

# APPRENTISSAGE AUTOMATIQUE POUR L'IDENTIFICATION DES CARACTÉRISTIQUES DE JEU D'UNE ÉQUIPE VICTORIEUSE AU RUGBY À XV

Arnaud Odet<sup>1,2</sup>, Thomas Béchard<sup>2</sup>, Pierre Moretto<sup>2</sup>, Sébastien Déjean<sup>1</sup> & Cristian Pasquaretta<sup>2</sup>

<sup>1</sup> *Institut de Mathématiques de Toulouse, UMR 5219 Université de Toulouse et CNRS*  
*{arnaud.odet, sebastien.dejean}@math.univ-toulouse.fr*

<sup>2</sup> *Centre de Recherches sur la Cognition Animale (CRCA), Centre de Biologie Intégrative (CBI), CNRS, Université Paul Sabatier, Toulouse III, France* *{thomas.bechard, pierre.moretto, cristian.pasquaretta}@univ-tlse3.fr*

**Résumé.** La prédiction de résultats de rencontres sportives est un sujet qui connaît un intérêt croissant depuis quelques années, bien aidé par la démocratisation de techniques d'apprentissage automatique. Néanmoins, l'utilisation des modèles prédictifs à des fins d'amélioration de la performance tactique des équipes dans les sports collectifs reste, à notre connaissance, limitée. C'est avec l'objectif de contribuer à ce sujet, et à travers un cas d'étude sur le Rugby à XV, que nous proposons une méthodologie combinant apprentissage automatique et techniques d'explicabilité des algorithmes. Le présent travail se déroule en deux temps : tout d'abord, nous avons établi un modèle de prédiction de résultat sur la base d'indicateurs de performances observés au cours des matchs, puis nous avons appliqué aux prédictions de ce modèle une analyse basée sur les *SHAP values*. Les résultats permettent en se plaçant (i) dans une perspective locale de proposer aux staffs techniques des analyses diagnostiques au sujet des matchs passés et (ii) dans une perspective globale de définir les indicateurs de performances déterminant l'issue d'un match. Nos résultats soulignent l'importance des jeux au pied, des plaquages, et des franchissements.

**Mots-clés.** Analyse diagnostique, *SHAP (SHapley Additive exPlanations) values*

**Abstract.** Predicting the outcomes of sports matches has garnered increasing interest in recent years, fueled by the development and popularization of machine learning techniques. However, the utilization of newly developed predictive models for the purpose of enhancing tactical team performance in team sports remains, to our knowledge, limited. With the aim of contributing to this field, and through a case study on Rugby Union, we suggest a methodology that combines machine learning and algorithm explainability techniques. This study unfolds in two phases : first, we sought to identify the type of modeling that best suits our data, establishing a prediction model based on performance indicators observed during games. Subsequently, we applied an analysis based on SHAP values to the predictions of this model. Our findings serve two primary purposes : (i) from a local perspective, providing technical staff with diagnostic analyses regarding past matches, and (ii) from a global standpoint, identifying which performance indicators mostly determine the match outcomes. Our results emphasize the importance of kicking games, tackling, and breakthroughs.

**Keywords.** Diagnosis analysis, SHAP (SHapley Additive exPlanations) values

# 1 Introduction

L'analyse de données appliquée à la prédiction des résultats des matchs dans le domaine du sport collectif connaît un engouement croissant ces dernières années en Europe.

Bien que son efficacité soit aujourd'hui largement reconnue (revue par Horvat et Job, 2020), la littérature scientifique demeure divisée quant au choix des modèles prédictifs les plus adaptés (Bunker et Susnjak, 2022). Les méthodes utilisées peuvent être des modèles de type *black-box* (réseaux de neurones, support vector machine, méthodes d'ensembles) ou *white-box* (méthodes linéaires). Cependant, elles sont rarement comparées et motivées.

Les prédictions sont en majorité abordées comme un problème de classification binaire (gagner ou non un match). Les prédicteurs utilisés pour résoudre ce problème de classification peuvent être de deux types : tirés des résultats de matchs passés (par exemple nombre de points marqués, classement avant la rencontre, etc. voir Lampis et al., 2023) ou des indicateurs de performances au sein des matchs (par exemple nombre de passes, nombre de tirs, etc. voir Miljkovic et al., 2010). La différence fondamentale entre ces deux types de prédicteurs est que les résultats des matchs précédents n'apportent aucune information sur la stratégie d'une équipe contrairement aux indicateurs de performance qui peuvent quantifier la pertinence des choix tactiques et techniques.

A notre connaissance, malgré les avancées significatives dans la prédiction de résultats de matchs sportifs, l'utilisation de telles analyses pour guider les décisions des staffs techniques reste encore marginale (e.g. Shin et Gasparyan, 2014).

Dans cette optique, notre objectif est double. Nous cherchons d'abord à comparer différents types de modélisation pour déterminer la plus pertinente à prédire l'issue d'un match. A des fins d'exploitation tactique, nous proposons ensuite d'adopter une approche *model agnostic* qui permet l'intégration des résultats obtenus dans les analyses diagnostiques. Cette méthodologie est ici appliquée au rugby à XV.

## 2 Les données

### 2.1 Description des données

Les données ont été obtenues à partir du site [aiasports.fr](https://www.iasports.fr)<sup>1</sup> pour les saisons 2021/2022 et 2022/2023 des championnats suivants : Premiership, Top14, ProD2, Super Rugby et United Championship, et contient des matchs de saison régulière. Les données ont été extraites de fichiers d'analyse de matchs, puis agrégées pour former un jeu de données contenant 1567 matchs.

Le jeu de données comprend de nombreuses variables, disponibles pour l'équipe locale (*home*) et extérieure (*away*). Ces variables peuvent être un nombre (e.g. nombre de rucks réussis) ou un pourcentage (e.g. pourcentage de rucks réussis). Certaines de ces variables étant

---

<sup>1</sup><https://www.iasports.fr/>

des combinaisons linéaires d'autres variables (par exemple, les totaux sont la somme des sous totaux), ou fortement colinéaires à d'autres variables (les pourcentages se calculent à partir de la variable d'intérêt et des autres sous-totaux), elles seront exclues de l'analyse. De plus, les caractéristiques liées au score (nombre d'essais, pénalités, etc) ne sont pas considérées dans l'analyse dans la mesure où une combinaison linéaire de ces indicateurs suffit à déterminer le résultat du match, et d'autres variables ont été ignorées, car incomplètes<sup>2</sup>.

Nous avons donc retenu un jeu de données de 40 variables. Ce sont les possessions (8 variables : nombre, durée, position dans l'air de jeu, occupation), les touches (3 variables : nombre, indicateur de qualité), les mêlées (3 variables : indicateurs de qualité), les jeux au pied (6 variables : taux de réussite, dégagement, terrain, pression, hors terrain, contest), les rucks (7 variables : durée, position dans l'aire de jeu, réussite), les passes (2 variables : simples, après contact), les franchissements (5 variables : position dans l'air de jeu, nombre de défenseurs battus), les plaquages (4 variables : indicateurs de qualité) et les cartons (2 variables : jaune et rouge).

La position sur le terrain (d'une longueur d'environ 100m) se décompose en 4 zones : lorsque l'équipe est dans ses 22 mètres, entre ses 22 mètres et la ligne médiane, entre la ligne médiane et les 22 mètres adverses, dans les 22 mètres adverses.

Les touches, les mêlées et les plaquages sont aussi repartis en 3 groupes en indiquant leur qualité : positifs, neutres, et négatifs. Ainsi, une touche positive est une touche non contestée lors de laquelle l'alignement adverse ne saute pas ou pas en miroir pas clair de l'alignement de l'équipe effectuant la remise en jeu. Une touche neutre est contestée mais l'équipe effectuant la remise en jeu conserve le contrôle du ballon, et une touche négative est une touche perdue. Pour les mêlées, la distinction est similaire : une mêlée positive est une mêlée remportée par l'équipe introduisant la balle, sans que la sortie de balle soit directement contestée. Une mêlée neutre est une mêlée dont la sortie de balle est directement contestée ou injouable (sanctionnée comme telle par l'arbitre, et re-jouée avec la même équipe introduisant la balle). Enfin, une mêlée négative est une mêlée où l'équipe introduisant la balle la perd. Pour les plaquages, un plaquage positif est un plaquage lors duquel la défense gagne la ligne d'avantage obligeant l'attaque à reculer. Un plaquage neutre est un plaquage lors duquel la ligne d'avantage est conservée et un plaquage négatif est un plaquage lors duquel la ligne d'avantage est gagnée par l'attaque, qui avance. Considérant que les plaquages positifs, neutres et négatifs sont réussis, nous disposons également du sous total de plaquages réussis. La qualification de ces données est effectuée par le site [aiasports.fr](http://aiasports.fr) et n'a demandé aucune intervention de notre part.

Les durées des possessions s'expriment en secondes et sont classées par catégories : de 0 à 30 secondes, de 30 à 60 secondes, plus de 60 secondes. Les durées des rucks sont également exprimées en secondes et classées par catégories : entre 0 et 3 secondes, entre 3 et 6 secondes, plus de 6 secondes.

---

<sup>2</sup>Présentes uniquement sur les matchs les plus récents.

## 2.2 Création de variables

Dans le but de tenir compte de la différence de niveau intrinsèque entre deux équipes, nous avons créé une variable "points ELO" (Elo, 1978), avec un facteur  $K$  fixé à 20, en appliquant les valeurs utilisées par la fédération internationale d'échecs (FIDE)<sup>3</sup>. Nous avons considéré que la situation de ligues ouvertes où les équipes sont regroupées par niveau ne correspondait pas à une situation de nouvelle arrivée dans le système de classement (cas où  $K = 40$  pour la FIDE) et que le faible nombre d'équipes professionnelles (comparé au nombre de joueurs d'échecs présents dans le classement FIDE) justifiait de ne pas établir un seuil au-delà duquel l'échange de points est plus faible (cas où  $K = 10$  pour la FIDE). Selon Lampis et al. (2023), la détermination de cette variable  $K$  peut faire l'objet d'une recherche approfondie.

Les points ELO sont initialisés au début de chaque saison afin (i) de tenir compte de la variabilité inter-saisons des effectifs, et (ii) d'intégrer les montées vs descentes entre les différentes divisions.

Considérant que les premiers matchs d'une saison sont d'une part des matchs où les points ELO ne reflètent pas encore le niveau des équipes, et d'autre part servent à de nombreuses mises au point et choix technico-tactiques, nous avons évincé les données des 4 premières rencontres.

Par ailleurs, nous avons classé les matchs suivant qu'ils étaient remportés par l'équipe locale (1) ou pas (0). Une limite de ce choix est la considération de 45 matchs nuls (2.9%), qui sont donc classés dans la même catégorie qu'une défaite de l'équipe locale. Cette approche est justifiable par l'existence du *home advantage* dans le sport (Courneya et Carron, 1992).

## 3 Méthode

### 3.1 Description des modèles choisis

Nous avons utilisé différents types de modèles parmi les plus employés (y compris dans les travaux liés au sport, voir Bunker et Susnjak, 2022) : des modèles linéaires (régression logistique, analyse discriminante par moindres carrés partiels ou PLS-DA), des méthodes d'ensembles (Random Forest, Adaptive Boost classifier, XGBoost Classifier), de Support Vector Machine (avec des kernels linéaires et RBF), un *k-Nearest-Neighbors*, et deux modèles de type *Artificial Neural Network*, qui diffèrent par leurs architectures. Nous avons également utilisé deux modèles de bases afin d'évaluer le gain de capacité de prédiction apporté par notre analyse : le modèle *Baseline Home*, qui prédit systématiquement une victoire de l'équipe locale (67% des matchs de notre jeu de données), et le modèle *Baseline ELO*, qui consiste en une régression logistique avec pour seul prédicteur la différence de points ELO entre les deux équipes avant le début de la rencontre.

---

<sup>3</sup><https://handbook.fide.com/chapter/B022024>

## 3.2 Métriques de comparaison

Nous avons choisi d'utiliser le modèle le plus performant sur la base des *accuracy* respectives. Nous avons également affiché le score F1 afin de rendre compte de la sensibilité du modèle aux faux positifs et faux négatifs.

L' *accuracy* est une métrique communément utilisée pour définir la qualité d'un modèle de classification. Elle se définit comme étant la fraction des individus correctement classés. Le score *F1* est la moyenne harmonique de la *precision* et du *recall*. Ces métriques se calculent comme suit :

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad F1 = \frac{2TP}{2TP + FP + FN}$$

où *TP* et *FP* sont respectivement le nombre de vrais (faux) positifs (*True Positive* / *False Positive*) et *TN* et *FN* sont respectivement le nombre de vrais (faux) négatifs (*True Negative* / *False Negative*)

## 3.3 Choix des données d'entraînements et de prédiction

Nous avons gardé les 4 dernières journées de chaque saison pour l'évaluation. Le choix des 4 dernières journées permet de garder environ 20% des données dans le *test set*. Ainsi, comme énoncé en 2.2, les 4 premières journées de chaque championnat ne sont pas utilisés (280 matchs), le modèle est entraîné sur les matchs des journées suivantes (1014 matchs), et évalué sur les 4 dernières journées (273 matchs<sup>4</sup>).

# 4 Résultats

## 4.1 Comparaison des modèles

Les résultats de la comparaison des modèles sont présentés dans la Table 1. On constate que le modèle Support Vector Classifier (Kernel RBF) obtient les meilleurs scores, tant en termes d'*accuracy* que de *F1-score*.

Il convient de noter que si les modèles linéaires (régression logistique et PLS-DA) performant moins que le modèle Support Vector Classifier (Kernel RBF), ils présentent l'avantage d'être plus facilement explicables.

Pour nos modèles de références, et contrairement aux attentes, le modèle naïf prédisant systématiquement une victoire de l'équipe locale obtient la même *accuracy* que le modèle de référence utilisant la différence de score ELO précédent la rencontre. Il présente également un score F1 supérieur.

---

<sup>4</sup>La différence du nombre de matchs entre les 4 premières et les 4 dernières journées s'explique par l'abandon des équipes Wasps et Worcester Warriors en cours de saison en Premiership 2022/23.

Table 1 : Tableau récapitulatif des Accuracy et des F1-score des différents modèles

Model	Accuracy	F1-score
Support Vector Classifier - RBF kernel	0.8168	0.8744
Support Vector Classifier - Linear kernel	0.7912	0.8496
Partial Least Squares - Discriminant Analysis	0.7875	0.8490
Logistic Regression	0.7839	0.8468
ANN - 1 hidden layer	0.7839	0.8468
ANN - 3 hidden layers	0.7839	0.8468
Ada Boost	0.7766	0.8373
Random Forest	0.7253	0.8219
XGB Classifier	0.7253	0.8072
k - Nearest Neighbors Classifier	0.6996	0.7960
Baseline Home	0.6923	0.8182
Baseline ELO	0.6923	0.8000

## 4.2 Analyse diagnostique

Afin d’expliquer un match donné, et fournir à l’encadrement technique d’une équipe les raisons susceptibles d’avoir conduit au résultat final, nous proposons d’analyser les prédictions du modèle avec la méthodologie développée par Lundberg et Lee (2017), introduisant les *SHAP (SHapley Additive exPlanations) values*. Cette méthodologie permet de mesurer l’impact des différentes variables sur la prédiction. Elle se base sur les valeurs de Shapley (Shapley, 1953), définies comme suit :

$$\phi_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(|N| - |S| - 1)!}{|N|!} [v(S \cup \{i\}) - v(S)]$$

où  $\phi_i$  est la valeur de Shapley associé au joueur  $i$ ,  $S$  est une sous-coalition de  $N$  ne contenant pas  $i$  et  $v(S)$  est la valeur de la coalition.

En théorie des jeux, une coalition  $S$  est un groupe de joueurs obtenant dans un jeu collaboratif la valeur  $v(S)$  et une sous-coalition de  $S$  est un sous ensemble de joueurs  $j \in S$ . La coalition  $N$  désigne l’ensemble des joueurs. L’objectif des valeurs de Shapley est d’attribuer à chaque participant d’une coalition une fraction de la valeur dégagée par la coalition proportionnelle à l’apport de ce joueur à la coalition. En apprentissage automatique, chaque variable (prédicteur) est considérée comme un joueur, la coalition analysée est l’ensemble des variables utilisées par un modèle, et enfin la valeur dégagée par la coalition est la valeur prédite par le modèle. Ainsi, l’objectif est de déterminer quelles sont les variables qui contribuent le plus à la prédiction observée.

Appliquée à l’échelle locale, cette méthode permet de montrer quelles sont les variables qui ont conduit à l’élaboration de la prédiction (cf Figure 1, résultat de cette analyse pour un match de Top 14 de la saison 2022/23). Dans l’exemple présenté dans la Figure 1, le modèle prédit une victoire de l’équipe locale (avec une probabilité de 91.2%) due principa-

lement aux variables suivantes : le nombre de franchissements dans les 22 mètres adverses de l'équipe locale a contribué positivement à la prédiction d'une victoire de l'équipe locale à hauteur de +5%, le nombre de jeux au pied de dégagement de l'équipe visiteuse a contribué négativement à cette même prédiction à hauteur de -4%. Le nombre de touches perdues par l'équipe visiteuse, de jeux au pied de terrain de l'équipe locale et son nombre de possessions dans les 22m adverses ont chacune contribué positivement à hauteur de +4%. Sachant que le match en question a été gagné par l'équipe locale, le staff technique de l'équipe visiteuse pourrait par exemple décider d'une utilisation différente des jeux au pied de terrain puisque cette variable a contribué à hauteur de +3% à la probabilité de victoire de l'équipe locale.

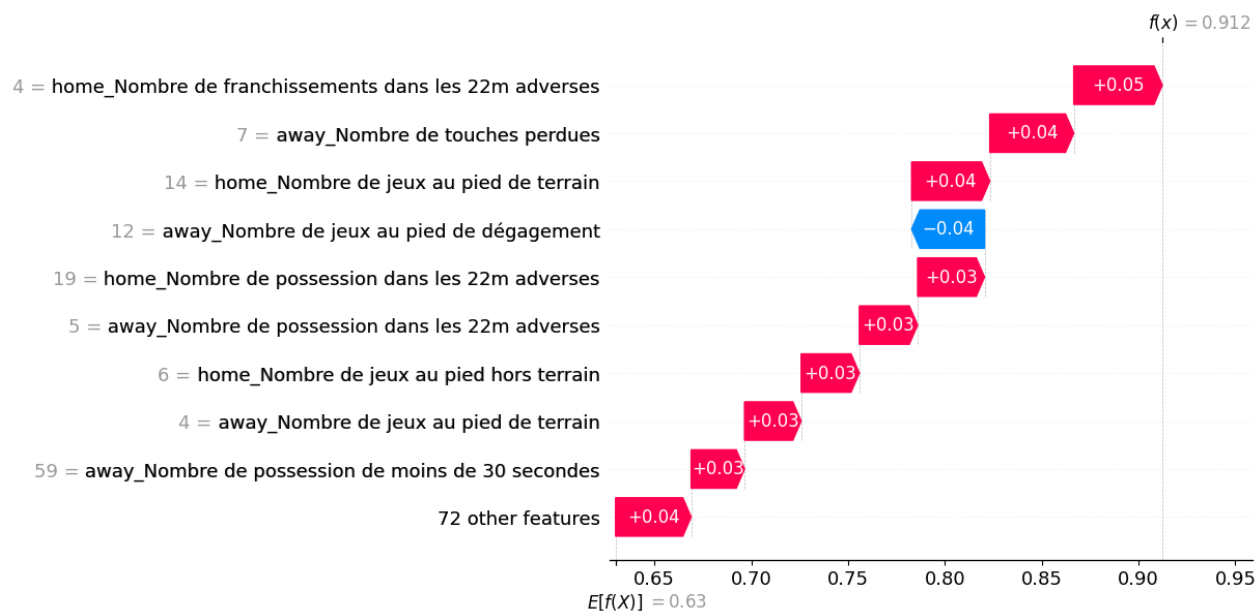


Figure 1 : Illustration de l'explication d'une prédiction locale pour un match de Top 14 lors de la saison 2022/23. L'axe des abscisses représente la probabilité que l'équipe locale remporte le match selon le modèle, et les valeurs présentées sur l'axe des ordonnées sont les valeurs des variables correspondantes. Une variable dont la valeur sur le match en question pousse le modèle à prédire un 1 (victoire de l'équipe domicile) est indiquée en rouge, et une variable dont la valeur pousse le modèle à prédire un 0 est indiquée en bleu. Les valeurs indiquées sur les flèches sont l'impact estimé de la valeur du prédicteur en pourcentage sur la probabilité de victoire de l'équipe locale.

Appliquée à l'échelle globale, elle permet de mettre en lumière les variables qui influent le plus sur l'issue d'un match de rugby sur notre jeu de test, comme l'illustre la Figure 2. À titre d'exemple, le nombre de passes simples de l'équipe locale semble être un facteur qui est négativement corrélé avec la probabilité de victoire de cette même équipe. En effet, les points où cette variable prend une valeur élevée se situent à gauche de l'axe central, indiquant que cette variable pousse la prédiction vers le 0. Les jeux au pied de terrain semblent à l'inverse être positivement corrélés avec les chances de victoires pour l'équipe qui en fait un nombre élevé. Cette observation est illustrée par les points rouges à gauche (respectivement droite) de l'axe central pour l'équipe visiteuse (respectivement locale). La variable ayant une plus faible concentration de points proches de l'axe central est donc la variable qui a le plus d'impact

sur les prédictions du modèle. Ici, la différence de points ELO précédant la rencontre semble être la variable impactant le plus le résultat de la rencontre.

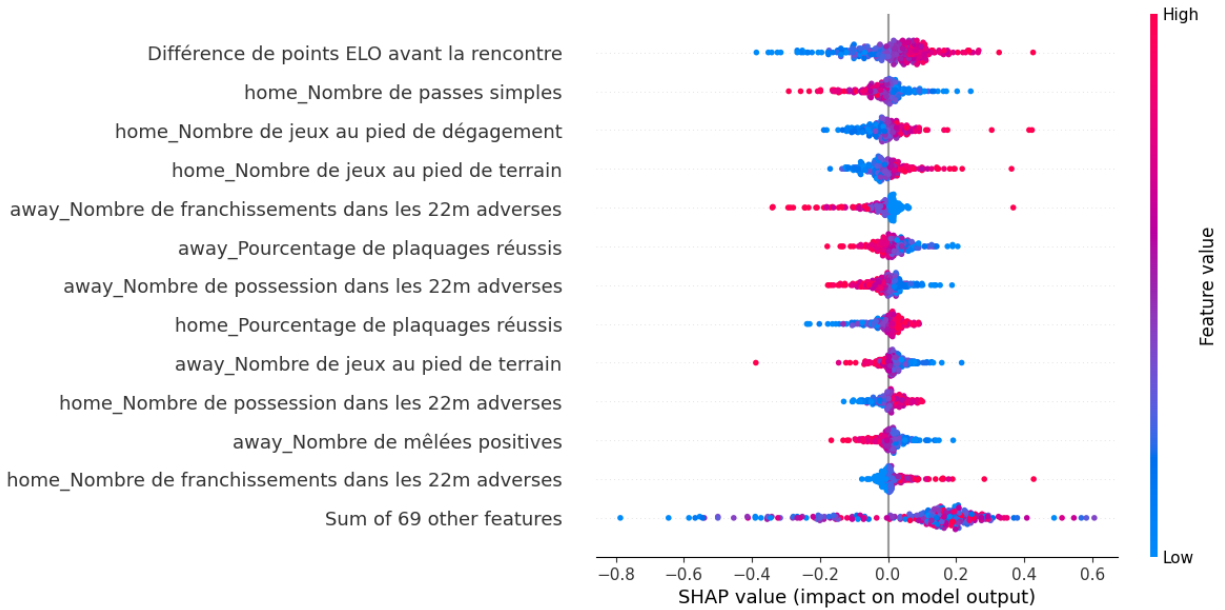


Figure 2 : Illustration de l’explication à l’échelle globale du modèle Support Vector Classifier (Kernel RBF). La coloration des points indique s’ils correspondent à une valeur élevée (rouge) ou faible (bleus) pour la variable en question, et la position sur l’axe horizontal représente l’impact associé aux points correspondants. Vers la gauche le facteur prédit un 0 et vers la droite un 1. Ainsi, plus une variable compte de points loin de l’axe central, plus son pouvoir d’influence sur le dénouement d’une rencontre est grand.

En conséquence, une hiérarchisation de la magnitude de l’impact des variables peut être proposée en fonction de l’écart type de leurs *SHAP values* (comme présenté sur la Figure 3). La différence de points ELO n’apparaît pas sur la Figure puisque c’est une variable commune aux deux équipes, mais elle reste la variable dont l’écart type des *SHAP values* est le plus important (0.11). Il apparaît alors que les variables les plus déterminantes sur notre jeu de données sont les franchissements dans les 22m adverses, le pourcentage de plaquages réussis, et le nombre de jeux au pied de terrain.

## 5 Discussion et conclusion

Dans l’étude actuelle, nous avons proposé une méthode permettant d’exploiter des indicateurs de performance pour fournir aux staffs techniques (i) une analyse globale des indicateurs de performance les plus pertinents au rugby et (ii) à niveau local un diagnostic des matchs écoulés.

Sur nos données, le Support Vector Classifier (Kernel RBF) affiche une *accuracy* de 81.68% sur le jeu de données de test, et révèle des bons prédicteurs de performance au rugby. En



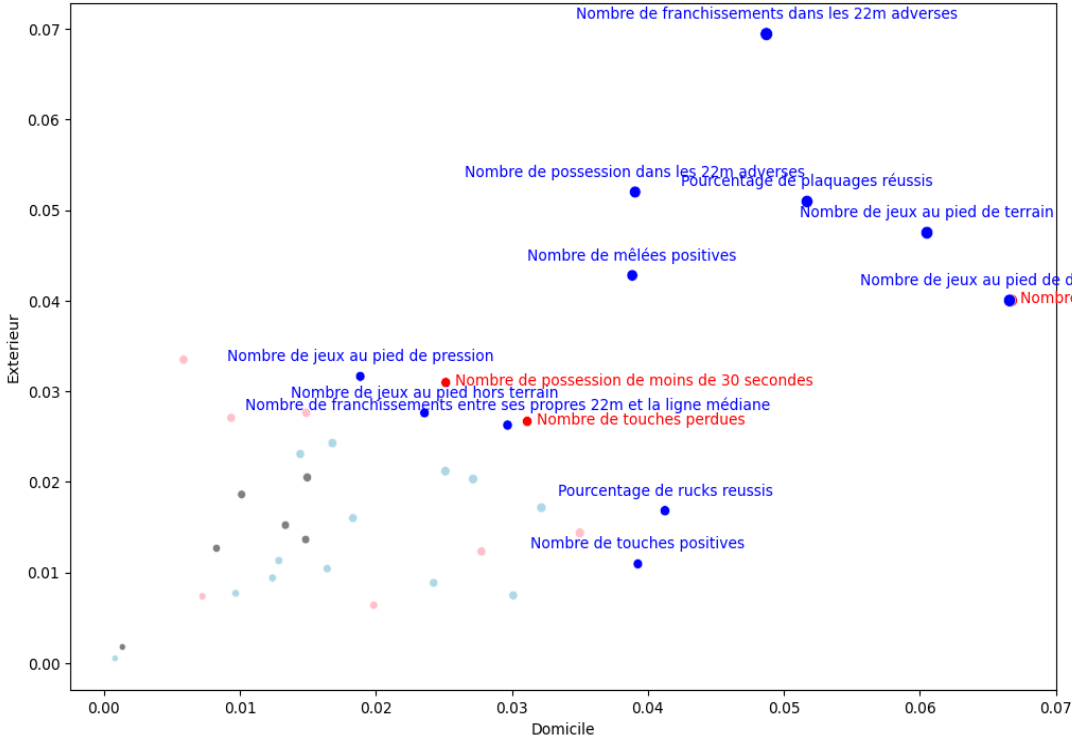


Figure 3 : Ecarts types des *SHAP values* des variables selon le modèle Support Vector Classifier (Kernel RBF). L'axe horizontal et l'axe vertical représentent respectivement l'importance d'une variable pour l'équipe locale et visiteuse. La coloration des points indique une corrélation positive (bleue) ou négative (rouge) avec les *SHAP values*, et, par conséquent, que les équipes ont intérêt de maximiser (ou minimiser) pour augmenter leurs chances de victoires. Les points gris représentent des variables dont l'impact n'est pas clairement identifié. Afin de préserver la lisibilité de la figure, seules les variables les plus significatives ( $\frac{\sigma_{home} + \sigma_{away}}{2} > 0.25$  où  $\sigma$  représente l'écart type), sont nommées, les autres apparaissent dans une couleur plus claire.

particulier la probabilité de gagner un match est positivement influencée par (i) nombre de franchissements dans les 22m adverses, (ii) un plus haut pourcentage de plaquages réussis, et (iii) un nombre supérieur de jeux au pied de terrain. Il est intéressant de noter que le nombre de passes simples apparaît comme négativement corrélé avec la probabilité de victoire au rugby à XV.

Bien que d'importance globale, ces prédicteurs peuvent influencer différemment le résultat lorsqu'ils sont observés au niveau d'un seul match (e.g. Figure 1). Notre méthode permet une vision multi-échelle et peut apporter un nouvel éclairage sur la stratégie à adopter dans la préparation des matchs.

Si notre travail n'a aucunement la prétention de se substituer à l'expérience et l'expertise d'un staff technique, nous pensons qu'il peut apporter un complément d'information, et des éléments d'aide à la décision, à travers l'analyse des points faibles et points forts de leur propre équipe ou des adversaires. Par ailleurs, l'utilisation de techniques d'apprentissage automatique peut permettre d'analyser un nombre de matchs qui serait impossible à traiter

pour un staff technique.

Notre méthode peut encore être améliorée car elle est basée sur un volume relativement restreint de données, ce qui peut avoir un impact sur la robustesse de certaines conclusions. La quantité de variables à disposition et les choix faits pour éviter de sélectionner des variables colinéaires ont également un impact sur la performance des différents modèles. Ensuite, une difficulté réside dans le fait que simuler l’absence d’une variable n’est pas trivial, or l’utilisation des *SHAP values* repose sur de telles simulations. En effet, elle suppose d’attribuer une valeur issue d’un *background* à la variable dont l’absence est simulée, et le choix de ce dernier influence les résultats (voir Albini et al., 2022). Par ailleurs, pour compléter le présent travail, il conviendrait de tenir compte d’une certaine dépendance entre les variables et de modéliser le report modal : pour reprendre l’exemple développé en Figure 1, si l’équipe visiteuse décidait d’utiliser davantage les jeux au pied de terrain, l’équipe aurait nécessairement moins de passes et/ou de rucks et/ou de franchissements.

Notons enfin que la méthode présentée, et illustrée ici à travers un cas d’étude sur le rugby à XV, est transposable dans d’autres sports.

## Remerciements

Nous remercions la société AIA SPORTS qui nous a permis d’utiliser les données mentionnées.

## Références

- Albini, E., Long, J., Dervovic, D., & Magazzeni, D. (2022). Counterfactual Shapley Additive Explanations. *2022 ACM Conference on Fairness, Accountability, and Transparency*.
- Bunker, R., & Susnjak, T. (2022). The Application of Machine Learning Techniques for Predicting Match Results in Team Sport : A Review. *Journal of Artificial Intelligence Research*, 73.
- Courneya, K., & Carron, A. (1992). The Home Advantage In Sport Competitions : A Literature Review. *Journal of Sport & Exercise Psychology*, 14.
- Elo, A. (1978). The rating of chessplayers, past and present.
- Horvat, T., & Job, J. (2020). The use of machine learning in sport outcome prediction : A review. *WIREs Data Mining and Knowledge Discovery*, 10(5).
- Lampis, T., Ioannis, N., Vasilios, V., & Stavrianna, D. (2023). Predictions of european basketball match results with machine learning algorithms. *Journal of Sports Analytics*, (Preprint).
- Lundberg, S., & Lee, S. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
- Miljkovic, D., Gajic, L., Kovacevic, A., & Konjovic, Z. (2010). The use of data mining for basketball matches outcomes prediction. *IEEE 8th International Symposium on Intelligent Systems and Informatics*.
- Shapley, L. (1953). A value for n-person games.
- Shin, J., & Gasparyan, R. (2014). A novel way to Soccer Match Prediction.