes équilibrées ; il est très fréquent que ces matchs opposent deux joueurs extrêmement performants, accompagnés de joueurs peu aguerris. Dans ce cas, la performance collective est médiocre.

7.3 Approche *Wrapper* avec RNN

Pour comparer les deux types d'indices, géométriques ou positionnels, nous avons utilisé une approche *wrapper* qui évalue la pertinence d'un indice selon sa capacité à améliorer la qualité de l'apprentissage.

La figure 7.3 présente un schéma de notre approche. L'algorithme d'apprentissage

1. https://morteli211.users.greyc.fr/dota_viz/

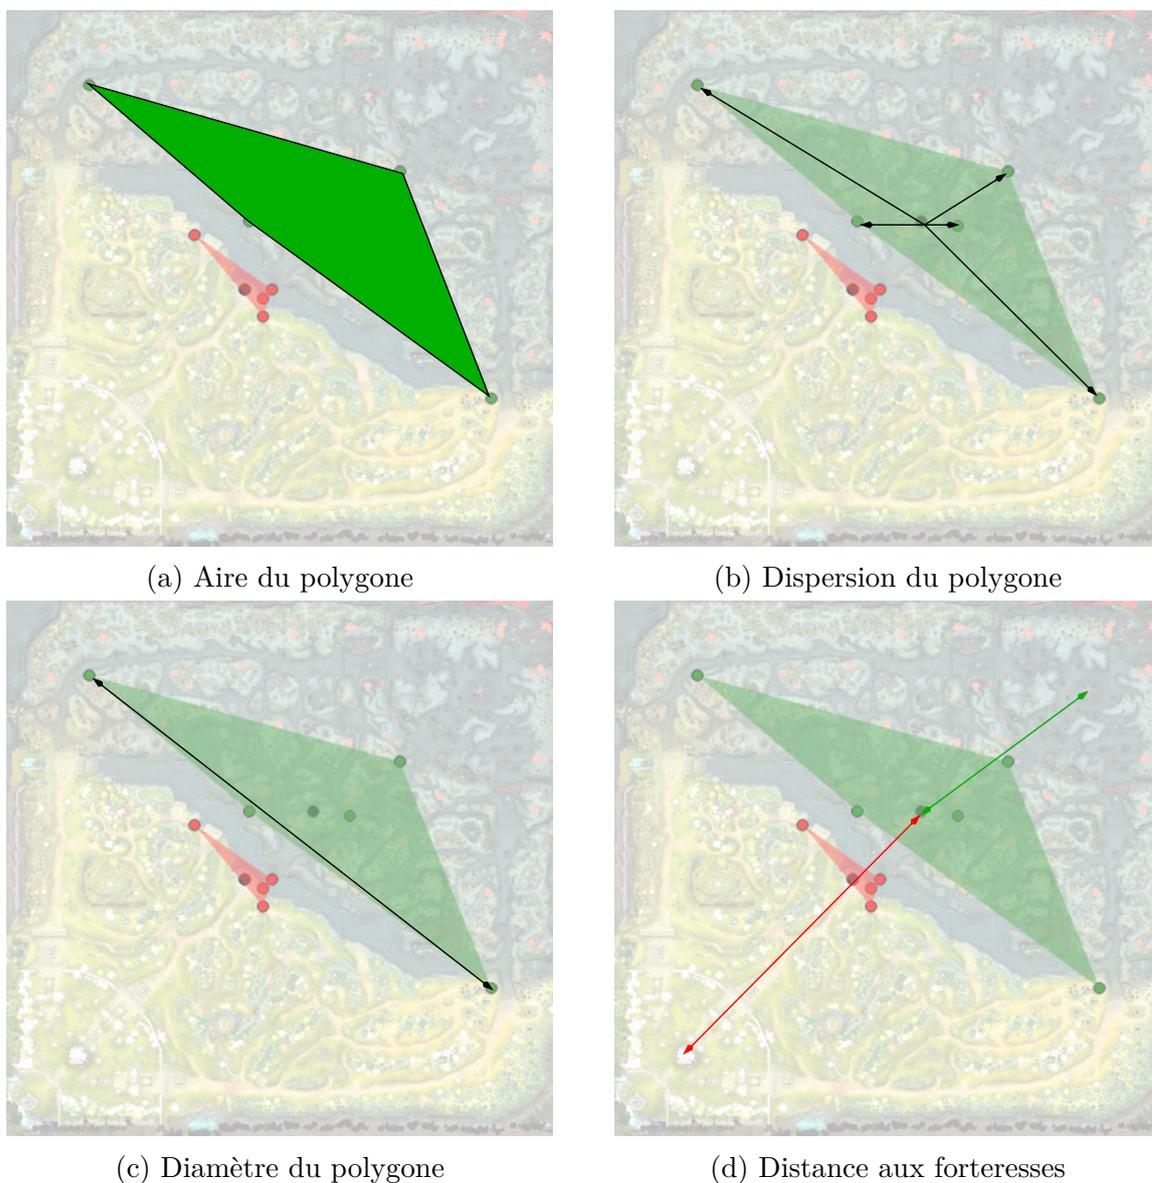


FIGURE 7.1 – Caractéristiques géométriques du polygone.

utilisé est le Long-Short Term Memory (LSTM), une architecture particulière de réseau neuronal récurrent (RNN) [SHERSTINSKY 2020]. Les RNN sont conçus pour traiter des données évoluant dans le temps : si une cellule calcule un signal de sortie à partir des entrées, elle transmet également un état caché à la cellule suivante, qui l'influence. Les cellules d'un LSTM comprennent en outre un mécanisme de mémoire/oubli qui résout le problème de l'évanouissement du gradient.

La sélection de la cible est importante dans toute modélisation prédictive, surtout

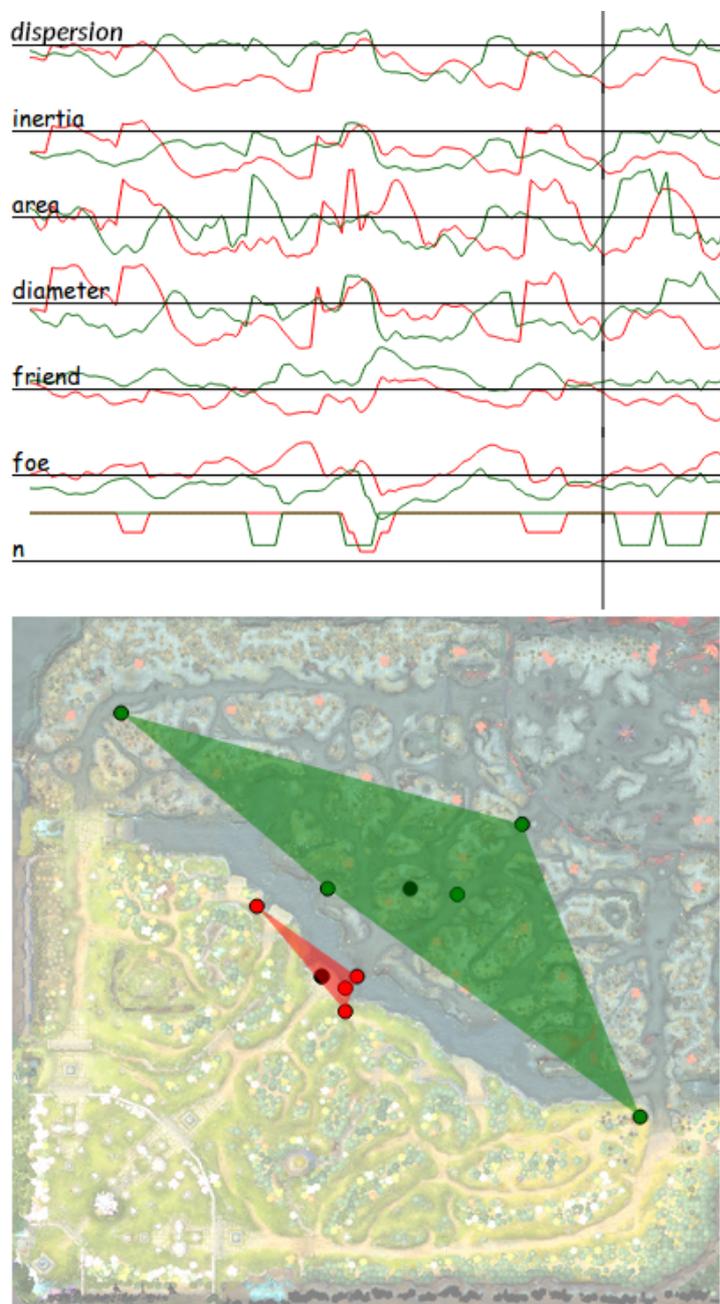


FIGURE 7.2 – Visualisation du polygone et ses caractéristiques au cours du temps.

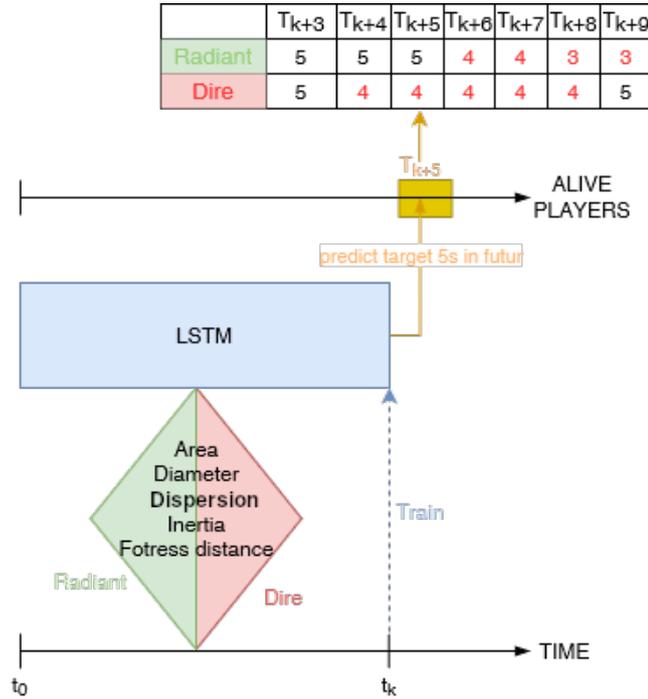


FIGURE 7.3 – Schéma d’entraînement du LSTM sur la continuité du jeu.

lorsque l’objectif *in fine* est de développer une tactique efficace. Dans le contexte de DotA2, plusieurs métriques pourraient être envisagées comme cibles d’apprentissage :

niveau d’expérience ou de richesse : ces métriques sont indicatives de la progression d’un joueur ou d’une équipe, mais elles peuvent fluctuer vivement et être influencées par de nombreux facteurs extérieurs ;

niveau total de vie : une métrique importante, mais elle peut être trop volatile pour servir de cible fiable, car elle peut varier rapidement en fonction des actions immédiates des joueurs.

Nous avons donc fait le choix du nombre de joueurs en vie comme cible. La population peut être une métrique plus stable et représentative pour plusieurs raisons :

indicateur de performance : le nombre de joueurs en vie à un moment donné est un indicateur direct de la performance de l’équipe. Plus il y a de joueurs en vie, plus l’équipe a de chances de dominer les combats d’équipe, contrôler les objectifs (comme Roshan ou les tours), et maintenir une pression sur la carte ;

impact sur la dynamique global : le fait d’avoir plus de joueurs en vie permet un meilleur contrôle du territoire, de la récolte de ressources et des pénétrations dans

les lignes. Cela affecte directement la tactique et les décisions de jeu.

Le LSTM est ici bien adapté à notre objectif qui est l'étude d'une partie longue (35 à 50 mn avec un échantillonnage à la seconde). La cible est le nombre de joueurs vivants 5 secondes dans le futur (comme recommandé par [CHU et CHOU 2015]), car la position d'un héros mort est par convention gelée à l'endroit de son décès, puis il renaît à sa forteresse. Si ce décalage n'était pas introduit, le LSTM pourrait utiliser cette information de gel et introduire un biais dans les résultats. De plus, nos expérimentations ont consisté à cibler le nombre de joueurs vivants de 5 à 60 secondes dans le futur, avec un intervalle de 5 secondes, et nous avons constaté que les meilleurs résultats se situent entre 5 et 15 secondes, corroborant ainsi les conclusions de [ibid.]. Les résultats exhaustifs sont omis pour alléger la présentation.

La cible étant le nombre de héros en vie dans chaque équipe, de 0 à 5, le LSTM fonctionne en *régression*. Pour élaborer les expériences dont les résultats sont décrits à la section suivante, nous avons choisi la *Mean Square Error* (MSE) comme fonction de perte. Ce choix est justifié par la capacité de la MSE d'évaluer l'erreur globale sur toutes les prédictions. Elle amplifie les grandes erreurs, encourageant ainsi le modèle à s'ajuster aux valeurs réelles, même pour des séries stables. Sa différentiabilité facilite l'optimisation par gradient lors de l'apprentissage.

Pour compléter nos expériences, il conviendrait de s'intéresser également aux résultats obtenus avec une fonction de perte recensant le nombre de changements de cible correctement prédits. Nous l'avons pour l'instant écarté car il peut offrir une évaluation partielle, masquant des erreurs significatives sur des périodes stables.

7.4 Résultats

Les résultats présentés ici ont été obtenus sur un LSTM monocouche de 128 cellules, qui a permis d'évaluer la différence de pertinence, selon que le LSTM est nourri par les indices géométriques du polygone ou par les indices positionnels : les trajectoires.

Pour vérifier s'il existait une différence significative de pertinence entre les indices géométriques ou positionnels, nous avons effectué un test *t* de Student. Ce test détermine le risque encouru lors de l'hypothèse nulle d'égalité entre les moyennes de deux distributions, ici les distributions de MSE obtenues par les deux types d'indices. Si le risque est inférieur à 0.05, l'hypothèse nulle peut être rejetée et, par conséquent, une configuration d'indices peut être différenciée d'une autre.

Nous avons évité d'introduire trop de couches dans le modèle car elles favoriseraient son comportement en approximateur universel : de simples trajectoires pourraient acquérir le même pouvoir expressif que les indices géométriques du polygone.

Au cours de nos expériences, nous considéré deux types de chronologie pour les entrées des LSTM :

apprentissage par phases : pour chaque match, le LSTM a été alimenté de avec trois séquences distinctes, correspondant à chaque phase (early, mid, late game) ;

apprentissage par fenêtre glissante : le LSTM a été alimenté avec de multiples séquences de $t - w$ à t et a prédit à $t + 5$, pour w une largeur de fenêtre que nous avons fait varier entre 5 et 120 s.

Ces deux approches ont permis d'explorer les dynamiques d'apprentissage du modèle LSTM dans le contexte spécifique de notre application. L'apprentissage depuis le début de la phase de jeu a fourni au modèle une vue d'ensemble sur l'évolution des données sur toute la durée du match, ce qui a pu être bénéfique pour capturer des dépendances à long terme et des tendances globales. En revanche, l'apprentissage par fenêtre glissante a permis de se concentrer sur des segments plus courts de données, favorisant une meilleure adaptation aux variations locales et potentielles fluctuations rapides au sein de la phase de jeu.

7.4.1 Apprentissage par phases

Dans un contexte où les variations globales sont essentielles dans les dynamiques du jeu, l'apprentissage sur séquence complète s'avère particulièrement efficace pour capturer les comportements collectifs, avec les indices géométriques du polygone révélant une performance supérieure aux indices positionnels.

La figure 7.4 compare les boxplots de la MSE, selon que les données d'entrée sont les mesures du polygone ou les trajectoires, pour chaque phase du jeu (early, mid, late, voir Section 2.2.1 page 11). On peut observer que, indépendamment de la phase, les mesures du polygone permettent une meilleure prédiction : la médiane de la MSE est la plus basse et la dispersion est moins importante.

Au début et au milieu du jeu, les trajectoires induisent une erreur médiane légèrement plus haute que les indices géométriques du polygone. Pour la fin du jeu, les résultats sont plus marqués, la dispersion augmente pour les deux types d'indices et il y a beaucoup plus de valeurs aberrantes. Cela pourrait s'expliquer par le fait qu'en fin de partie les

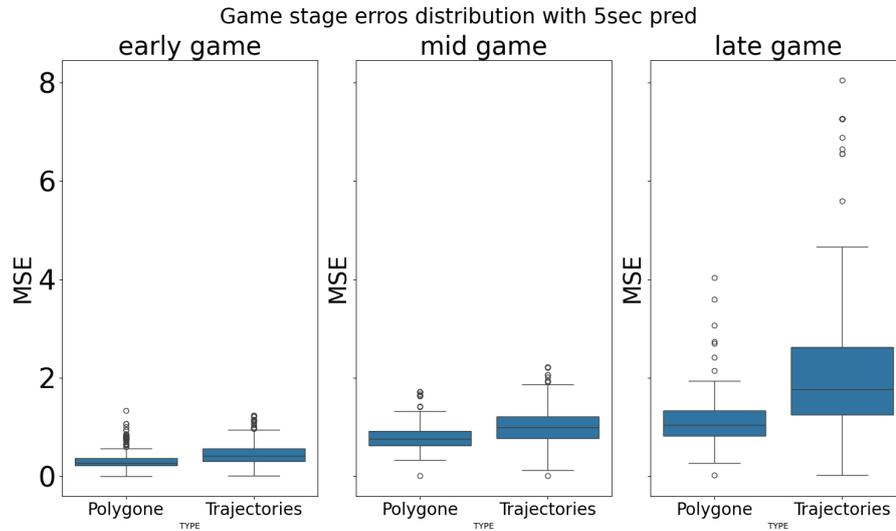


FIGURE 7.4 – Selon les polygones ou les trajectoires : MSE par phases.

morts virtuelles sont beaucoup plus punitives (leur durée dépend linéairement du niveau du joueur, maximum à cette période). Lorsqu'un comportement collectif conduisait à un moment important, le modèle le détectait, mais les joueurs étaient plus prudents en raison de l'enjeu et annulaient leur action au dernier moment.

Le tableau 7.1 indique les moyennes de MSE par phase, selon les polygones ou les trajectoires, et fournit les P-values des tests de Student. Ces valeurs confirment que les moyennes de MSE diffèrent.

Phase	MSE Polygone	MSE Trajectoire	P-values
Early Game	0.34	0.48	$2.989 \cdot 10^{-6}$
Mid Game	0.80	1.03	$1.121 \cdot 10^{-11}$
Late Game	1.16	2.23	$4.366 \cdot 10^{-9}$

TABLE 7.1 – Par phase, MSE moyenne et P-values du test de Student.

Le tableau 7.2 résume le nombre d'*époques* nécessaires pour l'entraînement du modèle LSTM sur des données de régression, en fonction de la phase du jeu et du type d'indices utilisés (mesures du polygone représentant le collectif ou trajectoires des joueurs). Une époque correspond à l'entraînement sur un batch, c'est une unité spécifique de mesure du temps de calcul.

Il est important de noter que l'entraînement a été réalisé avec un mécanisme d'early-stopping, qui permet d'interrompre le processus lorsque le modèle cesse d'améliorer ses

performances sur un ensemble de validation. Indépendamment de la phase de jeu, on constate que l’entraînement sur les indices du polygone nécessite bien moins d’époques, jusqu’à presque deux fois moins.

Phase	polygone	trajectoires
early game	2458	4775
mid game	2854	4394
late game	3093	4972

TABLE 7.2 – Nombre d’Epochs avant early-stop.

La figure 7.5 montre l’évolution de la MSE lorsque l’on augmente le nombre de couches du LSTM (chaque couche comporte 128 cellules). Bien que les indices de polygone restent les plus pertinents, on observe une convergence des deux types d’indices lorsque le nombre de couches augmente. Cela suggère que les indices de polygone capturent efficacement les informations pertinentes pour la tâche, permettant de simplifier l’entrée du réseau sans perte significative de performance.

Ce pré-calcul des indices de polygone présente un avantage notable en termes de réduction de la complexité du réseau et de son coût d’entraînement : on peut obtenir des performances élevées tout en limitant la profondeur du modèle, ce qui se traduit par des gains en efficacité computationnelle et en temps d’apprentissage.

Pour un apprentissage par phase, les indices géométriques du polygone se sont donc avérés être les indices les plus pertinents pour la prédiction de la population, quelle que soit la phase du jeu, tant du point de vue de l’évaluation que du temps de calcul.

7.4.2 Apprentissage par fenêtre glissante

Lorsque l’apprentissage est réalisé sur des fenêtres glissantes, la figure 7.6 montre les performances des différents types d’indices, selon les différentes largeurs de fenêtre testées. On constate que la performance est meilleure avec les trajectoires individuelles.

L’apprentissage par fenêtres glissantes améliore fortement les résultats des trajectoires précédemment obtenus par apprentissage par phases. Les indices du polygone sont beaucoup moins performants. La prise en compte de ces indices sur l’ensemble de la phase est nécessaire pour révéler leur pertinence potentielle.

La figure 7.6 indique également, par un trait pointillé, la MSE obtenue par les polygones en apprentissage par phase. Pour le début de partie, on constate une meilleure

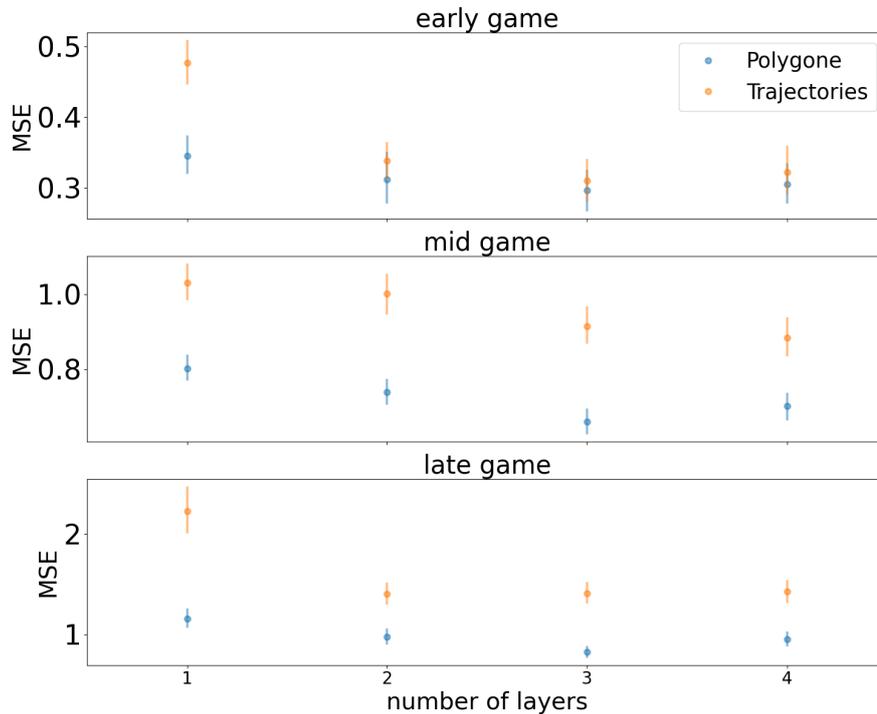


FIGURE 7.5 – Évolution de la MSE en fonction du nombre de couches.

performance des trajectoires en fenêtre glissante que les polygones par phase. Ceci est potentiellement dû à la faible fréquence des événements au début du jeu et à un étalement important des joueurs qui minore l'intérêt à court terme du polygone.

Cependant, si la fenêtre est de taille suffisante (90 secondes), les polygones en fenêtre glissante fournissent une performance comparable à celle des trajectoires : la performance fournie par les polygones nécessite un temps long pour s'exprimer.

En revanche, pour les phases de milieu et de fin de partie, la performance des trajectoires en fenêtre glissante n'améliore pas celle obtenue par les polygones appris par phase.

Ces expériences montrent que la pertinence des attributs du polygone dépend fortement de la taille de la fenêtre d'apprentissage. Celle-ci doit être longue, au minimum 90 s, et de préférence adaptée à la longueur d'une phase complète.

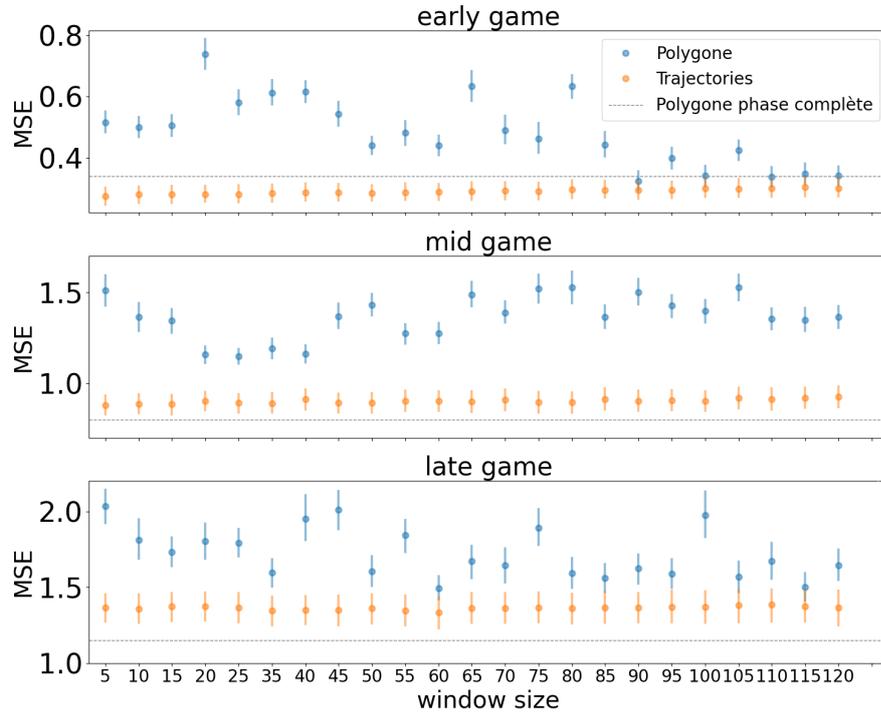


FIGURE 7.6 – Distribution de la MSE selon le type d’indice, en fonction de la largeur de la fenêtre glissante. Le trait pointillé indique la moyenne de MSE obtenue par les polygones en apprentissage par phase.

7.5 Conclusion

Nous avons montré que l’utilisation des indices géométriques obtenus à partir du polygone issu de l’enveloppe convexe des avatars était pertinente pour l’entraînement d’un modèle LSTM prédisant le nombre de héros vivants 5 secondes dans le futur. Cette pertinence est caractéristique d’un modèle capable de prédire correctement un indicateur de la performance au cours de la partie.

Bien que DotA2 soit un jeu complexe, il existe une forte relation entre les indices de position simples et l’occurrence des changements dans le nombre de joueurs en vie. Il ne semble pas nécessaire de scruter le comportement précis des héros en termes d’attaque ou de développement de compétences, ni leur équipement.

Parmi les indices examinés, ceux du polygone se sont avérés plus pertinents pour toutes les phases, au prix d’un apprentissage sur l’intégralité d’une phase. En utilisant des fenêtres de taille variable, les trajectoires ont donné de meilleurs résultats que les

polygones mais n'ont pas atteint la performance des polygones sur la continuité du jeu.

Nous avons également constaté que l'augmentation du nombre de couches dans le LSTM lui permettait de se comporter comme un approximateur universel : plus il y a de couches, moins les différences de performance entre les types d'indice sont sensibles, bien que les trajectoires nécessitent plus d'époques d'apprentissage. Les indices de polygone, obtenus au prix d'un léger calcul préliminaire, ont donc permis de réduire le coût de l'apprentissage.

La proposition d'une transformation des trajectoires pour des indices géométriques est une étape vers la conception de méthodes génériques pour le genre MOBA. Cette transformation améliore l'homogénéité des données nécessaires pour entraîner un RNN. Nous avons montré qu'il était pertinent de se baser sur des indices relatifs à l'organisation spatiale plutôt que sur des positions individuelles, afin de rendre les données comparables.

Ce chapitre a fait l'objet d'un poster à EGC 2022 [MORTELIER et RIOULT 2022b] et d'une publication à ICCCI 2022 [a].

TROISIÈME PARTIE

Métrique de performance

Nous cherchons à comprendre et à concevoir des métriques de performance dans le domaine du handball et des jeux vidéo pratiqués en compétition. C'est une étape importante pour la conception de cibles pour les modèles dédiés à l'analyse et la prédiction des moments clés dans les contextes (e-)sportifs et ludiques.

Le chapitre 8 aborde la conception d'un modèle d'expected goal adapté au handball. Nous mettons en avant une approche optimisée pour la collecte de données, potentiellement coûteuse, combinant le calcul par échantillonnage et le développement d'un modèle prédictif. En utilisant une approche *wrapper* de sélection d'attributs, nous identifions les données essentielles à inclure dans le modèle. Cette approche permet aux équipes de handball de développer un modèle d'xG pertinent tout en minimisant les coûts de collecte de données.

Le chapitre 9 propose une méthode pour déterminer si l'enthousiasme du public est une mesure de la performance en cours. L'application de cette méthode étudie comment le jeu **OverWatch** parvient à captiver et enflammer les foules. Nous commençons par extraire des descripteurs audio pertinents, puis construisons un modèle reliant ces descripteurs aux mesures d'intérêt, permettant d'identifier les moments qui suscitent le plus d'enthousiasme et d'engagement.

Ces deux chapitres offrent une perspective multidisciplinaire sur la conception de métriques de performance.

CONCEPTION D'UN MODÈLE D'*expected goal* POUR LE HANDBALL

Ce chapitre aborde la conception d'un modèle d'*expected goal* (xG) adapté au handball, en mettant en avant une approche pour alléger une collecte de données potentiellement coûteuse. Nous explorons une méthode combinant le calcul par échantillonnage et le développement d'un modèle prédictif, tout en utilisant une approche *wrapper* de sélection d'attributs pour identifier les données essentielles à inclure dans le modèle. Cette approche permet la conception d'un modèle d'xG pertinent tout en minimisant les coûts de collecte de données.

Rappelons qu'au cours de la section 5.1.1, nous avons défini l'xG, précisé ses modalités d'utilisation et détaillé les façons de la calculer : par échantillonnage pour déterminer une *vérité terrain* ou en construisant un modèle qui permet d'inférer cette mesure. À cette occasion, nous avons évoqué les questions concernant les attributs à considérer pour le calcul de l'xG. Ce chapitre propose une réponse dans le cas du handball.

Nous commençons donc par expliquer comment la vérité de terrain de l'xG relative aux championnats du monde de handball en 2015 au Qatar a été échantillonnée. Nous expliquons ensuite comment nous avons utilisé une approche *wrapper* pour déterminer les attributs pertinents pour le calcul de l'xG.

8.1 Calculs de l'xG pour le handball

Deux méthodes sont disponibles pour calculer l'xG : par échantillonnage et par modèle de calcul (section 5.1.1).

8.1.1 Calcul par échantillonnage

La première méthode pour calculer la métrique xG consiste en un échantillonnage des données, qui permet de déterminer le ratio entre le nombre de buts marqués et le nombre de tirs effectués pour chaque position de tir.

Les tirs se produisant à des positions toujours différentes, le terrain est divisé en une grille avec des cellules de taille variable selon la précision souhaitée. Le ratio entre le nombre de buts marqués et le nombre de tirs effectués est ensuite calculé pour chaque cellule de la grille. Ces valeurs peuvent être visualisées à l'aide d'une carte de chaleur. L'avantage de cette méthode est que la valeur de l' xG est disponible grâce à la connaissance de la seule position du tireur.

Sur les données du Qatar 2015, la densité de tirs, de buts et l' xG sont représentées par des cartes de chaleur à la figure 8.1. Même si l'on s'interroge sur les familles d'attributs à considérer pour un bon apprentissage d' xG , il semble pertinent de visualiser et analyser la vérité terrain.

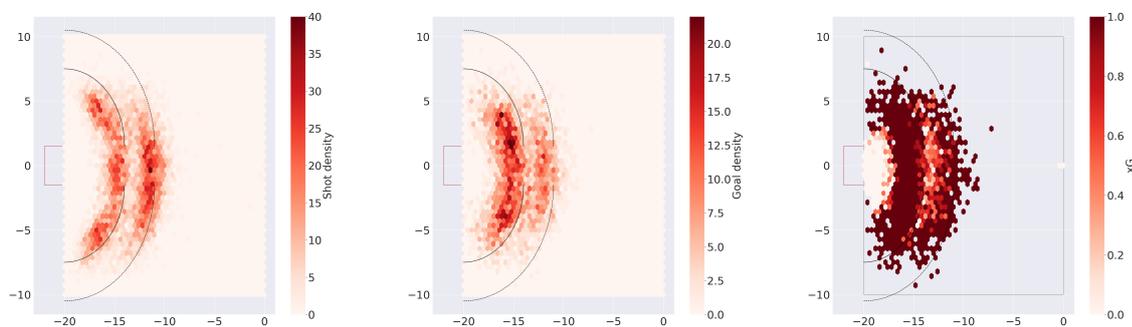


FIGURE 8.1 – Densité des tirs (gauche), densité des buts (milieu) et xG (droite) au handball.

On observe que la plupart des tirs sont effectués sur les lignes des 6 m et 9 m. En revanche, leur réussite semble dépendre de la distance par rapport au but : plus le tireur est loin, plus son angle de tir semble devoir être face au but. La densité suggère un cône de tir, avec la base large au plus proche du but, et son sommet plus proche du milieu de terrain. On peut supposer qu'il existe une corrélation entre la chance de réussite au but et l'angle ainsi que la distance du tireur. Du fait de la topographie atypique d'un terrain de handball, interdisant aux joueurs la zone des 6 m, on observe une plus grand réussite

des tirs dans cette zone. En effet, un attaquant peut y rentrer un bref instant tant qu'il est dans les airs, et être ainsi en duel contre le gardien, sans défenseur pour le gêner.

8.1.2 Calcul d'un modèle

La deuxième méthode pour obtenir la métrique xG consiste à entraîner un modèle sur la vérité terrain fournie précédemment. Grâce à une approche *wrapper*, la conception d'un modèle offre l'opportunité de discuter de la pertinence des attributs considérés.

Un modèle est une fonction prenant en entrée différents arguments comme l'angle d'ouverture du but, la distance du tir, *etc.* et donne en sortie la valeur de l'xG. Par exemple, en notant $xG(d, \theta)$ la fonction d'arguments d la distance de tir par rapport au but et θ l'angle d'ouverture du but, on pourrait définir cette fonction comme proportionnelle à $\frac{1}{d\theta}$. Cette fonction pourrait convenir car la probabilité de but est inversement proportionnelle à la distance et à l'angle d'ouverture. Cependant, l'expression exacte de cette fonction n'est pas connue, entre autres car elle dépend de nombreux autres arguments, par exemple la taille du tireur.

De plus, chaque expert du handball dispose d'une expérience personnelle unique et a ses propres intuitions. Il serait difficile d'aboutir à un consensus sur la définition précise de l'*expected goal*.

Déterminer le modèle adéquat et donc l'expression exacte de la fonction est une tâche prise en charge par apprentissage automatique, à partir de la vérité terrain. Pour la suite de cette présentation, nous avons utilisé sept algorithmes d'apprentissage parmi les plus répandus : RANDOMFOREST, régression logistique, arbres de décision et boosting de gradient : XGBOOST, CATBOOST et ADABOOST (voir annexe A).

Les modèles étudiés fonctionnent en *classification supervisée*. En effet, leur rôle est de classer les occasions de tir selon leur issue, positive ou négative. Dans la pratique, ces modèles calculent plutôt la probabilité de succès du tir et utilisent un seuil d'activation pour prendre la décision de classification. La performance d'un modèle est ici évaluée par son rappel, sa précision, son F1-score et l'aire sous la courbe ROC [FAWCETT 2003].

8.2 Approche *wrapper* de sélection d'attributs

Les modèles d'xG utilisent une même base d'attributs : position x et y au moment du tir, angle d'ouverture et distance du but. L'ajout d'attributs supplémentaires permet de

différencier les approches d'xG pour le football, mais il est nécessaire de déterminer les attributs prépondérants pour le handball.

Nous pensons qu'un modèle xG ne devrait pas prendre en compte les caractéristiques ou les compétences spécifiques des joueurs qui interviennent dans l'événement. [MADRERO PARDO 2020b] en tient compte dans l'apprentissage de ses modèles xG mais ce n'est pas le but de la métrique. On essaye de standardiser selon des milliers de points la probabilité qu'un joueur marque depuis une certaine position dans une certaine situation. Si le joueur est un buteur extraordinaire, il marquera probablement plus de buts que prévu. Si les compétences des joueurs sont prises en compte, la métrique serait biaisée.

Afin de déterminer les attributs du handball nécessaires à l'apprentissage d'un bon modèle d'xG, une technique dite de *sélection d'attribut* est nécessaire. Ces techniques peuvent être très coûteuses si elles doivent tester exhaustivement toutes les combinaisons potentielles d'attributs : pour n attributs, il existe en effet $2^n - 1$ combinaisons possibles.

L'approche *wrapper* effectue une recherche dans l'espace des sous-ensembles d'attributs, guidée par la performance de l'algorithme d'apprentissage du modèle. Le critère d'évaluation est simplement la mesure de performance de l'algorithme, qui dépend du modèle calculé.

Dans les expérimentations, nous ne cherchons pas la configuration d'optimale d'attributs. Nous nous contentons de comparer plusieurs familles emblématiques (voir table 8.1) :

pos : ne considère que la position du tireur ;

pos + θ + d : ajoute l'angle d'ouverture θ du but et la distance au but d ;

pos + θ + d + event : contiennent les données de position plus les informations sur les événements du match (temps écoulé depuis le tir précédent, différentiel de but, scores, etc.)

pos + θ + d + spatial : se concentrent sur les caractéristiques géométriques de la situation de jeu au moment du tir (position du gardien, vitesse du tireur, nombre de défenseurs, etc.) ;

all : rassemble l'intégralité des attributs.

Les attributs que nous avons choisis sont adaptés de la littérature sur les différents modèles d'xG pour le football [CAVUS et BIECEK 2022 ; FAIRCHILD, PELECHRINIS et KOKKODIS 2018 ; HEROLD et al. 2019 ; HEWITT et KARAKUŞ 2023 ; MADRERO PARDO 2020a ; UMAMI, D. GAUTAMA et H. HATTA 2021]. Tous ces modèles utilisent une base constituée de la position du tireur, l'angle d'ouverture du but et la distance au but.

	<i>pos</i>	<i>pos + θ + d</i>	event	spatial	all
position (x, y) du tireur	×	×	×	×	×
angle θ d'ouverture du but		×	×	×	×
distance du tir par rapport au but		×	×	×	×
temps écoulé depuis le tir précédent			×		×
différentiel de but			×		×
score de l'équipe du tireur			×		×
score de l'équipe adverse			×		×
l'équipe du tireur mène-t-elle ?			×		×
temps de possession du ballon			×		×
position du gardien (x, y)				×	×
distance du gardien au but				×	×
vitesse du tireur				×	×
situation de jeu				×	×
aire de la région dominante				×	×
nombre de connections dans Delaunay				×	×
nombre de défenseurs				×	×

TABLE 8.1 – Familles d'attributs pour le calcul de xG.

Cependant, la distance et l'angle peuvent se déduire des positions x et y du tireur. Ils sont donc *a priori* redondants avec la position du tireur. C'est pourquoi le modèle sera entraîné, d'une part avec les positions seules, d'autre part en ajoutant la distance et l'angle. Cette distinction permettra de décider si la position suffit pour calculer un bon modèle.

Pour les données événementielles, les attributs sont directement issus ou calculés à partir des données brutes. La caractérisation de la situation de jeu (attaque placée ou jeu de transition) est déterminée à partir des positions des joueurs de l'équipe : après un changement d'équipe qui possède le ballon, une situation de transition est caractérisée par un surnombre, indiquant le retard d'un ou plusieurs défenseurs.

Pour les données spatiales, on considère l'aire de la région de Voronoï dominante du tireur ainsi que son nombre de voisins dans le graphe de Delaunay. Nous pensons que ces informations sont révélatrices de la pression exercée sur le tireur.

8.3 Résultats

Au cours de nos expérimentations, nous avons comparé l'apprentissage de l' xG selon les familles d'attributs présentées précédemment. La table 8.2 montre les performances (précision, rappel, *etc.*) pour chaque famille et chaque algorithme.

Pour RANDOMFOREST, le F1-score varie entre 0.75 et 0.78 – le rappel et la précision sont quasi-identiques – et l'AUC varie entre 0.71 et 0.75. C'est le signe d'un modèle performant qui prédit plutôt correctement s'il y a but dans une situation donnée. Les autres modèles possèdent un F1-score entre 0.66 et 0.72, et une AUC entre 0.63 et 0.67 : RANDOMFOREST est bien plus performant que les autres.

Lorsque la richesse des attributs augmente, l'amélioration de la qualité de l'apprentissage est peu significative (F1-score de 0.75 pour les positions seules, 0.78 pour l'intégralité des attributs). Sans surprise, une nette augmentation du temps d'apprentissage est observée, entre la configuration la plus simple (*pos*) et la configuration la plus riche (*all*).

On constate également qu'il y a très peu de différences entre les configurations d'attributs événementiels et spatiaux. Le sur-coût engendré par le calcul d'attributs spatiaux, par exemple liés au graphe de Delaunay qui nécessite la position de l'intégralité des joueurs, n'est pas toujours justifié. C'est un trait caractéristique du handball, car au football, la richesse des attributs est importante et la considération d'attributs spatiaux est nécessaire.

De plus, au handball, les événements de buts surviennent plus régulièrement qu'au football et dans une zone plus petite, ce qui explique que l'ajout d'attribut améliore peu la performance du modèle.

8.4 Conclusion

L'adaptation du calcul de la métrique xG au handball est une étape déterminante pour l'analyse des performances des équipes dans ce sport. Nous avons utilisé une approche *wrapper* pour déterminer les attributs pertinents pour l'apprentissage d' xG . L'adaptation pour le handball des modèles du football, incluant un grand nombre d'attributs, ne parvient pas à augmenter significativement la précision du modèle obtenu avec la position du tireur.

Le choix des familles d'attributs, influencé par la disponibilité des données et le coût de collecte, détermine la précision du modèle d' xG . Pour le handball, nous avons montré qu'il n'est pas nécessaire d'investir énormément de moyens dans la collecte car les seules

input	model	accuracy	precision	recall	F1-score	AUC	learning time
pos	RANDOMFOREST	0.72	0.77	0.74	0.75	0.71	258 s
	LOGISTIC REGRESSION	0.64	0.64	0.69	0.66	0.63	16 s
	DECISION TREE	0.67	0.75	0.69	0.72	0.66	2 s
	xGBOOST	0.66	0.75	0.68	0.71	0.66	29 s
	CATBOOST	0.65	0.71	0.68	0.70	0.65	106 s
	ADABOOST	0.65	0.72	0.68	0.70	0.64	34 s
pos+ θ +d	RANDOMFOREST	0.73	0.78	0.74	0.76	0.72	412 s
	LOGISTIC REGRESSION	0.63	0.64	0.69	0.66	0.63	73 s
	DECISION TREE	0.65	0.71	0.68	0.70	0.65	7 s
	xGBOOST	0.66	0.73	0.68	0.71	0.65	83 s
	CATBOOST	0.65	0.73	0.68	0.70	0.65	176 s
	ADABOOST	0.65	0.72	0.68	0.70	0.64	48 s
pos + θ + d + event	RANDOMFOREST	0.74	0.79	0.76	0.77	0.73	344 s
	LOGISTIC REGRESSION	0.63	0.63	0.69	0.66	0.63	277 s
	DECISION TREE	0.65	0.74	0.67	0.70	0.65	46 s
	xGBOOST	0.66	0.73	0.69	0.71	0.66	49 s
	CATBOOST	0.66	0.74	0.68	0.71	0.65	164 s
	ADABOOST	0.65	0.72	0.68	0.70	0.64	58 s
pos + θ + d + spatial	RANDOMFOREST	0.75	0.77	0.78	0.78	0.75	475 s
	LOGISTIC REGRESSION	0.64	0.64	0.69	0.67	0.64	139 s
	DECISION TREE	0.65	0.73	0.67	0.70	0.65	42 s
	xGBOOST	0.70	0.74	0.73	0.73	0.69	68 s
	CATBOOST	0.66	0.72	0.69	0.70	0.65	233 s
	ADABOOST	0.67	0.73	0.69	0.71	0.66	73 s
all	RANDOMFOREST	0.75	0.77	0.78	0.78	0.75	385 s
	LOGISTIC REGRESSION	0.64	0.64	0.69	0.67	0.64	401 s
	DECISION TREE	0.65	0.67	0.69	0.68	0.64	91 s
	xGBOOST	0.68	0.73	0.70	0.72	0.67	71 s
	CATBOOST	0.67	0.72	0.70	0.71	0.66	215 s
	ADABOOST	0.66	0.72	0.68	0.70	0.65	115 s

TABLE 8.2 – Score des algorithmes pour l'apprentissage de l'xG à partir de différentes familles d'attributs.

positions du tir suffisent. Il s'agit d'un progrès significatif pour l'analyse des performances des joueurs et des équipes de handball, qui pourrait avoir des applications pratiques dans le domaine de la formation et de la tactique.

Ce chapitre a fait l'objet d'une publication à l'atelier MLSA d'ECML PKDD 2023 [MORTELIER, RIOULT et KOMAR 2023].

MÉTRIQUE DE LA PERFORMANCE POUR OverWatch

Ce chapitre explore comment **OverWatch** parvient à enflammer les foules en se basant sur l'analyse des retransmissions de matchs. Nous analysons le signal audio produit par les réactions des commentateurs et l'engouement de la foule, que nous mettons en relation avec les descripteurs de jeu calculés à partir d'événements qui se produisent pendant le jeu (niveaux de vie et de magie, mort, déclenchement d'un pouvoir ultime).

Nous proposons une méthode pour déterminer si l'enthousiasme est une mesure de la performance en cours, et s'il attire l'attention sur des situations critiques. Nous commençons par extraire des descripteurs audio pertinents. Ensuite, nous évaluons un modèle prédisant ces descripteurs audio à partir des descripteurs de jeu, permettant de comprendre quels sont les éléments déclencheurs qui suscitent l'enthousiasme et l'engagement chez les spectateurs.

9.1 Clameur de la foule, enthousiasme des commentateurs

Sur **OverWatch**, les parties officielles sont commentées par des experts, et certaines de ces parties se déroulent également sur scène devant un public nombreux. Dans le flux audio, la voix des commentateurs et le bruit de la foule sont mélangés. Pour chacun de ces matchs, la vidéo possède une sur-couche spectateur donnant des informations *objectives* sur l'état du match.

OverWatch ne disposant pas d'une API native pour extraire des données, nous avons dû développer un outil d'analyse des vidéos de retransmission (voir section 2.2.3). Cet outil est conçu pour extraire les informations pertinentes de la surcouche spectateur présente dans les vidéos. Les données extraites sont transformées en descripteurs de jeu, tandis

que le son de la retransmission est converti en descripteurs audio révélant la clameur de la foule et l'enthousiasme des commentateurs.

L'inclusion des commentateurs dans le bruit de la foule pour évaluer l'enthousiasme lors d'un match de compétition est controversée. Les commentateurs peuvent créer artificiellement une atmosphère enthousiaste pour captiver les spectateurs, ce qui peut ne pas refléter fidèlement la réalité du jeu. Leur comportement peut différer de celui des autres membres de la foule. Cependant, ils jouent souvent un rôle crucial en amplifiant les moments clés et en ajoutant du contexte, intensifiant ainsi l'enthousiasme général. Leur présence est donc considérée comme faisant partie intégrante de l'atmosphère d'un événement compétitif : ils influencent fortement la perception des spectateurs, leur enthousiasme contagieux augmente l'implication émotionnelle du public. Les ignorer pourrait donner une image incomplète de l'enthousiasme généré. Enfin, l'inclusion des commentateurs permet d'obtenir une image plus globale de l'environnement sonore d'un match de compétition. Les moments de silence, les exclamations soudaines et l'interaction avec la foule ajoutent à l'authenticité de l'expérience.

Afin de déterminer quels événements du jeu déclenchent un engouement de la foule, une approche *wrapper* (voir section 5.2) est employée. Cette approche détermine les attributs pertinents pour l'apprentissage, à partir des événements, des attributs audio, par un réseau neural récurrent (ici un GRU).

Les descripteurs de jeu sélectionnés quantifient les événements clés, tels que les dégâts infligés, les soins prodigués, les événements de morts, l'état des capacités ultimes, l'utilisation des capacités ultimes.

9.1.1 Transformation des données

Chaque vidéo de jeu est soumise à une analyse des données extraites grâce à notre utilitaire. Les descripteurs spécifiques du jeu sont disponibles : dégâts subis, soins reçus, état des capacités ultimes, utilisation des capacités ultimes, mort des héros. Les points de vie maximum de chaque joueur normalisent les dégâts subis par seconde (DPS) et les soins reçus par seconde. La disponibilité des capacités ultimes est considérée, ainsi que leur utilisation. La durée des décès et de l'utilisation des capacités ultimes est fixée à 10 secondes.

9.1.2 Extraction des descripteurs de l'audio

L'analyse audio est utile pour comprendre les aspects émotionnels et dynamiques des événements en direct, tels que les matchs d'*OverWatch*. Pour cette tâche, un ensemble de descripteurs audio est extrait à l'aide de Librosa, une bibliothèque Python spécialisée dans le traitement du signal audio [MCFEE et al. 2015]. Ces descripteurs, sélectionnés pour leur capacité à capturer différents aspects de l'ambiance sonore, offrent une perspective riche sur les variations d'excitation de la foule et l'enthousiasme du commentateur tout au long du match.

Tout d'abord, les coefficients MFCC (*Mel-Frequency Cepstral Coefficients*) sont utilisés pour représenter la forme spectrale du signal audio [S. DAVIS et MERMELSTEIN 1980]. Ces coefficients, souvent employés pour la reconnaissance de la parole, permettent de saisir les caractéristiques fréquentielles à différentes échelles temporelles. Dans le contexte des matchs d'*OverWatch*, les variations dans les MFCC peuvent révéler les fluctuations de l'ambiance de la foule et de l'excitation du commentateur lors de moments clés du jeu.

Le chroma STFT (*Short-Time Fourier Transform*) analyse la distribution de l'énergie des composantes harmoniques dans différentes classes de fréquence, offrant des informations sur la tonalité et les variations de tonalité dans l'audio [FUJISHIMA 1999]. Cette mesure peut être liée à la musique de fond ou aux sons caractéristiques des actions dans le jeu, enrichissant ainsi l'analyse de l'ambiance sonore globale.

Le centroïde spectral, qui indique le centre de gravité des fréquences dans le signal audio, peut révéler des informations sur la brillance du son [GREY et GORDON 1977]. Des valeurs élevées de cette mesure peuvent indiquer une présence accrue de sons aigus, tels que ceux produits par des cris ou des applaudissements dans un stade lors de moments de grande intensité.

La largeur de bande spectrale et le contraste spectral fournissent respectivement des informations sur la variété des fréquences présentes dans l'audio et les changements soudains dans la texture sonore [BAER, MOORE et GATEHOUSE 1993; PEETERS 2003]. Ces mesures permettent de détecter les moments d'excitation intense ou de calme relatif pendant le match.

Le taux de franchissement de zéro et la force d'apparition sont utilisés pour évaluer la quantité de variation et la présence des transitoires dans le signal audio [BELLO et al. 2005; GOUYON, PACHET, DELERUE et al. 2000]. Ces aspects sont essentiels pour comprendre le caractère percussif ou sonore de l'audio, mettant en évidence les moments d'action ou d'émotion vive.

Le tempo, le spectrogramme de puissance, le pitch et l'énergie sont également des descripteurs clés utilisés pour capturer le rythme perçu, l'intensité globale et la hauteur des sons [DIXON 2001; GHAEMMAGHAMI, DERICHE et BOASHASH 1997; KLAPURI 2004; RAMIREZ et al. 2004]. Ces mesures permettent de mettre en évidence les moments d'excitation de la foule, l'enthousiasme du commentateur et d'autres aspects de l'ambiance sonore du jeu, offrant ainsi une analyse complète et riche des événements en direct.

9.2 Expérimentations

La démarche *wrapper* est mise en œuvre comme suit : autant de modèles qu'il y a des combinaisons de descripteurs sont entraînés en régression pour prédire les descripteurs audio. La performance en entraînement (Mean Squared Error – MSE, et nombre d'époques pour la convergence) du modèle est évaluée pour déterminer la pertinence de chaque combinaison de descripteurs.

Le modèle entraîné est un réseau de neurones récurrents à portes (GRU) plutôt qu'un LSTM (Long Short-Term Memory), pour plusieurs raisons. Tout d'abord, il n'y a pas de dépendance temporelle à long terme (une force des LSTM) critique pour cette tâche spécifique. Contrairement aux LSTM, les GRU sont conçus pour capturer les dépendances temporelles à court et moyen terme. Cette simplification permet de réduire la complexité du modèle, ce qui peut favoriser la rapidité de sa convergence et l'efficacité de son entraînement.

9.2.1 Résultats

La table 9.1 classe les différentes combinaisons de mesures selon la MSE en prédiction des descripteurs audio. Pour synthétiser, la table 9.2 indique le rapport entre la performance des modèles entraînés *avec* une combinaison d'attributs contenant ce descripteur et ceux entraînés *sans* ce descripteur. La colonne *amélioration* indique l'apport du descripteur ; une valeur positive suggère que la présence de la mesure améliore la précision des prédictions, tandis qu'une valeur négative indique une dégradation de la prédiction.

En analysant les résultats, on observe que pour les mesures de soins et de dégâts, l'inclusion de ces mesures améliore la précision des prédictions (la MSE réduit). Cela suggère que ces mesures fournissent des informations importantes pour le modèle : il y a un lien fort entre les indicateurs du jeu et les caractéristiques du signal audio.

heal	damage	use of ulti	state of ulti	death	MSE
×	×	×	×	×	0.351
	×	×	×	×	0.352
×	×		×	×	0.355
×	×		×		0.356
×	×	×	×		0.357
×		×	×	×	0.357
×			×	×	0.361
					0.363
	×	×	×		0.365
	×		×		0.365
×	×	×			0.365
×	×	×		×	0.366
×			×	×	0.367
×		×		×	0.367
	×	×			0.374
×		×			0.375
×	×			×	0.394
	×	×		×	0.439
	×		×	×	0.441
	×	×	×		0.444
×	×				0.456
	×			×	0.468
×				×	0.478
	×				0.521
×					0.534
		×		×	0.710
			×	×	0.793
		×	×	×	0.793
				×	0.819
			×		0.872
		×			0.880
		×	×		0.881

TABLE 9.1 – MSE décroissante selon la présence des mesures.

mesure	MSE sans	MSE avec	amélioration (%)
heal	0.55	0.38	31.4
damage	0.53	0.39	26.2
use of ulti	0.45	0.45	-1.8
state of ulti	0.44	0.46	-6.2
death	0.43	0.47	-9.5

TABLE 9.2 – Apport des différentes mesures sur la MSE.

En revanche, l'utilisation des mesures relatives aux capacités ultimes ou aux évènements de mort conduit à une dégradation de la MSE. Cela peut indiquer que ces mesures introduisent du bruit ou des informations non pertinentes pour la tâche de prédiction, perturbant ainsi le processus d'apprentissage et diminuant la précision des prédictions.

L'analyse de ce tableau suggère que toutes les mesures ne contribuent pas de manière équivalente à l'amélioration des performances du modèle. Certains indicateurs semblent être plus pertinents que d'autres, soulignant ainsi l'importance de sélectionner judicieusement les caractéristiques à inclure dans le processus d'apprentissage pour obtenir les meilleurs résultats.

9.3 Conclusion

Notre méthode a permis de déterminer que l'enthousiasme des spectateurs peut être appris à partir des descripteurs de performance dans le jeu. L'enthousiasme peut donc être considéré comme une métrique fiable de la performance, tout en attirant l'attention sur les situations critiques durant les matchs. En se plaçant dans le contexte plus large de la métrologie de la performance, cette approche contribue à une meilleure compréhension de l'engagement des spectateurs dans les événements d'e-sport.

Nous avons démontré que les indicateurs liés aux soins et aux dégâts jouent un rôle important dans l'amélioration des modèles prédictifs de l'engagement, tandis que les caractéristiques associées aux capacités ultimes présentent des défis particuliers pour le processus d'apprentissage. Ces résultats éclairent les dynamiques complexes qui gouvernent l'enthousiasme du public, un domaine jusqu'alors peu exploré dans la littérature. Des perspectives stimulantes viseraient l'étude de la clameur de la foule dans le contexte d'activités sportives plus traditionnelles.

Ce chapitre a fait l'objet d'une publication à l'atelier IT4PSS d'IJCAI 2024 [MORTELIER,

HELLEU et al. 2024].

QUATRIÈME PARTIE

Analyse de la tactique

L'analyse tactique dans les sports et les jeux compétitifs est un domaine de recherche en pleine expansion, offrant des perspectives nouvelles pour améliorer la performance des équipes et comprendre les dynamiques complexes en jeu. Cette partie présente deux approches pour l'analyse des tactiques, appliquée au handball, un sport collectif traditionnel, et à DotA2, un jeu vidéo compétitif.

Le chapitre 10 introduit un observatoire de la tactique en sport collectif, spécifiquement conçu pour le handball. Cet outil innovant permet d'analyser et de visualiser les tactiques utilisées par les équipes pendant les matchs. Nous décrivons les fonctionnalités de l'observatoire, notamment sa capacité à présenter les tactiques sous forme de sous-graphes dynamiques, évaluées selon des métriques de performance. En outre, nous discutons de l'interface de visualisation, qui offre une perspective précieuse pour les experts souhaitant approfondir leur analyse tactique. Ce chapitre vise à démontrer le potentiel de l'observatoire pour enrichir la compréhension et l'analyse des tactiques dans le handball.

Le chapitre 11 se concentre sur l'analyse des dynamiques tactiques dans le jeu vidéo DotA2, caractérisée par la couche d'attention d'un RNN. L'objectif est d'identifier les comportements menant à des succès tels que les éliminations d'adversaires. Notre méthode met en lumière les caractéristiques les plus pertinentes, offrant des éclairages précieux sur les mouvements tactiques des équipes.

HANDBALL : OBSERVATOIRE DE LA TACTIQUE EN SPORT COLLECTIF

Ce chapitre détaille la création d'un observatoire de la tactique en sport collectif, appliqué au handball. Nous proposons un outil permettant d'analyser et de visualiser les tactiques utilisées par les équipes lors des matchs. Nous présentons l'observatoire et son utilité pour l'analyse tactique du handball, ainsi que sa capacité à représenter les tactiques sous forme de sous-graphes dynamiques. Nous abordons également l'évaluation des mesures d'intérêt des tactiques. Enfin, nous discutons de l'interface de visualisation et de son intérêt pour les experts du domaine.

10.1 Observatoire

Nous transposons ici au domaine du handball la notion d'*observatoire*. Cette notion est issue de la linguistique, où le corpus est un observatoire d'une théorie *a priori*, c'est également un *observé* dynamique qui permet de décrire puis d'élaborer des modèles *a posteriori* [MAYAFFRE 2005]. On peut classer les différentes activités de l'observatoire en trois segments d'intervention : une activité de production et de diffusion de connaissance ; une activité d'ordre stratégique par le biais de la production de notes d'analyse, de fiches ou éléments de langage concernant la situation du sujet ; et une activité d'ordre opérationnel en organisant des actions et mettant en place des outils [PUBLIQUE 2014]. Notre corpus est constitué de données de handball issues du championnat du monde 2015 au Qatar. Notre ambition est d'analyser la tactique au handball en agissant sur les trois segments d'intervention ci-dessus : diffuser de la connaissance sur les tactiques, produire des notes d'analyse et mettre en place des outils d'analyse.

10.2 Représenter les tactiques sous forme de *sous-graphes dynamique*

Pour analyser les tactiques mises en œuvre, il importe de considérer la suite des événements d'un match de handball tel qu'il est retranscrit dans les données à notre disposition. En pratique, nous disposons des trajectoires des joueurs et d'une succession d'événements (passe, tir, faute, *etc.*). La notion de *graphe dynamique*, détaillée au chapitre 4, permet de capturer la dynamique de l'évolution du jeu.

Un élément de tactique est une succession courte d'événements de passe. Cet élément est intéressant s'il a tendance à se produire fréquemment, ce qui lui confère une nature de *motif*. Cet intérêt naît de la reproduction de la situation et de la caractérisation qu'elle entraîne de l'équipe qui exécute cette tactique. Les tactiques dont nous proposons l'analyse sont donc le résultat de l'extraction de sous-séquences fréquentes dans la base de graphes dynamiques associée au jeu. Cette méthode produit des connaissances qui permettent d'activer le premier segment d'intervention de l'observatoire. Le second segment dédié à la production de notes d'analyse sera pris en charge par la réalisation d'une interface de visualisation des tactiques détectées.

L'identification de classes de situations et la détection de modèles de mouvements coordonnés sont au cœur de notre travail, pour aller au-delà des simples analyses de performances individuelles. Pour étudier les divers scénarios de jeu explorés par l'équipe, l'analyse tactique des mouvements collectifs nécessite de capturer des informations contextuelles clés et de construire un modèle des interactions.

10.3 Extraction de sous-séquences fréquentes

Pour procéder à l'extraction de tactiques, nous avons choisi d'explorer les graphes dynamiques sous la forme de séquences d'ensembles d'arêtes (voir section 6.3). Les contributions de la communauté fournissent des implémentations qui y identifient efficacement les motifs récurrents.

En particulier, nous avons utilisé un algorithme d'extraction de sous-séquences *fermées* de motifs [FOURNIER-VIGER, NKAMBOU et NGUIFO 2008]. Une sous-séquence fermée est une séquence à laquelle l'ajout d'éléments réduit la fréquence sans apporter de nouvelle information significative. Par exemple, si les séquences $\langle B, C \rangle$ et $\langle B, C, D \rangle$ apparaissent avec la même fréquence, $\langle B, C \rangle$ n'est pas fermée et sera ignorée. En revanche, si aucune

séquence étendue de $\langle B, C, D \rangle$ n'apparaît avec la même fréquence, alors $\langle B, C, D \rangle$ est fermée et pertinente pour l'analyse.

De plus, l'algorithme incorpore des contraintes temporelles pour garantir la pertinence des séquences extraites. Par exemple, on peut imposer que les événements dans une séquence soient consécutifs ($gap = 0$), pour éviter des combinaisons d'événements disparates sur de longues périodes. Cette contrainte est cruciale pour obtenir des séquences d'événements représentatives d'une même phase de jeu. Sans ces contraintes, l'algorithme pourrait identifier des séquences incohérentes, telles qu'une action au début d'un match suivie d'une autre à la fin du match.

10.4 Mesures d'intérêt des tactiques

L'algorithme d'extraction fournit un grand nombre de tactiques. Dans l'optique d'attirer l'attention sur les tactiques pertinentes, celles-ci peuvent être triées selon des mesures d'intérêt. Nous proposons ici trois mesures différentes : le support, l'expected goal et le taux d'émergence. Le *support* comptabilise le nombre de séquences de jeu au sein desquelles une tactique se produit. L'expected goal indique la probabilité de marquer à la position du tir, en fin de séquence. Cette mesure est obtenue grâce à un modèle entraîné sur les données du Qatar 2015 et nourri par la position du tireur (voir chapitre 8). Enfin, le *taux d'émergence* de la tactique mesure le rapport entre le nombre d'occurrences qui se sont soldées par un succès et celles qui se sont soldées par un échec.

Notons que le taux d'émergence est une mesure *prospective* ou anticipative, car il se réfère à l'évolution de la situation qu'il mesure. *A contrario*, l'expected goal est une mesure *retrospective* car elle est fournie par un modèle calculé sur une agrégation des données. L'expected goal n'est donc pas directement influencé par l'évolution de la situation en cours de caractérisation.

Si le taux d'émergence apporte une information sur la rentabilité d'une tactique, l'expected goal ne fait pas de supposition sur la qualité du tireur ou du gardien de but. C'est une information sur la *qualité de la situation* dans laquelle est mis le tireur pour tirer, indépendamment de la qualité du tir qui suit. Cette mesure est donc adéquate aux objectifs fixés : exhiber les motifs efficaces pour mettre le tireur en condition de tir favorable.

10.5 Interface de visualisation des tactiques

Les championnats du monde au Qatar en 2015 ont donné lieu à une base de 760 graphes dynamiques de cinq passes avant un tir. L’algorithme d’extraction des tactiques sous forme de séquences fermées a été utilisé avec un seuil de support minimal de 5 % (l’algorithme élague les séquences dont le support est en-dessous de ce seuil). Il a produit 6 820 tactiques dont les caractéristiques (nombre, moyenne des supports, du taux d’émergence ρ et de l’expected goal) sont indiquées à la table 10.1.

length	number	support	ρ	xG
2	4,836	26.88	1.56	0.58
3	1,420	26.82	1.68	0.58
4	392	26.22	1.30	0.56
5	172	25.23	0.97	0.58
all	6,820	26.88	1.55	0.58

TABLE 10.1 – Tactiques et pertinence moyennes, selon la taille.

L’extraction de sous-graphes dynamiques fréquents produit un nombre tellement important de tactiques qu’il est illusoire de vouloir les examiner exhaustivement. Il est donc nécessaire de proposer à l’expert chargé de leur analyse une interface de visualisation, à la fois pour faire un choix de la tactique à scruter mais également pour la remettre en contexte dans le match. Cette interface permet d’activer le deuxième segment d’intervention de l’observatoire en produisant des notes d’analyse.

Pour impliquer l’expert dans l’analyse de nos résultats et combler le fossé sémantique entre nos disciplines, il importe donc de privilégier une approche holistique en replaçant les résultats obtenus dans le cadre de l’activité handball : les séquences d’arêtes doivent être visualisées sur un diagramme des positions des joueurs, lui-même intégré dans le déroulement d’un match.

L’interface doit proposer une grande liberté d’action à l’expert pour choisir, parmi les nombreuses tactiques découvertes, celles qui l’intéressent. Si la tactique en cours d’analyse occupe naturellement une position centrale (zone 1) au sein de l’interface présentée à la figure 10.1, il est possible de sélectionner les ordres de priorité pour leur présentation (zone 2) : attaque ou défense, mesure d’intérêt associée (xG, émergence, support), longueur du motif, attaque placée ou contre-attaque, position de déclenchement au sein des séquences de données. La tactique en cours de visualisation dispose alors de mesures statistiques (zone 3) relativement à l’ensemble des données, associées au sélecteur d’ordre : xG, émer-

gence, support, position de déclenchement. Des mesures de sémantique plus sportive (zone 4) permettent à l'expert de diversifier les sources d'explication potentielle de l'intérêt du motif et de le situer dans la séquence dont il est issu : xG , déclenchement, pression des opposants (nombre de lien entre la balle et les opposants dans le graphe de Delaunay) et richesse de la solution offerte par les partenaires (nombre de liens entre le ballon et les partenaires dans le graphe de Delaunay).

Enfin, les occurrences de la tactique analysée sont situées dans le corpus complet des matchs (zone 5). Il est possible d'afficher une représentation en deux dimensions du graphe de Delaunay où les arêtes de la tactique sont soulignées (zone 6), ou d'accéder à la trace vidéo (zone 7). L'expert peut naviguer au sein de la séquence complète ou d'une occurrence à l'autre (zone 8).

De nombreuses interactions entre les différentes parties de l'interface de visualisation sont disponibles. Premièrement, en choisissant la tactique à analyser, un transfert de contexte est opéré vers les parties de l'interface fournissant des mesures ou une visualisation, ce qui permet de rendre la navigation cohérente. La navigation au sein des tactiques est dynamique grâce aux actions sur la sélection des ordres de priorité ou le filtrage des tactiques.

La figure 10.1 présente dans l'observatoire l'analyse de la tactique suivante : `[['28 Valentin Porte=Left Back_1'], ['Pivot=Left Wing_1']]`, ce qui indique qu'une relation est créée entre Valentin Porte et l'arrière gauche adverse, puis une passe plus tard une relation est créée entre le pivot et l'ailier gauche adverse. Ce schéma apparaît 22 fois (support) et possède un taux d'émergence $\rho = 6,33$ indiquant qu'il est 6,33 fois plus présent dans des situations menant à un but que dans celles ne menant pas à un but. Il s'agissait d'un schéma d'attaque placé, généralement déclenché 4 passes avant que le tir ne soit effectué. Ce schéma est apparu dans des séquences de jeu d'environ 14" et donne un xG moyen au moment du tir de 0,63 même sous la pression de 3 adversaires sur le tireur.

10.6 Intérêt pour l'expert

Comme mentionné précédemment, l'un des principaux avantages d'une démarche comme celle présentée ici est l'identification des récurrences. Cependant, pour être plus précis, il s'agit de la récurrence d'une dynamique (c'est-à-dire des interactions entre les éléments et leur évolution) qui est repérée grâce à cet outil. Cela est particulièrement pertinent dans un sport tel que le handball, qui est par nature très dynamique. Lorsqu'il s'agit d'analyser

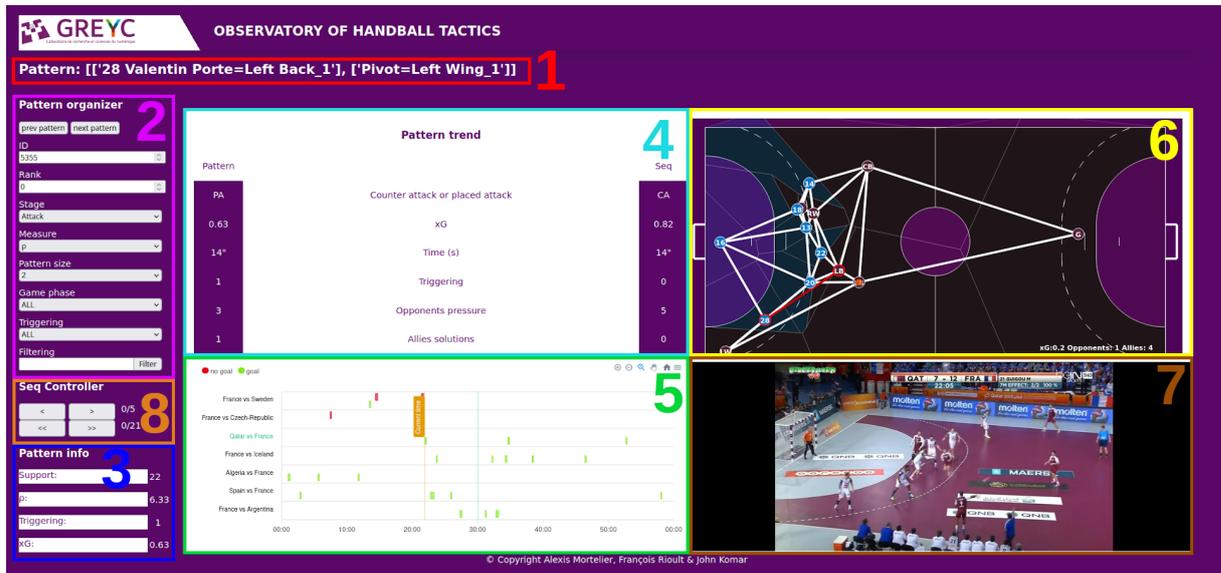


FIGURE 10.1 – Observatoire du handball - <https://morteli211.users.greyc.fr/observatory/>.

un style de jeu connu, généralement pour vérifier que la tactique préparée avant le match a bien été respectée, accéder à ces récurrences de motifs ou de mouvements des joueurs permet de quantifier la tactique effectivement mise en œuvre durant le match.

Ces données peuvent ainsi fournir une vision objective des styles de jeu appliqués, en évitant les biais souvent présents dans l'analyse vidéo classique. En effet, lorsqu'un entraîneur ou un analyste se base principalement sur l'analyse vidéo d'un match, il est facile de mettre en avant certains passages de la vidéo comme étant importants, alors qu'ils ne représentent en fait qu'une petite partie de ce qui s'est réellement passé durant le match, en raison des attentes préalables de l'entraîneur ou de l'analyste.

Le couplage avec une valeur de sortie rétrospective, c'est-à-dire une estimation de la performance de chaque motif observé, permet de savoir si un motif est non seulement récurrent, mais aussi efficace pour l'équipe. Encore une fois, les biais de subjectivité de l'entraîneur, qui souhaite souvent inconsciemment que certains motifs (qu'il a préparés) soient récurrents et efficaces, sont ici limités par une analyse objective : la vidéo, utile pour illustrer les données, n'est plus la source principale d'information.

En outre, cette approche est intéressante non seulement pour objectiver l'analyse de sa propre équipe, mais aussi dans le cadre de la préparation des confrontations futures. Un tel outil permet d'identifier les points forts et les points faibles des adversaires. Connaître les motifs récurrents et très efficaces de l'adversaire permet de préparer des contre-mesures

pour le prochain match. De même, repérer les motifs récurrents mais inefficaces chez l'adversaire peut permettre de les piéger, en les incitant à utiliser davantage ces motifs peu efficaces. La véritable valeur de ces analyses réside dans le fait que l'adversaire n'en est pas conscient, ce qui rend l'utilisation des graphes dynamiques particulièrement intéressante. Ces graphes peuvent révéler des aspects plus profonds de l'activité, qui ne sont pas facilement accessibles à première vue à travers une analyse plus traditionnelle.

10.7 Conclusion

Dans ce chapitre, nous avons présenté une méthode pour la conception d'un observatoire dédié à l'analyse tactique du handball, explorant des graphes dynamiques à la recherche de régularités. Cette approche ajoute une dimension temporelle à l'exploration des modèles de jeu. En permettant de saisir les interactions complexes entre les joueurs, leurs trajectoires sur le terrain et les séquences de passes, cette représentation offre une meilleure compréhension des dynamiques du jeu.

Les tactiques découvertes sont illustrées au sein de l'observatoire, offrant aux entraîneurs et aux analystes une meilleure compréhension des tendances, des forces et des faiblesses.

Il serait intéressant d'explorer davantage les possibilités d'intégration de données supplémentaires, telles que les données physiologiques des joueurs ou les données de performance individuelle. De plus, l'extension de cette méthodologie à d'autres sports pourrait ouvrir de nouvelles voies de recherche et permettre des comparaisons interdisciplinaires enrichissantes. Enfin, il serait bénéfique de collaborer avec des entraîneurs et des analystes du sport pour affiner et adapter continuellement cette approche aux besoins réels du terrain.

Ce chapitre a fait l'objet d'une publication à ISACE 2024 [MORTELIER, RIOULT et KOMAR 2024].

ATTENTION POUR L'ANALYSE DE DYNAMIQUE D'ÉQUIPE DANS DotA2

Ce chapitre est le résultat d'une collaboration fructueuse avec Sébastien Bougleux [MORTELIER, BOUGLEUX et RIOULT 2024].

Nous proposons pour terminer une analyse de la dynamique d'équipe dans DotA2, à l'aide du mécanisme de l'attention. Cette dynamique est captée par l'interprétation des poids de la couche d'attention d'un RNN chargé de prédire la survenue d'un événement à partir des indices géométriques de l'organisation de l'équipe.

Nous détaillons notre méthode d'analyse de la couche d'attention en commençant par disséquer les indices géométriques qui nourrissent le modèle. Son architecture est ensuite décrite, avec un focus sur la couche d'attention et son analyse à des fins tactiques.

11.1 Méthode

Avant d'analyser la couche d'attention, il importe de choisir les indices géométriques qui vont nourrir le RNN. Nous approfondissons le travail présenté au chapitre 7 pour déterminer, parmi les indices géométriques à notre disposition, les combinaisons pertinentes, parmi les trois suivantes :

- locale** : cette combinaison ne contient que des indices du polygone formé par les joueurs d'une équipe ;
- relative** : cette combinaison d'indices contient les indices du polygone et considère en sus la distance entre les barycentres ;
- complète** : cette combinaison complète la précédente avec la distance des barycentres aux bases.

Entre une combinaison locale d'indices, caractéristiques de la forme du polygone, et la considération des distances relatives puis des distances absolues éclairant sur la position précise des barycentres, il est ainsi possible de choisir des indices fournissant des informations de plus en plus précises sur la localisation de l'action. Dans la section 11.3 qui relate nos expérimentations, nous commencerons par déterminer la combinaison d'indices la plus pertinente pour l'apprentissage du modèle, pour ensuite analyser la couche d'attention sur les indices de cette combinaison.

11.2 Architecture du modèle

L'analyse de la tactique dans DotA2 consiste à scruter les poids de la couche d'attention d'un RNN chargé de prédire la survenue d'un événement à partir des indices géométriques de l'organisation de l'équipe. La figure 11.1 montre une représentation de l'architecture du réseau neuronal. Dans le cas d'un match, l'entrée consiste en une séquence de T valeurs par indice polygonal pour une équipe, représentée par une matrice de taille $T \times f$, avec f le nombre de caractéristiques d'entrée ($f = 4$ sur notre figure).

L'objectif est de prédire si tous les joueurs de l'équipe adverse sont vivants (*noKill*) ou non (*kill*). Il s'agit d'un problème de classification binaire. Pour décider, le réseau extrait d'abord l'information spatio-temporelle des caractéristiques d'entrée par une couche de convolution séparable en profondeur 1D suivie de deux couches LSTM, réduisant la séquence d'entrée de $f = 4$ caractéristiques à une séquence cachée de une caractéristique par pas de temps. Ensuite, $f = 4$ mécanismes indépendants d'attention sont appliqués à cette séquence pour se concentrer sur les entrées importantes pour la prédiction finale. Les quatre séquences de caractéristiques résultantes, une par caractéristique d'entrée, sont concaténées et introduites dans une couche dense avec un biais et une fonction d'activation sigmoïde, qui produit la prédiction binaire pour chaque étape temporelle de la séquence d'entrée.

La couche de convolution séparable en profondeur 1D applique une convolution temporelle 1D séparée par séquence de caractéristiques d'entrée avec un noyau de taille 7, suivie de 32 convolutions ponctuelles indépendantes (convolutions 1×1) pour apprendre les corrélations entre les caractéristiques. La sortie de cette couche est une matrice de caractéristiques de $T \times 32$.

Ensuite, les dépendances à court et à long terme des caractéristiques sont capturées par deux couches LSTM. À cette fin, la séquence de 32 caractéristiques est décomposée

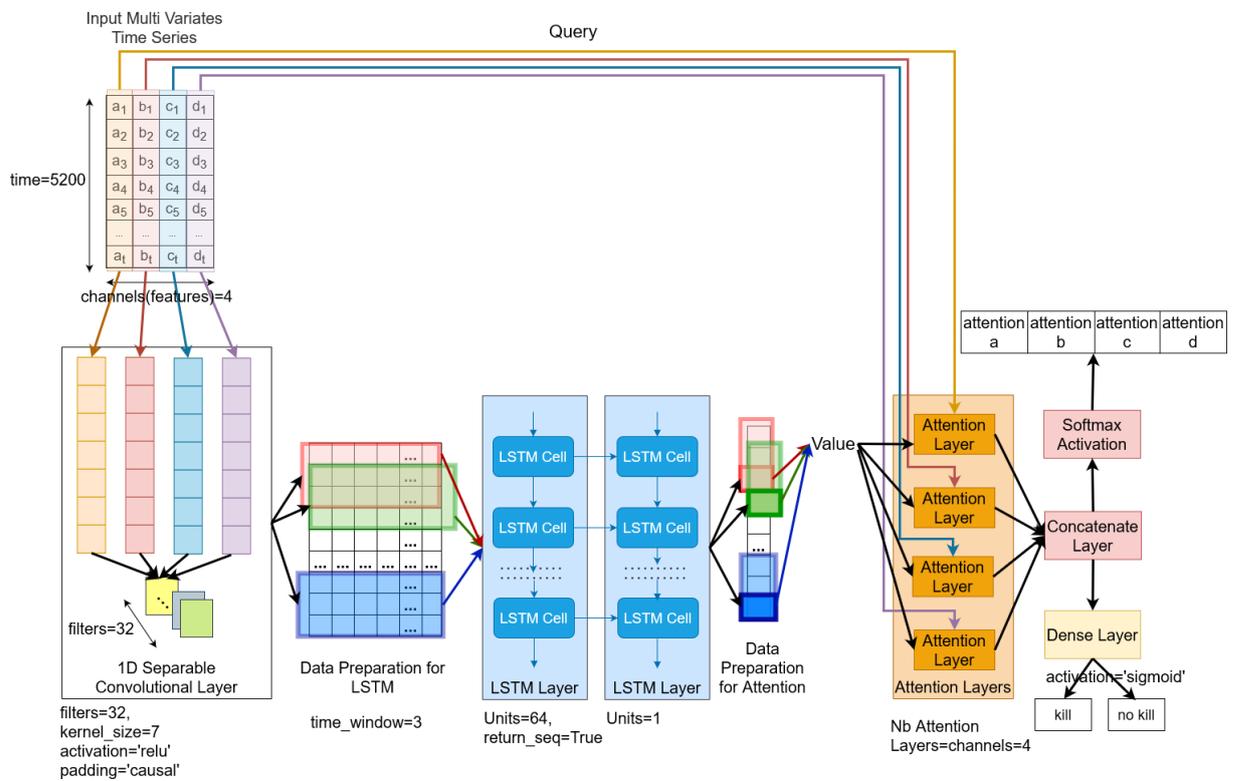


FIGURE 11.1 – Architecture du modèle.

en sous-séquences superposées de 60 pas de temps, ce qui donne $T/60$ sous-séquences de 32 caractéristiques. Chaque sous-séquence est transmise à une première couche LSTM composée de 60 cellules (une par pas de temps), une cellule étant composée de 64 unités pour produire une matrice de caractéristiques intermédiaires de 60×64 . Les matrices de caractéristiques intermédiaires $T/60$ sont ensuite transmises à une deuxième couche LSTM, produisant des matrices de caractéristiques $T/60$ de taille 60×1 . Ensuite, le dernier pas de temps des sous-séquences $T/60$ est concaténé en une séquence de caractéristiques de longueur T (matrice $T \times 1$), notée H , qui est utilisée par le mécanisme d'attention.

L'attention permet de relier la séquence d'entrée à la séquence de sortie H du LSTM, en capturant les influences spécifiques de chaque indice. À cette fin, le mécanisme d'attention par points calcule les scores de similarité entre la séquence d'entrée (*requête*) et H (*clé*), avec un produit scalaire suivi d'un softmax, pour pondérer H (*valeur*). Cela permet au réseau de se concentrer sur les parties les plus pertinentes de la séquence pour chaque caractéristique. La concaténation de toutes les couches d'attention est normalisée par un softmax et conduit à une *attention spatio-temporelle*, offrant une vue détaillée de l'importance de chaque indice à chaque étape temporelle.

11.3 Expérimentations

11.3.1 Protocole

L'ensemble de données est composé de 258 matchs de DotA2, d'une durée maximale de 5 200 s. Les 516 exemples d'équipe ont été répartis aléatoirement en ensembles d'apprentissage (60%), de validation (20%) et de test (20%). Comme toutes les séquences n'ont pas la même longueur, nous avons normalisé leur longueur à une même valeur (5 200) en utilisant la technique du padding (0 padding), afin qu'elles puissent être traitées en lot.

Pour entraîner le réseau, nous ciblons l'attribut de classe prenant ses valeurs dans $\{kill, noKill\}$ pour l'équipe adverse à chaque moment des séquences, directement à partir de la ligne de vie. La classe *noKill* est largement majoritaire et une technique d'*apprentissage sensible au coût* [ELKAN 2001] modifie la fonction de perte pour tenir compte de ce déséquilibre. Les états des LSTM sont remis à zéro après chaque séquence, de sorte que la fin d'une séquence et le début de la suivante ne sont pas considérés comme étant dans la même séquence. Le réseau est optimisé en fonction de la perte d'entropie croisée binaire, avec l'optimiseur Adam, un taux d'apprentissage de 0,001 et une taille de batch de 32.

Pour comparer la performance du modèle en utilisant les trois combinaisons d'indicateurs, nous avons adopté une approche *wrapper*, abordée à la section 5.2. Cette approche consiste à intégrer chaque combinaison dans le modèle de manière distincte, puis à évaluer la performance prédictive du modèle sur un ensemble de données test pour chaque configuration. En procédant ainsi, nous pouvons non seulement identifier quelle combinaison d'indicateurs conduit à la meilleure performance, mais aussi déterminer la contribution spécifique de chaque type de mesure (distances globales, distances relatives, caractéristiques locales) à la précision du modèle.

11.3.2 Pertinence de la couche d'attention

Nos premières expérimentations consistent à vérifier que la couche d'attention est utile dans notre architecture. La table 11.3 compare les résultats des deux modèles CNN-LSTM avec et sans mécanisme d'attention. Le modèle avec attention surpasse le modèle sans attention, quels que soient les indices géométriques, avec des scores autour de 0.85 quand le modèle sans attention plafonne à 0.74. Ces résultats démontrent d'une part la robustesse du modèle CNN-LSTM pour traiter le jeu de données mais surtout confirment l'apport du mécanisme d'attention. La couche d'attention est utile pour l'apprentissage et son interprétation est en capacité de fournir des informations précisant la relation entre les indices du polygone en entrée et la cible.

	complet	relatif	local
accuracy	0.87	0.86	0.85
precision	0.86	0.85	0.83
recall	0.87	0.85	0.85
f1 score	0.86	0.85	0.84

TABLE 11.1 – avec attention.

	complet	relatif	local
accuracy	0.74	0.73	0.71
precision	0.73	0.72	0.69
recall	0.74	0.73	0.71
f1 score	0.73	0.72	0.69

TABLE 11.2 – sans attention.

TABLE 11.3 – Performance de la couche d'attention du modèle.

Pour alléger la présentation nous nous concentrerons sur les résultats avec la combinaison d'indices locaux, l'annexe B propose des résultats supplémentaires pour les autres combinaisons.

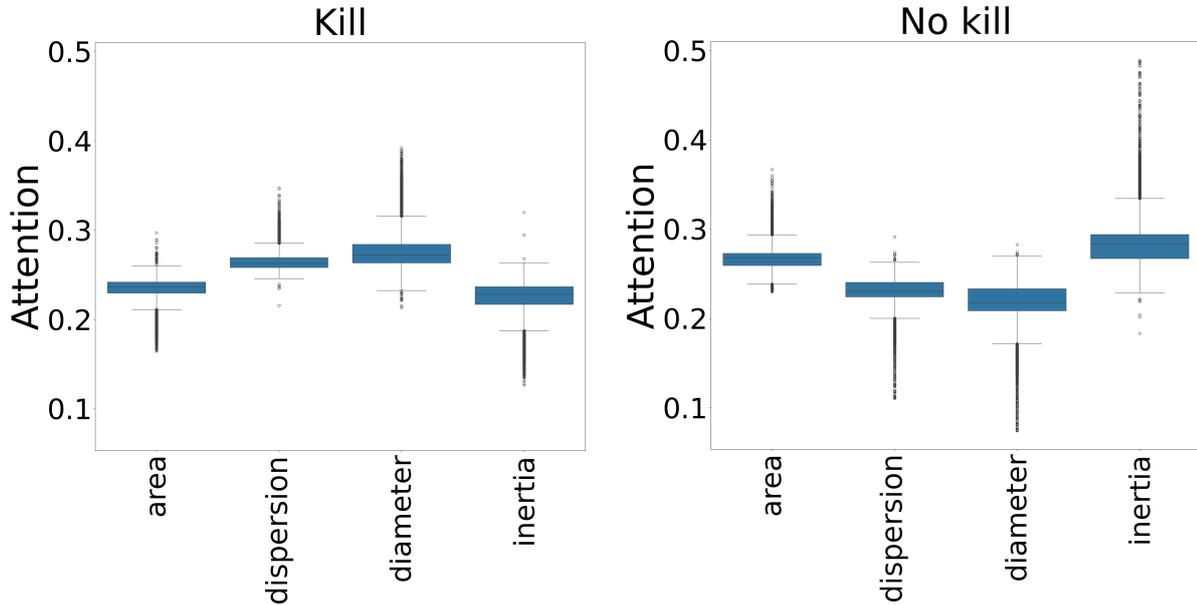


FIGURE 11.2 – Importance des indices avec attention pour la combinaison d'indices locaux.

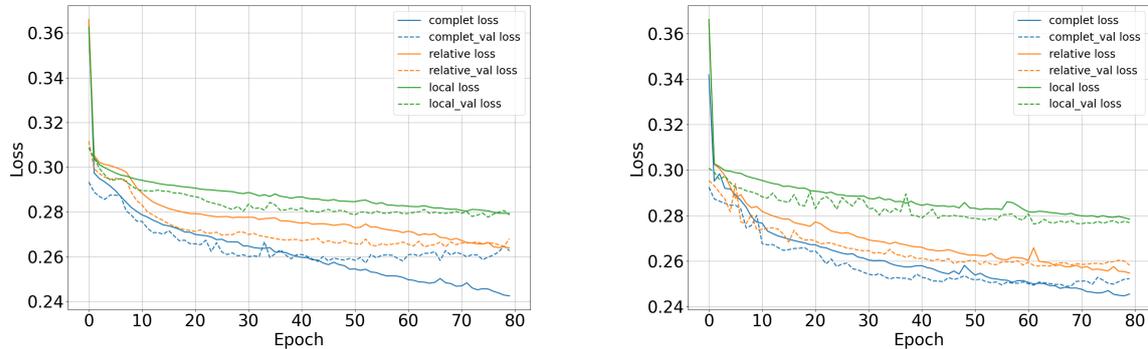
11.3.3 Analyse statistique de l'attention

La Figure 11.2 montre la répartition de l'attention entre les caractéristiques du polygone, selon que l'événement à prédire est *kill* ou *noKill*. Lors d'un événement *kill*, *diameter* et *dispersion* montrent des valeurs d'attention plus élevées avec une distribution large. *area* et *inertia* enregistrent une valeur plus faible. Quand il s'agit d'un événement *noKill*, la tendance s'inverse.

Pour prédire un événement *kill*, l'attention est donc attirée sur les descripteurs *dispersion* et *diameter*, qui sont caractéristiques de la forme du polygone, selon qu'il est plus ou moins étiré. Pour prédire un événement *noKill*, le réseau est à l'inverse plus attentif à l'inertie du polygone, relative à la variation de sa forme.

L'annexe B donne des résultats complets pour l'attention sur tous les indices géométriques. Ainsi, les figures B.1 et B.4 confirment que l'inversion de la tendance sur les poids d'attention se produit sur l'intégralité des indices.

La figure 11.3a montre les courbes de perte d'entraînement et de validation pour les trois combinaisons de caractéristiques pour le modèle avec attention. Une courbe de perte évalue la performance d'un modèle d'apprentissage automatique au cours de son entraînement. La perte est une mesure qui quantifie la différence entre les prédictions du modèle et les résultats attendus. Elle permet de voir si le modèle apprend bien en vérifiant si la



(a) Courbes de perte du modèle avec attention. (b) Courbes de perte du modèle sans attention.

FIGURE 11.3 – Courbes de perte du modèle.

perte diminue et si les courbes de perte d'entraînement ($loss$) et de validation ($loss_val$) se rapprochent rapidement. Lorsque ces courbes convergent vite, cela signifie que le modèle généralise bien. En revanche, si la courbe $loss$ descend en-dessous de celle de $loss_val$, cela indique un sur-apprentissage : le modèle est habitué aux données d'entraînement mais ne généralise pas bien sur des données nouvelles.

La présence d'une couche d'attention procure une meilleure stabilité et une convergence plus douce, notamment avec les combinaisons complètes et relative. Sans couche d'attention (figure 11.3b), bien que les courbes de perte d'entraînement et de validation descendent également, elles présentent plus de fluctuations, surtout avec la combinaison complète.

Les deux modèles performant mieux avec la prise en compte des distances aux fontaines et entre les barycentres : ces distances apportent une information significative. La courbe de perte nous indique aussi qu'il faut entraîner le modèle avec le jeu complet pendant moins d'époques afin d'éviter un sur-apprentissage.

11.3.4 Analyse dynamique de l'attention

La figure 11.4 montre l'évolution de la distribution des poids d'attention pendant les 30 s qui précèdent la mise à mort d'un avatar. On constate qu'un changement dans l'attention accordée aux indices se produit entre 10 et 15 s avant un évènement, ce qui vient appuyer [CHU et CHOU 2015] qui indique que la plage avec le meilleur taux de détection des événements importants se situe jusqu'à 15 secondes. De plus, on observe une variation nette de l'attention accordée à la dispersion et au diamètre.

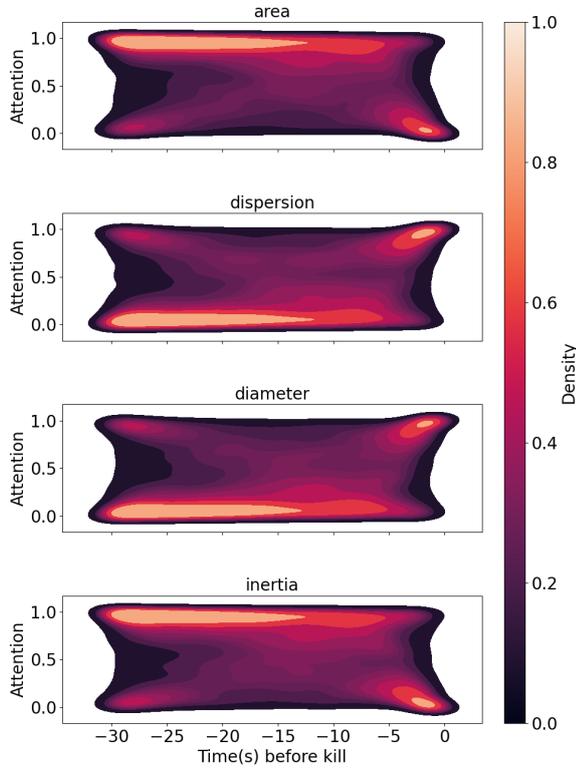


FIGURE 11.4 – Distribution de l'attention avant le *kill* à $t = 0$.

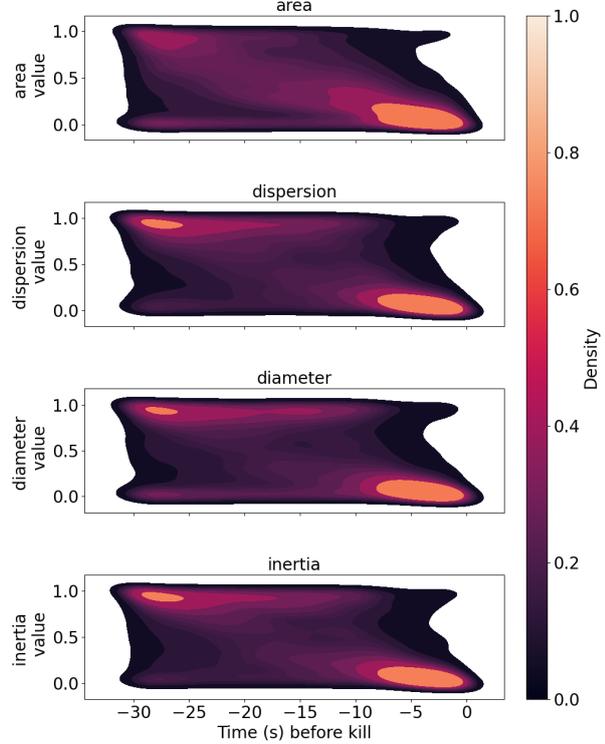


FIGURE 11.5 – Distribution de la valeur des indices avant le *kill* à $t = 0$.

La figure 11.5 montre l'évolution des valeurs de chaque indice de t à $t-30$ s avant un évènement de mort sur un avatar. On observe que les valeurs des indices évoluent dans le temps. En outre, nous pouvons clairement constater que l'équipe a tendance à se regrouper pour réaliser un *kill*.

Les figures B.2, B.5 et 11.4 montrent l'évolution des poids d'attention de t à $t-30$ s avant un évènement de mort sur un avatar, pour chaque jeu d'indice d'entrée. En comparant ces figures, on constate que les indices locaux du polygone permettent une meilleure généralisation sans l'utilisation des distances, tandis que considérer les distances relatives ou absolues fournit au modèle un contexte plus détaillé.

Nous pensons que l'ajout des distances aide à différencier les dynamiques propices à un *kill* de celles liées à la prise d'objectifs. De plus, on observe une corrélation très nette entre l'attention et les valeurs des indices, ce qui nous amène à conclure qu'un *kill* nécessite un

regroupement des joueurs, pour s'entraider et bloquer les voies d'échappement de la cible, et une proximité suffisante avec l'équipe ennemie.

11.4 Conclusion

L'utilisation d'un réseau CNN-LSTM avec attention a non seulement amélioré la précision des prédictions en se concentrant sur les informations pertinentes, mais a également fourni un moyen d'interprétation des décisions prises par le modèle. En examinant les poids d'attention, il a été possible d'identifier les caractéristiques géométriques influençant le plus le réseau. Ces informations ont révélé les attributs spécifiques qui précédaient les moments influençant le nombre de joueurs actifs dans l'équipe adverse.

L'analyse de la couche d'attention ouvre des perspectives prometteuses pour la caractérisation des moments importants, en repérant des profils emblématiques de variation de l'attention.

Ce chapitre a fait l'objet d'une publication à l'atelier MLSA de ECML/PKDD2024 [MORTELIER, BOUGLEUX et RIOULT 2024]

Conclusion - Perspectives

CONCLUSION - PERSPECTIVES

Bilan

Le panorama des contributions de cette thèse pour la conception d'un observatoire de la tactique en (e-)sport collectif représente une vision globale et complète de l'analyse tactique. À travers l'étude du handball et de l'e-sport, nous avons proposé plusieurs méthodes pour soutenir le travail des entraîneurs et des analystes. Nous avons contribué aux trois étapes majeures de l'analyse sportive : traitement de la trajectoire, conception de métriques de performance et analyse de la tactique.

Traitement de la trajectoire

L'étude des trajectoires et des interactions dans les jeux collectifs comme le handball et DotA2 a permis de mettre en évidence l'efficacité de différentes approches géométriques et algorithmiques pour traiter de façon efficace et créative les trajectoires individuelles, dans le but d'une analyse du comportement collectif.

Dans le cas du handball, la représentation par graphes dynamiques différentiels issus de la triangulation de Delaunay a permis de capturer avec précision les interactions entre les joueurs. La transformation gnomonique du terrain a amélioré la fidélité de la modélisation des interactions.

En parallèle, l'utilisation d'un réseau de neurones LSTM pour prédire la performance des joueurs dans DotA2 a démontré la pertinence des indices géométriques simples sur les positions des avatars. La prédiction du nombre d'avatars vivants, basée sur des indices de la géométrie des polygones formés par les avatars, s'est révélée performante.

Ces deux approches mettent en lumière l'utilité des représentations géométriques et des modèles d'apprentissage automatique pour l'analyse des jeux collectifs.

Conception de métriques de performance

Cette partie de notre travail englobe des analyses approfondies sur l'adaptation des métriques de performance pour le handball et leur lien avec l'engagement des spectateurs dans les diffusions de match avec une étude de cas de l'OverWatch League.

Dans le contexte du handball, nous avons adapté la métrique xG pour évaluer les performances des équipes en mettant l'accent sur les positions de tir. Contrairement aux approches traditionnelles qui nécessitent une collecte étendue de données sur les tirs, notre méthode a montré qu'une collecte de données plus modeste était suffisante, ce qui a facilité son application tout en conservant une grande précision dans l'analyse des performances.

Parallèlement, l'étude de diffusions de l'OverWatch a mis en évidence la pertinence de certains indicateurs de jeu pour prédire l'engagement de la foule. Cette pertinence confirme la nature de métrique de performance associée à l'engagement de la foule.

Analyse de la tactique

Nous avons développé un observatoire d'analyse tactique du handball basé sur des graphes dynamiques. Cette méthode permet de visualiser et de comprendre les interactions complexes entre les joueurs et leurs trajectoires sur le terrain. L'observatoire favorise les interactions avec les tactiques, qui sont hiérarchisées selon des mesures d'intérêt telles que le taux d'émergence et l'xG.

Enfin, l'interprétation d'une couche d'attention aura permis l'analyse des dynamiques de jeu dans DotA2. En pesant sur les différentes caractéristiques géométriques, l'attention exhibe les actions impactant le nombre d'avatars vivants et fournit des connaissances sur la dynamique du jeu collectif.

En combinant ces approches, nous avons démontré l'intérêt des graphes dynamiques et des réseaux de neurones pour l'analyse tactique du (e-)sport. L'intégration de méthodes géométriques et d'apprentissage automatique offre une vision détaillée et exploitable des interactions complexes sur le terrain.

Perspectives

L'intégration de données en sus des trajectoires représente un domaine de recherche prometteur. En explorant des sources telles que les données physiologiques des sportifs, les données de performance individuelle ou même les données contextuelles telles que les

conditions météorologiques, nous pouvons enrichir notre compréhension des dynamiques de jeu et des tactiques employées. Ces données supplémentaires pourraient favoriser le développement de modèles prédictifs plus précis et des analyses approfondies de la performance des équipes.

De plus, l'application de notre travail à d'autres sports promet un terrain d'exploration passionnant. Chaque sport possède ses propres caractéristiques uniques et adapter notre approche à des disciplines telles que le basketball, le football américain ou le rugby pourrait révéler de nouvelles perspectives sur la tactique et la performance dans ces sports. Cette démarche pourrait également faciliter les comparaisons interdisciplinaires.

Parallèlement, il est important de continuer à collaborer étroitement avec les entraîneurs, les analystes et les praticiens du sport pour affiner et adapter nos méthodes aux besoins réels du terrain. En travaillant en partenariat avec ceux qui sont directement impliqués dans la pratique du sport, nous pouvons vérifier si nos analyses sont pertinentes, utiles et directement applicables dans un contexte opérationnel.

CINQUIÈME PARTIE

Annexes

MODÈLES D'APPRENTISSAGE

Ce chapitre propose une rapide présentation des différents modèles d'apprentissage utilisés lors des contributions de cette thèse. Sont examinés la régression logistique, les arbres de décision, les forêts aléatoires, le boosting de gradient et enfin les réseaux de neurones récurrents : LSTM et GRU.

A.1 Régression logistique

La régression logistique [HOSMER JR, LEMESHOW et STURDIVANT 2013] est un modèle statistique permettant d'étudier les relations entre un ensemble de variables qualitatives X_i et une variable qualitative Y . Il s'agit d'un modèle linéaire généralisé utilisant une fonction logistique comme fonction de lien. Un modèle de régression logistique permet donc de prédire la probabilité de survenue d'un événement à partir de l'optimisation des coefficients de régression. Lorsque la valeur prédite est supérieure à un seuil choisi par l'expert (par exemple en lien avec la probabilité de marquer un but suite à un tir), l'événement est susceptible de se produire [AGRESTI 2018].

A.2 Arbre de décision

L'apprentissage par arbre de décision [L. BREIMAN et al. 1984] désigne une méthode basée sur l'utilisation d'un arbre de décision comme modèle prédictif. Les feuilles représentent les valeurs de la variable-cible et les embranchements correspondent à des combinaisons de variables d'entrée qui mènent à ces valeurs, comme représenté à la Figure A.1. C'est une technique d'apprentissage supervisé : on utilise un ensemble de données pour lesquelles on connaît la valeur de la variable-cible afin de construire l'arbre (données dites étiquetées), puis on extrapole les résultats à l'ensemble des données de test.

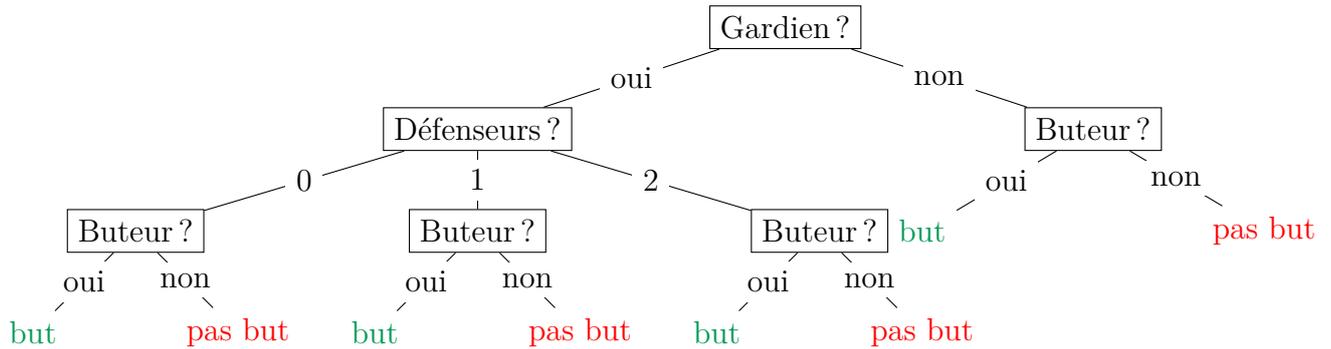


FIGURE A.1 – Arbre de décision.

A.3 Forêts aléatoires

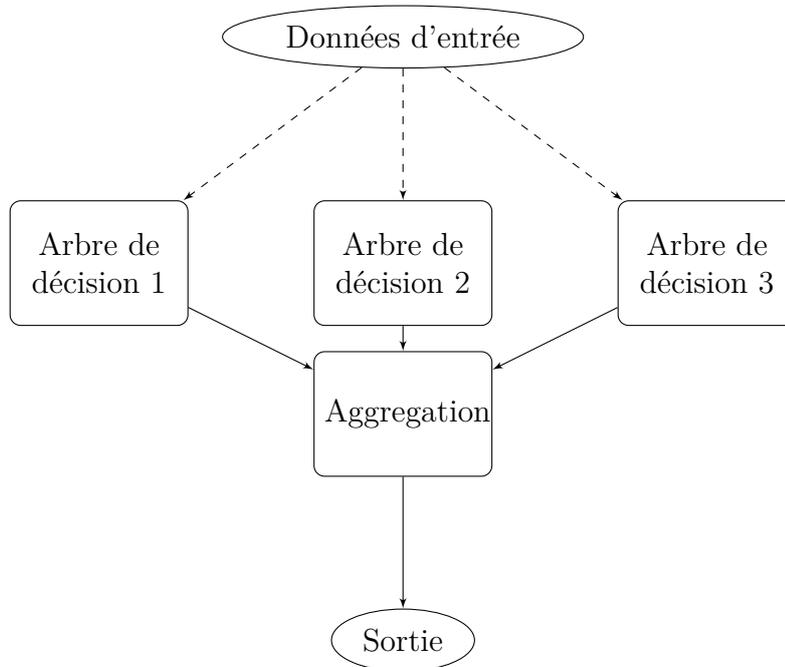


FIGURE A.2 – Forêt aléatoire.

Une forêt aléatoire [Leo BREIMAN 2001] est composée de plusieurs arbres de décision (voir figure A.2), entraînés de manière indépendante sur des sous-ensembles de l'ensemble d'apprentissage (méthode de bagging). Chaque arbre produit une estimation, et c'est la combinaison des résultats qui va donner la prédiction finale. Ce procédé permet de réduire la variance. Chaque modèle est distribué de façon aléatoire en sous-ensembles d'arbres de décision. L'estimation finale consiste à choisir la catégorie de réponse la plus fréquente.

Plutôt qu'utiliser tous les résultats obtenus, on procède à une sélection en recherchant la prévision qui revient le plus souvent.

A.4 Boosting de gradient

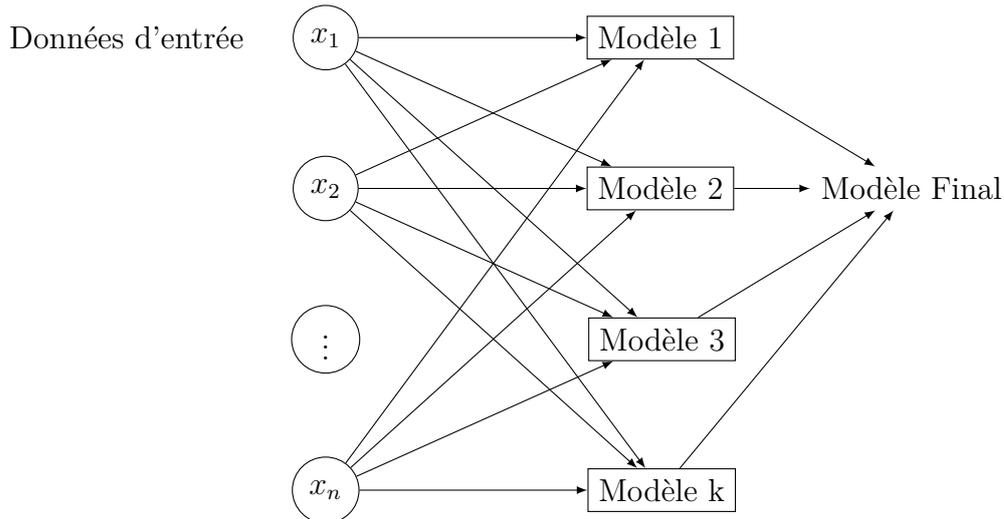


FIGURE A.3 – Boosting de gradient.

Le boosting de gradient [FRIEDMAN 2001] combine un ensemble de modèles de prédiction faibles : des arbres de décision à peine meilleurs que l'aléatoire (voir figure A.3). Il repose sur l'intuition que le meilleur modèle possible, lorsqu'il est combiné aux modèles obtenus précédents, minimise l'erreur de prédiction globale. L'idée clé est de définir les résultats cibles pour ce prochain modèle afin de minimiser l'erreur. Le résultat cible pour chaque instance dépend de l'impact de la modification de la prédiction sur l'erreur de prédiction globale :

- si une petite modification entraîne une forte baisse de l'erreur, la valeur cible suivante est augmentée. Les prédictions du nouveau modèle qui sont proches de ses cibles réduiront l'erreur ;
- si une petite modification ne provoque aucun changement dans l'erreur, alors le prochain résultat cible du cas est fixé à zéro. La modification de cette prédiction ne réduit pas l'erreur.

Le terme de boosting de gradient vient du fait que les résultats cibles sont définis en fonction du gradient de l'erreur par rapport à la prédiction. Chaque nouveau modèle fait un pas dans la direction qui minimise l'erreur de prédiction.

A.5 CNN

Un réseau de neurones convolutionnels (CNN) est un type de réseau de neurones artificiels spécifiquement conçu pour traiter des données structurées en grille, comme les images. Inspirés par l'organisation et le fonctionnement du cortex visuel des animaux, les CNN sont particulièrement efficaces pour les tâches de reconnaissance d'image et de classification [LECUN, BOSER et al. 1989]. Ces réseaux se composent de couches de convolution, de pooling et de couches entièrement connectées. Les couches de convolution appliquent des filtres optimisés pour détecter des motifs locaux dans les images, ce qui permet de capturer des caractéristiques spatiales hiérarchiques [FUKUSHIMA 1980]. En termes de traitement du signal, les opérations de convolution sont similaires à l'application de filtres linéaires, une technique courante pour extraire des caractéristiques spécifiques dans les signaux [OPPENHEIM, SCHAFER et BUCK 1999]. Les couches de pooling, quant à elles, réduisent la dimensionnalité des données, ce qui diminue la charge computationnelle tout en conservant les informations pertinentes [LECUN, BOTTOU et al. 1998]. En traitement du signal, cela correspond à une forme de sous-échantillonnage, permettant de réduire la redondance tout en maintenant les caractéristiques essentielles [S. W. SMITH 1997]. Enfin, les couches entièrement connectées interprètent les caractéristiques extraites pour réaliser la tâche de classification [KRIZHEVSKY, SUTSKEVER et HINTON 2012]. Les CNN ont révolutionné de nombreux domaines de l'apprentissage automatique et sont devenus un outil essentiel pour les applications nécessitant une analyse visuelle complexe [GOODFELLOW, BENGIO et COURVILLE 2016].

A.5.1 1D Séparable CNN

Un réseau de neurones convolutionnels séparable en 1D (1D Separable CNN) est une variante spécialisée des réseaux de neurones convolutionnels conçue pour traiter des données unidimensionnelles, telles que des séries temporelles ou des signaux audio. Contrairement aux CNN traditionnels qui utilisent des convolutions classiques, les 1D Separable CNN décomposent cette opération en deux étapes distinctes : une convolution en profondeur suivie d'une convolution point à point. Cette approche réduit significativement le nombre de paramètres et les coûts computationnels tout en maintenant des performances élevées [CHOLLET 2017]. La convolution en profondeur (depthwise convolution) applique un filtre unique à chaque canal d'entrée, capturant des motifs locaux spécifiques dans chaque canal individuel [HOWARD et al. 2017]. Ensuite, la convolution point à point

(pointwise convolution), souvent implémentée comme une convolution 1×1 , combine les résultats de la convolution en profondeur pour extraire des caractéristiques plus abstraites et complexes [SIFRE et MALLAT 2014].

En termes de traitement du signal, cette méthode est analogue à l'application de filtres passe-bas ou passe-haut spécifiques à différentes bandes de fréquence avant de les combiner, une technique couramment utilisée pour analyser des signaux complexes [OPPENHEIM, SCHAFER et BUCK 1999]. Les 1D Separable CNN sont particulièrement efficaces pour les tâches nécessitant une analyse fine de motifs temporels ou séquentiels, comme la reconnaissance de la parole, la détection d'anomalies dans des séries temporelles, et l'analyse biométrique [RAVANELLI et BENGIO 2018]. En réduisant le nombre de paramètres, ces réseaux permettent également de construire des modèles plus légers et rapides, adaptés aux dispositifs avec des ressources limitées comme les smartphones et les capteurs embarqués [S. MEHTA et al. 2018]. Par rapport aux CNN classiques, les 1D Separable CNN offrent une meilleure efficacité computationnelle tout en conservant une capacité d'apprentissage robuste et flexible, faisant d'eux un outil précieux dans l'arsenal des techniques de traitement des données unidimensionnelles [GOODFELLOW, BENGIO et COURVILLE 2016].

A.6 RNN

Un réseau de neurones récurrents (RNN) [SHERSTINSKY 2020] est un type de réseau de neurones artificiels qui est particulièrement bien adapté au traitement de données séquentielles. Contrairement aux réseaux de neurones classiques où l'information circule uniquement de l'entrée vers la sortie, les RNN ont des connexions récurrentes qui leur permettent de conserver une mémoire des états précédents pendant le traitement de la séquence. Les RNN sont conçus pour gérer efficacement des séquences de longueurs variables en prenant en compte les interactions temporelles entre les éléments de la séquence. Cela les rend utiles dans une variété de tâches, telles que la modélisation de langage naturel, la traduction automatique, la génération de texte, l'analyse de séries temporelles, *etc.* Le fonctionnement d'un RNN repose sur l'utilisation de boucles récurrentes dans le réseau, qui permettent de réinjecter les sorties précédentes en tant qu'entrées pour les étapes suivantes. Ainsi, à chaque pas de temps, le réseau prend en compte à la fois l'entrée actuelle et l'état caché (représentant l'information passée) pour générer une sortie et mettre à jour son état caché pour la prochaine étape. Cette capacité à conserver une mémoire

des états précédents permet aux RNN de capturer des dépendances à long terme dans les données séquentielles. Cependant, les RNN traditionnels peuvent souffrir du problème de disparition du gradient, où les gradients se propageant à travers les multiples étapes de récurrence peuvent devenir très petits, rendant l'apprentissage de dépendances à long terme difficile.

A.6.1 GRU

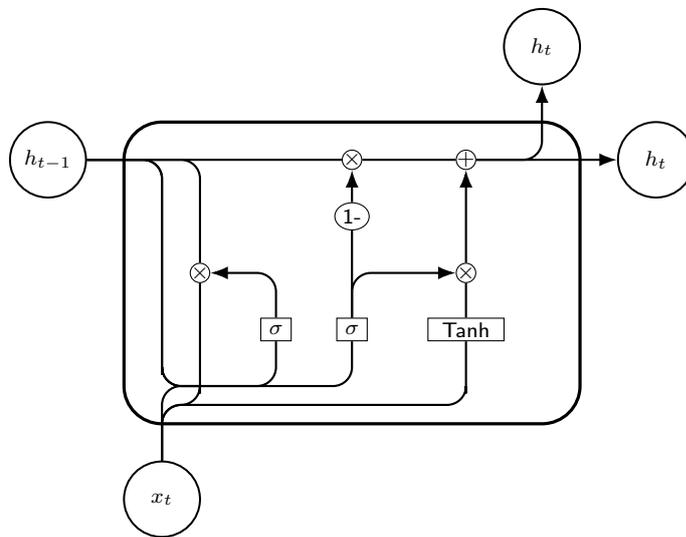


FIGURE A.4 – Cellule GRU.

Une unité récurrente à portes (GRU) [CHO et al. 2014] constitue un type de réseau récurrent conçu pour mieux capturer les dépendances dans les séquences de données. Contrairement aux RNN traditionnels, les GRU disposent de mécanismes de porte qui contrôlent le flux d'informations à travers les cellules. Chaque cellule GRU (représentée à la figure A.4) contient une porte de réinitialisation qui décide quelles informations passées doivent être oubliées et une porte de mise à jour qui régule la quantité d'informations nouvellement calculées à conserver. Ces mécanismes de porte permettent aux GRU de gérer efficacement les problèmes de disparition ou d'explosion du gradient, qui peuvent survenir lors de l'entraînement des réseaux de neurones récurrents traditionnels. De plus, les GRU sont capables de conserver et d'utiliser des informations sur des périodes de temps plus longues, ce qui les rend particulièrement efficaces pour modéliser des séquences temporelles complexes.

A.6.2 LSTM

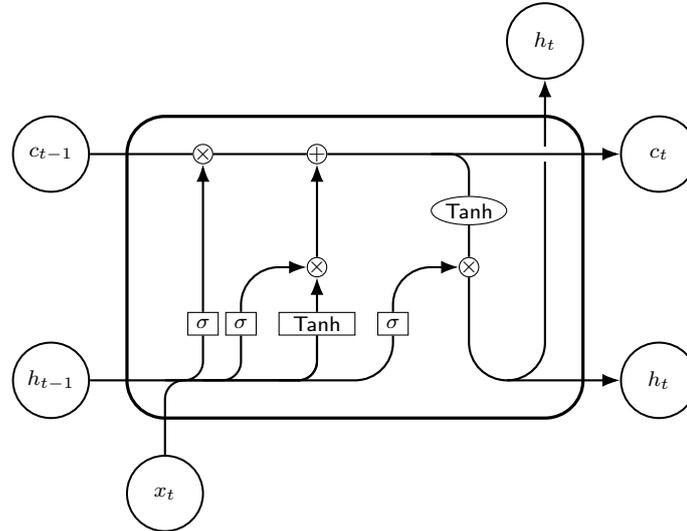


FIGURE A.5 – Cellule LSTM.

Les LSTM [HOCHREITER et SCHMIDHUBER 1997], sont une variante des réseaux de neurones récurrents conçus pour résoudre le problème de la disparition du gradient et pour capturer les dépendances à court et long terme dans les séquences de données. Les LSTM possèdent une architecture plus complexe, comprenant des cellules mémoire (voir figure A.5) avec trois portes distinctes : la porte d'oubli, la porte d'entrée et la porte de sortie. La porte d'oubli contrôle le degré auquel les informations précédemment stockées dans la cellule mémoire doivent être oubliées ou conservées. La porte d'entrée permet de réguler l'ajout de nouvelles informations dans la cellule mémoire. Enfin, la porte de sortie détermine quelles informations de la cellule mémoire doivent être transmises en sortie du LSTM.

Cette architecture permet aux LSTM de conserver des informations sur des périodes de temps étendues, tout en régulant soigneusement le flux d'informations à travers les cellules. Ainsi, les LSTM sont capables de modéliser efficacement les dépendances à long terme dans les séquences de données, ce qui les rend particulièrement adaptés à des tâches telles que la prédiction séquentielle, la traduction automatique et l'analyse des séquences temporelles.

Les LSTM ont été appliqués avec succès dans divers contextes sportifs pour analyser et prédire des séquences de données temporelles complexes. L'analyse de données d'entraînement et de performance des athlètes a permis de détecter des schémas subtils et de

prédire les performances futures [DIJKSTRA et J. SMITH 2019]. En analysant les séquences temporelles des performances passées des équipes et des joueurs, les LSTM peuvent être utilisés pour prédire les résultats de matchs dans divers sports [BREFELD et GAEDCKE 2018]. En modélisant les réponses physiologiques des athlètes à l'entraînement et à la récupération, les LSTM peuvent aider à optimiser les programmes d'entraînement et à minimiser les risques de blessures [VESCOVI et al. 2018]. Les LSTM peuvent être utilisés pour analyser les schémas tactiques et les stratégies de jeu dans des sports d'équipe comme le football ou le basketball, en examinant les séquences d'événements au fil du temps [XUE et al. 2020].

Les succès des LSTM est confirmé sur des données de jeu vidéo. La nature chronologique d'un match de jeu vidéo et la popularité des méthodes de réseaux de neurones ont conduit à une utilisation importante des techniques de réseaux de neurones récurrents, par exemple pour prédire l'issue du match [LAN et al. 2018; QI, SHU et J. TANG 2018; SILVA, PAPPÀ et CHAIMOWICZ 2018]. Ce type de réseau peut aider à comprendre les phases de préparation stratégique du jeu (choix/interdiction des héros) [YU, ZHU et SUN 2019]. Au fur et à mesure que le jeu progresse, une tâche importante est la recommandation d'équipements, soutenue par un LSTM [Q. YAO, LIAO et JIN 2018] qui modélise l'intérêt du joueur à partir de séquences de matchs historiques. Un RNN peut également prédire les performances d'un joueur sur la base des performances précédentes [WHITE et ROMANO 2020].

RÉSULTATS SUPPLÉMENTAIRES SUR L'ATTENTION POUR L'ANALYSE DYNAMIQUE D'ÉQUIPE DANS DotA2

Cette annexe complète les résultats présentés au Chapitre 11 sur l'analyse de la couche d'attention pour la prédiction d'événements dans DotA2. Ces résultats sont déclinés selon les différentes configurations d'indices géométriques : complète (incluant les distances aux bases) ou relative (sans distances aux bases mais avec la distance entre les deux barycentres).

Configuration complète d'indices

La Figure B.1 montre la répartition de l'attention entre les indices de la configuration complète, selon que l'événement à prédire est *kill* ou *noKill*. Lors d'un événement de mort, l'attention sur *distFountAlly*, *distFountEnemy* et *dispersion* montre des valeurs plus élevées, avec une distribution large. *area* et *diameter* enregistrent une valeur plus faible. Quand il s'agit d'un événement *noKill*, l'attention est portée sur *area*, *diameter* et *distBarycentre*. La distribution de l'attention est plus stable lors d'un événement *noKill*.

Pour prédire un événement *kill*, l'attention est donc attirée sur les indices *distFountAlly*, *distFountEnemy* et *dispersion* qui sont caractéristiques de la dynamique d'équipe. Nous pensons que considérer les deux distances absolues permet au réseau de situer le polygone sur la carte et d'identifier les zones dans lesquelles les événements de kill surviennent régulièrement. Pour prédire un événement *noKill*, le réseau est plus attentif à l'aire, au diamètre et à la distance entre les deux barycentres, révélateurs de la distance entre les équipes et de leur contrôle du terrain.

La Figure B.2 montre l'évolution des poids d'attention 30 s avant un kill. On observe un changement environ 5 s avant un événement de mort. La Figure B.3 montre l'évolution

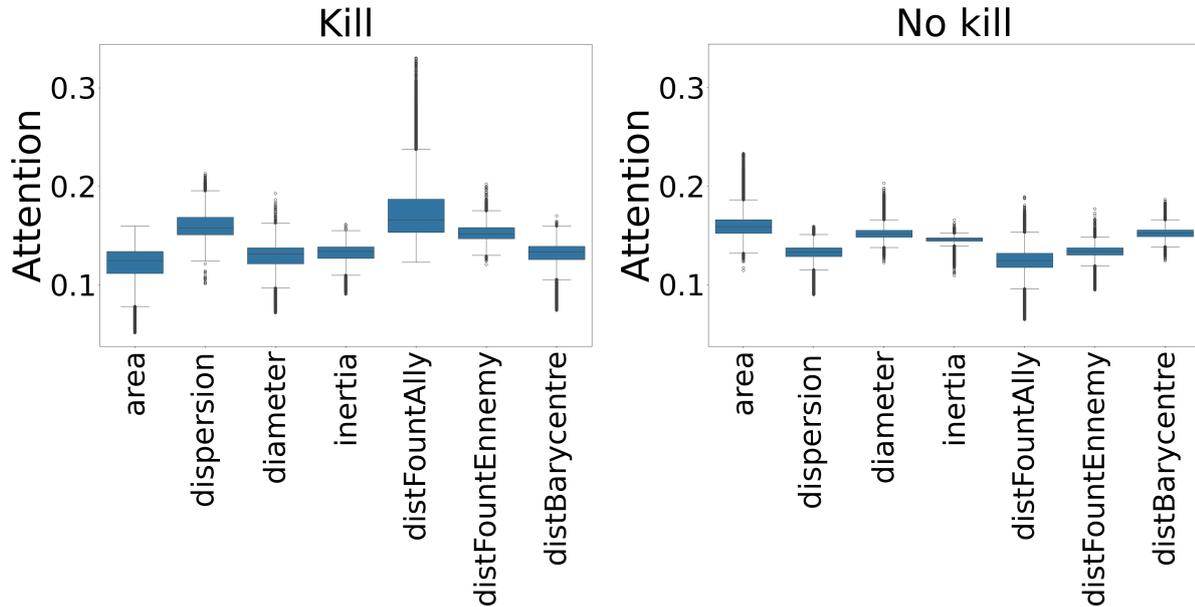


FIGURE B.1 – Attention pour la configuration complète d'indices.

des valeurs des indices 30 s avant kill. Nous pouvons clairement constater que l'équipe, pour réaliser un *kill*, a tendance à se regrouper, ralentir son mouvement (diminution de l'inertie) mais aussi à augmenter la distance avec la base adverse et réduire la distance avec la base allié. Ce mécanisme peut indiquer que l'équipe va initier le combat et forcer l'équipe adverse à la suivre dans la zone du terrain qu'elle contrôle pour s'aider des bâtiments, des creeps, ou des créatures neutres.

Configuration relative d'indices

La Figure B.4 montre la répartition de l'attention, selon que l'événement à prédire est *kill* ou *noKill*. Lors d'un événement de mort, *dispersion*, *diameter* et *distBarycentre* montrent des valeurs d'attention plus élevée : le réseau est sensible au contexte indiqué par les positions relatives des équipes. *area* et *inertia* enregistrent une valeur plus faible. Quand il s'agit d'un évènement *noKill*, la tendance s'inverse.

La Figure B.5 montre l'évolution des poids d'attention 30 s avant un kill pour la combinaison relative d'indice. On observe un changement dans l'attention accordée aux indices environ 10 s avant un évènement de mort. De plus, on observe une nette variation dans l'attention accordée aux indices de dispersion, de diamètre et de distance entre les barycentres.

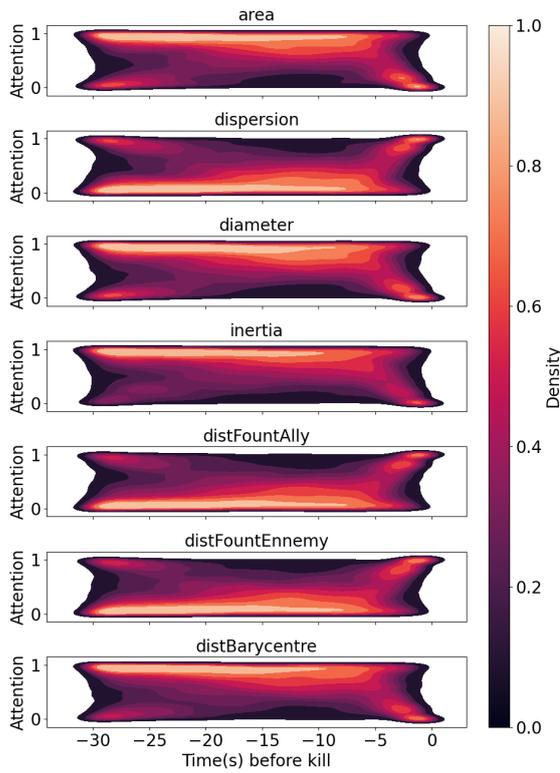


FIGURE B.2 – Distribution de l'attention pour la configuration complète 30 s avant un kill.

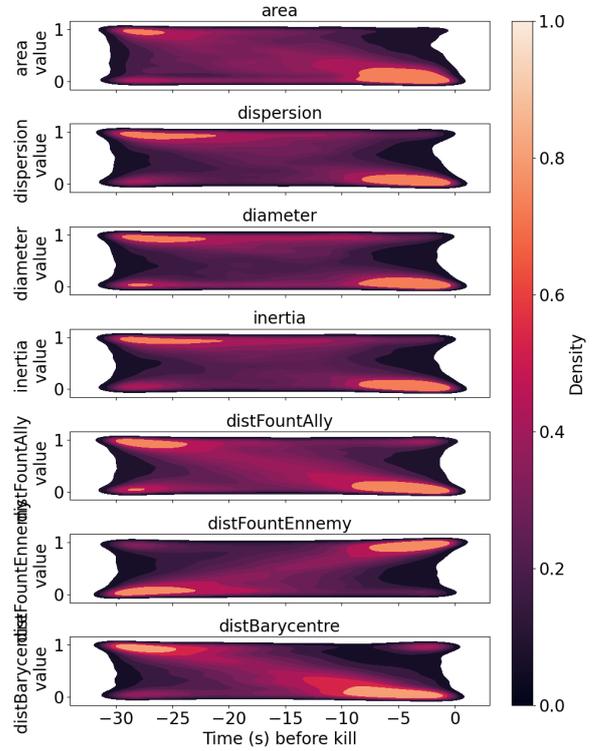


FIGURE B.3 – Distribution des valeurs d'attribut pour la configuration complète 30 s avant un kill.

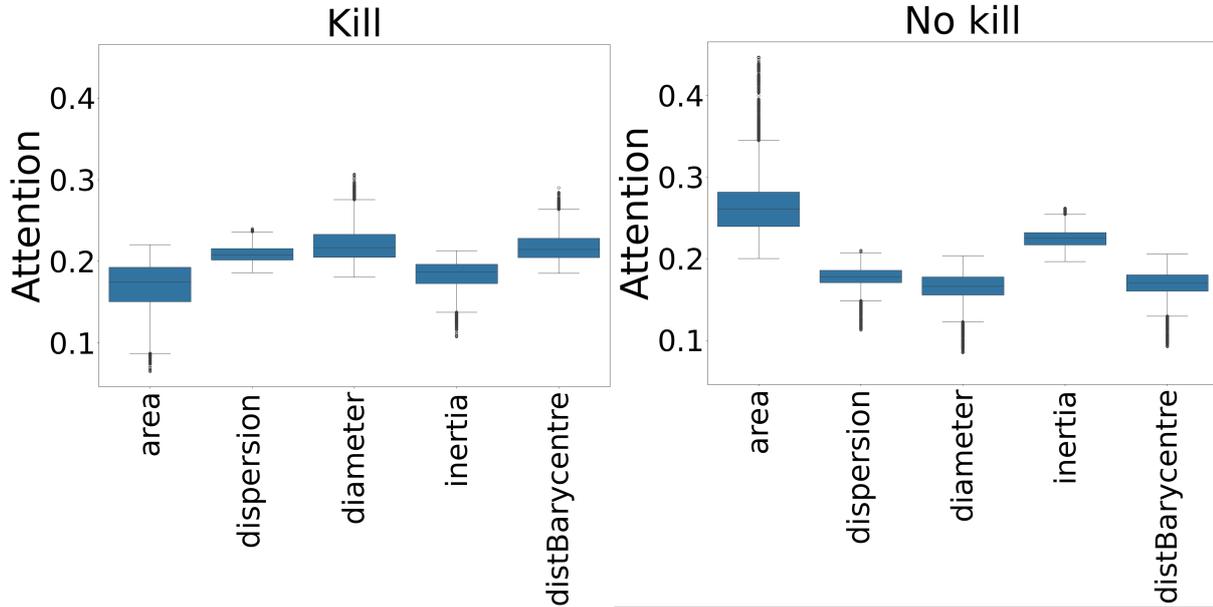


FIGURE B.4 – Attention pour la combinaison relative d'indices.

La Figure B.6 montre l'évolution des valeurs des indices d'entrée 30 s avant un kill. On observe que les valeurs des indices évoluent dans le temps. En outre, nous pouvons clairement constater que l'équipe a tendance à se regrouper, ralentir son mouvement (diminution de l'inertie) et à diminuer sa distance avec le polygone adverse pour réaliser un *kill*.

Conclusion

Notre analyse met en lumière les configurations d'indices géométriques pour la prédiction des événements dans DotA2. La configuration complète, qui inclut les distances aux bases, permet au modèle de localiser les zones critiques sur la carte où les événements de type *kill* sont plus susceptibles de se produire, en se focalisant sur des indices comme *distFountAlly*, *distFountEnemy* et *dispersion*. En revanche, pour la configuration relative, qui exclut les distances aux bases, l'attention du modèle se concentre davantage sur les relations spatiales entre les équipes, notamment la *dispersion*, le *diameter*, et la *distance entre les barycentres*. Dans les deux cas, l'évolution des poids d'attention avant un événement *kill* suggère une dynamique d'équipe où le regroupement et le contrôle de la position jouent un rôle important. Ces observations confirment que les distances et les relations spatiales sont des indicateurs clés pour anticiper les événements de jeu dans DotA2.

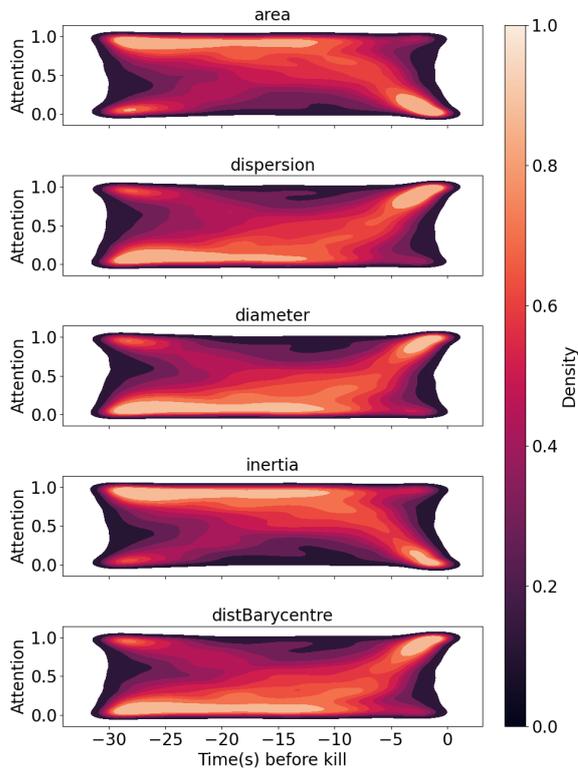


FIGURE B.5 – Configuration relative : distribution de l'attention 30 s avant un kill.

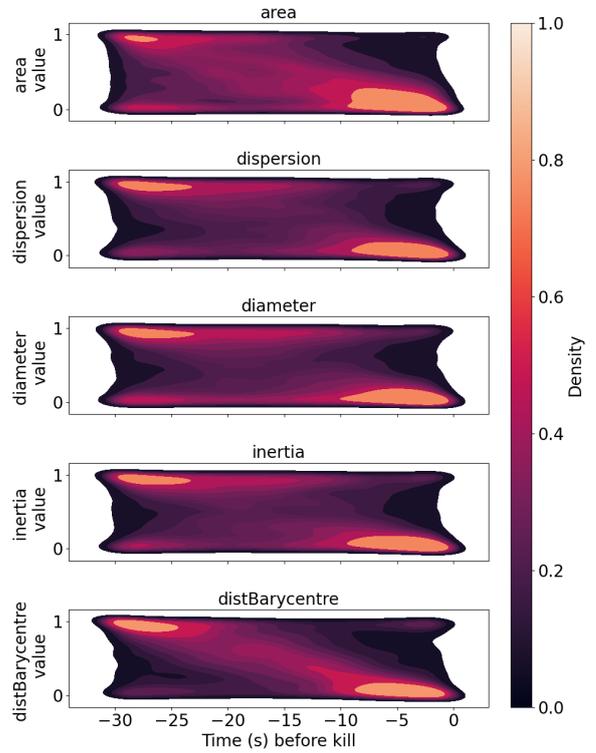


FIGURE B.6 – Configuration relative : distribution de la valeur des indices 30 s avant un kill.

BIBLIOGRAPHIE

- ABNAR, Samira et Willem ZUIDEMA (2020), « Quantifying attention flow in transformers », in : *arXiv preprint arXiv :2005.00928*.
- AGRAWAL, Rakesh et Ramakrishnan SRIKANT (1994), « Fast algorithms for mining association rules », in : *Proceedings of the 20th International Conference on Very Large Data Bases*, p. 487-499.
- AGRESTI, Alan (2018), *An introduction to categorical data analysis*, John Wiley & Sons.
- AHMAD, Sabbir et al. (2019), « Modeling Individual and Team Behavior through Spatio-temporal Analysis », in : *Proceedings of the Annual Symposium on Computer-Human Interaction in Play*, p. 601-612.
- AKOGLU, Leman, Hanghang TONG et Danai KOUTRA (2015), « Graph-Based Anomaly Detection and Description : A Survey », in : *Data Mining and Knowledge Discovery* 29.3, p. 626-688.
- ANDRIENKO, Gennady et al. (2016), « Coordinate transformations for characterization and cluster analysis of spatial configurations in football », in : *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, Springer, p. 27-31.
- ANZER, Gabriel et Pascal BAUER (2021), « A goal scoring probability model for shots based on synchronized positional and event data in football (soccer) », in : *Frontiers in Sports and Active Living* 3, p. 624475.
- ATKINSON, Michael A, Richard P LIPPMANN et Kush R VARSHNEY (2013), « An algebra for encoding temporal graph structure », in : *Information Sciences* 220, p. 1-17.
- BAER, Thomas, Brian CJ MOORE et Stuart GATEHOUSE (1993), « Spectral contrast enhancement of speech in noise for listeners with sensorineural hearing impairment : Effects on intelligibility, quality, and response times », in : t. 30, Citeseer, p. 49-49.
- BAŞBUĞ, Ahmet Melih et Mustafa SERT (2019), « Analysis of deep neural network models for acoustic scene classification », in : p. 1-4.
- BELLO, Juan Pablo et al. (2005), « A tutorial on onset detection in music signals », in : t. 13, 5, IEEE, p. 1035-1047.

- BERGER-WOLF, Tanya Y et Jude S SHAFLIK (2007), « A framework for graph compression and mining in domains with binary edge labels », in : *Proceedings of the 22nd national conference on Artificial intelligence - Volume 1*, AAAI Press, p. 313-319.
- BERLINGERIO, Michele, Fabio PINELLI et Michele Andrea TIZZONI (2012), « Characterizing the Dynamics of Urban Areas by Space-Time Graphs of Social Network Data », in : *Data Mining and Knowledge Discovery* 24.3, p. 515-544.
- BIALKOWSKI, Alina et al. (2014), « Large-scale analysis of soccer matches using spatio-temporal tracking data », in : *2014 IEEE International Conference on Data Mining*, IEEE, p. 725-730.
- BIBAL, Adrien et al. (2022), « Is attention explanation ? an introduction to the debate », in : *Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics (Volume 1 : Long Papers)*, p. 3889-3900.
- BLOCK, Florian et al. (2018), « Narrative bytes : Data-driven content production in esports », in : *Proceedings of the 2018 ACM International Conference on Interactive Experiences for TV and Online Video*, p. 29-41.
- BREFELD, Ulf et Felix GAEDCKE (2018), « Forecasting Sports Outcomes : Exploiting Game and Player Characteristics for Improved Predictions », in : *International Conference on Advances in Social Networks Analysis and Mining*, IEEE, p. 437-442.
- BREFELD, Ulf, Jan LASEK et Sebastian MAIR (2019), « Probabilistic movement models and zones of control », in : *Machine Learning* 108.1, p. 127-147.
- BREIMAN, L., J. H. FRIEDMAN, R. A. OLSHEN et C. J. STONE (1984), *Classification and regression trees*, CRC press.
- BREIMAN, Leo (2001), « Random forests », in : *Machine learning* 45.1, p. 5-32.
- CARDINALE, Marco, Rodney WHITELEY, Ahmed Abdelrahman HOSNY et Nebojsa POPOVIC (2017), « Activity profiles and positional differences of handball players during the World Championships in Qatar 2015 », in : *International journal of sports physiology and performance* 12.7, p. 908-915.
- CASTEIGTS, Arnaud, Paola FLOCCHINI, Walter QUATTROCIOCCHI et Nicola SANTORO (2012), « Time-varying graphs and dynamic networks », in : *International Journal of Parallel, Emergent and Distributed Systems* 27.5, p. 387-408.
- CASTRONOVA, Edward (2020), « The Surprising Impact of Professional Sports on Esports », in : *Journal of Sports Economics* 21.7, p. 705-717.
- CAVADENTI, Olivier, Victor CODOCEDO, Jean-François BOULICAUT et Mehdi KAYTOUE (oct. 2016), « What did I do Wrong in my MOBA Game ? : Mining Patterns Discri-

- minating Deviant Behaviours », in : *International Conference on Data Science and Advanced Analytics*, Montréal, Canada, URL : <https://hal.archives-ouvertes.fr/hal-01388321>.
- CAVUS, Mustafa et Przemysław BIECEK (2022), *Explainable expected goal models for performance analysis in football analytics*, DOI : 10.48550/ARXIV.2206.07212, URL : <https://arxiv.org/abs/2206.07212>.
- CHEN, Juan et al. (2013), « A survey of qualitative spatial representations », in : *Knowledge Engineering Review* 30.1, p. 106-136.
- CHO, Kyunghyun et al. (2014), « Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation », in : *arXiv preprint arXiv :1406.1078*.
- CHOLLET, François (2017), « Xception : Deep learning with depthwise separable convolutions », in : *Proceedings of the IEEE conference on computer vision and pattern recognition*, p. 1251-1258.
- CHU, Wei-Ta et Yung-Chieh CHOU (2015), « Event detection and highlight detection of broadcasted game videos », in : *Computational Models of Social Interactions*, p. 1-8.
- (2017), « On broadcasted game video analysis : event detection, highlight detection, and highlight forecast », in : *Multimedia Tools and Applications* 76.7, p. 9735-9758.
- CINTIA, Paolo, Michele COSCIA et Luca PAPPALARDO (2016), « The Haka network : Evaluating rugby team performance with dynamic graph analysis », in : *2016 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*, IEEE, p. 1095-1102.
- Corsi (p. d.), [https://en.wikipedia.org/wiki/Corsi_\(statistic\)](https://en.wikipedia.org/wiki/Corsi_(statistic)), Accessed : 2023-03-02.
- CROCCO, Marco, Marco CRISTANI, Andrea TRUCCO et Vittorio MURINO (2016), « Audio surveillance : A systematic review », in : *ACM Computing Surveys (CSUR)* 48.4, p. 1-46.
- DAVIS, Stephen et Paul MERMELSTEIN (1980), « Mel Frequency Cepstral Coefficients (MFCCs) », in : *Speech and Audio Signal Processing*.
- DEJA, Dominik et Mateusz MYŚLAK (juil. 2015), « Topological Clues for Predicting Outcomes of Multiplayer Online Battle Arena Games », in : *IADIS*.
- DIJKSTRA, Peter et John SMITH (2019), « Using LSTMs to predict football matches », in : *Journal of Sports Analytics* 5.1, p. 45-56.
- DIXON, Simon (2001), « Automatic tempo and beat analysis of acoustic musical signals », in : *Journal of New Music Research*, t. 30, 1, p. 39-58.

- DODGE, Somayeh, Robert WEIBEL et Anna-Katharina LAUTENSCHÜTZ (2008), « Towards a taxonomy of movement patterns », in : *Information visualization 7.3-4*, p. 240-252.
- DOSBAYEV, Zhandos et al. (2021), « Audio surveillance : detection of audio-based emergency situations », in : p. 413-424.
- DRACHEN, Anders et al. (2014), « Skill-based differences in spatio-temporal team behaviour in defence of the ancients 2 (dota 2) », in : *2014 IEEE Games Media Entertainment*, IEEE, p. 1-8.
- EKIN, Ahmet, A Murat TEKALP et Rajiv MEHROTRA (2003), « Automatic soccer video analysis and summarization », in : *IEEE Transactions on Image processing 12.7*, p. 796-807.
- ELKAN, Charles (2001), « The foundations of cost-sensitive learning », in : *International joint conference on artificial intelligence*, t. 17, 1, Lawrence Erlbaum Associates Ltd, p. 973-978.
- FACULTY, Washington (2023), *Lecture 5 : Prediction*, URL : http://faculty.washington.edu/yenchic/20A_stat512/Lec5_prediction.pdf.
- FAIRCHILD, Alexander, Konstantinos PELECHRINIS et Marios KOKKODIS (2018), « Spatial analysis of shots in MLS : A model for expected goals and fractal dimensionality », in : *Journal of Sports Analytics 4.3*, p. 165-174.
- FAWCETT, Tom (2003), *ROC Graphs : Notes and Practical Considerations for Researchers*, Technical Report HPL-2003-4, HP Laboratories.
- Fenwick (p. d.), [https://en.wikipedia.org/wiki/Fenwick_\(statistic\)](https://en.wikipedia.org/wiki/Fenwick_(statistic)), Accessed : 2023-03-02.
- FEUERHAKE, Udo (2016), « Recognition of repetitive movement patterns—the case of football analysis », in : *ISPRS International Journal of Geo-Information 5.11*, p. 208.
- FEUERHAKE, Udo et Monika SESTER (2013), « Mining group movement patterns », in : *Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*, p. 520-523.
- FLOUVAT, Frédéric (2019), *Extraction de motifs spatio-temporels : co-localisations, séquences et graphes dynamiques attribués*, Habilitation à Diriger les Recherches, Université de la Nouvelle-Calédonie.
- FOURNIER-VIGER, Philippe, Ganghuan HE et al. (2020), « A survey of pattern mining in dynamic graphs », in : *Wiley Interdisciplinary Reviews : Data Mining and Knowledge Discovery 10.6*, e1372.

- FOURNIER-VIGER, Philippe, Jerry Chun-Wei LIN, Antonio GOMARIZ et al. (2016), « The SPMF open-source data mining library version 2 », in : *Machine Learning and Knowledge Discovery in Databases : European Conference, ECML PKDD 2016, Riva del Garda, Italy, September 19-23, 2016, Proceedings, Part III 16*, Springer, p. 36-40.
- FOURNIER-VIGER, Philippe, Jerry Chun-Wei LIN, Rage Uday KIRAN et al. (2017), « A survey of sequential pattern mining », in : *Data Science and Pattern Recognition 1.1*, p. 54-77.
- FOURNIER-VIGER, Philippe, Roger NKAMBOU et Engelbert Mephu NGUIFO (2008), « A knowledge discovery framework for learning task models from user interactions in intelligent tutoring systems », in : *Mexican international conference on artificial intelligence*, Springer, p. 765-778.
- FRANZONI, Valentina, Giulio BIONDI et Alfredo MILANI (2020), « Emotional sounds of crowds : spectrogram-based analysis using deep learning », in : *Multimedia tools and applications 79.47*, p. 36063-36075.
- FRENCKEN, Wouter, Koen LEMMINK, Nico DELLEMAN et Chris VISSCHER (2011), « Oscillations of centroid position and surface area of soccer teams in small-sided games », in : *European Journal of Sport Science 11.4*, p. 215-223.
- FRIEDMAN, Jerome H (2001), « Greedy function approximation : A gradient boosting machine », in : *Annals of statistics 29.5*, p. 1189-1232.
- FU, Tianyu, Chiyue WEI, Yu WANG et Rex YING (2024), « Desco : Towards generalizable and scalable deep subgraph counting », in : *Proceedings of the 17th ACM International Conference on Web Search and Data Mining*, p. 218-227.
- FUJIMURA, Akira et Kokichi SUGIHARA (2005), « Geometric analysis and quantitative evaluation of sport teamwork », in : *Systems and Computers in Japan 36.6*, p. 49-58.
- FUJISHIMA, T. (1999), « Chroma feature analysis and synthesis », in : *Proceedings of the International Computer Music Conference*.
- FUKUSHIMA, Kunihiko (1980), « Neocognitron : A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position », in : *Biological cybernetics 36.4*, p. 193-202.
- GERMANO, Massimo (1992), « Turbulence : the filtering approach », in : *Journal of Fluid Mechanics 238*, p. 325-336.
- GHAEMMAGHAMI, S, Mohamed DERICHE et Boualem BOASHASH (1997), « A new approach to pitch and voicing detection through spectrum periodicity measurement », in : 2, p. 743-746.

- GIONIS, Aristides, Heikki MANNILA et Panayiotis TSAPARAS (2007), « Clustering Aggregation », in : *ACM Transactions on Knowledge Discovery from Data (TKDD)* 1.1, p. 1-30.
- GOODFELLOW, Ian, Yoshua BENGIO et Aaron COURVILLE (2016), *Deep learning*, MIT press.
- GOTO, Masanori et Joseph RYNKIEWICZ (2019), « Performance indicators and team styles in Dota 2 », in : *International Journal of Performance Analysis in Sport* 19.6, p. 1120-1131.
- GOUYON, Fabien, François PACHET, Olivier DELERUE et al. (2000), « On the use of zero-crossing rate for an application of classification of percussive sounds », in : *Proceedings of the COST G-6 conference on Digital Audio Effects (DAFX-00)*, Verona, Italy, t. 5, p. 16.
- GREY, John M. et James W. GORDON (1977), « Spectral centroid and timbre in complex, multiple instrumental textures », in : *The Journal of the Acoustical Society of America* 61.5, p. 1270-1277.
- GRUNZ, Andreas, Daniel MEMMERT et Jürgen PERL (2009), « Analysis and simulation of actions in games by means of special self-organizing maps », in : *International Journal of Computer Science in Sport* 8.1, p. 22-37.
- (2012), « Tactical pattern recognition in soccer games by means of special self-organizing maps », in : *Human movement science* 31.2, p. 334-343.
- GUDMUNDSSON, Joachim et Michael HORTON (2017), « Spatio-temporal analysis of team sports », in : *ACM Computing Surveys (CSUR)* 50.2, p. 1-34.
- HAASE, Jens et Ulf BREFELD (2013), « Finding Similar Movements in Positional Data Streams. », in : *MLSA@ PKDD/ECML*, p. 49-57.
- HAMARI, J. et M. SJÖBLOM (2017), « What is eSports and why do people watch it? », in : *Internet Research* 27.2, p. 211-232.
- HAN, Jiawei, Jian PEI et Yiwen YIN (2000), « Mining frequent patterns without candidate generation », in : *ACM sigmod record* 29.2, p. 1-12.
- Handball playbook* (2021), Amphora.
- HANSEN, Clint, Fernando SANZ-LOPEZ et al. (2017), « Performance analysis of male handball goalkeepers at the World Handball championship 2015 », in : *Biology of sport* 34.4, p. 393.
- HANSEN, Clint, R WHITELEY et al. (2019), « A video-based analysis to classify shoulder injuries during the Handball World Championships 2015 », in : *Sportverletzung*

- Sportschaden : Organ der Gesellschaft für Orthopädisch-traumatologische Sportmedizin* 33.1, p. 30-35.
- HASSAN, Amr, Norbert SCHRAPP, Wael RAMADAN et Markus TILP (2017), « Evaluation of tactical training in team handball by means of artificial neural networks », in : *Journal of sports sciences* 35.7, p. 642-647.
- HATTINGH, W., L. VAN DEN BERG et A. BEVAN-DYE (2024), « The "why" behind generation Y amateur gamers' ongoing eSports gameplay intentions », in : *International Journal of Sports Marketing and Sponsorship* 25.1, p. 67-87.
- HAURI, Sandro, Nemanja DJURIC, Vladan RADOSAVLJEVIC et Slobodan VUCETIC (2021), « Multi-modal trajectory prediction of NBA players », in : *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, p. 1640-1649.
- HEROLD, Mat et al. (2019), « Machine learning in men's professional football : Current applications and future directions for improving attacking play », in : *International Journal of Sports Science & Coaching* 14.6, p. 798-817, DOI : 10.1177/1747954119879350, eprint : <https://doi.org/10.1177/1747954119879350>, URL : <https://doi.org/10.1177/1747954119879350>.
- HEWITT, James Henry et Oktay KARAKUŞ (2023), *A Machine Learning Approach for Player and Position Adjusted Expected Goals in Football (Soccer)*, DOI : 10.48550/ARXIV.2301.13052, URL : <https://arxiv.org/abs/2301.13052>.
- HIMMELSTEIN, Matthew et Joshua SHAPIRO (2020), « Esports : A New Era of Sport with Opportunities for Sports Scientists », in : *International Journal of Sports Physiology and Performance* 15.4, p. 485-487.
- HOCHREITER, Sepp et Jürgen SCHMIDHUBER (1997), « Long short-term memory », in : *Neural computation* 9.8, p. 1735-1780.
- HOLME, Petter (2015), « Modern temporal network theory : a colloquium », in : *The European Physical Journal B* 88.9, p. 234.
- HOSMER JR, David W, Stanley LEMESHOW et Rodney X STURDIVANT (2013), *Applied logistic regression*, John Wiley & Sons.
- HOWARD, Andrew G et al. (2017), « Mobilenets : Efficient convolutional neural networks for mobile vision applications », in : *arXiv preprint arXiv :1704.04861*.
- INGALALLI, Vijay, Dino IENCO et Pascal PONCELET (2018), « Mining frequent subgraphs in multigraphs », in : *Information Sciences* 451, p. 50-66.
- JAIN, Sarthak et Byron C WALLACE (2019), « Attention is not explanation », in : *arXiv preprint arXiv :1902.10186*.

- JANG, W.W. et al. (2024), « What makes esports consumers watch streamers' esports live-streaming contents? Extending the theory of planned behavior », in : *International Journal of Sports Marketing and Sponsorship* 25.2, p. 288-309.
- JOHNSON, Todd P (2020), « An Introduction to Esports Data Analytics », in : *E-Sports Performance and Analytics*, Springer, Cham, p. 1-21.
- JONSSON, Gudberg K et al. (2010), « Application of T-pattern detection and analysis in sports research », in : *The Open Sports Sciences Journal* 3.1.
- KAMATH, Raghavendra S, Sung H CHOI, Sutanay CHOUDHURY et Viktor K PRASANNA (2014), « Exploiting Temporal and Structural Locality to Enhance Dynamic Graph Analysis », in : *Proceedings of the 28th International Conference on Supercomputing*, ACM, p. 351-360.
- KATONA, Adam et al. (2019), « Time to Die : Death Prediction in Dota 2 using Deep Learning », in : *2019 IEEE Conference on Games (CoG)*, IEEE, p. 1-8.
- KEMPE, Matthias, Andreas GRUNZ et Daniel MEMMERT (2015), « Detecting tactical patterns in basketball : comparison of merge self-organising maps and dynamic controlled neural networks », in : *European journal of sport science* 15.4, p. 249-255.
- KHALIL, Ruhul Amin et al. (2019), « Speech emotion recognition using deep learning techniques : A review », in : *IEEE access* 7, p. 117327-117345.
- KIM, Hyunsung et al. (2022), « SoccerCPD : Formation and Role Change-Point Detection in Soccer Matches Using Spatiotemporal Tracking Data », in : *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, p. 3146-3156.
- KIM, S. (juil. 2004), « Voronoi Analysis of a Soccer Game », in : *Nonlinear Analysis : Modelling and Control* 9.3, p. 233-240, DOI : 10.15388/NA.2004.9.3.15154, URL : <https://www.journals.vu.lt/nonlinear-analysis/article/view/15154>.
- KLAPURI, Anssi (2004), « Signal processing methods for the automatic transcription of music », in : Tampere University of Technology Finland.
- KOHAVI, Ron et George H JOHN (1998), « The wrapper approach », in : *Feature extraction, construction and selection*, Springer, p. 33-50.
- KOHONEN, Teuvo (1982), « Self-organized formation of topologically correct feature maps », in : *Biological cybernetics* 43.1, p. 59-69.
- KOKKINAKIS, Athanasios et al. (2020), « DAX : Data-Driven Audience Experiences in Esports », in : *Proceedings of ACM International Conference on Interactive Media Experience (IMX) 2020*, Association for Computing Machinery (ACM), p. 1-12.

- KRIZHEVSKY, Alex, Ilya SUTSKEVER et Geoffrey E HINTON (2012), « Imagenet classification with deep convolutional neural networks », in : *Advances in neural information processing systems*, p. 1097-1105.
- KVELADZE, Irakli, Prithwish BASU et Dinesh MANOCHA (2018), « Voronoi-based analysis of fan dispersion in sports stadiums », in : *IEEE Transactions on Computational Social Systems* 5.2, p. 467-478.
- LAGO-BALLESTEROS, Joaquin et Carlos LAGO-PEÑAS (2010), « Performance in team sports : Identifying the keys to success in soccer », in : *Journal of Human kinetics* 25.2010, p. 85-91.
- LAN, Xuan et al. (2018), « A player behavior model for predicting win-loss outcome in MOBA games », in : *International Conference on Advanced Data Mining and Applications*, Springer, p. 474-488.
- LAUBE, Patrick, Marc van KREVELD et Stephan IMFELD (2005), « Finding REMO—detecting relative motion patterns in geospatial lifelines », in : *Developments in spatial data handling*, Springer, p. 201-215.
- LECUN, Yann, Bernhard BOSER et al. (1989), « Backpropagation applied to handwritten zip code recognition », in : *Neural computation* 1.4, p. 541-551.
- LECUN, Yann, Léon BOTTOU, Yoshua BENGIO et Patrick HAFFNER (1998), « Gradient-based learning applied to document recognition », in : *Proceedings of the IEEE* 86.11, p. 2278-2324.
- LEFÈVRE, Bruno, Rachit AGARWAL, Valérie ISSARNY et Vivien MALLET (2021), « Mobile crowd-sensing as a resource for contextualized urban public policies : a study using three use cases on noise and soundscape monitoring », in : *Cities & Health* 5.1-2, p. 179-197.
- LEONTIDIS, Makis et Antonis CONSTANTINO (2016), « Wrapper-based feature selection method for multi-sensor activity recognition », in : *Expert Systems with Applications* 47, p. 54-63.
- LI, Minghua, Rui ZHANG et Zhigang LI (2017), « Graph-Based Techniques for Web Content Mining », in : *IEEE Transactions on Knowledge and Data Engineering* 29.6, p. 1223-1237.
- LI, Quan, Ziming WU et al. (2018), « A multi-phased co-design of an interactive analytics system for MOBA game occurrences », in : *Proceedings of the 2018 Designing Interactive Systems Conference*, p. 1321-1332.

- LI, Quan, Peng XU et al. (2016), « A visual analytics approach for understanding reasons behind snowballing and comeback in MOBA games », in : *IEEE transactions on visualization and computer graphics* 23.1, p. 211-220.
- LI, Ruonan, Rama CHELLAPPA et S. Kevin ZHOU (juin 2009), « Learning multi-modal densities on Discriminative Temporal Interaction Manifold for group activity recognition », in : *2012 IEEE Conference on Computer Vision and Pattern Recognition* 0, p. 2450-2457, DOI : 10.1109/CVPR.2009.5206676.
- LIN, Tsai-Yang, Kuei-Hui CHEN et Han-Hsi LU (2013), « Application of Delaunay triangulation in the analysis of offensive and defensive performance indicators of soccer players », in : *Journal of Physical Education and Sports* 10.1, p. 23-28.
- LIU, Wenbin, Wei LIN, Yong JIANG et Jun ZHOU (2017), « Optimizing player position and movement in basketball games using Voronoi diagrams », in : *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, IEEE, p. 3162-3167.
- LOPES, António, Oleguer CAMERINO, M Teresa ANGUERA et Gudberg K JONSSON (2010), « Ball recovery in the handball tournament of the 2008 Beijing Olympic Games : sequential analysis of positional play as used by the Spanish team's defence », in : *Proceedings of the 7th International Conference on Methods and Techniques in Behavioral Research*, p. 1-4.
- MACDONALD, Brian (2012a), in : *Journal of Quantitative Analysis in Sports* 8.3, DOI : doi:10.1515/1559-0410.1447, URL : <https://doi.org/10.1515/1559-0410.1447>.
- (2012b), « An expected goals model for evaluating NHL teams and players », in : *Proceedings of the 2012 MIT Sloan Sports Analytics Conference*.
- MADRERO PARDO, Pau (juin 2020a), « Creating a model for expected Goals in football using qualitative player information », thèse de doct., UPC, Facultat d'Informàtica de Barcelona, Departament de Ciències de la Computació, URL : <http://hdl.handle.net/2117/328922>.
- (2020b), « Creating a model for expected goals in football using qualitative player information », mém. de mast., Universitat Politècnica de Catalunya.
- MAHMOOD, Ashique Rupam et Richard S SUTTON (2013), « Representation search through generate and test », in : *Workshops at the Twenty-Seventh AAAI conference on artificial intelligence*.
- MAO, Wei, Miaomiao LIU et Mathieu SALZMANN (2020), « History repeats itself : Human motion prediction via motion attention », in : *Computer Vision-ECCV 2020 : 16th*

- European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part XIV 16*, Springer, p. 474-489.
- MARTINETZ, Thomas M, Stanislav G BERKOVICH et Klaus J SCHULTEN (1993), « 'Neural-gas' network for vector quantization and its application to time-series prediction », in : *IEEE transactions on neural networks* 4.4, p. 558-569.
- MAYAFFRE, Damon (2005), « Rôle et place du corpus en linguistique. Réflexions introductives », in : *Actes du colloque JETOU'2005*, Université de Toulouse-Le Mirail, p. 5-17.
- McFEE, Brian et al. (2015), *librosa : Audio and music signal analysis in python*.
- MEHTA, Nishita, Vinayak PANDIT, Mihir PARIKH et Raj SHAH (2019), « A Comparative Study of LSTM and Attention Mechanisms for Named Entity Recognition in Radiology Reports », in : *Journal of Digital Imaging* 32.4, p. 632-640.
- MEHTA, Sachin et al. (2018), « Espnetv2 : A light-weight, power efficient, and general purpose convolutional neural network », in : *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*.
- MONTI, Alessio, Alessia BERTUGLI, Simone CALDERARA et Rita CUCCHIARA (2021), « Dag-net : Double attentive graph neural network for trajectory forecasting », in : *2020 25th International Conference on Pattern Recognition (ICPR)*, IEEE, p. 2551-2558.
- MORA-CANTALLOPS, Marçal et Miguel-Ángel SICILIA (2018), « MOBA games : A literature review », in : *Entertainment computing* 26, p. 128-138.
- MORTELIER, Alexis, Sebastien BOUGLEUX et François RIOULT (2024), « Team Dynamics in DotA2 through Attention Mechanism », in : *11th Workshop on Machine Learning and Data Mining for Sports Analytics – ECML/PKDD 2024*, Vilnius, Lituanie, p. 1-11.
- MORTELIER, Alexis, Boris HELLEU, Wiem BELHEDI et François RIOULT (2024), « Analysis of Enthusiasm Triggers in Competitive Video Games : Overwatch Case Study », in : *IT4PSS – IJCAI 2024*, Jeju, Korea, p. 1-8.
- MORTELIER, Alexis et François RIOULT (sept. 2022a), « Addressing the Complexity of MOBA Games through Simple Geometric Clues », in : *International Conference on Computational Collective Intelligence*, Springer, p. 643-649.
- (jan. 2022b), « Pertinence d'indices géométriques sur les trajectoires pour la prédiction de moments importants », in : *Extraction et Gestion des Connaissances (EGC)-2022*.
- MORTELIER, Alexis, François RIOULT et John KOMAR (2023), « What data should be collected for a good handball Expected Goal model ? », in : *10th Workshop on Machine*

- Learning and Data Mining for Sports Analytics – ECML/PKDD 2023*, Turin, Italy, p. 1-12.
- MORTELIER, Alexis, François RIOULT et John KOMAR (juil. 2024), « Design of a Handball Tactics Observatory Based on Dynamic Sub-Graphs », in : *Proceedings of the International Sports Analytics Conference and Exhibition (ISACE)*, Lecture Notes in Computer Science (LNCS), Paris, France : Springer.
- NEIGER, Vincent, Christophe CREPELLE et Eric FLEURY (2012), « On the structure of changes in dynamic contact networks », in : *2012 Eighth International Conference on Signal Image Technology and Internet Based Systems*, IEEE, p. 731-738.
- OPPENHEIM, Alan V, Ronald W SCHAFFER et John R BUCK (1999), *Discrete-time signal processing*, Prentice Hall.
- Opta xG* (p. d.), <https://www.statsperform.com/opta-analytics/>, Accessed : 2024-01-09.
- PAPPALARDO, Luca et al. (2019), « A public data set of spatio-temporal match events in soccer competitions », in : *Scientific Data* 6.1, p. 1-15.
- PATEL, Tirth et Samuel LINDLEY (2020), « Analyzing physical exertion in esports : A review », in : *Entertainment Computing* 34, p. 100387.
- PEETERS, Geoffroy (2003), « Measuring the Timbre of Audio Signals », in : *Proceedings of the ISMIR*.
- PERL, Jürgen (2002), « Game analysis and control by means of continuously learning networks », in : *International Journal of Performance Analysis in Sport* 2.1, p. 21-35.
- PETTERSEN, Svein Arne et al. (2014), « Soccer video and player position dataset », in : *Proceedings of the 5th ACM Multimedia Systems Conference*, p. 18-23.
- PIZZO, A.D. et al. (2018), « eSport vs. Sport : A comparison of spectator motives », in : *Sport Marketing Quarterly* 27.2, p. 108-123.
- PROKSCH, Shannon et al. (2023), « Recurrence quantification analysis of crowd sound dynamics », in : *Cognitive Science* 47.10, e13363.
- PUBLIQUE, Cabinet Planète (2014), *évaluation externe de l'Observatoire de la langue française. Un rôle au-delà de l'observation ?*, URL : https://www.francophonie.org/sites/default/files/2019-10/Evaluation%20_observatoire_oif_2014.pdf (visité le 09/01/2024).
- QI, Z., X. SHU et J. TANG (sept. 2018), « DotaNet : Two-Stream Match-Recurrent Neural Networks for Predicting Social Game Result », in : *2018 IEEE Fourth International*

- Conference on Multimedia Big Data (BigMM)*, p. 1-5, DOI : 10.1109/BigMM.2018.8499076.
- QIAN, T. Y., J. J. ZHANG, J. J. WANG et J. HULLAND (2020), « Beyond the Game : Dimensions of Esports Online Spectator Demand », in : *Communication & Sport* 8.6, p. 825-851, DOI : 10.1177/2167479519839436.
- RAMIREZ, Javier et al. (2004), « Efficient voice activity detection algorithms using long-term speech information », in : t. 42, 3-4, Elsevier, p. 271-287.
- RAO, K Sreenivasa, Shashidhar G KOOLAGUDI et Ramu Reddy VEMPADA (2013), « Emotion recognition from speech using global and local prosodic features », in : *International journal of speech technology* 16, p. 143-160.
- RATHKE, Alex (2017), « An examination of expected goals and shot efficiency in soccer », in : *Journal of Human Sport and Exercise* 12.2, p. 514-529.
- RAVANELLI, Mirco et Yoshua BENGIO (2018), « Speaker recognition from raw waveform with SincNet », in : *2018 IEEE Spoken Language Technology Workshop (SLT)*, p. 1021-1028.
- REIMERS, Victor et Josiah GOLDMAN (2019), « League of Legends : The Influence of the Map on Performance in Esports », in : *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, p. 2658-2666.
- REKIK, Imen et Abdelmajid BEN HAMADOU (2018), « Wrapper-based feature selection approach for intrusion detection systems », in : *Computers & Security* 78, p. 190-211.
- RIC, Angel et al. (2016), « Soft-assembled multilevel dynamics of tactical behaviors in soccer », in : *Frontiers in psychology* 7, p. 1513.
- RINGER, Charles et Mihalis A NICOLAOU (2018), « Deep unsupervised multi-view detection of video game stream highlights », in : *Proceedings of the 13th International Conference on the Foundations of Digital Games*, p. 1-6.
- RIOULT, François et al. (2014), « Mining Tracks of Competitive Video Games », in : *{AASRI} Conference on Sports Engineering and Computer Science (SE CS 2014)*, t. 8, p. 82-87, DOI : <http://dx.doi.org/10.1016/j.aasri.2014.08.014>, URL : <http://www.sciencedirect.com/science/article/pii/S221267161400081X>.
- ROSSI, Ryan A, Brian GALLAGHER, Jennifer NEVILLE et Keith HENDERSON (2013), « Modeling dynamic behavior in large evolving graphs », in : *Proceedings of the sixth ACM international conference on Web search and data mining*, p. 667-676.
- RUIZ, H, PJ LISBOA, PJ NEILSON et W GREGSON (2015), « Measuring scoring efficiency through goal expectancy estimation », in : *ESANN 2015 proceedings of the European*

- symposium on artificial neural networks, computational intelligence and machine learning*, p. 149-154.
- SADEGHI, Reihaneh Ramezani, Mahmood FATHY, Hamid R RABIEE et Mohammad Hossein YAGHMAEE (2017), « Dynamic Graph Summarization Using Graph Difference », in : *2017 25th Iranian Conference on Electrical Engineering (ICEE)*, IEEE, p. 1477-1482.
- SANFORD, Ryan et al. (2020), « Group activity detection from trajectory and video data in soccer », in : *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, p. 898-899.
- SARTI, Alessio et Gregorio D'AGOSTINO (2019), « A wrapper-based approach to predictive modeling for soccer match prediction », in : *Expert Systems with Applications* 118, p. 53-62.
- SCHRAPF, Norbert et Markus TILP (sept. 2013), « Action sequence analysis in team handball », in : *Journal of Human Sport and Exercise* 8, S615-S621, DOI : 10.4100/jhse.2013.8.Proc3.07.
- SCHUBERT, Matthias, Anders DRACHEN et Tobias MAHLMANN (2016), « Esports Analytics Through Encounter Detection Other Sports », in : *In Proceedings of the 10th MIT SLOAN Sports Analytics Conference (SSAC)*.
- SCHUBERT M., Lischke L. (2010), « User Behavior in Games », in : *Entertainment Computing-ICEC*.
- SCHULLER, B. W. (2018), « Automatic Emotion Recognition from Speech : A Review of the Literature and Recommendations for Practical Realization », in : *Speech Communication* 99, p. 102-128.
- SCHULTE, Simon et al. (2019), « Exploring Biometric Data Acquisition and Analysis in Esports », in : *2019 IEEE Conference on Games (CoG)*, IEEE, p. 1-8.
- SCOTT, Atom et al. (2022), « Soccertrack : A dataset and tracking algorithm for soccer with fish-eye and drone videos », in : *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, p. 3569-3579.
- SERPIELLO, FR et al. (2018), « Validity of an ultra-wideband local positioning system to measure locomotion in indoor sports », in : *Journal of sports sciences* 36.15, p. 1727-1733.
- SHAH, Rajiv et Rob ROMIJNDERS (2016), « Applying deep learning to basketball trajectories », in : *arXiv preprint arXiv :1608.03793*.

- SHERSTINSKY, Alex (2020), « Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network », in : *Physica D : Nonlinear Phenomena* 404, p. 132306.
- SIFA, Rafet, Anders DRACHEN et Christian BAUCKHAGE (2018), « Profiling in Games : Understanding Behavior from Telemetry », in : *Social Interactions in Virtual Worlds : An Interdisciplinary Perspective*.
- SIFRE, Laurent et Stéphane MALLAT (2014), « Rigid-motion scattering for texture classification », in : *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, p. 501-508.
- ŠILJAK, DD (2008), « Dynamic graphs », in : *Nonlinear Analysis : Hybrid Systems 2.2*, p. 544-567.
- SILVA, Antonio Luis Cardoso, Gisele Lobo PAPPÀ et Luiz CHAIMOWICZ (2018), « Continuous Outcome Prediction of League of Legends Competitive Matches Using Recurrent Neural Networks », in : *SBC-Proceedings of SBCGames*, p. 2179-2259.
- SMITH, Steven W (1997), *The scientist and engineer's guide to digital signal processing*, California Technical Pub.
- SOULET, Arnaud, François RIOULT et Bruno CRÉMILLEUX (2022), « Condensed Survey on Condensed Representations of Patterns », in : *Workshop on Knowledge Discovery in Inductive Databases (co-located with ECML/PKDD-2022)*.
- SPEARMAN, William (2018), « Beyond expected goals », in : *Proceedings of the 12th MIT sloan sports analytics conference*, p. 1-17.
- STENSLAND, Håkon Kvale et al. (2014), « Bagadus : An integrated real-time system for soccer analytics », in : *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)* 10.1s, p. 1-21.
- STHDA (2023), « Test de corrélation entre deux variables (Kendall, Spearman) », in : *STHDA*, URL : <http://www.sthda.com/french/wiki/test-de-correlation-entre-deux-variables>.
- SUMMERVILLE, Adam, Michael COOK et Ben STEENHUISEN (2016), « Draft-analysis of the ancients : predicting draft picks in dota 2 using machine learning », in : *Twelfth Artificial Intelligence and Interactive Digital Entertainment Conference*.
- TAKI, T. et J. HASEGAWA (2000), « Visualization of dominant region in team games and its application to teamwork analysis », in : *Proceedings Computer Graphics International 2000*, p. 227-235, DOI : 10.1109/CGI.2000.852338.

- TAKI, Tsuyoshi, Jun-ichi HASEGAWA et Teruo FUKUMURA (1996), « Development of motion analysis system for quantitative evaluation of teamwork in soccer games », in : *Proceedings of 3rd IEEE international conference on image processing*, t. 3, IEEE, p. 815-818.
- TANG, Yongyi, Lin MA, Wei LIU et Weishi ZHENG (2018), « Long-term human motion prediction by modeling motion context and enhancing motion dynamic », in : *arXiv preprint arXiv :1805.02513*.
- TENGA, Albin, Lars T RONGLAN et Roald BAHR (2010), « Measuring the effectiveness of offensive match-play in professional soccer », in : *European journal of sport science* 10.4, p. 269-277.
- TIBSHIRANI, Robert (1996), « Regression shrinkage and selection via the lasso », in : *Journal of the Royal Statistical Society : Series B (Methodological)* 58.1, p. 267-288.
- TIIPPANA, Tuomas et al. (2020), « How accurately does the expected goals model reflect goalscoring and success in football? », in :
- TILP, M et N SCHRAPF (2015), « Analysis of tactical defensive behavior in team handball by means of artificial neural networks », in : *IFAC-PapersOnLine* 28.1, p. 784-5.
- TURO, Victor J, David BLANCO et Héctor SOLANA (2016), « Spatial distribution of sports facilities within cities : Application of Delaunay triangulation », in : *Journal of Urban Planning and Development* 142.3, p. 04016001.
- UMAMI, Izzatul, Deden GAUTAMA et Heliza HATTA (2021), « implementing the Expected Goal (xG) model to predict scores in soccer matches », in : *International Journal of Informatics and Information Systems* 4.1, p. 38-54, ISSN : 2579-7069, DOI : 10.47738/ijiis.v4i1.76, URL : <http://ijiis.org/index.php/IJIIS/article/view/76>.
- UMAMI, Izzatul, Deden Hardan GAUTAMA et Heliza Rahmania HATTA (2021), « Implementing the Expected Goal (xG) model to predict scores in soccer matches », in : *International Journal of Informatics and Information Systems* 4.1, p. 38-54.
- VAN HAAREN, Jan (2021), « Why Would I Trust Your Numbers? On the Explainability of Expected Values in Soccer », in : *arXiv preprint arXiv :2105.13778*.
- VASWANI, Ashish et al. (2017), « Attention is all you need », in : *Advances in Neural Information Processing Systems*, t. 30, p. 5998-6008.
- VERCRUYSSSEN, Vincent, Luc DE RAEDT et Jesse DAVIS (2016), « Qualitative spatial reasoning for soccer pass prediction », in : *CEUR Workshop Proceedings*, t. 1842.

- VESCOVI, Jason D, Amanda MURRAY, Katherine A FIALA et Douglas W VAN PELT (2018), « Application of Long Short-Term Memory in Sports Performance : A Review », in : *Journal of Strength and Conditioning Research* 32.10, p. 2928-2936.
- VICTOR, Brandon, Aiden NIBALI, Zhen HE et David L CAREY (2021), « Enhancing trajectory prediction using sparse outputs : application to team sports », in : *Neural Computing and Applications* 33, p. 11951-11962.
- VOISIN, Nicolas et Nicolas BESOMBES (2023), « Esport », in : *Publictionnaire. Dictionnaire encyclopédique et critique des publics*, URL : <https://publictionnaire.humanum.fr/notice/esport/>.
- WAGNER, Herbert, Thomas FINKENZELLER, Sabine WÜRTH et Serge P VON DUVILLARD (2014), « Individual and team performance in team-handball : A review », in : *Journal of sports science & medicine* 13.4, p. 808.
- WANG, Kai et al. (2020), « Spatio-Temporal Attention Networks for Next Location Prediction », in : *arXiv preprint arXiv :2005.10190*.
- WANG, Peng, Qing SONG, Xiaohua LIN et Yichao LU (2019), « An Analysis on Strategy Evolution in DotA 2 », in : *Proceedings of the 10th International Conference on Internet Multimedia Computing and Service*, p. 46-50.
- WANG, W. (2023), « Returning for skill or popularity? The demand for esports match replay », in : *International Journal of Sports Marketing and Sponsorship* 24.2, p. 295-310, DOI : 10.1108/IJSMS-07-2022-0146.
- WANG, Weiqi (déc. 2016), « Predicting Multiplayer Online Battle Arena (MOBA) Game Outcome Based on Hero Draft Data », mém. de mast., Dublin, National College of Ireland, URL : <http://trap.ncirl.ie/2523/>.
- WANG, Yongjie, Tong ZHANG, Xu GUO et Zhiqi SHEN (2024), *Gradient based Feature Attribution in Explainable AI : A Technical Review*, arXiv : 2403.10415 [cs.AI].
- WEGENER, Ingo (2005), *Complexity theory : exploring the limits of efficient algorithms*, Springer Science & Business Media.
- WHITE, Alfonso et D ROMANO (2020), « Scalable Psychological Momentum Estimation in Esports », in : *Workshop SUM '20 : State-based User Modelling, The Thirteenth ACM International Conference on Web Search and Data Mining (WSDM '20)*, ACM.
- WIEGREFFE, Sarah et Yuval PINTER (2019), « Attention is not not explanation », in : *arXiv preprint arXiv :1908.04626*.

- XUE, Sida, Jiaxiang DONG, Yuancheng WANG et Yan ZHANG (2020), « Action type recognition in basketball using long short-term memory », in : *IEEE Access* 8, p. 13739-13747.
- YAO, Huaxiu et al. (2018), « Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction », in : *arXiv preprint arXiv :1610.00081*.
- YAO, Qiongjie, Xiaofei LIAO et Hai JIN (2018), « Hierarchical Attention Based Recurrent Neural Network Framework for Mobile MOBA Game Recommender Systems », in : *2018 IEEE Intl Conf on Parallel & Distributed Processing with Applications, Ubiquitous Computing & Communications, Big Data & Cloud Computing, Social Computing & Networking, Sustainable Computing & Communications (ISPA/IUCC/BDCloud/SocialCom/SustainCom)*, IEEE, p. 338-345.
- YING, Rex, Tianyu FU et al. (2024), « Representation Learning for Frequent Subgraph Mining », in : *arXiv preprint arXiv :2402.14367*.
- YING, Rex, A WANG, Jiaxuan YOU et Jure LESKOVEC (2020), « Frequent subgraph mining by walking in order embedding space », in : *Proc. Int. Conf. Mach. Learn. Workshops*.
- YU, Cheng, Wan-ning ZHU et Yu-meng SUN (2019), « E-Sports Ban/Pick Prediction Based on Bi-LSTM Meta Learning Network », in : *International Conference on Artificial Intelligence and Security*, Springer, p. 97-105.
- ZAWBAA, Hossam M, Nashwa EL-BENDARY, Aboul Ella HASSANIEN et Tai-hoon KIM (2012), « Event detection based approach for soccer video summarization using machine learning », in : *International Journal of Multimedia and Ubiquitous Engineering* 7.2, p. 63-80.
- ZEGHINA, Assaad, Aurélie LEBORGNE, Florence LE BER et Antoine VACAVANT (2023), « Multi-SPMiner : A Deep Learning Framework for Multi-Graph Frequent Pattern Mining with Application to spatiotemporal Graphs », in : *Procedia Computer Science* 225, p. 1094-1103.
- ZHANG, Qiyun et al. (2022), « Sports match prediction model for training and exercise using attention-based LSTM network », in : *Digital Communications and Networks* 8.4, p. 508-515.
- ZHANG, Yifan et Yang LIU (2019), « A wrapper-based approach for player performance prediction in fantasy basketball », in : *International Journal of Forecasting* 35.2, p. 664-676.

- ZHAO, Yu et al. (2018), « Applying deep bidirectional LSTM and mixture density network for basketball trajectory prediction », in : *Optik* 158, p. 266-272.
- ZIYI, Zhang, Rory BUNKER, Kazuya TAKEDA et Keisuke FUJII (2023), « Multi-agent deep-learning based comparative analysis of team sport trajectories », in : *IEEE Access*.

Titre : Observatoire de la tactique en (e-)sport collectif

Mot clés : analyse du sport, graphe dynamique, observatoire de la tactique

Résumé : Cette thèse explore les dynamiques de jeu et les performances collectives en alternant entre les analyses de sports traditionnels, comme le handball, et des e-sports, tels que DotA2 et OverWatch. L'objectif est de segmenter le processus de traitement des données en plusieurs étapes, chacune apportant une compréhension spécifique. En adoptant une approche comparative entre sport et e-sport, ce travail non seulement distingue les différentes étapes de traitement des données, mais propose également une vue d'ensemble de l'analyse du (e-)sport. La première contribution réside dans le développement de techniques de représentation des matchs de handball à l'aide de graphes dynamiques, ainsi que dans la simplification des trajectoires dans

DotA2 grâce à des indices géométriques. Ces méthodes permettent une meilleure visualisation et compréhension des mouvements collectifs. La deuxième contribution se concentre sur la définition et le calcul de métriques de performance, essentielles pour l'apprentissage automatique. Des modèles d'expected goal (xG) pour le handball et des facteurs d'engagement dans OverWatch ont été élaborés pour servir de cibles aux algorithmes. La troisième contribution est la création d'un observatoire tactique dédié au handball, et l'étude des configurations géométriques dans DotA2 qui mènent à des événements clés. Ces analyses approfondissent la compréhension des tactiques qui influencent le déroulement des matchs.

Title: Observatory of tactics in collective (e-)sport

Keywords: sports analytics, dynamic graphs, tactics observatory

Abstract: This thesis explores game dynamics and collective performance by alternating between analyses of traditional sports, such as handball, and e-sports, such as DotA2 and OverWatch. The aim is to segment the data processing process into several stages, each providing a specific understanding. By adopting a comparative approach between sport and e-sport, this work not only distinguishes the different stages of data processing, but also offers an overview of (e-)sport analysis. The first contribution is the development of techniques for representing handball matches using dynamic graphs, and the simplification

of trajectories in DotA2 using geometric indices. The second contribution focuses on the definition and calculation of performance metrics, essential for machine learning. Expected goal (xG) models for handball and commitment factors in OverWatch have been developed as targets for algorithms. The third contribution is the creation of a tactical observatory dedicated to handball, and the study of geometric configurations in DotA2 that lead to key events. These analyses deepen our understanding of the tactics that influence the course of matches.