

وزارة التعليم العالي والبحث العلمي
جامعة حسية بن بوعلی الشلف
معهد التربية البدنية والرياضية
قسم التدريب الرياضي



أطروحة مقدمة لنيل شهادة دكتوراه

الشعبة : تدريب رياضي

التخصص : تدريب رياضي نخبوي

العنوان

الانتقاء الرياضي باستخدام أدوات الذكاء الاصطناعي

من إعداد الطالب:

محمد الأمين عشيظ هني

المناقشة بتاريخ 2026/04/18 من طرف اللجنة المكونة من:

رئيس	أستاذ محاضر أ	جامعة حسية بن بوعلی الشلف	علي قيصاري
مشرف	أستاذ	جامعة حسية بن بوعلی الشلف	يوسف سعدي زروقي
مساعد مشرف	أستاذ محاضر أ	جامعة حسية بن بوعلی الشلف	عباش أحمد
ممتحن	أستاذ محاضر أ	جامعة حسية بن بوعلی الشلف	خلافي عزيز
ممتحن	أستاذ محاضر أ	جامعة الجزائر 03	بوقفة محمد
ممتحن	أستاذ محاضر أ	جامعة سوق أهراس	قطاوي محفوظ

إهداء

بسم الله الرحمن الرحيم

الحمد لله وكفى والصلاة على الحبيب المصطفى الحمد لله الذي بنعمته تتم الصالحات و تصلح الأعمال
وتتيسر الصعوبات وتهون العقبات، الحمد لله فلولا هداه لما اهتدينا لهذا، فنسأل المولى عز وجل أن يكون
هذا العمل خالصا لوجهه الكريم في سبيل العلم والمعرفة

أهدي هذا البحث العلمي الذي كان ثمرة مجهود كبير الى الذي نفتخر في المجالس بذكر اسمه ابي الشيخ
عشيط رحمه الله وجمعني به في جنة الفردوس ..

الى التي وهبني الحياة وسهرت على تربيتي ..امي اطل الله في عمرها ورزقني برها ورضاها ..

الى من تقاسمت معي حلو الحياة ومرها زوجتي ورفيقة دربي وشريكة حياتي
إلى أولادي الأعزاء الذين زينوا حياتنا وانا روا بيتنا ادامهم الله ضحكة لا تزول
الى الروح الطاهرة لوالدي زوجتي رحمهما الله واسكنهما فسيح جناته

إلى إخوتي وأخواتي وعائلاتهم أطل الله في أعمارهم وحفظهم وأولادهم
إلى كل عائلة عشيط هني ومصطفى دلة صغيرهم وكبيرهم وكل من يقربهم من قريب أو بعيد
حفظ الله الجميع وأنشأهم في رعايته وحفظه وأدام الله علينا أجمعين موفور الصحة والعافية.

محمد الأمين

شكر وتقدير

الحمد لله ربّ العالمين، والصلاة والسلام على أشرف المرسلين سيدنا محمد وعلى آله وصحبه أجمعين.

أما بعد،

" رب أوزعني أن أشكر نعمتك التي أنعمت علي و على والدي وأن أعمل صالحا ترضه، وأدخلني برحمتك في عبادك الصالحين."

يسعدني ويسرّني أن أتقدّم بخالص آيات الشكر والتقدير والعرفان إلى كل من كان لهم الفضل في إنجاز هذه الأطروحة وبلوغها إلى هذه المرحلة.

وأول كلمات الامتنان أهديها إلى أستاذي المشرف **سعيد زروقي يوسف**، الذي لم يبخل علي بتوجيهاته السديدة، فجزاه الله عني خير الجزاء.

كما أتقدّم بجزيل الشكر والتقدير إلى مساعد المشرف الأستاذ **عباش أحمد**، الذي استفدت من ملاحظاته القيّمة كان لها أثر كبير في تصميم التطبيق الذكي.

ولا يسعني أيضًا إلا أن أعبر عن امتناني للأستاذ الفاضل **ماحي صفيان**، على ما قدّمه من نصائح ساهمت في تجاوز عدد من الصعوبات العلمية والعملية، وأشكره على الوقت الذي خصّصه لمساعدتي لإنجاز هذا العمل.

كما أتوجّه بالشكر إلى السادة أعضاء لجنة المناقشة على تخصيص جزء من وقتهم للاطلاع على هذا العمل وتقييمه، وإلى جميع الأساتذة الذين تعلمت منهم خلال مسيرتي الجامعية، وإلى كل موظفي وعمال معهد التربية البدنية بجامعة **حسيبة بن بوعلي بالشلف**.

كما أتوجّه بالشكر إلى اللاعبين والمدربين والمسيرين لفريقي أقل من 19 و 17 سنة بنادي جمعية أولمبي الشلف، على تعاونهم وتسهيلهم لعمليات جمع البيانات.

ولا يفوتني أن أتقدّم بالشكر إلى كل من ساعدني ولو بكلمة طيبة، وإلى عائلتي الكريمة التي كانت السند الدائم والدافع الأكبر لمواصلة هذا المشوار.

أسأل الله أن يجزي الجميع خير الجزاء، وأن يجعل هذا العمل نافعا ولبنة في بناء المعرفة العلمية.

محمد الأمين

ملخص

الانتقاء الرياضي باستخدام أدوات الذكاء الاصطناعي

تهدف هذه الأطروحة إلى تصميم نموذج ذكي قائم على تقنيات الذكاء الاصطناعي وتعلم الآلة لتوجيه لاعبي كرة القدم نحو مراكز اللعب الأمثل بناءً على خصائصهم البدنية والمورفولوجية. اعتمدت الدراسة على المنهج الوصفي المسحي مع تحليل بيانات 938 لاعباً من الدوري الفرنسي (ليغ 1 وليغ 2) للموسم الرياضي 2022-2023، حيث تم جمع القياسات البدنية والمورفولوجية وتطبيق خوارزميات التعلم الآلي (KNN, SVM, Random Forest) لتصنيف اللاعبين حسب مراكزهم حسب القياسات البدنية. كشفت النتائج عن قدرة نماذج التعلم الآلي على تصنيف اللاعبين بدقة تراوحت بين 70.21% و 89.36%، مع وجود فروق بدنية واضحة بين المراكز المختلفة، حيث تميز لاعبو وسط الدفاع بالطول والقوة والارتفاع، بينما برز لاعبو وسط الميدان في التحمل والرشاقة، وتتميز لاعبو الخطوط الهجومية بالسرعة والتسارع والقدرة الانفجارية. كما أظهرت النتائج تفوق طفيف لخوارزمية Random Forest في معظم حالات التصنيف. تقدم الدراسة إطاراً عملياً يمكن للمدربين والأكاديميات الكروية الاعتماد عليه لتحسين عمليات الانتقاء والتوجيه الرياضي.

الكلمات الدالة: الانتقاء الرياضي، الذكاء الاصطناعي، تعلم الآلة، اللياقة البدنية، مراكز اللعب، كرة القدم، التوجيه

الرياضي

Abstract

Sports Selection Using Artificial Intelligence Tools

This thesis aims to design an intelligent model based on artificial intelligence and machine learning techniques to guide football players towards optimal playing positions based on their physical and morphological characteristics. The study adopted a descriptive survey methodology, analyzing data from 938 players in the French League (Ligue 1 and Ligue 2) for the 2022-2023 sports season. Physical and morphological measurements were collected, and machine learning algorithms (KNN, SVM, Random Forest) were applied to classify players into positions based on physical metrics. The results revealed that the machine learning models were able to classify players with an accuracy ranging between 70.21% and 89.36%, with clear physical differences observed between various positions. Central defenders were characterized by height, strength, and jumping ability; midfielders excelled in endurance and agility; while attacking players were distinguished by speed, acceleration, and explosive power. The results also showed a slight superiority of the Random Forest algorithm in most classification scenarios. The study provides a practical framework that coaches and football academies can rely on to enhance sports selection and orientation processes.

Keywords: Sports Selection, Artificial Intelligence, Machine Learning, Physical Fitness, Playing Positions, Football, Sports Orientation.

Résumé

Sélection Sportive par les Outils de l'Intelligence Artificielle

Cette thèse vise à concevoir un modèle intelligent basé sur les techniques d'intelligence artificielle et d'apprentissage automatique pour orienter les joueurs de football vers les postes de jeu optimaux en fonction de leurs caractéristiques physiques et morphologiques. L'étude a adopté une méthodologie descriptive par enquête, analysant les données de 938 joueurs du Championnat de France (Ligue 1 et Ligue 2) pour la saison sportive 2022-2023. Les mesures physiques et morphologiques ont été collectées, et des algorithmes d'apprentissage automatique (KNN, SVM, Random Forest) ont été appliqués pour classer les joueurs selon leurs postes sur la base des mesures physiques. Les résultats ont révélé que les modèles d'apprentissage automatique étaient capables de classer les joueurs avec une précision variant entre 70,21% et 89,36%, avec des différences physiques nettes observées entre les différents postes. Les défenseurs centraux se caractérisaient par la taille, la force et la capacité de saut ; les milieux de terrain excellaient en endurance et en agilité ; tandis que les joueurs offensifs se distinguaient par la vitesse, l'accélération et la puissance explosive. Les résultats ont également montré une légère supériorité de l'algorithme Random Forest dans la plupart des scénarios de classification. L'étude fournit un cadre pratique sur lequel les entraîneurs et les académies de football peuvent s'appuyer pour améliorer les processus de sélection et d'orientation sportive.

Mots-clés: Sélection Sportive, Intelligence Artificielle, Apprentissage automatique, Condition Physique, Postes de Jeu, Football, Orientation Sportive.

قائمة المحتويات، الجداول والأشكال

قائمة المحتويات

1	المقدمة
الفصل التمهيدي	
4	الإشكالية
5	تساؤلات الدراسة
6	فرضيات الدراسة
6	أهداف البحث
6	أهمية البحث
7	تحديد مصطلحات الدراسة
10	الدراسات السابقة
18	التعليق على الدراسات السابقة

الباب الأول: الجانب النظري

الفصل الأول:

22	تمهيد
23	1- الانتقاء الرياضي
23	1-1- تعريف الانتقاء الرياضي
24	1-2- أهداف الانتقاء الرياضي
25	1-3- أنواع الانتقاء الرياضي
25	1-3-1- الانتقاء الأولي (Initial Selection)
25	1-3-2- الانتقاء المرحلي (Developmental/Intermediate Selection)
26	1-3-3- الانتقاء النهائي (Final Selection)
26	1-4- مراحل عملية الانتقاء
26	1-4-1- مرحلة التعرف (Identification Phase)
26	1-4-2- مرحلة التقويم والتنبؤ (Assessment & Prognosis Phase)
26	1-4-3- مرحلة التوجيه (Orientation Phase)

27	 (Selection Decision Phase) مرحلة اتخاذ القرار	1-4-4-4
27	 معايير الانتقاء الرياضي في كرة القدم	1-5-5-5
27	 (Physical Criteria) المعايير البدنية	1-5-5-1
27	 (Physiological Criteria) المعايير الفسيولوجية	1-5-5-2
27	 (Technical Criteria) المعايير المهارية	1-5-5-3
28	 (Psychological Criteria) المعايير النفسية	1-5-5-4
28	 (Cognitive and Tactical Criteria) المعايير الإدراكية والتكتيكية	1-5-5-5
28	 العمر البيولوجي كمعيار من معايير الانتقاء	1-5-5-6
28	 الخصائص الوراثية كمحدد غير عملي للانتقاء	1-5-5-7
29	 أهمية الانتقاء	1-6-6-6
30	 التوجيه الرياضي	2-2-2-2
30	 مفهوم التوجيه	2-1-1-1
30	 التوجيه الرياضي	2-2-2-2
31	 أهداف التوجيه وتطبيقاته في الرياضة	2-3-3-3
32	 الفرق بين الانتقاء والتوجيه	2-4-4-4
33	 مراحل التوجيه خلال المسار التكويني للرياضي	2-5-5-5
33	 المرحلة الأولى (مرحلة التوجيه التمهيدي)	2-5-5-1
34	 المرحلة المتوسطة (مرحلة التوجيه شبه المتخصص)	2-5-5-2
34	 المرحلة النهائية (مرحلة التوجيه التخصصي)	2-5-5-3
34	 التوجيه حسب مراكز اللعب في كرة القدم	2-6-6-6
35	 حارس المرمى	2-6-6-1
35	 وسط الدفاع (مدافع أوسط)	2-6-6-2
35	 لاعب الرواق (لاعب الجناح)	2-6-6-3
36	 وسط الميدان	2-6-6-4

36	 2-6-5- المهاجم (قلب الهجوم)
37	 3- الصفات البدنية وعلاقتها بمراكز اللعب في كرة القدم
37	 3-1- تعريف الصفات البدنية
38	 3-2- التحمل في كرة القدم
38	 3-2-1- التحمل الهوائي
38	 3-2-2- التحمل اللاهوائي
38	 3-3- السرعة وأنواعها في كرة القدم
39	 3-3-1- سرعة رد الفعل (الاستجابة) (Reaction speed)
39	 3-3-2- سرعة التنفيذ (Execution speed)
39	 3-3-3- السرعة الحركية أو الجسدية (Movement speed)
39	 3-3-4- السرعة القصوى (Sprint speed)
39	 3-3-5- التسارع (Acceleration)
39	 3-3-6- السرعة التكرارية (Repeated Sprint Ability – RSA)
40	 3-4- القوة وأنواعها في كرة القدم
40	 3-4-1- القوة العظمى
41	 3-4-2- قوة التحمل
41	 3-4-3- القوة المميزة بالسرعة
41	 3-4-4- القوة الانفجارية
41	 3-5- الرشاقة (Agility)
42	 3-6- التوازن (Balance)
42	 3-7- المرونة
43	 3-7-1- مرونة عامة
43	 3-7-2- مرونة خاصة
43	 3-8- المتطلبات البدنية حسب مراكز اللعب في كرة القدم
43	 3-8-1- حارس المرمى
44	 3-8-2- المدافعون (قلب الدفاع)

44	3-8-3- لاعبو الرواق (الأجنحة)
44	3-8-4- وسط الميدان
44	3-8-5- المهاجمون
45	3-9- التكامل مع الذكاء الاصطناعي
46	الخاتمة

الفصل الثاني: الذكاء الاصطناعي

48	تمهيد
49	1- محطات تاريخية
51	2- الذكاء الاصطناعي (Artificial intelligence)
51	2-1- تعريف الذكاء
51	2-2- مفهوم "الاصطناعي"
51	2-3- تعريف الذكاء الاصطناعي
53	2-4- تصنيفات الذكاء الاصطناعي
54	2-4-1- الذكاء الاصطناعي الضيق (Weak AI / Narrow AI)
54	2-4-2- الذكاء الاصطناعي القوي (Strong AI)
55	2-4-5- الفرق بين الذكاء الاصطناعي الضيق والقوي
56	3- تعلم الآلة (Machine Learning)
56	3-1- تعريف تعلم الآلة
56	3-2- المكونات الرئيسية لبناء نموذج لتعلم الآلة
56	3-2-1- البيانات (Data أو Dataset)
56	3-2-2- الميزات (Features)
57	3-2-3- الخوارزميات (Algorithms)
57	3-3- طرق التعلم الآلي

57		1-3-3-1	التعلم الموجه أو التعلم تحت الإشراف (Supervised learning)
58		1-1-3-3	البيانات (Data أو Dataset)
58		2-1-3-3	النموذج (Model)
58		3-1-3-3	دالة التكلفة (Fonction Coût)
58		4-1-3-3	التعلم من دالة التكلفة
58		5-1-3-3	تطبيقات التعلم تحت الإشراف
59		2-3-3-2	التعلم الغير موجه أو التعلم بدون إشراف (Unsupervised learning)
59		1-2-3-3	التجميع (Clustering)
59		2-2-3-3	تقليل الأبعاد (Dimensionality Reduction)
60		3-2-3-3	تعلم قواعد الارتباط (Association Rule Learning)
61		3-3-3-3	التعلم المعزز (Rienforcement learning)
61		1-3-3-3	المكونات الرئيسية
62		2-3-3-3	أنواع التعلم المعزز
62		1-2-3-3-3	التعلم المعزز القائم على نموذج (Model-Based RL)
62		1-2-3-3-3	التعلم المعزز الغير قائم على نموذج (Model-Free RL)
63		4-3-3-3	الشبكات العصبية والتعلم العميق (Artificial Neural Networks and Deep- Learning)
63	..	1-4-3-3	الشبكات العصبية الاصطناعية (Artificial Neural Networks – ANNs)
63	...	1-1-4-3-3	الشبكات العصبية متعددة الطبقات (Multilayer Perceptron –MPL)
64	..	2-1-4-3-3	الشبكات العصبية التلافيفية (Convolutional Neural Networks – CNNs)
64		3-1-4-3-3	الشبكات العصبية المتكررة (Recurrent Neural Networks – RNNs)
64		2-4-3-3	التعلم العميق (Deep Learning)
65		1-2-4-3-3	تحديات التعلم العميق
65		2-2-4-3-3	الفرق بين التعلم العميق والشبكات العصبية التقليدية

66	4- مجالات استخدام الذكاء الاصطناعي
66	4-1- الذكاء الاصطناعي في الرعاية الصحية
67	4-2- الذكاء الاصطناعي في الأعمال والتسويق
67	4-3- الذكاء الاصطناعي في التعليم والترجمة
67	4-4- الذكاء الاصطناعي في التمويل
67	4-5- الذكاء الاصطناعي في القانون
68	4-6- الذكاء الاصطناعي في التصنيع
68	4-7- الذكاء الاصطناعي في النقل والمركبات الذاتية
68	4-8- الذكاء الاصطناعي في الأمن
68	4-9- الذكاء الاصطناعي في الزراعة
68	4-10- الذكاء الاصطناعي في الزراعة
70	الخاتمة

الباب الثاني: الجانب التطبيقي

الفصل الثالث: الإجراءات المنهجية والتطبيقية

73	تمهيد
74	1- منهج البحث
74	2- الدراسة الاستطلاعية
74	2-1- أدوات الدراسة الاستطلاعية
74	2-2- إجراءات الدراسة الاستطلاعية
75	2-3- أهداف الدراسة الاستطلاعية
75	2-4- نتائج الدراسة الاستطلاعية
76	3- مجتمع الدراسة
77	4- عينة الدراسة

78	5-مجالات الدراسة
78	5-1-المجال المكاني
78	5-2-المجال الزمني
78	6-متغيرات البحث
78	6-1-المتغير المستقل
78	6-2-المتغيرات التابعة
79	7- أدوات البحث
79	7-1- قاعدة البيانات
79	7-2- أجهزة الأداء والتتبع الالكترونية EPTS
79	7-3- الشروط العلمية للأجهزة
80	7-4- . الوسائل الإحصائية ومعالجة البيانات
81	7-5- توزيع Anaconda3 Distribution
82	7-6- منصة Jupyter Notebook
83	7-7- لغة Python3
84	7-8- خوارزمية أقرب الجيران (KNN) KNeighborsClassifier
84	7-9- خوارزمية آلة متجه الدعم (SVM) Support Vector Machine
84	7-10- خوارزمية الغابة العشوائية Random Forest
85	7-11- تقنية تقسيم البيانات إلى تدريب واختبار Train Test Split
85	7-12- تقنية التحقق المتقاطع Cross Validation
86	8- تصميم التطبيق
86	8- واجهة التطبيق
87	8- زر اختيارات التطبيق
88	8- زر بدء التطبيق

89	9- صعوبات البحث
90	خلاصة
	الفصل الرابع: عرض، تحليل ومناقشة النتائج
92	تمهيد
93	1- عرض وتحليل النتائج
94	1-1- عرض وتحليل نتائج الفرضية الأولى
99	2-1- عرض وتحليل نتائج الفرضية الثانية
104	3-1- عرض وتحليل نتائج الفرضية الثالثة
110	4-1- عرض وتحليل نتائج الفرضية الرابعة
116	2- مناقشة النتائج
116	2-1- مناقشة الفرضية الأولى
117	2-2- مناقشة الفرضية الثانية
118	2-3- مناقشة الفرضية الثالثة
119	2-4- مناقشة الفرضية الرابعة
120	خلاصة
122	خاتمة
131	الملاحق

قائمة الجداول

الرقم	عنوان الجدول	الصفحة
1-2	يبيّن الفرق بين الذكاء الاصطناعي الضيق والقوي	55
1-3	توزيع المجتمع حسب كل فريق	77
2-3	توزيع أفراد عينة البحث حسب متغير منصب اللعب في كرة القدم	78
1-4	خصائص الطول، الوزن وعناصر اللياقة البدنية لدى أفراد عينة البحث	93
2-4	يبيّن فروقات الطول والوزن بين لاعبي وسط الدفاع والمناصب الأخرى	94
3-4	يبيّن الفروقات في عناصر اللياقة البدنية بين لاعبي وسط الدفاع والمناصب الأخرى	94
4-4	يبيّن نسب دقة نماذج تعلم الآلة للفرضية الأولى	98
5-4	يبيّن فروقات الطول والوزن بين لاعبي وسط الميدان والمناصب الأخرى	99
6-4	يبيّن لفروقات في عناصر اللياقة البدنية بين لاعبي وسط الميدان والمناصب الأخرى	99
7-4	يبيّن نسب دقة نماذج تعلم الآلة للفرضية الثانية	104
8-4	يبيّن فروقات الطول والوزن بين لاعبي الأروقة والمناصب الأخرى	104
9-4	يبيّن لفروقات في عناصر اللياقة البدنية بين لاعبي الأروقة والمناصب الأخرى	105
10-4	يبيّن نسب دقة نماذج تعلم الآلة	110
11-4	يبيّن فروقات الطول والوزن بين لاعبي قلب الهجوم والمناصب الأخرى	110
12-4	يبيّن لفروقات في عناصر اللياقة البدنية بين لاعبي قلب الهجوم والمناصب الأخرى	111
13-4	يبيّن نسب دقة نماذج تعلم الآلة	116

قائمة الأشكال

الرقم	عنوان الشكل	الصفحة
1-2	رسم توضيحي للعلاقة بين علوم الحاسوب، الذكاء الاصطناعي، تعلم الآلة	53
2-2	أكثر أساليب التعلم الآلي استخداماً	57
3-2	الفرق بين الشبكات العصبية التقليدية والتعلم العميق	66
1-3	واجهة توزيع Anaconda distribution	81
2-3	واجهة منصة Jupyter notebook	82
3-3	واجهة مشروع بلغة Python باستخدام منصة Jupyter notebook	83
4-3	واجهة التطبيق لإدخال البيانات	86
5-3	اختيارات نوع التقييم	87
6-3	زر بدء التقييم	88
1-4	يمثل مقارنة النموذج البدني بين لاعبي محور الدفاع والمناصب الأخرى في الليغ 1 و2	95
2-4	يمثل مصفوفة تقييم أداء نموذج KNN	96
3-4	يمثل مصفوفة تقييم أداء نموذج SVM	97
4-4	يمثل مصفوفة تقييم أداء نموذج Random Forest	98
5-4	يمثل مقارنة النموذج البدني بين لاعبي وسط الميدان والمناصب الأخرى في الليغ 1 و2	100
6-4	يمثل مصفوفة تقييم أداء نموذج KNN	101
7-4	يمثل مصفوفة تقييم أداء نموذج SVM	102
8-4	يمثل مصفوفة تقييم أداء نموذج Random Forest	103
9-4	يمثل مقارنة النموذج البدني بين لاعبي الأروقة والمناصب الأخرى في الليغ 1 و2	106
10-4	يمثل مصفوفة تقييم أداء نموذج KNN	107
11-4	يمثل مصفوفة تقييم أداء نموذج SVM	108
12-4	يمثل مصفوفة تقييم أداء نموذج Random Forest	109

110	يمثل مقارنة النموذج البدني بين لاعبي قلب الهجوم والمناصب الأخرى في الليغ 1 و2	13-4
113	يمثل مصفوفة تقييم أداء نموذج KNN	14-4
114	يمثل مصفوفة تقييم أداء نموذج SVM	15-4
115	يمثل مصفوفة تقييم أداء نموذج Random Forest	16-4

المقدمة

تُعتبر كرة القدم من أبرز الرياضات الجماهيرية في العالم وأكثرها تطلبًا من الناحية البدنية والتكتيكية، حيث أصبح الأداء العالي فيها يرتبط بمجموعة من العوامل المتداخلة التي تجمع بين القدرات البدنية، المهارات الفنية، الصفات النفسية، والمعارف الخططية. ومع ازدياد حدة التنافس في المستويات العليا وتنامي متطلبات اللعب الجماعي، بات الانتقاء الرياضي عملية محورية لضمان حسن استثمار المواهب وتوجيهها نحو المراكز التي تتوافق مع خصائصها وقدراتها الفردية. فالانتقاء لم يعد مجرد اختيار تقليدي قائم على الملاحظة والانطباعات الشخصية، بل أصبح علمًا متكاملًا يركز على أسس موضوعية وبيانات دقيقة.

وفي ظل التطور التكنولوجي الهائل الذي يشهده العالم المعاصر، برز الذكاء الاصطناعي كأحد أهم الأدوات الحديثة القادرة على إحداث نقلة نوعية في مجال التدريب والانتقاء الرياضي. إذ تسمح تقنيات تعلم الآلة (Machine Learning) بتحليل كميات ضخمة من البيانات واستخلاص أنماط دقيقة تساعد على التنبؤ بالأداء الرياضي وتوجيه اللاعبين إلى المراكز المناسبة. وتُعد كرة القدم من أكثر الرياضات التي استفادت من هذا التوجه، بالنظر إلى طبيعتها المعقدة وتعدد متغيراتها البدنية والفنية والتكتيكية.

إن التوجيه نحو مراكز اللعب يُمثل عنصرًا حاسمًا في تطوير المسار الرياضي للاعب، حيث أن اختيار المنصب الملائم لقدراته يساهم في تعظيم أدائه الفردي وتعزيز مردودية الفريق ككل. وعليه، فإن دمج تقنيات الذكاء الاصطناعي في عملية الانتقاء الرياضي يتيح فرصًا جديدة أمام المدربين والأكاديميات لاتخاذ قرارات أكثر موضوعية وفعالية، بعيدًا عن التقديرات الانطباعية التي قد يشوبها التحيز أو النقص في المعلومات.

انطلاقًا من هذه الأهمية، جاءت هذه الأطروحة لمعالجة إشكالية كيفية توظيف تقنيات الذكاء الاصطناعي في عملية الانتقاء الرياضي وتوجيه لاعبي كرة القدم نحو مراكز اللعب وفق قدراتهم البدنية، وذلك من خلال تصميم نموذج ذكي قادر على الاستفادة من البيانات الإحصائية والبدنية لتسهيل عملية اتخاذ القرار الفني.

ولتحقيق ذلك، قُسمت هذه الأطروحة إلى فصل تمهيدي وأربعة فصول رئيسية على النحو التالي:

الفصل التمهيدي: خصص لعرض إشكالية البحث، أهميته، أهدافه، الفرضيات المطروحة، بالإضافة إلى منهجية البحث المعتمدة وأدواته وحدوده.

الفصل الأول: تناول الجوانب النظرية المتعلقة بالانتقاء والتوجيه الرياضي، محدداتهما، وعلاقتهما بعناصر اللياقة البدنية الأساسية، مع التطرق إلى خصوصيات مراكز اللعب في كرة القدم.

الفصل الثاني: حُصص للتطرق إلى مفاهيم الذكاء الاصطناعي وتعلم الآلة، نشأتها، خصائصها، أهم الخوارزميات المستعملة، والتطبيقات العملية لهما في المجال الرياضي عمومًا وكرة القدم خصوصًا.

الفصل الثالث: عرض الإجراءات الميدانية للبحث، بما في ذلك اختيار العينة، تحديد أدوات القياس، الاختبارات البدنية المعتمدة، والأسلوب الإحصائي المستخدم في المعالجة.

الفصل الرابع: حُصص للمعالجة الإحصائية للبيانات، عرض النتائج وتحليلها في ضوء الفرضيات، مع مناقشتها بالاستناد إلى الدراسات السابقة، وصولاً إلى الخلاصات العامة والاقتراحات العملية.

إن هذا البناء المنهجي المتدرج يهدف إلى الربط بين الجانب النظري والتطبيقي، وبين العلوم الرياضية التقليدية والتقنيات الحديثة في الذكاء الاصطناعي، في محاولة لتقديم إسهام علمي يثري مجال الانتقاء والتوجيه الرياضي، ويمنح المدربين والباحثين أداة عملية تساعد في تحسين نوعية القرارات الفنية والتكوينية داخل كرة القدم الحديثة.

الفصل التمهيدي

مدخل عام للدراسة

الإشكالية:

شهد العالم في العقود الأخيرة ثورة علمية وتكنولوجية غير مسبوقة، حيث أصبح الذكاء الاصطناعي من أبرز مظاهر هذه الثورة، لما يحمله من إمكانيات هائلة في معالجة البيانات واتخاذ القرار وحل المشكلات المعقدة. فقد أتاح هذا المجال المستحدث للباحثين والعلماء في مختلف التخصصات تطوير أدوات ونماذج تتجاوز في قدراتها حدود الإنسان من حيث السرعة والدقة، وهو ما جعل الذكاء الاصطناعي عنصرًا محوريًا في مسار التطور العلمي والتقني. وإذا كان الذكاء الاصطناعي قد بدأ حضوره في ميادين الصناعة والطب والاقتصاد، فإن الرياضة بدورها لم تكن بمنأى عن هذا التحول، بل صارت واحدة من أكثر المجالات استفادة من تطبيقاته الحديثة، حيث برز دوره في التدريب، والتحليل الفني، والتنبؤ بالأداء، وتقليل الإصابات، بل وحتى في تحسين قرارات الحكام من خلال تقنيات المساعدة بالفيديو (VAR).

وفي إطار الرياضة الجماعية، تظل كرة القدم أكثر الرياضات ارتباطًا بالتطورات التكنولوجية، نظرًا لتعقيدها وتعدد متغيراتها وتوسع شعبيتها عالميًا. لقد أصبحت كرة القدم الحديثة قائمة على الصرامة التكتيكية والنسق العالي في اللعب، سواء بالكرة أو بدونها، مما جعل الحمل البدني والذهني للاعبين يزداد بدرجة ملحوظة حسب مراكز اللعب المختلفة. هذا التباين في المتطلبات جعل مسألة الانتقاء الرياضي (Sport Selection) والتوجيه الدقيق للاعبين إلى المراكز المناسبة عملية جوهرية، إذ إن نجاح الفريق مرتبط بمدى التوظيف الصحيح لقدرات اللاعبين حسب خصائصهم البدنية والفنية والنفسية (Cazorla & Fahi, 1998)؛ (Lambertain, 2004).

ورغم الأهمية البالغة لعملية الانتقاء والتوجيه الرياضي، إلا أن هذه العملية ما تزال في كثير من الأوساط الرياضية، خصوصًا المحلية منها، تعتمد على الملاحظة الانطباعية والخبرة الشخصية للمدربين، دون الاستناد إلى أساليب علمية دقيقة أو قواعد بيانات موضوعية. وهو ما يؤدي في كثير من الأحيان إلى سوء توظيف اللاعبين أو ضياع مواهب كان يمكن أن تحقق نتائج أفضل لو وُجهت إلى المراكز المناسبة. وفي هذا السياق، يشير هوار عبد اللطيف (2015) إلى أن غياب نظام معلوماتي لتوجيه اللاعبين يعد من أبرز النقائص التي يعاني منها واقع كرة القدم الجزائرية، خاصة مع محدودية الاهتمام بالانتقاء المبكر المبني على أسس علمية دقيقة.

ومع تطور تقنيات الذكاء الاصطناعي، ظهرت إمكانيات جديدة لتجاوز هذه النقائص من خلال بناء نماذج تعلم آلي (Machine Learning) قادرة على تحليل البيانات البدنية والمهارية والفسولوجية للاعبين، والتنبؤ بالمركز الأنسب لهم. فقد أثبتت العديد من الدراسات الحديثة فعالية هذه النماذج؛ إذ طور (Schumaker et al. 2018).

نموذجًا باستخدام خوارزميات التصنيف مثل SVM و Random Forest للتنبؤ بمراكز اللاعبين بناءً على بياناتهم الفردية، وأظهرت النتائج أن هذه الخوارزميات قادرة على تقديم نسب دقة معتبرة في التصنيف. وفي دراسة أحدث، اقترح (Di Giacomo et al. (2022) استخدام تقنيات التعلم الآلي لتحليل بيانات تتبع اللاعبين أثناء المباريات، مما مكن من التعرف على مواقعهم في الملعب بدقة بلغت 95.4% على المحور X و 92% على المحور Y عند تقسيم الملعب إلى ثلاث مناطق، وهو ما يعكس قوة هذه النماذج في التتبع والتصنيف في الزمن الحقيقي. كما بينت دراسة (Cortés et al. (2022) إمكانية التنبؤ بالمتغيرات الفسيولوجية للاعبين الذين يشكلون فريقًا فائزًا بدقة بلغت 79%، مما يدل على قيمة الذكاء الاصطناعي كأداة داعمة لاتخاذ القرار الرياضي.

هذه الدراسات، وغيرها مثل مراجعة (Claudino et al. (2019)، توضح أن إدماج الذكاء الاصطناعي في الممارسة الرياضية لم يعد ترفاً أكاديمياً بل ضرورة ملحة لمواكبة التطور العالمي. فالذكاء الاصطناعي، بخوارزمياته المتنوعة مثل: خوارزمية أقرب الجيران (K-Nearest Neighbors (KNN)، خوارزمية آلة الدعم الموجه Support Vector Machine (SVM)، وخوارزمية الغابة العشوائية Random Forest، يتيح إمكانية بناء تطبيقات ذكية تساعد المدربين على التعرف على خصائص اللاعبين وتوجيههم نحو المراكز التي تتناسب مع قدراتهم البدنية. ولعل هذا يكتسي أهمية خاصة في ظل الإشكاليات التي يعرفها واقع كرة القدم الجزائرية بعد الاحتراف، حيث أضحت غياب قاعدة بيانات موحدة لتقييم اللاعبين، واعتماد أسلوب الملاحظة فقط، من أبرز العوائق أمام التكوين الصحيح للاعبين المحليين.

ومن هذا المنطلق، تبرز الإشكالية المركزية التي تسعى هذه الدراسة لمعالجتها:

إلى أي مدى تستطيع تقنيات تعلم الآلة، اعتماداً على عناصر اللياقة البدنية، تصنيف لاعبي كرة القدم حسب مراكز اللعب المختلفة في البطولة الفرنسية الأولى والثانية ؟

وانطلاقاً من هذه الإشكالية العامة، تتفرع الأسئلة البحثية التالية:

تساؤلات الدراسة:

➤ هل يستطيع تعلم الآلة التعرف على لاعبي وسط الدفاع البطولة الفرنسية ليع 1 و 2 من خلال عناصر اللياقة البدنية؟

- هل يستطيع تعلم الآلة التعرف على لاعبي وسط الميدان البطولة الفرنسية ليغ 1 و 2 من خلال عناصر اللياقة البدنية ؟
- هل يستطيع تعلم الآلة التعرف على لاعبي الأروقة البطولة الفرنسية ليغ 1 و 2 من خلال عناصر اللياقة البدنية ؟
- هل يستطيع تعلم الآلة التعرف على لاعبي قلب الهجوم البطولة الفرنسية ليغ 1 و 2 من خلال عناصر اللياقة البدنية ؟

فرضيات الدراسة:

- يستطيع تعلم الآلة التعرف على لاعبي وسط الدفاع البطولة الفرنسية ليغ 1 و 2 من خلال عناصر اللياقة البدنية.
- يستطيع تعلم الآلة التعرف على لاعبي وسط الميدان البطولة الفرنسية ليغ 1 و 2 من خلال عناصر اللياقة البدنية.
- يستطيع تعلم الآلة التعرف على لاعبي الأروقة البطولة الفرنسية ليغ 1 و 2 من خلال عناصر اللياقة البدنية.
- يستطيع تعلم الآلة التعرف على لاعبي قلب الهجوم البطولة الفرنسية ليغ 1 و 2 من خلال عناصر اللياقة البدنية.

أهداف البحث:

- التعرف على العلاقة بين عناصر اللياقة البدنية ومراكز اللعب في كرة القدم .
- إبراز الفروق البدنية بين اللاعبين حسب مراكز اللعب.
- توظيف تقنيات الذكاء الاصطناعي في تحليل بيانات اللاعبين .
- تصميم نموذج ذكي قادر على اقتراح مركز اللعب الأنسب لكل لاعب اعتمادًا على خصائصه البدنية.

أهمية البحث:

- إدخال التكنولوجيا والذكاء الاصطناعي في مجال الانتقاء الرياضي.
- مساعدة المدربين على اتخاذ قرارات أكثر دقة في توجيه اللاعبين.
- المساهمة في تطوير المواهب الرياضية بطريقة علمية.
- بناء نموذج وصفي للخصائص البدنية لكل مركز لعب .
- فتح المجال أمام دراسات أخرى تربط بين علوم الرياضة والتكنولوجيا.
- تطوير طرق الانتقاء الرياضي في الأندية والمدارس الكروية.

وبذلك، فإن هذه الدراسة تسعى إلى الجمع بين الجانب النظري (الانتقاء الرياضي وأهميته في كرة القدم) والجانب التطبيقي (بناء نموذج ذكي يوجه اللاعبين وفق قدراتهم)، في محاولة لتقديم إضافة علمية وميدانية يمكن أن تدعم المدربين والأكاديميات الكروية في مهام التكوين والانتقاء.

تحديد مصطلحات الدراسة:

تعريف اللياقة البدنية:

يعرفها مفتي إبراهيم بأنها "مقدرة يتسم بها الفرد تتمكن من خلالها أجهزته الفسيولوجية من الوفاء بمتطلبات بعض الواجبات البدنية والحياة بكفاءة وفاعلية". (مفتي، 2004)

إجرائيا: قدرة يتسم بها اللاعب في الوفاء بكفاءة وفاعلية بمتطلبات الأداء البدني المتمثلة في التسارع، السرعة، سرعة رد الفعل، الرشاقة، التوازن، الارتقاء، القوة، التحمل.

تعريف التسارع (Acceleration):

القدرة على زيادة السرعة من حالة السكون أو من سرعة منخفضة إلى أقصى سرعة ممكنة في أقصر زمن ممكن. (Leroux, 2006)

إجرائيا: يقصد بالتسارع القيمة الرقمية التي تعبر عن قدرة اللاعب على الوصول إلى سرعته القصوى في زمن قصير، كما هي ممثلة في قاعدة بيانات على موقع sofifa.

تعريف السرعة الانتقالية (Sprint):

يعرفها فرانك ديك بأنها القدرة على تحريك أطراف أو جزء من روافع الجسم أو الجسم ككل في أقل زمن ممكن. (عبدالفتاح و سيد، 2008)

إجرائيا: تعرف السرعة على أنها القيمة الرقمية التي تعبر عن قدرة اللاعب على بلوغ السرعة القصوى أثناء الجري، كما هي ممثلة في قاعدة بيانات على موقع sofifa.

تعريف سرعة رد الفعل (Reactions):

هي الفترة الزمنية بين التي تنقضي بين لحظة ظهور مثير معين وبداية الاستجابة لهذا المثير. (سيد، 2003)

إجرائيا: تعرف سرعة ردّ الفعل على أنها القيمة الرقمية التي تعبّر عن قدرة اللاعب على الاستجابة السريعة للمثيرات المختلفة أثناء اللعب، كما هي ممثلة في قاعدة بيانات على موقع sofifa.

تعريف الرشاقة (Agility):

القدرة على تغيير أوضاع الجسم والاتجاهات في أقصر وقت ممكن، وبكفاءة عالية، مع المحافظة على التوازن أثناء الأداء الحركي (محمود أ.، 2016)

إجرائيا: تعرف الرشاقة على أنها القيمة الرقمية التي تعبّر عن قدرة اللاعب على تغيير اتجاهه بسرعة وكفاءة أثناء الحركة، كما هي ممثلة في قاعدة بيانات على موقع sofifa.

تعريف التوازن (Balance):

يعرف التوازن بأنه القدرة على التحكم في وضعية الجسم أثناء الثبات أو الحركة، بما يسمح للاعب بالحفاظ على استقراره في مختلف المواقف (Pradet, 2012)

إجرائيا: يعرف التوازن على أنه القيمة الرقمية التي تعبّر عن قدرة اللاعب على الحفاظ على استقرار جسمه أثناء الحركة أو عند التعرض لاحتكاك، كما هي ممثلة في قاعدة بيانات على موقع sofifa.

تعريف الارتقاء (Jumping):

قدرة العضلات على التغلب على مقاومة ثقل الجسم والقفز عاليا. (علاوي، 1990)

إجرائيا: يعرف الارتقاء على أنه القيمة الرقمية التي تعبّر عن قدرة اللاعب على القفز عموديا للوصول إلى أقصى ارتفاع ممكن، كما هي ممثلة في قاعدة بيانات على موقع sofifa.

تعريف القوة (Strength):

مقدرة العضلات على التغلب على المقاومات الخارجية المختلفة أو مواجهتها. (سيد، 2003)

إجرائيا: تعرف القوة على أنها القيمة الرقمية التي تعبّر عن قدرة اللاعب على التفوق في المواجهات البدنية ومقاومة الالتحامات والحفاظ على الكرة تحت الضغط، كما هي ممثلة في قاعدة بيانات على موقع sofifa.

تعريف التحمل (Stamina):

يرى بعض العلماء أنه قدرة الفرد على العمل لفترات طويلة دون هبوط مستوى الكفاية أو الفاعلية، كما يعرفه البعض الآخر بأنه قدرة أجهزة الجسم على مقاومة التعب البدني، العقلي، الحسي والانفعالي. (علاوي، 1990)

إجرائياً: يعرف التحمل على أنه القيمة الرقمية التي تعبر عن قدرة اللاعب على الاستمرار في الأداء البدني بنفس الكفاءة طوال مدة المباراة دون انخفاض ملحوظ في المستوى البدني، كما هي ممثلة في قاعدة بيانات على موقع sofifa.

تعريف الانتقاء الرياضي:

" الانتقاء الرياضي هو عملية اختيار الأفراد الذين يمتلكون أفضل الصفات البدنية والفسولوجية والمهارية والنفسية، والتي تؤهلهم لتحقيق أفضل الإنجازات في النشاط الرياضي المعين." (حسانين، الاختبارات والمقاييس في التربية الرياضية، 1999)

وحسب علي بن صالح " مصطلح الانتقاء يعبر عن أو يضم مصطلحي التوجيه والانتقاء في مفهوم شامل، أي أن استعمال مصطلح الانتقاء يعني ضمناً توجيه اللاعبين إلى النشاط أو المركز المناسب حسب مؤهلاتهم". (كرميش، 2020)

إجرائياً: توجيه لاعبي كرة القدم نحو مراكز اللعب (وسط الدفاع، وسط الميدان، الأروقة أو الأجنحة وقلب الهجوم)

تعريف الذكاء الاصطناعي

علم تفرع عن علوم الحاسب الآلي يهتم بالذكاء الإنساني والمهارة البشرية من خلال إعداد برامج وأجهزة يمكنها أن تقوم بعمليات شبيهة بهذا الذكاء وتلك المهارة (زين، 2000).

إجرائياً: تعليم الآلة (الحاسوب) التعرف على مراكز اللاعبين في كرة القدم من خلال تزويدها بالمعلومات والخصائص البدنية لمجموعة من اللاعبين في مختلف مناصب اللعب.

الدراسات السابقة:

1- دراسة هوار عبداللطيف (2015) تحت عنوان " Elaboration d'un programme informatique pour orienter les jeunes footballeurs vers les compartiments de jeu suivant le profil morphologique et les

attributs de l'aptitude physique et technique : هدفت الدراسة إلى تصميم برنامج حاسوبي لتوجيه لاعبي كرة القدم أقل من 17 سنة حسب خطوط اللعب وفق المؤشرات المورفولوجية وعناصر اللياقة البدنية والمهارية، وقد استخدم الباحث المنهج الوصفي لملائمته طبيعة الدراسة، وتكونت العينة من 208 لاعب من فرق البطولة المحترفة الأولى والثانية للموسم الكروي 2012-2013، حيث استعمل مجموعة من القياسات الجسمانية تمثلت في وزن الجسم، طول القامة، مؤشر الكتلة الجسمانية، نسبة الدهون، كما طبق مجموعة من الاختبارات البدنية والمهارية، تمثلت في اختبار Luc Léger لقياس VO2max، اختباري 10 و 40 متر، اختبار الوثب العمودي من الثبات، اختبار الجري بالكرة لمسافة 30 متر، اختبار الجري بالكرة 30 متر x 5، واختبار التحكم في الكرة في مساحة محددة (Huit)، وقد توصلت نتائج الدراسة إلى تصميم برنامج حاسوبي يوجه لاعبي كرة القدم أقل من 17 سنة حسب خطوط اللعب وحسب المتغيرات التي تم ذكرها في أقل زمن وجهد وأكثر دقة، وأوصى الباحث باستعمال البرنامج في تقييم وتوجيه لاعبي كرة القدم لأقل من 17 سنة، وإدخال التكنولوجيات الحديثة في كرة القدم الجزائرية وتصميم المزيد من البرامج الحاسوبية لفئات عمرية أخرى وعلى متغيرات أخرى.

2- دراسة بومدين قادة، كوتشوك سيدي محمد وميم مختار (2018) تحت عنوان " دراسة مقارنة بين بعض معايير التوجيه البدنية والمهارية على حسب خطوط اللعب (دفاع، وسط، هجوم) " : هدفت الدراسة إلى مقارنة بين خطوط اللعب (دفاع، وسط ميدان، هجوم) لدى لاعبي كرة القدم أقل من 17 سنة، فيما يخص بعض القدرات البدنية (قوة الأطراف السفلية، السرعة)، وبعض القدرات المهارية (دقة التمرير، دقة التصويب، ضرب الكرة لأبعد مسافة وضرب الكرة بالرأس). حيث تم استخدام المنهج الوصفي، وتكونت عينة الدراسة من 36 لاعب من 4 فرق تابعة لولاية تيارت ينتمون إلى رابطة سعيدة الجهوية للموسم الكروي 2016-2017، حيث كانت العينة مقسمة على 12 لاعب دفاع، 12 لاعب وسط ميدان و 12 لاعب هجوم. وتم استخدام الاختبارات التالية: اختبار سارجنت، اختبار القفز الطويل من الثبات، اختباري السرعة 10م و 30م، اختبار دقة التمرير (فاينس ومسا)، اختبار دقة التصويب (فاينس ومسا)،

اختبار ضرب الكرة بالرجل إلى أبعد مسافة وضرب الكرة بالرأس إلى أبعد مسافة. توصلت الدراسة إلى وجود فروق بين لاعبي خط الهجوم ولاعبي باقي الخطوط في الاختبارات الموضوعة، مما يوحي إلى اختلاف المتطلبات البدنية والمهارية وخصوصيتها حسب خطوط اللعب، وأوصت الدراسة بتوجيه اللاعبين إلى مناصب اللعب حسب قدراتهم البدنية والمهارية.

3- دراسة Manaswitta Datta et Bhawana Rudra (2022) تحت عنوان " An intelligent decision support system for bid prediction of undervalued football players ": هدفت الدراسة إلى استخدام تقنيات الذكاء الاصطناعي لانتقاء لاعبين من بين اللاعبين المحترفين ذوي القيمة التسويقية الضعيفة لكن بخصائص وأداء مماثل للاعبين بقيمة تسويقية عالية. تم استخدام قاعدة بيانات Fifa 21 تم تحميلها من موقع sofifa.com، حيث شملت عينة الدراسة 18207 لاعب مع عدد خصائص قدر بـ 89 لكل لاعب. بعد تنظيف وتصفية البيانات تم استخدام خمسة نماذج لتعلم الآلة: SVM، Random forest، Decision tree، Linear regression، XGboost، وتم تدريب واختبار كل نموذج ثم حساب CV error، حيث كانت أفضل نتيجة لتقنية XGboost بـ 0.0122 و 0.0107 لـ test error و cv error على التوالي.

4- دراسة بليدي تواتي وآخرون (2017) تحت عنوان " Sur quel critères nos entraineurs U17 sélectionnent leurs équipes type en football ": هدفت الدراسة إلى كشف مدى فعالية الطرق المستخدمة من قبل المدربين الجزائريين لفئة أقل من 17 سنة في اختيار التشكيلة الأساسية (11 لاعب أساسي). من أجل ذلك تم استخدام الطريقة الوصفية، فكانت العينة عبارة عن 24 لاعب من فريق تدريبي مستغانم أقل من 17 سنة، حيث تم تطبيق القياسات الأنثروبومترية (مؤشر كتلة الجسم BMI، نسبة الدهون في الجسم BFP) واختبار بريكسي لحساب الاستهلاك الأقصى للأكسجين (VO2max). أظهرت النتائج فروق بين التشكيلة الأساسية والتشكيلة الاحتياطية لصالح هذه الأخيرة، وعليه تم اعتبار الطرق التقليدية المستخدمة من طرف المدربين والتي تعتمد على خبراتهم غير فعالة، كما توصي الدراسة المدربين باستخدام الممارسات العلمية من خلال تطبيق الاختبارات

العلمية، الأخذ بعين الاعتبار تحليلات الخاصة بكرة القدم الحديثة ومراعاة الفروق الفردية في عملية اختيار التشكيلة الأساسية للفريق.

5- دراسة سعداوي فيصل وحريط سامي (2021) تحت عنوان " تقييم معايير انتقاء المواهب الشابة في كرة القدم الجزائرية بمقارنة مع المعايير الدولية ": هدفت الدراسة إلى تقييم واقع الانتقاء والتوجيه الرياضي في نوادي النخبة الجزائرية ومدى اعتماده على المعايير المدروسة والمقننة التي تعتمد عليها مراكز التكوين الأوروبية مستخدمة المنهج الوصفي، حيث تم تطبيق استبيان على مجموعة من المدربين بلغ عددهم 33 مدرب، ومجموعة من الاختبارات البدنية (السرعة الانتقالية 10م، السرعة الانتقالية 40م، اختبار القفز العمودي من الثبات واختبار vameval) على عينة قدرت بـ 53 لاعب فئة أقل من 14 سنة لفريقي نجم مقرة ووافق سطيف وتم مقارنتها بمعايير محكية لعينة فرنسية. أفضت النتائج إلى تفوق العينة الفرنسية في مختلف الاختبارات البدنية نظرا لابتعاد النوادي الجزائرية على المعايير العلمية في عملية الانتقاء. في الأخير أوصت الدراسة بضرورة الاعتماد على المعايير العلمية والدولية في تقنين عملية الانتقاء والتوجيه الرياضي.

6- دراسة أركان حسن جبار وآخرون (2018) تحت عنوان " دراسة مقارنة لبعض الصفات والقدرات البدنية على وفق خطوط اللعب للاعبين الشباب في كرة القدم ": هدفت الدراسة إلى التعرف على الفروق في بعض القدرات البدنية لدى لاعبي كرة القدم وفق خطوط اللعب. استخدم الباحثون المنهج الوصفي بأسلوبه المسحي، وكانت الدراسة على لاعبي شباب فريق النهرين العراقي لكرة القدم، حيث شملت العينة 12 لاعب من بين 18 بعد استبعاد 6 لاعبين بسبب الإصابة. بالإضافة لقياس الطول والوزن، قام الباحثون بتطبيق 6 اختبارات بدنية، الجري لمسافة 1000م لقياس التحمل، الجري المتعرج 5م x 3م لقياس الرشاقة، الجري 30م من الوقوف لقياس السرعة الانتقالية، اختبار الدفع الأقصى (الضفدع) لقياس القوة العضلية، الوثب العمودي (سارجنت) لقياس القوة الانفجارية واختبار الحجل على رجل واحدة (اليمنى ثم اليسرى) لمسافة 30م لقياس القوة المميزة بالسرعة للأطراف السفلى. أظهرت النتائج أفضلية لاعبي خط الهجوم في صفات الرشاقة، القوة الانفجارية والقوة المميزة بالسرعة، وأفضلية لاعبي خط الوسط في صفتي التحمل والقوة العضلية، فيما كانت الأفضلية في صفة السرعة للاعبين خط الدفاع.

7- دراسة أعراب عبد الرحيم ومحمدي مهدي (2022) تحت عنوان " محددات عمليتي انتقاء وتوجيه اللاعبين نحو مناصب اللعب في أندية كرة القدم الجزائرية ": هدفت الدراسة إلى معرفة المحددات التي تقوم عليها انتقاء وتوجيه لاعبي كرة القدم الجزائرية نحو مناصب اللعب، ولتحقيق ذلك تم استخدام المنهج الوصفي حيث طبق استبيان على عينة مكونة من 30 مدرب لفتي أقل من 15 سنة وأقل من 17 سنة مختارة بطريقة عشوائية من مجتمع يتكون من 45 مدرب ينتمون لرابطة باتنة الجهوية. توصلت الدراسة إلى عدم اعتماد غالبية مدربي الفئات الشبانية لرابطة باتنة الجهوية لكرة القدم على الأسس العلمية في انتقاء وتوجيه اللاعبين نحو مناصب اللعب والاكتفاء فقط بالملاحظة خلال المباريات التطبيقية.

8- دراسة زروال محمد (2017) تحت عنوان " بناء بطارية اختبارات بدنية بغرض الانتقاء للفرق املدرسة لكرة القدم يف املرحل الثانية - دراسة ميدانية لبعض ثانويات بلدية بسكرة- ": هدفت الدراسة إلى تصميم بطارية اختبارات بدنية لانتقاء لاعبي كرة القدم لفائدة فرق كرة القدم المدرسية للمرحلة الثانوية. اعتمدت الدراسة على المنهج الوصفي، كما تم اختيار عينة الدراسة بطريقة قصدية متمثلة في 48 تلميذ (لاعب) ينتمون لفريقي ثانوية محمد قروف وثانوية محمد بلونار من أصل 175 تلميذ (لاعب) ينتمون ل 7 فرق مدرسية للمرحلة الثانوية لبلدية بسكرة، حيث تم استخدام 12 اختبار بدني (اختبار كوبر و Navette 20م للمداومة والتحمل، اختبار sj واختبار cmj للقوة، اختباري الجري 30م و50م للسرعة الانتقالية، واختباري سرعة رد الفعل السمعية والبصرية، اختبار الجري 10x4م واختبار T للرشاقة وأخيرا اختباري ثني الجذع للأمام من الوقوف وثني الجذع من الجلوس الطويل، أما بالنسبة للوسيلة الإحصائية فقد استخدم التحليل العاملي. توصلت النتائج إلى تصميم بطارية اختبار مكونة من 4 اختبارات: اختبار سرعة رد الفعل البصرية، اختبار قوة الأطراف السفلية cmj، اختبار السرعة الانتقالية 30م واختبار T للرشاقة.

9- دراسة عشيظ هني محمد الأمين وآخرون (2024) تحت عنوان " بناء بطارية اختبارات بدنية بغرض الانتقاء للفرق املدرسة لكرة القدم يف املرحل الثانية - دراسة ميدانية لبعض ثانويات بلدية بسكرة- ": هدفت الدراسة إلى التعرف على قدرة الذكاء الاصطناعي في تحديد لاعبي كرة القدم البطولة الألمانية المحترفة الأولى والثانية أكابر الذين يمكنهم اللعب في مركز قلب الدفاع وذلك حسب قدراتهم البدنية من خلال استخدام تعلم الآلة. تم استخدام المنهج الوصفي بأسلوبه المسحي، وتكونت عينة الدراسة من 884 لاعب من مجتمع مكون من 1008 من البطولة

الألمانية البوندسليغا البوندسليغا 2 للموسم الكروي 2022-2023، حيث تم الاستغناء عن 124 لاعب يمثلون حراس المرمى نظراً لخصوصيات هذا المنصب. كما استخدمت الدراسة ثلاث نماذج لتعلم الآلة، خوارزمية أقرب الجيران (KNeighboresClassifier (KNN)، خوارزمية الغابة العشوائية Random Forest وخوارزمية آلة المتجه الداعم (Support Vector Machine (SVM). وقد أظهرت النتائج قدرة معتبرة لنماذج الذكاء الاصطناعي المستخدمة في تحديد لاعبي مركز خط الدفاع، حيث كانت دقة النماذج على التوالي 0.8484 ، 0.8574 و 0.8506، وعليه أوصت الدراسة باستخدام تقنيات تعلم الآلة في عملية انتقاء وتوجيه اللاعبين.

10- دراسة Manish.S وآخرون (2021) تحت عنوان " Prediction of Football Players Performance using Machine Learning and Deep Learning Algorithms

: هدفنا هذه الدراسة إلى التنبؤ بأداء لاعبي كرة القدم وفقاً لمراكز اللعب المختلفة (مهاجم، وسط، مدافع، حارس مرمى) باستخدام تقنيات التعلم الآلي والتعلم العميق. اعتمد الباحثون على بيانات إحصائية حقيقية من موسم 2018-2019 شملت 572 لاعباً، مع أكثر من 46 متغيراً يصف الأداء البدني والفني للاعبين. تم تطبيق خطوات منهجية دقيقة تضمنت استخراج البيانات، إعدادها، معالجة المتغيرات من خلال تحليل الارتباط وتقليل الأبعاد، ثم بناء نماذج منفصلة لكل مركز لعب. استخدمت الدراسة أربعة نماذج رئيسية: الانحدار الخطي المتعدد، الشبكات العصبية الاصطناعية، XGBoost Regression، وانحدار آلة الدعم النقطي (SVR)، وتم تقييم أدائها باستخدام معايير إحصائية مثل R^2 ، MSE، RMSE، و MAE.

أظهرت النتائج أن نموذج الانحدار المتعدد تفوق على جميع النماذج الأخرى، حيث قدم أدق التنبؤات بأداء اللاعبين، خاصة بفضل قابلية المتغيرات للفصل الخطي وقوة ارتباطها بالمتغيرات المستهدفة. جاء بعده نموذج XGBoost بنتائج مقبولة، بينما أظهرت الشبكات العصبية وانحدار SVR أداءً أضعف نسبياً مع معدلات خطأ أكبر. خلصت الدراسة إلى أن النماذج الإحصائية البسيطة، مثل الانحدار المتعدد، قد تكون أكثر فعالية من النماذج المعقدة عند التعامل مع بيانات منظمة وقابلة للفصل الخطي، كما أوصت بتوسيع البحث ليشمل مجموعات بيانات أكبر ومتنوعة للتحقق من عمومية النتائج.

11- دراسة دي جاكومو وزملاؤه (2022) تحت عنوان " Machine Learning on Soccer Player Positions

: هدفت الدراسة إلى تطوير منهجية قائمة على تقنيات التعلم الآلي للتعرف على مواقع لاعبي كرة القدم أثناء المباريات، وذلك لتحليل التزامهم بالتعليمات التكتيكية وتقييم الأداء الفني. اعتمد الباحثون على بيانات نظام تتبع (ZXY Sport Tracking) وكاميرات فيديو بملعب Alfheim Stadium في النرويج، حيث جُمعت حوالي 495,000 ملاحظة بمعدل 20 قياساً في الثانية لكل لاعب، وشملت سبعة متغيرات (موقع اللاعب والكرة، السرعة، الاتجاه، زاوية النظر). قُسم الملعب إلى ثلاث، أربع وخمس مناطق لتصنيف مواقع اللاعبين، واستُخدمت عدة خوارزميات تعلم آلي مثل J48، Rep Tree، Random Tree، Hoeffding Tree. أظهرت النتائج أن أفضل أداء تحقق بخوارزمية Random Tree بدقة بلغت 95.4% على المحور X و 92% على المحور Y عند تقسيم الملعب إلى ثلاث مناطق، مع بقاء الدقة مرتفعة نسبياً عند زيادة عدد المناطق (أكثر من 89%). خلصت الدراسة إلى أن المنهجية المقترحة تسمح بتحديد مواقع اللاعبين بدقة عالية وفي الزمن الحقيقي، مما يوفر أداة مهمة للمدربين لمراقبة الالتزام الخططي وتحليل الأداء، وأوصت بتطوير النظام لزيادة قابليته للتفسير وتوظيفه كوسيلة داعمة لاتخاذ القرار الفني

12- دراسة Utomo, K. S., & Wiradinata, T. (2021) تحت عنوان: " Optimal Playing Position Prediction in Football Matches: A Machine Learning Approach

: هدفت هذه الدراسة إلى تطوير نموذج يعتمد على تقنيات التعلم الآلي للتنبؤ بالمركز الأمثل للاعبين كرة القدم أثناء المباريات، وذلك بالاعتماد على بيانات الأداء الفعلية للاعبين. ركز الباحثان على اختبار قدرة الخوارزميات الحديثة على دعم عملية الانتقاء والتوجيه الرياضي، بما يساهم في مساعدة المدربين على اتخاذ قرارات دقيقة بشأن توظيف اللاعبين. اعتمدت الدراسة على منهج كمي تجريبي، حيث تم جمع بيانات اللاعبين من مباريات كرة قدم حقيقية تضمنت مؤشرات متنوعة مثل التمريرات، الاستحواذ، التسديدات، وعدد التدخلات الدفاعية، إضافة إلى معلومات بدنية وتقنية أخرى مرتبطة بالأداء. استخدم الباحثان عدة خوارزميات للتعلم الآلي من بينها K-Nearest Neighbors (KNN)، Support Vector Machine (SVM)، Random Forest، حيث جرى تدريب النماذج على البيانات المتاحة ثم اختبار دقتها في تصنيف اللاعبين حسب مراكزهم داخل أرضية الميدان (وسط دفاع، وسط ميدان، أروقة، قلب هجوم). أظهرت النتائج أن النماذج قادرة على التنبؤ بمراكز اللاعبين بدقة معتبرة، حيث حققت خوارزمية Random Forest أفضل أداء مقارنة ببقية الخوارزميات في بعض

السيناريوهات. وأكدت الدراسة أن الجمع بين البيانات الإحصائية وأدوات الذكاء الاصطناعي يمثل وسيلة فعالة لدعم قرارات المدربين والأكاديميات الرياضية. أوصى الباحثان بضرورة دمج هذه النماذج ضمن أنظمة دعم القرار الفني والتكتيكي، بما يسمح بتوجيه اللاعبين نحو المراكز الأكثر توافقاً مع خصائصهم وأدائهم، واقتراحاً لتوسيع نطاق الدراسات المستقبلية لتشمل قواعد بيانات أكبر ومؤشرات إضافية مثل العوامل النفسية والفسولوجية.

13- دراسة بلغول فتحي (2011) تحت عنوان " Analyse physique de l'activité du footballeur professionnel (championnats anglais et espagnol) en vue d'une modélisation de la préparation et de la formation

إلى تحليل النشاط البدني للاعب كرة القدم المحترفين في البطولات الأوروبية الكبرى (الإنجليزية والإسبانية) بغرض بناء نموذج علمي للتحضير والتكوين يتماشى مع متطلبات كرة القدم العصرية. اعتمد الباحث على المنهج التحليلي عبر تحليل 436 شوطاً للاعب الهجوم، 888 شوطاً للاعب الوسط الدفاعي، 73 شوطاً للاعب الوسط الأيمن/الأيسر، 57 شوطاً للاعب الوسط الهجومي، 147 شوطاً للمدافعين الجانبيين، و966 شوطاً للمدافعين المحوريين. تضمنت الدراسة تحليلاً كميًا ونوعيًا للجهود (المسافة المقطوعة، عدد السيرنات، شدة الجهد، العمل بالكرة وبدونها) باستخدام تقنيات يدوية وأخرى تكنولوجية متقدمة مثل نظام Amisco System المستعمل من طرف أندية عالمية (ريال مدريد، برشلونة، ليفربول). أظهرت النتائج أن المدافعين المحوريين يقطعون أقل المسافات الكلية (~10556م) مقارنة بلاعب الوسط (<11000م)، وأن المهاجمين يقومون بأكبر عدد من السيرنات (269م في المتوسط)، بينما يبقى المدافعون المحوريون الأقل نشاطاً في هذا الجانب (201م). خلصت الدراسة إلى أن فهم الخصائص البدنية المرتبطة بكل مركز لعب يعتبر ضرورياً لتصميم برامج تدريبية نوعية وفعالة، وأن التحضير الحديث يجب أن يدمج بين التحليل الكمي والنوعي للأداء من أجل إعداد اللاعبين وفقاً لمتطلبات مراكزهم.

14- دراسة E. Ozceylan وآخرين (2020) تحت عنوان: " An intelligent decision support system for talent identification in football Multi-Criteria

نظام دعم قرار ذكي لتحديد المواهب في كرة القدم اعتماداً على أسلوب متعدد المعايير (Multi-Criteria Decision Making). اعتمد الباحثون على منهج كمي تطبيقي من خلال دمج تقنيات AHP (Analytic Hierarchy Process) و TOPSIS من أجل ترتيب اللاعبين حسب أهم مؤشرات الأداء. شملت العينة عدداً من اللاعبين الناشئين في أكاديميات كرة القدم بتركيا، حيث جمعت بيانات تشمل مؤشرات مورفولوجية (الطول، الوزن،

مؤشر كتلة الجسم)، مؤشرات بدنية (القوة، السرعة، التحمل)، ومؤشرات مهارية (دقة التمرير، السيطرة على الكرة، التسديد). أظهرت النتائج أن العوامل الأكثر تأثيراً في تحديد المواهب كانت القدرات البدنية (خاصة السرعة والتحمل)، يليها المهارات الفنية، في حين احتلت المؤشرات المورفولوجية المرتبة الأخيرة. خلصت الدراسة إلى أن استخدام نظم دعم القرار الذكية يساهم في تسهيل عملية الانتقاء الرياضي، ويتيح للمدربين أداة موضوعية لتصنيف اللاعبين وتوجيههم نحو مراكز اللعب الملائمة. وأوصى الباحثون بدمج هذه النماذج مع أنظمة معلوماتية أكبر لتطوير سياسات انتقاء وطنية على مستوى الأكاديميات والاتحادات الرياضية.

التعليق على الدراسات السابقة:

من خلال استعراض الدراسات السابقة التي تناولت موضوع الانتقاء الرياضي، سواء في السياق المحلي أو الدولي، يمكن ملاحظة أن هذه الدراسات اختلفت من حيث المنهجية، طبيعة العينات، والأدوات المستخدمة، لكنها اجتمعت على هدف رئيسي يتمثل في البحث عن أفضل السبل لتوجيه اللاعبين نحو المراكز التي تتلاءم مع قدراتهم وإمكاناتهم.

لقد بينت الدراسات التقليدية – مثل دراسة هوار عبد اللطيف (2015)، بومدين قادة وزملاؤه (2018)، وزروال محمد (2017) – أن عملية الانتقاء في كرة القدم استندت غالباً إلى المؤشرات المورفولوجية والاختبارات البدنية والمهارية، كالقوة، السرعة، الرشاقة، والتحمل. وقد اعتمدت معظم هذه البحوث على المنهج الوصفي لملاءمته طبيعة موضوعها، واستخدمت عينات من فئات عمرية مختلفة (من أقل من 14 سنة إلى أقل من 19 سنة)، فضلاً عن لاعبين من المستويات المدرسية أو النخبة المحلية. كما ركزت على مقارنة القدرات البدنية والمهارية بين خطوط اللعب (دفاع، وسط، هجوم) لاستخلاص الفروق الجوهرية بين المتطلبات الخاصة بكل مركز.

من جهة أخرى، كشفت بعض الدراسات – مثل دراسة بليدي تواتي (2017) وأعراب عبد الرحيم ومحمدي مهدي (2022) – عن استمرار اعتماد المدربين الجزائريين على الخبرة الشخصية والملاحظة المباشرة في اختيار التشكيلات وتوجيه اللاعبين، مع إغفال واضح لاستخدام الأدوات العلمية الدقيقة. وقد بينت هذه الدراسات أن الطرق التقليدية لا تحقق النتائج المرجوة في التقييم، وأن غياب الاعتماد على المقاييس العلمية يؤدي إلى قصور في عملية الانتقاء، مقارنة بما هو معمول به في مراكز التكوين الأوروبية التي تركز على المعايير الموضوعية والبطاريات المعيارية.

في المقابل، أبرزت الدراسات الأجنبية الحديثة – مثل أعمال Utomo & Datta & Rudra (2022)، Ozceylan و Wiradinata (2021)، وآخرين (2020) – نقلة نوعية في الموضوع من خلال توظيف تقنيات الذكاء الاصطناعي والتعلم الآلي. إذ تم استخدام قواعد بيانات ضخمة، تضمنت آلاف اللاعبين وعشرات الخصائص البدنية والفنية والتكتيكية، لتطوير نماذج قادرة على التنبؤ بمراكز اللاعبين أو التمييز بين المواهب ذات القيمة السوقية العالية والمنخفضة. وأظهرت هذه البحوث أن خوارزميات مثل XGBoost، SVM، Random Forest وغيرها يمكن أن تحقق دقة مرتفعة في تصنيف اللاعبين وتحديد المراكز الأنسب لهم، بل إن بعضها أثبت تفوقه على طرق التقييم اليدوية التقليدية.

وتجدر الإشارة إلى أن بعض الدراسات (مثل دراسة Manish.S وزملاؤه، 2021) أوضحت أن النماذج الإحصائية البسيطة ك الانحدار الخطي المتعدد قد تكون أكثر فعالية من النماذج العميقة والمعقدة في حال كانت البيانات منظمة وقابلة للفصل الخطي، وهو ما يعكس أهمية اختيار النموذج المناسب تبعاً لطبيعة البيانات والمعطيات المتاحة.

انطلاقاً من العرض السابق، يمكن استخلاص مجموعة من النقاط الأساسية:

✓ اعتمدت الدراسات التقليدية على المنهج الوصفي والاختبارات البدنية، بينما ركزت الدراسات الحديثة على النماذج التنبؤية والذكاء الاصطناعي.

✓ أوضحت معظم الدراسات الجزائرية أن عملية الانتقاء ما تزال تقليدية وتعتمد على الخبرة الشخصية دون الاستناد إلى أسس علمية أو أدوات تكنولوجية حديثة.

✓ أكدت غالبية الدراسات أن لكل مركز لعب خصائص بدنية ومهارية مميزة، مما يجعل الاعتماد على هذه العناصر أمراً أساسياً عند التوجيه.

✓ بينت الدراسات الأجنبية أن تقنيات التعلم الآلي قادرة على تقديم دقة عالية في التنبؤ بمراكز اللعب والأداء، وأنها تمثل نقلة نوعية في دعم القرار الرياضي.

✓ تبرز الحاجة إلى الجمع بين القياسات التقليدية والذكاء الاصطناعي من أجل تطوير أنظمة ذكية شاملة تساعد المدربين على اتخاذ قرارات أدق.

✓ لم تحظ موضوعات الذكاء الاصطناعي في الانتقاء الرياضي بدراسة معمقة في السياق الجزائري، ما يجعل موضوع البحث الحالي - المتمثل في تصميم تطبيق ذكي يوجه لاعبي كرة القدم نحو مراكز اللعب حسب صفاتهم البدنية - ذا أصالة وجِدّة علمية وعملية.

يتضح مما سبق أن الدراسات التقليدية ساهمت في تحديد المؤشرات البدنية والمهارية المرتبطة بمراكز اللعب، بينما قدمت الدراسات الحديثة حلولاً ذكية عبر توظيف الذكاء الاصطناعي لتحسين دقة الانتقاء والتوجيه. هذا التدرج من التقليدي إلى التكنولوجي يؤكد أن البحث الحالي يندرج ضمن توجه علمي حديث، ويهدف إلى سد فجوة قائمة في الأدبيات الجزائرية من خلال تطوير تطبيق ذكي يجمع بين المعرفة العلمية والقدرات التقنية الحديثة لتوجيه اللاعبين نحو المراكز الأنسب لهم بدقة وموضوعية.

الباب الأول

الجانب النظري

الفصل الأول

الأسس النظرية للانتقاء

والتوجيه الرياضي اعتماداً على

الصفات البدنية في كرة القدم

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

تمهيد:

يُعد الانتقاء والتوجيه الرياضي من أهم العمليات التي تُسهم في بناء فرق رياضية ناجحة، خصوصًا في رياضة جماعية مثل كرة القدم التي تتطلب تكاملًا في الأدوار بين اللاعبين حسب مراكز اللعب المختلفة. ويتناول هذا الفصل الجوانب النظرية المرتبطة بهذه العملية، من خلال دراسة المفاهيم الأساسية للانتقاء والتوجيه الرياضي، وتحليل العلاقة الوثيقة بين هذه العمليات والقدرات البدنية. كما يهدف إلى توضيح كيفية توظيف الخصائص البدنية في توجيه اللاعبين إلى المراكز التي تناسب مع إمكانياتهم، بما يضمن التوازن داخل الفريق والرفع من مردودية الأداء الجماعي.

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

1- الانتقاء الرياضي:

الانتقاء، بوجه عام، هو عملية اختيار دقيقة تستند إلى أسس علمية، تستخدم في مختلف مجالات الحياة. وفي المجال الرياضي تهدف إلى تحديد أفضل العناصر التي تمتلك مقومات الوصول إلى أعلى المستويات التنافسية. ولا يقتصر تحقيق هذه المستويات على تطبيق برامج تدريبية مبنية على أسس علمية فحسب، بل يتطلب أيضًا توافق تلك البرامج مع الخصائص الجسمانية، والقدرات البدنية، والسمات النفسية للرياضي.

ويمكن التمييز بين مفهومين "الانتقاء" و"الاختيار"، حيث يعد الانتقاء أكثر دقة وتفاعلية، وإن كان كلا المفهومين يشتركان في الجوهر ذاته. ومع تطور المعرفة الرياضية، أصبح الانتقاء الرياضي مجالًا دراسيًا متخصصًا، يجمع بين الجوانب النظرية والتطبيقية، ويستند إلى قواعد وإجراءات علمية محددة.

1-1- تعريف الانتقاء الرياضي:

- " الانتقاء هو عملية علمية منظمة تهدف إلى التعرف على الأفراد ذوي الاستعدادات والصفات التي تتناسب مع متطلبات نوع معين من الأنشطة الرياضية، وذلك من خلال استخدام مجموعة من الاختبارات والمقاييس النفسية والبدنية والفنية." (حسانين، الاختبارات والمقاييس في التربية الرياضية والنفسية. ، 1995)
- " الانتقاء الرياضي هو عملية اختيار الأفراد الذين يمتلكون أفضل الصفات البدنية والفسولوجية والمهارية والنفسية، والتي تُؤهلهم لتحقيق أفضل الإنجازات في النشاط الرياضي المعين." (حسانين، الاختبارات والمقاييس في التربية الرياضية.، 1999)
- " الانتقاء في الرياضة هو عملية علمية تتضمن اختبار وتقييم الرياضيين الناشئين من أجل تحديد مدى ملائمتهم لأدوار أو مراكز محددة داخل الرياضة، وذلك استنادًا إلى مؤشرات فسيولوجية ومؤشرات الأداء." (Reilly & Williams, Science and Soccer (2nd ed.), 2003)
- " يشير تحديد الموهبة، أو الانتقاء، إلى العملية التي يتم من خلالها التعرف على الرياضيين الذين يمتلكون أعلى قدر من الإمكانيات للنجاح في رياضة معينة، وتوجيههم إلى مسارات تدريبية مناسبة." (Bompa & Haff, Periodization: Theory and Methodology of Training (5th ed.), 2009)
- " الانتقاء الرياضي هو عملية تربوية مدروسة تهدف إلى اختيار الأفراد الذين يُظهرون استعدادات بدنية وخصائص وظيفية ونفسية ومهارية تؤهلهم لممارسة نشاط رياضي معين، مع العمل لاحقًا على توجيههم إلى

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

المراكز أو التخصصات المناسبة داخل ذلك النشاط، وفقًا لما تكشف عنه النتائج الميدانية والتقييمات المستمرة." (بن صالح، الانتقاء الرياضي: الأسس النظرية والتطبيقية..، 2010)

- حسب علي بن صالح " مصطلح الانتقاء يعبر عن أو يضم مصطلحي التوجيه والانتقاء في مفهوم شامل، أي أن استعمال مصطلح الانتقاء يعني ضمناً توجيه اللاعبين إلى النشاط أو المركز المناسب حسب مؤهلاتهم." (كرميش، 2020)

وعليه يمكن تعريف الانتقاء الرياضي بأنه عملية منهجية علمية تهدف إلى اكتشاف المواهب الرياضية وتوجيهها نحو التخصص المناسب بناء على تقييم شامل للقدرات البدنية والمهارية والنفسية. تشير الدراسات الحديثة إلى أن هذه العملية تمثل حجر الزاوية في بناء الفرق الرياضية الناجحة، حيث تساهم في تحديد المسار الأمثل لتطور اللاعبين منذ المراحل العمرية المبكرة. وتبرز أهمية الانتقاء الرياضي في كونه يقلل من هدر الطاقات الكامنة ويرفع من كفاءة برامج تطوير المواهب، كما يوضح البحث الذي أجراه (Williams & Reilly) أن الأندية التي تطبق أنظمة انتقاء علمية تحقق نتائج أفضل بنسبة 35% في اكتشاف المواهب مقارنة بالأساليب التقليدية (Williams & REILLY, 2000).

1-2- أهداف الانتقاء الرياضي

يُعد الانتقاء الرياضي مرحلة أساسية في بناء قاعدة قوية من الرياضيين القادرين على تحقيق الإنجازات، سواء على المستوى المحلي أو الدولي. ومن أبرز أهدافه ما يلي:

✓ اكتشاف المواهب الرياضية مبكرًا

يساعد الانتقاء على التعرف على الأفراد ذوي الاستعدادات البدنية والمهارية والنفسية العالية في سن مبكرة، مما يسمح بتوجيههم نحو رياضات أو مراكز تناسب قدراتهم الفطرية والمكتسبة. (Reilly & Williams, Science and Soccer (2nd ed.), 2003)

✓ تقليل الهدر في الوقت والجهد خلال مراحل التكوين

من خلال التركيز على العناصر الواعدة، يساهم الانتقاء في تقليص الجهد المبذول في تدريب رياضيين قد لا يمتلكون المؤهلات اللازمة للنجاح في تخصص معين. (محمود ع.، 2002)

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

✓ رفع جودة التدريب والتخطيط طويل المدى

يعمل الانتقاء على تحسين نوعية الرياضيين المنخرطين في البرامج التدريبية، مما يسمح للمدربين بوضع خطط أكثر دقة وفعالية. (Bompa و Haff، Periodization: Theory and Methodology of Training، (5th ed.)، 2009).

✓ توجيه الرياضي إلى التخصص المناسب

يسهم الانتقاء في توجيه اللاعب إلى المركز أو التخصص الرياضي الذي يتلاءم مع قدراته البدنية والنفسية، ما يعزز فرص نجاحه وتطوره. (كرميش، 2020)

✓ دعم كفاءة وفعالية التخطيط الرياضي

يُعد الانتقاء عملية تنبؤية تهدف إلى تحديد الأفراد الذين يمتلكون الإمكانيات اللازمة لتحقيق النجاح في المستقبل، مما يجعل هذه العملية أساسية في بناء برامج التخطيط الرياضي الفعالة، ويعزز من كفاءتها ودقتها على المدى البعيد. (Abbott & Collins، 2002)

1-3- أنواع الانتقاء الرياضي

يُقصد بأنواع الانتقاء الرياضي تلك التصنيفات التي تُحدد بناءً على توقيت التدخل في العملية التدريبية، وطبيعة القرار المتخذ تجاه اللاعب، ومدى استمرارية التقييم. وقد صنف عدد من الباحثين الانتقاء الرياضي إلى ثلاثة أنواع رئيسية: (Bompa، Talent Identification and Development in Sport، 2009)

1-3-1- الانتقاء الأولي (Initial Selection)

ويتم في المراحل الأولى من التكوين الرياضي، ويهدف إلى التعرف على الأفراد الذين يمتلكون مؤشرات بدنية أو مهارية أولية تدل على إمكانية نجاحهم في نشاط رياضي معين. وغالبًا ما يعتمد هذا النوع على اختبارات بسيطة أو ملاحظة ميدانية عامة.

1-3-2- الانتقاء المرحلي (Developmental/Intermediate Selection)

ويتم خلال المراحل المتقدمة من التدريب، عندما يكون الرياضي قد خضع لفترة من التكوين القاعدي. الهدف من هذا الانتقاء هو تقييم مدى تطور الرياضي ومدى ملاءمته للاستمرار أو التخصص في مركز معين.

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

يُستخدم الانتقاء المرحلي كأداة لمراقبة التقدم، وتوجيه الرياضي نحو مراكز لعب تتوافق مع قدراته المكتسبة والناشئة.

1-3-3 - الانتقاء النهائي (Final Selection)

وهو النوع الذي يُجرى في المراحل النهائية، عادة قبل الانضمام إلى فريق النخبة أو المنتخب، ويكون الهدف منه اختيار أفضل العناصر المتوفرة لتمثيل الفريق أو المؤسسة الرياضية، ويستند إلى الأداء الفعلي والجاهزية البدنية والنفسية والمهارية.

1-4-4 - مراحل عملية الانتقاء

تتضمن عملية الانتقاء مجموعة من المراحل المتسلسلة، وهي الخطوات الإجرائية التي تهدف إلى ضمان اتخاذ قرارات مبنية على أسس علمية دقيقة، وتُراعى فيها مختلف أبعاد الأداء الرياضي: (Bompa, Talent Identification and Development in Sport, 2009)

1-4-1 - مرحلة التعرف (Identification Phase)

في هذه المرحلة، يتم اكتشاف المواهب الأولية بناءً على الملاحظة أو المشاركة في مسابقات مدرسية أو محلية. يُنظر في المؤشرات العامة كالقوام البدني، والرشاقة، وسرعة الاستجابة.

1-4-2 - مرحلة التقييم والتنبؤ (Assessment & Prognosis Phase)

يتم في هذه المرحلة إخضاع اللاعبين لاختبارات قياسية تشمل الجوانب البدنية، الفسيولوجية، والمهارية. وتُستخدم نتائج هذه الاختبارات للتنبؤ بإمكانية نجاح اللاعب في المستقبل.

1-4-3 - مرحلة التوجيه (Orientation Phase)

إذا ما أظهرت نتائج التقييم وجود قدرات خاصة لدى اللاعب، يتم توجيهه إلى الرياضة المناسبة أو إلى مركز اللعب الأنسب داخل الفريق، بناءً على خصائصه الفردية، حيث أن التوجيه الفعال للاعبين نحو تخصصات أو مراكز تتوافق مع قدراتهم يُعد من أهم ضمانات النجاح الرياضي.

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

1-4-4-مرحلة اتخاذ القرار (Selection Decision Phase)

يُتخذ في هذه المرحلة القرار النهائي بشأن استمرارية اللاعب في البرنامج، أو إدماجه في فريق النخبة، أو حتى استبعاده إذا ثبت عدم توفر المؤهلات المطلوبة، بناءً على النتائج الرقمية للاختبارات، وملاحظات المدرب وخبرته الميدانية.

1-5-5-معايير الانتقاء الرياضي في كرة القدم

تُعد معايير الانتقاء الرياضي بمثابة الأسس التي يتم على ضوءها تقييم اللاعبين وتقدير مدى توافقهم مع متطلبات ممارسة كرة القدم، سواء من حيث الأداء الفردي أو الجماعي. ووفقًا لأدبيات علم التدريب والانتقاء، تتنوع هذه المعايير لتشمل الجوانب البدنية، المهارية، الفسيولوجية، النفسية، والقدرات المعرفية والتكتيكية، وهي كما يلي:

1-5-1-المعايير البدنية (Physical Criteria)

تشمل قياسات مثل السرعة، القوة العضلية، التحمل، الرشاقة، والتوازن، والتي تمثل حجر الأساس في أداء اللاعب. فالقدرة على الجري السريع، وتغيير الاتجاهات بكفاءة، والتحمل طوال شوطي المباراة، كلها مهارات بدنية حاسمة في كرة القدم. (Reilly & Williams, Science and Soccer (2nd ed.), 2003)

1-5-2-المعايير الفسيولوجية (Physiological Criteria)

تتضمن كفاءة الجهاز الدوري التنفسي، التركيب الجسمي (نسبة الدهون، الكتلة العضلية)، وسرعة الاستشفاء بعد الجهد. تُظهر الاختبارات الفسيولوجية قدرة اللاعب على الأداء العالي في ظروف اللعب المكثف، وقدرته على مقاومة التعب. (REILLY و Williams، 2000)

1-5-3-المعايير المهارية (Technical Criteria)

مثل التمرير، المراوغة، التسديد، السيطرة على الكرة، والتي تعد ضرورية للتفوق في المواقف الفنية أثناء اللعب. تُقيّم هذه المهارات عبر اختبارات قياسية أو ملاحظات مباشرة أثناء المباريات. (Vaeyens, Lenoir, Williams, & Philippaerts, 2008)

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

1-5-4- المعايير النفسية (Psychological Criteria)

تتعلق بمستويات الدافعية، الثقة بالنفس، التركيز، ضبط الانفعالات، وقابلية التعلم. هذه الجوانب تؤثر بشكل كبير على ثبات الأداء تحت الضغط، والتكيف مع بيئة التدريب والمنافسة. (Abbott & Collins, 2002)

1-5-5- المعايير الإدراكية والتكتيكية (Cognitive and Tactical Criteria)

تشمل القدرة على اتخاذ القرار، قراءة اللعب، التوقع، والتفاعل مع زملاء الفريق. تعتبر من العوامل الحاسمة في نجاح اللاعبين، خصوصًا في المراكز التي تتطلب وعيًا تكتيكيًا عاليًا. (Williams و REILLY, 2000)

1-5-6- العمر البيولوجي كمعيار من معايير الانتقاء

يُعد العمر البيولوجي من المعايير الفسيولوجية المهمة في عمليات الانتقاء الرياضي، خاصة في فئة الناشئين. ويشير إلى درجة نضج الجهاز الهيكلي والعضلي والهرموني، والتي لا تتطابق دائمًا مع العمر الزمني. ويساعد تقييم العمر البيولوجي على اختيار توقيت التدريب والانتقاء الأنسب، بما يتوافق مع مرحلة النمو الفردية لكل لاعب، ما يقلل من خطر الإقصاء الخاطئ للمواهب المتأخرة في النضج. ويُستخدم العمر البيولوجي فعليًا من خلال قياسات مثل Peak Height Velocity (PHV) أو نضج العظام (Bone Age) لتقدير مدى استعداد الرياضي لمتطلبات التدريب التخصصي أو شغل مراكز لعب معينة. (Malina, Bouchard, & Bar-Or, 2004)

1-5-7- الخصائص الوراثية كمحدد غير عملي للانتقاء

رغم أن الخصائص الوراثية مثل الطول المحتمل أو التركيب الجيني للعضلات قد تُعتبر محددات نظرية للأداء الرياضي، إلا أنها لا تُستخدم كمعيار فعلي في الانتقاء داخل الأندية أو الأكاديميات. ويرجع ذلك إلى محدودية الاختبارات الوراثية المتاحة، حيث لا تزال معظم التحاليل الوراثية في المجال الرياضي تفتقر إلى القدرة التنبؤية الدقيقة، كما أن معظم الرياضيين النخبة لا يملكون "بروفيلات جينية" مميزة تمامًا عن غيرهم، ما يجعل استخدامها في سياقات الانتقاء غير موثوق. (Williams & Folland, 2008)

كما توجد مخاوف تتعلق بالأخلاقيات، خصوصًا عند التعامل مع القاصرين، حيث أن استخدام الجينات كمعيار للانتقاء، خاصة عند الأطفال أو القُصّر، يطرح إشكالات أخلاقية وقانونية، تتعلق بالتمييز والاستبعاد المبكر بناءً على معلومات بيولوجية (Pitsiladis, et al., 2016).

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

بالإضافة إلى ذلك، فإن الطبيعة المتعددة العوامل للأداء الرياضي تجعل من الاعتماد على الخصائص الجينية أمرًا غير دقيق، فالأداء لا يعتمد فقط على الاستعداد الجيني، بل يتأثر بعوامل بيئية، نفسية، تدريبية، واجتماعية. لذا، فإن الاختصار على المعطى الوراثي يُعد اختزالًا غير علمي لطبيعة النجاح الرياضي. (Pitsiladis, et al., 2016) وبناءً على ذلك، تُناقش الوراثة غالبًا في السياقات البحثية فقط، دون إدراجها ضمن المعايير المعتمدة ميدانيًا في الانتقاء.

هذه المعايير لا تُستخدم بمعزل عن بعضها البعض، بل يتم تكاملها في إطار شامل يُراعي خصوصية كل مركز من مراكز اللعب في كرة القدم. كما يُوصى بتكرار عملية التقييم دوريًا لمواكبة تطور اللاعب وتحديد مدى استجابته لبرامج التدريب.

كما يؤكد تقرير الاتحاد الدولي لكرة القدم أن نجاح الانتقاء الرياضي يعتمد بدرجة كبيرة على شمولية ودقة المعايير المعتمدة، والتي ينبغي أن تشمل الجوانب البدنية والمهارية والفنية والنفسية، إلى جانب تتبع تطور الأداء على المدى الطويل. ((FIFA), 2025)

1-6- أهمية الانتقاء

تكمن أهمية عملية الانتقاء في دورها المحوري في تحديد المسار التدريبي الأمثل لكل لاعب، استنادًا إلى خصائصه الفردية من حيث القدرات البدنية، المهارية، والنفسية. وتشير الدراسات الحديثة إلى أن تطبيق أساليب انتقاء علمية مبنية على بيانات متعددة الأبعاد يسهم بشكل فعال في تطوير المواهب الكروية بشكل ممنهج. فقد أوضح Williams & Reilly (2000) أن الأندية التي تعتمد أنظمة انتقاء تستند إلى اختبارات معيارية وملاحظات نوعية تُحقق معدلات تطور أعلى للاعبين مقارنة بتلك التي تعتمد على الانطباعات الشخصية أو أساليب التقييم غير المنهجية. كما بين Williams & Reilly (2003) أن الانتقاء القائم على أسس علمية يُسهم في خفض معدلات التسرب من المدارس الرياضية عبر توجيه اللاعبين إلى مراكز اللعب التي تتوافق مع قدراتهم وخصائصهم البيولوجية. علاوة على ذلك، فإن هذه المنهجية تضمن استثمار الموارد التدريبية بشكل أكثر فاعلية من خلال تركيزها على اللاعبين ذوي الإمكانيات الأعلى للنمو والتطور المستقبلي.

الفصل الأول: الأسس النظرية للاقتقاء والتوجيه الرياضي اعتماداً على الصفات البدنية في كرة القدم

2- التوجيه الرياضي

2-1- مفهوم التوجيه

التوجيه لغة: كلمة "التوجيه" في اللغة العربية مأخوذة من الجذر "وَجَّهَ"، وهي تدل على الإرشاد، والدلالة على الطريق، وتحديد المسار أو الاتجاه نحو غاية أو هدف معين. جاء في لسان العرب أن: "وَجَّهَهُ تَوْجِيهًا: أي بيَّن له وجه الأمر، أي طريقه ومقصده" (ابن منظور، 2003)

التوجيه اصطلاحاً: يُعد التوجيه أحد المفاهيم التربوية الأساسية التي تهدف إلى مساعدة الفرد على إدراك ذاته، وفهم قدراته وميوله، بما يُمكنه من اتخاذ قرارات ملائمة لمساره الشخصي أو المهني. ويؤكد التوجيه على دعم الفرد في التعامل مع متطلبات الحياة والتكيف مع الظروف المحيطة، من خلال تقديم خدمات منظمة ومستمرة تساعد في تحقيق ذاته واتخاذ قرارات رشيدة. (عبد المجيد، التوجيه والإرشاد النفسي، 2004)

فالتوجيه، بهذا المعنى، ليس مجرد تقديم نصيحة آنية، بل هو عملية ديناميكية ترافق الفرد في مختلف مراحل نموه، وتجمع بين البعد النفسي والاجتماعي والمعرفي، بما يعزز من فرص نجاحه وتوازنه الشخصي والاجتماعي.

2-2- التوجيه الرياضي

يندرج التوجيه الرياضي ضمن هذا الإطار العام، إلا أنه يتسم بخصوصيات ترتبط بطبيعة المجال الرياضي، وخصائص النمو الحركي والمهاري للرياضيين، فيما يلي مجموعة من أبرز التعاريف الأكاديمية لمفهوم التوجيه الرياضي:

- "العملية التي تهدف إلى تحديد التخصص أو المركز المناسب للرياضي، اعتماداً على نتائج الاختبارات البدنية والمهارية والنفسية، بما يساهم في توظيف أفضل لطاقت الرياضي وتحقيق أقصى درجات التكيف مع متطلبات النشاط". (محمود ع.، 2002)

- "التوجيه الرياضي هو عملية منظمة يتم من خلالها مطابقة اللاعبين مع المراكز أو الأدوار التي تتناسب مع خصائصهم البدنية والمعرفية، بما يعزز من انسجام الفريق وتطور الفرد". (Reilly & Williams, Science and Soccer (2nd ed.), 2003)

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

- "التوجيه هو عملية تربوية مستمرة تهدف إلى مساعدة الفرد في إدراك قدراته واستعداداته وميوله، بغية اتخاذ قرارات مناسبة تتعلق بمستقبله الرياضي أو الأكاديمي، بما يعزز توافقه الذاتي والاجتماعي". (عبد المجيد، التوجيه والإرشاد النفسي، 2004)
- "تقديم الدعم العلمي والتربوي للرياضي بهدف توجيهه نحو التخصص أو المركز الأنسب، بناءً على تقييم موضوعي لخصائصه البدنية والنفسية، وذلك لتحقيق أقصى مردودية ممكنة في الأداء الرياضي". (بن صالح، مطبوعة مقياس الانتقاء والتوجيه الرياضي (غير منشورة). قسم علوم وتقنيات النشاطات البدنية والرياضية، 2022)

2-3- أهداف التوجيه وتطبيقاته في الرياضة

يُعد التوجيه الرياضي من الأدوات التربوية المهمة التي تهدف إلى تحقيق توافق بين خصائص الرياضي ومتطلبات التخصص أو المركز الذي يشغله داخل الفريق. وتتمثل أبرز أهدافه فيما يلي:

تحقيق التوافق بين قدرات الرياضي ومتطلبات التخصص: يهدف التوجيه إلى ضمان انسجام قدرات اللاعب البدنية، المهارية، والنفسية مع طبيعة المركز أو التخصص الذي يشغله، مما يُسهم في تعزيز الأداء الرياضي وتجنب الإحباط أو الإرهاق الناجم عن سوء التوجيه. (Mujika, Halson, Burke, Balagué, & Farrow, 2017)

تسهيل عملية التخصص المبكر أو المتأخر: يساعد التوجيه على تحديد التوقيت الأنسب لتوجيه اللاعب نحو تخصص معين، سواء في سن مبكرة أو لاحقًا، بما يتماشى مع مسار تطوره البدني والنفسي. (Abbott & Collins, 2002)

تحسين الكفاءة التدريبية داخل الفرق: من خلال توزيع اللاعبين في المراكز التي تتناسب مع خصائصهم، يُسهم التوجيه في رفع فعالية الحصص التدريبية وتقليل الفروقات داخل المجموعات التدريبية. (Reilly & Williams, Science and Soccer (2nd ed.), 2003)

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

دعم تخطيط المسار المهني للرياضي: يلعب التوجيه دورًا في وضع خطط طويلة المدى لتطور اللاعب، من خلال مساعدته على فهم نقاط قوته وضعفه، وتحديد المسارات الممكنة لتقدمه في المجال الرياضي. (Williams و REILLY، 2000)

تحقيق الاستقرار النفسي والاجتماعي للرياضي: يساعد التوجيه على تقليل القلق الناتج عن عدم وضوح الدور أو المركز، ويُسهّم في تحسين الانسجام داخل الفريق وزيادة الرضا الذاتي للاعب. (Côté, Lidor, & Hackfort, ISSP Position Stand: To Sample or to Specialize? Seven Postulates about Youth Sport Activities that Lead to Continued Participation and Elite Performance, 2009)

ومن خلال هذه الأهداف، يتضح أن التوجيه الرياضي لا يقتصر على توزيع اللاعبين في المراكز، بل يتعداه إلى التأثير في المسار المهني والانسجام النفسي للفرد داخل البيئة الرياضية.

2-4- الفرق بين الانتقاء والتوجيه

يمثل التوجيه الرياضي المرحلة التكاملية التي تلي عملية الانتقاء، حيث يركز على تحديد المركز الأمثل لكل لاعب بناءً على تحليل مفصل لخصائصه وقدراته البدنية، والمهارية، والنفسية. بينما يهتم الانتقاء بالاختيار الأولي للمواهب القادرة على ممارسة النشاط الرياضي، فإن التوجيه يتعامل مع التخصص الدقيق للاعب، ووضعه في المركز الذي يتناسب مع إمكانياته ضمن الفريق (Reilly, Williams, Nevill, & Franks, 2000). وقد أوضحت العديد من الدراسات أن القرارات الصحيحة في التوجيه الرياضي تساهم في رفع فعالية الأداء الجماعي، وتُقلل من حالات الإحباط المرتبطة بسوء توظيف اللاعب، إذ أشار البعض إلى أن نسب التحسن في الأداء قد تصل إلى 25% في حال تم التوجيه الصحيح (Vaeyens, Lenoir, Williams, & Philippaerts, 2008).

ويُعد التوجيه عملية مستمرة ومتغيرة، ترافق اللاعب في مراحل تطوره، وتُبنى على تقييم دوري ومتكامل. ومن وجهة نظر منهجية، يمكن اعتبار التوجيه جزءًا لا يتجزأ من عملية الانتقاء، خاصة عندما يتعلق الأمر بالفئات المتقدمة، مثل فرق الأكابر، حيث لا يُكتفى بمجرد اختيار اللاعبين، بل يُسعى لتوزيعهم بدقة على المراكز حسب متطلبات كل مركز. وقد

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

أشار كل من Bomp & Haff إلى أن التوجيه يجب أن يُبنى على أسس موضوعية تشمل الاختبارات البدنية والفسيولوجية، إلى جانب الملاحظة الفنية (Bomp & Haff، و Periodization: Theory and Methodology of Training (5th ed.)، 2009).

وقد بين كل من Hoare و Lidor & Ziv أن الفصل بين الانتقاء والتوجيه في بعض الأدبيات لا يعكس الواقع التطبيقي بدقة، خاصة في الرياضات الجماعية، حيث يتداخل المفهومان وظيفيًا. فبينما يشير الانتقاء إلى قرار "من يمكنه أن يلعب"، يُجيب التوجيه على سؤال "أين يمكنه أن يلعب؟". ويُؤكّد ذلك أن التوجيه الناجح لا يعتمد فقط على القدرات الحالية، بل على قابلية اللاعب للتطور في مركز معين (Hoare, 2000) (Lidor & Ziv, 2015).

يتضح مما سبق أن التوجيه لا يُعد مرحلة منفصلة عن الانتقاء، بل هو امتداد حتمي وضروري له. في واقع كرة القدم الحديثة، يُعد الانتقاء دون توجيه دقيق بمثابة اختيار بلا هدف، إذ أن قيمة اللاعب لا تبرز إلا حين يُوظف بالشكل الصحيح. إن الدمج بين المفهومين ضمن منظور علمي شامل يُعد شرطًا لتحقيق الفعالية في الأداء، خصوصًا مع التوسع في استخدام التقنيات الذكية التي تدعم القرار الفني، مما يجعل من التوجيه ركيزة أساسية في الانتقاء الذكي والفعال.

2-5- مراحل التوجيه خلال المسار التكويني للرياضي

تمر عملية التوجيه الرياضي خلال المسار التكويني للرياضي بعدة مراحل مترابطة، تبدأ منذ سن مبكرة وتستمر حتى المستويات العليا من الاحتراف، ويُراعى فيها التطور البيولوجي والمهاري والنفسي، بالإضافة إلى السياق التدريبي والتنافسي الذي يعيشه اللاعب. ويمكن تقسيم هذه المراحل إلى ثلاث فترات رئيسية:

2-5-1- المرحلة الأولى (مرحلة التوجيه التمهيدي):

تبدأ هذه المرحلة عادة بين سن 10 و13 سنة، وتهدف إلى استكشاف قدرات اللاعبين وتوسيع قاعدة الممارسة. في هذه المرحلة، يُشجع اللاعبون على تجربة مراكز لعب مختلفة، مما يسمح بفهم أوسع لإمكاناتهم وتكيفهم مع متطلبات اللعبة. كما يتم التركيز على التطوير الشامل للقدرات البدنية والمهارية دون حصر اللاعب في مركز واحد. (Côté, Baker, & Abernethy, Practice and play in the development of sport expertise, 2007)

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتماداً على الصفات البدنية في كرة القدم

2-5-2- المرحلة المتوسطة (مرحلة التوجيه شبه المتخصص):

تتراوح بين سن 14 و16 سنة تقريباً، ويبدأ خلالها المدربون في تضيق نطاق مراكز اللعب التي يشارك فيها اللاعب بناءً على ملاحظات الأداء، والفحوصات البدنية، والتطور المهاري والتكتيكي. يُراعى في هذه المرحلة النضج البيولوجي والنفسي، وتبدأ ملامح التخصص بالظهور دون حسم نهائي. (Vaeyens, Lenoir, Williams, & Philippaerts, 2008)

2-5-3- المرحلة النهائية (مرحلة التوجيه التخصصي):

تبدأ بعد سن 16 سنة، وتُعد مرحلة الحسم في اختيار المركز المناسب لكل لاعب، استناداً إلى بيانات دقيقة حول الأداء الفسيولوجي، المهاري، والنفسي، إضافة إلى الخبرة الميدانية للمدربين. في هذه المرحلة، يُثبت اللاعب غالباً في مركز يُظهر فيه أعلى درجات التوافق والنجاح. (Bompa و Haff، Periodization: Theory and Methodology of Training (5th ed.), 2009).

ومع ذلك، فإن التوجيه لا يُعد عملية مغلقة حتى في هذه المرحلة، بل يبقى خاضعاً للمراجعة المستمرة، لا سيما في ظل التغيرات التي قد تطرأ على قدرات اللاعب، أو استراتيجيات الفريق. إذ أثبتت الدراسات أن حتى اللاعبين في الفرق المحترفة أو المنتخبات الوطنية يمكن أن يُعاد توجيههم لمراكز جديدة، سواء لأسباب تتعلق بتغير قدراتهم أو بسبب متطلبات تكتيكية (Williams و REILLY، 2000، Carling, Reilly, & Williams، Performance Assessment for Field Sports (1st ed.), 2008).

وقد شهدت الساحة الرياضية أمثلة عديدة على لاعبين غيّرُوا مراكزهم بنجاح خلال مشوارهم الاحترافي، مما يعكس أهمية التوجيه المرن في مختلف مراحل المسار الرياضي.

2-6- التوجيه حسب مراكز اللعب في كرة القدم

يُعدّ التوجيه حسب مراكز اللعب من الركائز الجوهرية في عملية التكوين الرياضي للاعب كرة القدم، إذ تختلف المتطلبات البدنية، مهارية، والفسيولوجية لكل مركز داخل أرضية الميدان. ويهدف هذا النوع من التوجيه إلى وضع اللاعب في المركز الأنسب لقدراته الفردية بما يعزز من فعاليته داخل الفريق ويرفع من الأداء الجماعي العام. وقد أكدت الدراسات

الفصل الأول: الأسس النظرية للاقتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

أن متطلبات اللعب تختلف بوضوح بين المراكز، مما يستلزم إجراء اختبارات دقيقة تشمل الجوانب البدنية (السرعة، القوة، التحمل، الرشاقة)، والمهارية (التمرير، التسديد، السيطرة على الكرة)، إضافة إلى الجوانب النفسية (الثقة، التركيز، الاستجابة تحت الضغط) قبل اتخاذ القرار النهائي بشأن التوجيه. (Bangsbo, Mohr, & Krustup, 2006)

2-6-1- حارس المرمى

يُعد مركز حراسة المرمى من أكثر المراكز خصوصية، حيث يتطلب قدرات مميزة مثل رد الفعل السريع، التوقيت المثالي في التدخلات، التوازن، إضافة إلى الطول المناسب الذي يساعد في تغطية أكبر مساحة من المرمى. كما يحتاج الحارس إلى قدرات نفسية عالية، من أهمها الثقة بالنفس، التحكم في الأعصاب، والقدرة على تحمل الضغط المستمر، نظرًا لحساسية الدور الذي يقوم به. وقد أوضحت أبحاث متخصصة أن حراس المرمى يختلفون بشكل واضح عن لاعبي الميدان من حيث التركيبة الجسمية، والخصائص الفسيولوجية والأداء في المنافسات. (Ziv و Lidor, 2011)

2-6-2- وسط الدفاع (مدافع أوسط)

يتطلب مركز الدفاع الأوسط بنية جسمانية قوية، قوة بدنية عالية، وقدرة على الالتحام مع المنافسين. كما يحتاج المدافع إلى التحمل، التركيز، وحس تكتيكي يمكنه من قراءة مجريات اللعب واتخاذ القرارات الدفاعية المناسبة. إضافة إلى ذلك، يمتاز هذا المركز بضرورة امتلاك قدرات قيادية تساعد على تنظيم خط الدفاع والتواصل الفعال مع الحارس وبقية زملاء. وقد بينت التحليلات أن لاعبي قلب الدفاع يقطعون مسافات أقل نسبيًا مقارنة بالوسط أو الأجنحة، لكنهم يؤدون عددًا أكبر من الصراعات الهوائية والدفاعية. (Carling, Reilly, & Williams, Performance Assessment for Field Sports (1st ed.), 2008)

2-6-3- لاعب الرواق (لاعب الجناح)

يُعدّ مركز الجناح من المراكز الأكثر تطلبًا من الناحية البدنية والمهارية، حيث يعتمد على السرعة القصوى، الرشاقة، والقدرة على تغيير الاتجاهات بشكل متكرر وسريع. كما يحتاج اللاعب إلى مهارات فنية عالية مثل المراوغة، إرسال العرضيات بدقة، وتنفيذ الانطلاقات على الخطوط الجانبية. وقد أشارت الدراسات إلى أن لاعبي الأجنحة يقومون بعدد

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

مرتفع من الجهود اللاهوائية المتكررة مقارنة ببقية المراكز، مما يعكس الطبيعة البدنية الخاصة بهذا الدور. (Di Salvo, et al., 2010)

2-6-4- وسط الميدان

يُعتبر خط الوسط بمثابة القلب النابض للفريق، إذ يمثل محور الربط بين الدفاع والهجوم. ويتطلب هذا المركز قدرات بدنية وفسيولوجية عالية خاصة في جانب التحمل الهوائي، إضافة إلى الرؤية الميدانية، سرعة التمرير، والدقة في اتخاذ القرارات التكتيكية. وغالبًا ما يُوجه لهذا المركز اللاعبون ذوو القدرة على العمل المستمر طوال المباراة مع الحفاظ على مستوى ثابت من الأداء. وقد أظهرت الدراسات أن لاعبي خط الوسط يقطعون أكبر المسافات داخل المباراة مقارنة ببقية المراكز، مما يعكس أهمية الجانب الهوائي لديهم. (Lago-Peñas, Rey, Lago-Ballesteros, Casáis, & Domínguez, 2011)

2-6-5- المهاجم (قلب الهجوم)

يرتكز أداء المهاجم على الحس التهديفي العالي، القدرة على التمرکز في مناطق خطيرة، والفعالية في استغلال أنصاف الفرص. كما يحتاج المهاجم إلى سرعة الانطلاق، القوة في المواجهات الفردية، والقدرة على التعامل مع الكرات الهوائية والتسديد تحت الضغط. وبينت الأبحاث أن المهاجمين يختلفون عن بقية اللاعبين من حيث عدد المحاولات الهجومية، وعدد التسديدات، ومعدل استغلال الكرات في مناطق الجزاء. (Hughes & Franks, 2005)، (Dellal, et al., 2011)

في المجمل، يظل التوجيه حسب مراكز اللعب عملية ديناميكية وقابلة للتغيير تبعًا لتطور قدرات اللاعب أو احتياجات الفريق التكتيكية. وقد بينت الدراسات أن بعض اللاعبين يعاد توجيههم خلال مسيرتهم إلى مراكز جديدة أكثر ملاءمة لإمكاناتهم، وهو ما يعكس أهمية التوجيه المرن المبني على أسس علمية دقيقة. (Williams و REILLY, 2000)

الفصل الأول: الأسس النظرية للاقتناء والتوجيه الرياضي اعتماداً على الصفات البدنية في كرة القدم

3- الصفات البدنية وعلاقتها بمراكز اللعب في كرة القدم

3-1- تعريف الصفات البدنية

تُعدّ الصفات البدنية أساس الأداء الرياضي بجميع أنواعه، إذ تُشكّل الخلفية البيولوجية والفسولوجية التي يقوم عليها التفوق الحركي. فقد عرّف Weineck الصفات البدنية بأنها: القدرات الوظيفية للجهاز العصبي العضلي والجهاز الدوري التنفسي، والتي تُكوّن الأساس الحيوي للأداء الرياضي، وتظهر في أشكال القوة، التحمل، السرعة، المرونة، التوازن، والرشاقة. (Weineck, 1999)

أما Pradet فيرى أن الصفات البدنية تمثل مجموعة من القدرات الأساسية التي تُمكن اللاعب من تحقيق الأداء الرياضي بكفاءة عالية، وتُترجم عملياً من خلال تنمية القوة، التحمل، السرعة، والقدرات التوافقية، والتي تُشكل قاعدة الإعداد البدني العام والخاص. (Pradet, 2012)

ويُضيف Verheijen منظوراً أكثر خصوصية لكرة القدم، حيث يعتبر أن الصفات البدنية هي: المتطلبات الفسيولوجية والميكانيكية التي يجب تطويرها بما يتناسب مع خصوصية اللعبة، وتشمل التحمل الخاص بكرة القدم، السرعة المرتبطة بالكرة، القوة الانفجارية، والقدرة على تكرار الجهد الحركي بكفاءة عالية. (Verheijen, 1997)

وعلى الصعيد العربي، يشير محمد حسن علاوي إلى أن الصفات البدنية هي: الأسس البيولوجية التي يقوم عليها الأداء الحركي، وتُعد حجر الزاوية في تحقيق التفوق الرياضي، وهو ما يبرز دورها المركزي في تكوين اللاعب وتوجيهه نحو التخصص الرياضي المناسب. (علاوي، 1998)

انطلاقاً من التعريفات السابقة، يمكن القول إنّ الصفات البدنية هي:

"مجموعة من القدرات الفسيولوجية والوظيفية للجهاز العصبي العضلي والدوري التنفسي، تُترجم إلى أشكال مختلفة مثل القوة، التحمل، السرعة، المرونة، الرشاقة، والتوازن. وتُعد هذه الصفات قاعدة أساسية للإعداد البدني العام والخاص، كما تُحدد بدرجة كبيرة قابلية اللاعب على التكيف مع متطلبات مراكز اللعب في كرة القدم. فهي تمثل الأساس البيولوجي الذي يقوم عليه الأداء الحركي والرياضي، مع ضرورة تطويرها بشكل نوعي يتناسب مع خصوصية كل نشاط أو مركز لعب."

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

3-2- التحمل في كرة القدم

يُعدّ التحمل من الركائز الأساسية للأداء في كرة القدم، إذ يمكن اللاعب من الحفاظ على الأداء البدني والفني عبر زمن المباراة. ويُعرّف علماء التربية البدنية التحمل بأنه القدرة على مقاومة التعب والعمل لفترة طويلة دون تراجع في الأداء. وينقسم التحمل بصفة عامة إلى نوعين رئيسيين: التحمل الهوائي والتحمل اللاهوائي.

3-2-1- التحمل الهوائي يتعلق بقدرة الجهازين الدوري والتنفسي على تزويد العضلات بالأكسجين أثناء الجهد المستمر، مما يتيح أداءً فعالاً لفترات طويلة مثل الانتشار داخل الملعب.

3-2-2- التحمل اللاهوائي يعتمد على أنظمة إنتاج الطاقة بدون استخدام الأكسجين (الفوسفاجيني والتحلل اللاهوائي للجلوكوز)، ويظهر بوضوح في المجهودات القصيرة عالية الشدة، مثل الانطلاقات السريعة، القفزات، أو التكرارات المتعددة للركض المكثف، والتي تُعد حاسمة في المواقف التكتيكية كالضغط العالي أو الهجمات المرتدة. (محمود أ.، 2016)

إن التميز في كرة القدم الحديثة يتطلب تطوير كلا النوعين من التحمل بشكل متوازن، نظرًا لأن اللاعب المحترف يقطع ما معدله **10-12 كيلومترًا** في المباراة، مع مئات التغييرات في نمط الحركة من جري، تسارع، توقف، وتغيير اتجاه، ما يبرز الطابع المتكامل للتحمل في اللعبة. (Katanic, et al., 2025)

3-3- السرعة وأنواعها في كرة القدم

تُعدّ السرعة من القدرات البدنية الأساسية والمميزة للأداء الرياضي عمومًا، ولأداء كرة القدم خصوصًا، حيث يُنظر إليها باعتبارها القدرة على إنجاز الحركات أو قطع المسافات في أقصر زمن ممكن (Kenney, Wilmore, & Costill, 2011). ويُعرّفها حسن مصطفى بأنها قدرة اللاعب على أداء الحركات أو المهارات المختلفة في أقل وقت ممكن، سواء كانت حركات بسيطة أو مركبة (حسن، 2001). أما في إطار كرة القدم، فقد عرّفها نويوة وزملاؤه بأنها قدرة اللاعب على الاستجابة السريعة لتغيرات اللعب وتنفيذ الحركات الفنية والخططية بسرعة عالية تتناسب مع متطلبات الموقف (نويوة، زروال، و ولد حمو، 2018). ويؤكد (Kunz, Engel, Holmberg, & Sperlich, 2019) أن السرعة في كرة القدم ليست مقتصرة على الجري في خط مستقيم، بل تشمل الاستجابة للمثيرات، التسارع، سرعة تغيير الاتجاه، وسرعة التكرار في مواقف المباريات.

ويُجمع الباحثون على أن السرعة في كرة القدم تتخذ عدة أشكال متكاملة، يمكن تصنيفها إلى ما يلي:

الفصل الأول: الأسس النظرية للاقتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

3-3-1- سرعة رد الفعل (الاستجابة) (Reaction speed)

تُعرف بأنها الفترة الزمنية الفاصلة بين استقبال اللاعب لمثير خارجي (كحركة الخصم أو تمريرة الكرة) وبين بدء الحركة المناسبة (خروبي، 2019). وتمثل عنصرًا جوهريًا لحراس المرمى والمدافعين عند التعامل مع التسديدات أو الانطلاقات المفاجئة.

3-3-2- سرعة التنفيذ (Execution speed)

يقصد بها القدرة على أداء المهارات الفنية بأعلى سرعة ممكنة مع المحافظة على الدقة، خصوصًا في ظل الضغط الزمني والمكاني الذي يفرضه الخصم (Reilly & Williams, Science and Soccer (2nd ed.), 2003). ويتجلى ذلك في سرعة التسديد، التمرير، أو المراوغة.

3-3-3- السرعة الحركية أو الجسدية (Movement speed)

وهي سرعة أداء الحركات الجزئية أو المتكررة باستخدام أجزاء معينة من الجسم (خروبي، 2019) وتظهر بوضوح في سرعة تحريك القدمين للتمويه أو الخطوات القصيرة المتلاحقة عند المراوغة.

3-3-4- السرعة القصوى (Sprint speed)

بأنها القدرة على أداء حركات عضلية تؤدي إلى انتقال الجسم أو أحد أجزائه بأقصى سرعة ممكنة، خلال فترات زمنية قصيرة، دون ارتباط بعوامل التعب، أي دون أن تواجه فيها العضلات مقاومات خارجية كبيرة، باستثناء تأثير الجاذبية. (Pradet, 2012)

3-3-5- التسارع (Acceleration)

القدرة على زيادة السرعة من حالة السكون أو من سرعة منخفضة إلى أقصى سرعة ممكنة في أقصر زمن ممكن

3-3-6- السرعة التكرارية (Repeated Sprint Ability – RSA)

هي قدرة اللاعب على أداء تجارب متكررة من العدو القصير شديد الشدة (عادةً من 3 إلى 10 ثوانٍ)، مع فترات راحة قصيرة بين المحاولات (غالبًا من 10 إلى 60 ثانية)، مع الحفاظ على أقصى أداء ممكن عبر السلسلة. (Bishop, Girard, & Villanueva, 2011)

الفصل الأول: الأسس النظرية للاقتقاء والتوجيه الرياضي اعتماداً على الصفات البدنية في كرة القدم

من خلال ما سبق يتضح أن السرعة في كرة القدم ليست عنصراً أحادي البعد، بل هي قدرة مركبة تتضمن جوانب إدراكية وحركية وفسيولوجية، وتشمل سرعة الاستجابة، سرعة التنفيذ، السرعة الحركية، السرعة القصوى، التسارع، وتحمل السرعة. ويعكس هذا التنوع الدور الحيوي للسرعة في تحقيق الأداء العالي داخل المستطيل الأخضر، ما يفرض على المدربين الاهتمام بتطوير جميع أشكالها بما يتوافق مع متطلبات مراكز اللعب المختلفة.

3-4- القوة وأنواعها في كرة القدم (بوحاج، 2012)

تُعتبر القوة من أهم الصفات البدنية الأساسية، كما تُعد هدفاً رئيسياً من أهداف الإعداد البدني الخاص، لكونها تسهم بشكل مباشر في تحقيق الإنجاز الرياضي والتفوق في الأداء، إذ ترتبط بالقابليات الجسدية والحركية للاعب داخل الملعب. ويُعرّف سامي صفار القوة في كرة القدم بأنها عملية تهدف إلى تقوية جسم اللاعب بصفة عامة، إضافةً إلى تنمية المجموعات العضلية التي تساعد على زيادة سرعة الحركات المختلفة، وكذلك القدرة على تمرير الكرة لمسافات أطول أثناء المباراة.

أما ثامر محسن واثق ناجي فيرى أن القوة تمثل درجة كفاءة ومثانة عضلات الجسم بشكل عام، وهي القاعدة الرئيسية للياقة البدنية، حيث يعتمد عليها اللاعب في سرعة الانطلاق، القفز، وأداء مختلف المتطلبات البدنية والفنية. ويؤكد إبراهيم مشعلان أن القوة تعني قدرة العضلات على أداء العمل وبذل الجهد في مواجهة المقاومات الخارجية، وهي في الوقت نفسه القوة التي يستخدمها لاعب كرة القدم أثناء تنفيذ متطلباته المهارية. في حين يوضح علي فهمي البيك أن القوة العضلية هي قدرة العضلة أو مجموعة من العضلات على التغلب على المقاومات الخارجية سواء برفعها، دفعها، أو مقاومتها. كما يشير R. Taelman إلى أن القوة العضلية تعني قدرة العضلة على مواجهة أو التغلب على مقاومة خارجية معينة.

ويضيف أسامة كامل راتب أن القوة العضلية تُعرف بأنها قدرة العضلة على التغلب على المقاومات المختلفة، وهي بذلك ترتبط بمقدار ما تمتلكه العضلات من قوة، بما يتناسب مع طبيعة النشاط الرياضي التخصصي ومتطلباته. يمكن التمييز بين عدة أنماط أساسية للقوة العضلية ذات الأهمية في كرة القدم، من أبرزها:

3-4-1- القوة العظمى

يُعبّر عنها بأنها أكبر قوة يمكن أن تنتجها العضلة أو مجموعة من العضلات من خلال انقباض عضلي إرادي أقصى (إيزومتري).

الفصل الأول: الأسس النظرية للاقتناء والتوجيه الرياضي اعتماداً على الصفات البدنية في كرة القدم

3-4-2- قوة التحمل

عرّفها R. Taelman بأنها قدرة الجهاز العضلي على مقاومة التعب أثناء المجهود المستمر، وتمتاز بارتباطها بمستويات النشاط العضلي وبإمكانية الاستمرار لفترات زمنية طويلة.

3-4-3- القوة المميزة بالسرعة

أوضح علي فهمي البيك أنها تعني القدرة على التغلب على المقاومات باستخدام سرعة عالية للانقباض العضلي، فيما يشير R. Taelman إلى أنها تتعلق بقدرة الجهاز العصبي العضلي على إنتاج انقباضات سريعة بدرجة عالية للتغلب على المقاومات. ومن هنا يمكن القول إن القوة المميزة بالسرعة في كرة القدم تتجلى في الأداء المهاري عندما يقوم اللاعبون بتنفيذ مهارات قوية وسريعة مثل المراوغات والانطلاقات المتكررة.

3-4-4- القوة الانفجارية

يُشير علي فهمي البيك إلى أنها القدرة على التغلب على مقاومة صغيرة أو متوسطة بأقصى قوة ممكنة وفي أقصر زمن. وتظهر هذه القوة بشكل بارز في كرة القدم، وخاصة لدى لاعبي الأطراف الذين يستخدمونها في القفزات المتكررة لضرب الكرة أو في التسديدات المفاجئة. وبذلك فهي تمثل قدرة اللاعب على العمل بأقصى قوة ممكنة وبسرعة عالية ولمدة طويلة نسبياً، وهو ما يُمكنه من تحقيق التفوق والأداء الفعال وصولاً إلى الانتصار.

3-5- الرشاقة (Agility)

تُعد الرشاقة من الصفات البدنية الأساسية في كرة القدم، ويُعرّفها أشرف محمود بأنها القدرة على تغيير أوضاع الجسم والاتجاهات في أقصر وقت ممكن، وبكفاءة عالية، مع المحافظة على التوازن أثناء الأداء الحركي (محمود أ.، 2016). هذا التعريف يبرز الجانب الحركي والميكانيكي للرشاقة، باعتبارها القدرة على الانتقال بين أوضاع مختلفة بسرعة مع الحفاظ على الاستقرار.

من جهة أخرى، يرى Sheppard & Young أنه لا يوجد حتى الآن اتفاق كامل على تعريف دقيق للرشاقة في العلوم الرياضية، ويقترحان تعريفاً أكثر شمولية: "هي حركة سريعة تشمل الجسم بأكمله، تتضمن تغييراً في السرعة أو الاتجاه استجابةً لمثير خارجي" (Sheppard & Young, 2006). ويؤكد الباحثان أن الرشاقة ليست مجرد قدرة

الفصل الأول: الأسس النظرية للاقتقاء والتوجيه الرياضي اعتماداً على الصفات البدنية في كرة القدم

بدنية، بل تتأثر أيضاً بمكونات معرفية مثل سرعة المعالجة البصرية، تقنيات المسح البصري، والتوقع، إضافةً إلى الصفات البدنية القابلة للتدريب مثل القوة والقدرة الانفجارية والتكنيك. ويُظهر هذا التباين أن الرشاقة في كرة القدم تتطلب مزيجاً من القدرات البدنية (قوة، سرعة، مرونة) والقدرات المعرفية (سرعة الاستجابة، التوقع، واتخاذ القرار)، مما يجعلها من أكثر الصفات ارتباطاً بالأداء الخططي والتكتيكي داخل الملعب.

3-6- التوازن (Balance)

يُعرف التوازن بأنه القدرة على التحكم في وضعية الجسم أثناء الثبات أو الحركة، بما يسمح للاعب بالحفاظ على استقراره في مختلف المواقف (Pradet, 2012). ويُعتبر التوازن من الصفات البدنية الأساسية المرتبطة بالقدرات التوافقية، إذ يشكل قاعدة مهمة للأداء الحركي في كرة القدم.

ويظهر التوازن في شكلين رئيسيين:

التوازن الثابت (Static Balance): وهو القدرة على الحفاظ على ثبات الجسم في وضعية معينة دون حركة، مثل وقوف الحارس أثناء التحضير للتصدي لتسديدة.

التوازن الديناميكي (Dynamic Balance): وهو القدرة على الحفاظ على استقرار الجسم أثناء الحركة، مثل المراوغة أو تغيير الاتجاه بسرعة مع السيطرة على الكرة.

ويؤكد Pradet (2012) أن تطوير التوازن يُعدّ عنصراً محورياً في الإعداد البدني، لأنه يساعد اللاعب على التحكم في جسده بكفاءة أثناء الاحتكاكات، والتكيف مع المواقف المتغيرة للعبة، مما يعزز من جودة الأداء المهاري ويقلل من فقدان السيطرة في المواقف التنافسية.

3-7- المرونة

تُعدّ المرونة إحدى الصفات البدنية الأساسية التي يقوم عليها الأداء الرياضي، وتمثل عنصراً محورياً في تحسين كفاءة الحركة وتقليل خطر الإصابات.

يرى Weineck أن المرونة هي القدرة على أداء الحركات بأوسع مدى حركي وإرادي وهادف (Weineck, 1999)، مما يعكس ارتباطها المباشر بسلامة المفاصل ومرونة العضلات والأوتار.

الفصل الأول: الأسس النظرية للاقتناء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

أما Pradet فيؤكد أن المرونة ليست مجرد اتساع في مدى الحركة، بل هي قدرة وظيفية تُسهم في تحسين الاقتصاد الحركي وتدعيم الأداء المهاري والفني، خاصة في الرياضات التي تتطلب أوضاعًا معقدة ومتغيرة مثل كرة القدم (Pradet, 2012).

بينما يشير محمود إلى أن المرونة تمثل القاعدة التي تسمح للاعب بأداء الحركات بانسيابية عالية، وأن تطويرها يُسهم في تحسين الدقة الفنية وتخفيف الضغط الواقع على الجهاز العضلي المفصلي أثناء الأداء العالي الشدة (محمود أ.، 2016). وتنقسم المرونة إلى:

3-7-1 مرونة عامة: تتعلق بالمدى الحركي للمفاصل الكبرى مثل العمود الفقري والورك والكتف.

3-7-2 مرونة خاصة: ترتبط بالمهارات المطلوبة في كرة القدم مثل حركة مفصل الورك في التسديد أو مفصل الكاحل في المراوغة.

وقد أشار كل من Pradet ومحمود إلى أن إدماج تدريبات الإطالة ضمن برامج الإعداد البدني يُسهم في تحسين مدى الحركة للمفاصل وزيادة كفاءة الجهاز العضلي المفصلي، الأمر الذي ينعكس إيجابًا على الأداء المهاري ويُقلل من احتمالية الإصابات العضلية الهيكلية.

3-8- المتطلبات البدنية حسب مراكز اللعب في كرة القدم

تختلف المتطلبات البدنية في كرة القدم باختلاف مراكز اللعب، حيث يفرض الدور الخططي والتكتيكي لكل مركز خصائص بدنية محددة ينبغي تطويرها لدى اللاعب. وقد تناول كل من Vermeulen وعراجي هذه الفروقات بشكل تفصيلي، مبرزين كيف أن طبيعة الأداء داخل المباراة تحدد نوعية القدرات البدنية الأكثر أهمية لكل مركز.

3-8-1 حارس المرمى

يتميز حارس المرمى بخصوصية كبيرة مقارنة ببقية المراكز، إذ يعتمد أساسًا على سرعة رد الفعل والتوازن، إضافة إلى القوة الانفجارية في الأطراف السفلية للتصدي للتسديدات والكرات العالية. وقد أكد كل من Vermeulen وعراجي أن هذه الصفات تمثل الركيزة الأساسية للأداء الفعّال لحراس المرمى.

الفصل الأول: الأسس النظرية للاقتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

3-8-2- المدافعون (قلب الدفاع)

يحتاجون بدرجة عالية إلى القوة العظمى والانفجارية للتفوق في الالتحامات الهوائية والأرضية، إلى جانب التحمل اللاهوائي للتعامل مع الضغط العالي والمواجهات الثنائية المتكررة. يوضح Vermeulen أن مدافعي الوسط يعتمدون على القوة والتوازن بدرجة أكبر مقارنة ببقية المراكز.

3-8-3- لاعبو الرواق (الأجنحة)

يُعد هذا المركز من أكثر المراكز تطلبًا من الناحية البدنية، نظرًا لطبيعته المزدوجة بين الواجبات الدفاعية والهجومية. إذ يحتاج اللاعبون في الأروقة إلى مستويات مرتفعة من السرعة القصوى والسرعة التكرارية (RSA) من أجل القيام بالصعود المتكرر على الخطوط والعودة السريعة لتغطية الدفاعية، إضافة إلى التسارع والرشاقة لدعم الانطلاقات الهجومية والمراوغات في مواجهة المنافسين. كما يتطلب هذا المركز قدرة عالية على التحمل اللاهوائي لمواجهة الجهود المتكررة المرتبطة بالهجمات المرتدة والتحركات السريعة على الأطراف

3-8-4- وسط الميدان

يمثلون القلب النابض للفريق، لذلك يحتاجون إلى مستويات عالية من التحمل الهوائي لتغطية أكبر مساحة ممكنة من الملعب، مع الرشاقة وسرعة التنفيذ تحت الضغط، نظرًا لكثرة مشاركتهم في الجانبين الدفاعي والهجوم.

3-8-5- المهاجمون

يرتكز أدائهم على التسارع، السرعة القصوى، والقوة الانفجارية، نظرًا لأهمية الانطلاقات القصيرة المفاجئة والتسديدات القوية والدقيقة. يؤكد Vermeulen أن الفعالية الهجومية ترتبط مباشرة بالقدرة على الانطلاق السريع وإنهاء الهجمة.

يتضح من ذلك أن التميز البدني في كرة القدم الحديثة لا يمكن أن يتحقق إلا من خلال إعداد نوعي يراعي خصوصيات كل مركز لعب، فالفروقات الموجودة تُظهر أن كل مركز لعب في كرة القدم يستلزم إعدادًا بدنيًا متخصصًا يراعي طبيعة الدور الخططي والتكتيكي، مما يفرض على المدربين تخصيص برامج تدريبية متباينة لتطوير الصفات البدنية وفقًا لمتطلبات كل مركز. (Vermeulen & Sollied, 2004) (Aradji, 2012)

3-9- التكامل مع الذكاء الاصطناعي

لم يعد تحليل المتطلبات البدنية في كرة القدم مقتصرًا على الملاحظة المباشرة أو القياسات التقليدية ، بل تطور ليشمل أنظمة مدعومة بالذكاء الاصطناعي (Artificial Intelligence) وتستخدم هذه الأنظمة تقنيات مثل تعلم الآلة (Machine Learning) والرؤية الحاسوبية (Computer Vision) لمعالجة بيانات الأداء البدني والفني بدقة متناهية، حيث تتيح هذه الأنظمة تتبع مؤشرات مثل المسافة المقطوعة، السرعة القصوى، عدد مرات التسارع، ومعدلات الاسترداد، ثم مقارنتها بقواعد بيانات مرجعية مثل تقارير الفيفا، لتحديد مدى توافق اللاعب مع متطلبات مركزه (Bradley, 2023).

وقد أظهرت الدراسات الحديثة أن الذكاء الاصطناعي يمكنه التنبؤ بالأداء لللاعب كرة القدم بناءً على تحليل بياناته البدنية والأدائية، حيث يتم جمع بيانات التدريب والمباريات عبر أنظمة التتبع بالـ GPS والأجهزة القابلة للارتداء، ثم معالجتها باستخدام خوارزميات التعلم الآلي لتحديد المركز الذي يناسب قدرات اللاعب بشكل أفضل، سواء كان ذلك في مركز الوسط أو الدفاع أو الهجوم (Utomo & Wiradinata, 2023) ، علاوة على ذلك، يمكن توظيف تقنيات التعلم الآلي للتعرف على مواقع اللاعبين في أرضية الميدان بدقة زمنية آنية، بالاستناد إلى بيانات الموقع، اتجاه الحركة، وسرعة اللاعبين، مما يسمح للمدربين بمتابعة مدى التزام اللاعبين بالتعليمات التكتيكية وتصحيح تمرّكهم خلال المباريات أو الحصص التدريبية (Di Giacomo, Mercaldo, Santone, & Capobianco, 2022). كما يُستخدم الذكاء الاصطناعي بنجاح في مجال الوقاية من الإصابات من خلال مراقبة الحمل التدريبي وتحليل مؤشرات الجهد مثل المسافة المقطوعة بسرعات عالية وتسارع العدو والتباطؤ، مما يمكن المدربين من تصميم برامج تدريبية فردية تقلل من خطر تعرض اللاعبين للإصابات (Rossi, et al., 2018) .

بالإضافة إلى ذلك، تبنت الفيفا والاتحادات القارية أنظمة تحليل مدعومة بالذكاء الاصطناعي خلال بطولات كبرى مثل كأس العالم قطر 2022، حيث تم دمج بيانات التتبع البدني والتكتيكي في منصات مثل FIFA Training Centre لتقديم مؤشرات مرجعية تساعد في إعداد اللاعبين وتوجيههم (Bradley P. , 2023). ويؤكد ذلك أن التكامل بين الذكاء الاصطناعي والمتطلبات البدنية لم يعد مجرد توجه بحثي، بل أصبح تطبيقًا عمليًا في كرة القدم الحديثة يساهم في رفع جودة الاقتقاء والتوجيه الرياضي.

الفصل الأول: الأسس النظرية للانتقاء والتوجيه الرياضي اعتمادًا على الصفات البدنية في كرة القدم

الخلاصة

يتضح من خلال ما عُرض في هذا الفصل أن عمليتي الانتقاء والتوجيه الرياضي تمثلان ركيزتين أساسيتين في بناء الفرق الكروية الناجحة، حيث يقوم الانتقاء على اختيار العناصر التي تتمتع بالمؤهلات البدنية والفسولوجية والمهارية والنفسية الملائمة، في حين يُعنى التوجيه بتوزيع هذه العناصر على مراكز اللعب وفقًا لقدراتهم الفردية وخصوصية كل مركز. وقد بينت الأدبيات أن نجاح هذه العمليات يستند إلى اعتماد معايير علمية دقيقة تشمل الجوانب البدنية، المهارية، التكتيكية، والنفسية، بعيدًا عن الانطباعات الذاتية أو القرارات العشوائية.

كما أبرز الفصل أن الصفات البدنية مثل التحمل، السرعة، القوة، الرشاقة، التوازن والمرونة، تشكّل القاعدة الفسولوجية التي يقوم عليها الأداء الرياضي، وأن لكل مركز في كرة القدم متطلبات بدنية خاصة تُحدد طبيعة إسهامه في الأداء الجماعي. فحراس المرمى مثلاً يركزون على رد الفعل والتوازن، والمدافعون على القوة والتحمل، ولاعبو الأروقة على السرعة والتكرار الحركي، ولاعبو الوسط على التحمل الهوائي والرشاقة، بينما يعتمد المهاجمون على التسارع والقوة الانفجارية. هذه الخصوصية توجب على المدربين إعداد برامج تدريبية متميزة تراعي متطلبات كل مركز لتحقيق التكامل بين الخطوط. ومن جهة أخرى، أظهرت التطورات الحديثة أن التكامل بين الذكاء الاصطناعي والانتقاء الرياضي أصبح ضرورة ملحة في كرة القدم المعاصرة، حيث تُسهم تقنيات مثل تعلّم الآلة والرؤية الحاسوبية في تحليل بيانات الأداء البدني والتكتيكي بدقة متناهية، وتقديم توصيات موضوعية بشأن المراكز الأنسب للاعبين، بالإضافة إلى المساهمة في الوقاية من الإصابات وتحسين كفاءة التخطيط التدريبي. كما أن تبني الفيفا لهذه الأنظمة في بطولات كبرى، مثل كأس العالم قطر 2022، يعكس الانتقال من البعد النظري إلى التطبيق العملي الذي أحدث نقلة نوعية في طرق التقييم والانتقاء والتوجيه الرياضي. وعليه، يمكن القول إن الجمع بين المعرفة النظرية والأدوات التطبيقية الحديثة يمهد الطريق نحو بناء أنظمة انتقاء وتوجيه أكثر دقة وفعالية، تُسهم في تطوير الأداء الفردي والجماعي، وتدعم استراتيجيات إعداد لاعبي كرة القدم بما يتوافق مع متطلبات اللعبة الحديثة.

الفصل الثاني

الذكاء الاصطناعي

تمهيد:

لا يخفى على أحد أهمية الآلات والحواسيب خاصة مع تعميم رقمنة جميع نواحي الحياة، حيث تلعب دورا كبيرا في الكثير من المهام التي يقوم بها البشر حاليا، ورغم التطور الكبير سواء للآلات والحواسيب أو برامجها، إلا أن ذلك لم يعد كافيا للإنسان، وأصبح بحاجة لجعل الآلة تفكر وتتعلم وتتخذ قرارات أي ما ينطبق مع مواصفات الكائن الحي الذكي. وبسبب ما يحتاجه الباحثون من تمويل كبير فالأبحاث وما أنجز من تطبيقات الذكاء الاصطناعي تقتصر على الحكومات والشركات الكبيرة التي وجهت اهتمامها بهذا المجال، وتتسابق فيما بينها لإنتاج خوارزميات أكثر ذكاء وتطور، ونجح بعضهم في إنتاج ما يمكن تسميته آلات ذكية، كما باتت معظم مواقع وتطبيقات التواصل الاجتماعي تنشئ خوارزميات ذكاء اصطناعي مثل التعرف على المحتويات التي تحمل طابع العنف أو الارهاب والتعامل معها، الصور والصوتيات.

في هذا الفصل وبعد ذكر أهم المحطات التاريخية سنقدم مفاهيم للذكاء الاصطناعي وتقنياته.

1- محطات تاريخية:

كان هدف الباحثين الأوائل الوصول إلى تصميم آلات ذكية قادرة على تقليد الانسان في أعماله الفكرية المعقدة. ومع الفهم السريع لحدود هذه الطموحات، اتجه الباحثون الذين خلفوهم نحو تقنيات حاسوبية جديدة (سوفت أو هارد)، ولغات البرمجة الرمزية (Langage LISP). وخلال مرحلة تطور الذكاء الاصطناعي يمكن ذكر بعض المحطات المهمة:

1738: بط جاك دو فوكانسون (Jacques de Vaucanson)، حيث تمكن من تصميم آلة على شكل بطة من النحاس المذهب تقوم بالأكل، الشرب، السباحة والبطبطة كأى بطة عادية (Papini, Marquis، و Prade، 2014)

1936: التصميم النظري لآلة تورينغ (Machine de Turing) التي كانت أساس ظهور الآلة الحاسبة والحواسيب.

1941: تصميم جهاز كهروميكانيكي يعتمد على مبدأ آلة تورينغ ودون تدخل البشر، كان له الفضل في اختصار مدة الحرب العالمية الثانية من 2 إلى 4 سنوات من خلال فك شفرات إشارات رسائل الجيش الألماني.

1943: تصميم أول نموذج لشبكة عصبية اصطناعية من طرف وارن ستورجيس ماكولوتش (Warren Sturgis McCulloch)، حيث نمذج شبكة عصبية بسيطة بواسطة دوائر كهربائية (عبد النور، 2005)..

1952: ظهور مصطلح تعلم الآلة (Machine Learning) بواسطة آرثر سامويل (Arthur Samuel) الذي صمم برنامج يعلم نفسه بنفسه لعبة الداما (Checkers) (الحلح، 2020).

1956: أطلق جون مكارثي (John McCarthy) لأول مرة مصطلح الذكاء الاصطناعي (Artificial Intelligence) خلال مؤتمر دارتماوث (Dartmouth Summer School) (عبد النور، 2005).

1958: ابتكار جون مكارثي (John McCarthy) للغة البرمجة LISP والتي مازالت من أهم لغات برمجة في الذكاء الاصطناعي.

1969: تصميم Shakey أول رجل آلي يتحرك، يدرك ويستطيع حل بعض المسائل.

- 1975:** تصميم Cognitron أول شبكة عصبية متعددة الطبقات من طرف الياباني كونيهيكو فوكوشيما (Kunihiko Fukushima).
- 1988:** نجاح الذكاء الاصطناعي في فرض نفسه كصناعة خلال فترة الثمانينات يبينه التطور المذهل في المبيعات في هذا المجال، حيث قفزت المبيعات من 425 مليون دولار سنة 1986 إلى 2 بليون دولار سنة 1988.
- 1997:** بعد دخول تطبيقات الذكاء الاصطناعي المجال الرياضي والمجال الترفيهي، تمكن الحاسوب لأول مرة والمجهر بنظام Deep Blue الذكي من هزم بطل العالم للشطرنج 12 سنة غاري كاسباروف (Gari Kasparov)، وخلال نفس السنة أقيمت أول بطولة رسمية للروبوتات في كرة القدم وبمشاركة 40 فريق (عبد النور، 2005).
- 2006:** جيفري هينتون وزملاؤه أعادوا إحياء الاهتمام بالشبكات العصبية العميقة (Deep Learning) من خلال تطوير خوارزميات فعالة لتدريب الشبكات متعددة الطبقات (HINTON, OSINDERO, & TEH, 2006).
- 2011:** ظهور مساعدين افتراضيين أذكى مثل Siri من Apple ، مما أظهر قدرة الذكاء الاصطناعي على التفاعل مع البشر بشكل طبيعي.
- 2016:** برنامج AlphaGo التابع لشركة DeepMind هزم بطل العالم في لعبة Go ، وهي لعبة معقدة للغاية تتطلب تفكيراً استراتيجياً عميقاً (SILVER, HUANG, MADDISON, & and All, 2016).
- 2018:** تطوير نموذج GPT (Generative Pre-trained Transformer) من قبل OpenAI ، الذي أحدث ثورة في معالجة اللغة الطبيعية (Radford, Narasimhan, Salimans, & Sutskever, 2018).
- 2020:** إطلاق GPT-3 ، أحد أكثر نماذج الذكاء الاصطناعي تقدماً في معالجة اللغة الطبيعية، مع 175 مليار معامل (BROWN, MANN, RYDER, & and All, 2020) .

2- الذكاء الاصطناعي (Artificial intelligence):

قبل التطرق لتعريف الذكاء الاصطناعي علينا تسليط الضوء على معنى الكلمتين المكونة له: الذكاء والاصطناعي.

2-1- تعريف الذكاء: (GARDNER, 1999)

يعرف الذكاء بأنه "القدرة على التعلم، والفهم، والتحليل، وحل المشكلات بطريقة منطقية وإبداعية. وهو يشمل القدرة على التكيف مع الظروف المختلفة، والتفكير النقدي، والابتكار". ويمكن تصنيفه إلى:

الذكاء المنطقي-الرياضي: القدرة على التحليل والاستدلال.

الذكاء اللغوي: القدرة على استخدام اللغة بمهارة.

الذكاء العاطفي: القدرة على فهم المشاعر والتعامل معها.

الذكاء الاجتماعي: التفاعل الجيد مع الآخرين.

الذكاء الحركي: السيطرة الجيدة على الحركات الجسدية

2-2- مفهوم "الاصطناعي"

يُطلق مصطلح "اصطناعي" على أي فعل يعتمد على الحيلة أو التقنية، حيث إن ما هو اصطناعي ليس فطريًا، بل مُصنَّع بالكامل بهدف معين. كما أن صفة "اصطناعي" مشتقة من الجذر "فن (Art)"، مما يشير إلى أنه نتاج عملية مدروسة تتبع منهجًا صحيحًا. ويمكن ربط الاصطناعي بالمصطلح "أداة مصنعة" أو **Artefact**، أي كيان يتم تصنيعه بواسطة التقنية البشرية وليس عن طريق الطبيعة (صليبا، 1982)

2-3- تعريف الذكاء الاصطناعي:


الذكاء الاصطناعي هو فرع من علوم الحاسوب يهدف إلى تطوير أنظمة مدمجة تحتوي على كم هائل من المعرفة والمعالجة، تُعرف بالأنظمة الذكية. وبالتالي، يقود الذكاء الاصطناعي إلى مجموعة من التعريفات حيث:

- يتمثل في دراسة التقنيات التي تتيح حل المشكلات المعقدة بسرعة معقولة من خلال استغلال المعرفة الخاصة بالمجال المعني.

- يجب أن يعطي الانطباع بأن الآلة تتصرف كشريك (مثل الذراع الروبوتية)، وأحياناً بشكل مستقل تماماً (كما في حالة الروبوتات الذاتية).
- يتمثل في برمجة الحواسيب لتنفيذ مهام يُنفذها البشر بشكل أكثر كفاءة (MINSKY, 1969).
- يعتمد على استخدام الآلات لتنفيذ أعمال ستُعتبر ذكية إذا قام بها البشر، أي أن الآلة تتصرف بذكاء كما لو كان الإنسان هو الفاعل (BODEN, 1977).
- هو أتمتة الأنشطة المرتبطة بالتفكير البشري، مثل اتخاذ القرار، وحل المشكلات، والتعلم (BELLMAN, 1978).
- يهدف إلى دراسة القدرات العقلية من خلال استخدام نماذج حاسوبية (CHAMIAK & McDERMOTT, 1985).
- يركز على برمجة الحواسيب لأداء المهام التي يكون البشر أكثر كفاءة في تنفيذها حالياً، وذلك من خلال محاكاة التفكير البشري لحل المشكلات المعقدة (RICH & KNIGHT, 1991).
- يعد فرعاً من علوم الحاسوب مخصصاً لأتمتة السلوكيات الذكية، (LUGER & STUBBLEFIELD, 1993).
- محاولة إدخال السلوك الذكي على الآلات الاصطناعية من خلال دراسة هذا السلوك في البشر والحيوانات (Whitbay, 2008).
- علم تفرع عن علوم الحاسب الآلي يهتم بالذكاء الإنساني والمهارة البشرية من خلال إعداد برامج وأجهزة يمكنها أن تقوم بعمليات شبيهة بهذا الذكاء وتلك المهارة (زين، 2000).
- مجموعة من التقنيات والنماذج الرياضية التي تهدف إلى محاكاة الذكاء البشري، سواء من خلال التعلم، التفكير، أو اتخاذ القرار (GACOGNE, 2015).

- هو تزويد الأنظمة بآليات تحاكي سلوك الكائنات الحية، مما يساعدها على الفهم والتكيف مع التغيرات البيئية. وهو لا يقتصر على الروبوتات أو ألعاب الفيديو، بل يشمل العديد من مجالات المعلوماتية (MATHIVET, 2019).

ومن خلال كل ما سبق يمكن تعريف الذكاء الاصطناعي على أنه مجال متقدم من علوم الحاسوب يركز على تطوير أنظمة وبرامج قادرة على محاكاة القدرات العقلية البشرية، مثل التفكير، واتخاذ القرارات، وحل المشكلات، والتعلم. يسعى الذكاء الاصطناعي إلى إنشاء آلات وأنظمة تتصرف بذكاء مشابه لذكاء الإنسان، سواء كان ذلك من خلال التفاعل المباشر مع البيئة أو تنفيذ مهام معقدة بشكل مستقل. يتضمن ذلك استخدام تقنيات متنوعة مثل التعلم الآلي، ومعالجة اللغة الطبيعية، والرؤية الحاسوبية، لتحقيق هذه الأهداف. يهدف الذكاء الاصطناعي إلى تحسين كفاءة وفعالية الأنظمة الحاسوبية في مجالات متعددة، مما يساهم في تحقيق تقدم كبير في التكنولوجيا وتحسين جودة الحياة البشرية.



الشكل رقم (2-1) : رسم توضيحي للعلاقة بين علوم الحاسوب، الذكاء الاصطناعي، تعلم الآلة

2-4- تصنيفات الذكاء الاصطناعي:

يمكن تصنيف الذكاء الاصطناعي إلى قسمين رئيسيين: الذكاء الاصطناعي الضيق (Weak AI)، ويعرف أيضا باسم الذكاء الاصطناعي الضعيف أو الضيق (Narrow AI)، والذكاء الاصطناعي القوي (Strong AI)، الذي يطلق عليه أحيانا الذكاء الاصطناعي الفائق (RUSSELL & NORVIG, 2021).

2-4-1- الذكاء الاصطناعي الضيق (Weak AI / Narrow AI) (الشنقيطي، 2020):

هو الذكاء الاصطناعي الذي تم تصميمه لأداء مهام محددة بدقة وكفاءة، لكنه لا يمتلك القدرة على التفكير أو التعلم خارج نطاق المهام المبرمج عليها.

يعد هذا النوع الأكثر شيوعاً في حياتنا اليومية، إذ يستخدم في أنظمة التوصية، البحث، والتفاعل مع المستخدمين.

أمثلة على الذكاء الاصطناعي الضيق:

- ✓ عند شراء كتاب من أمازون، تقترح لك المنصة كتباً مشابهة بناءً على عمليات بحثك السابقة.
- ✓ عند مشاهدة مقطع فيديو على يوتيوب، يتم اقتراح مقاطع فيديو أخرى ذات صلة.
- ✓ عند استخدام محركات البحث مثل جوجل، يتم عرض الإعلانات والنتائج بناءً على اهتماماتك السابقة.
- ✓ المساعدات الافتراضية مثل Siri و Google Assistant تقوم بمعالجة الأوامر الصوتية ولكنها لا تفهمها كما يفعل الإنسان.

رغم أن الذكاء الاصطناعي الضيق يتفوق على البشر في بعض المهام المحددة، مثل الحسابات المعقدة أو تحليل البيانات بسرعة، إلا أنه يفتقر إلى الفهم الحقيقي والإدراك، حيث يعمل فقط ضمن إطار محدد مسبقاً ولا يستطيع التفكير أو اتخاذ قرارات إبداعية.

2-4-2- الذكاء الاصطناعي القوي (Strong AI) (الشنقيطي، 2020):

على عكس الذكاء الاصطناعي الضيق، يتمتع الذكاء الاصطناعي القوي بقدرة تشبه العقل البشري، حيث يستطيع التعلم، التفكير، التكيف، واتخاذ القرارات بناءً على المنطق والتجربة. هذا النوع من الذكاء الاصطناعي لا يقتصر على مهمة واحدة، بل يمكنه حل المشكلات، التفكير النقدي، والتفاعل مع البيئات الجديدة بطريقة تشبه الذكاء البشري. رغم التقدم الكبير في الذكاء الاصطناعي، إلا أن الذكاء الاصطناعي القوي لم يتحقق بعد، وما زال قيد البحث والتطوير.

أمثلة على الذكاء الاصطناعي القوي (إذا تحقق مستقبلاً):

- ✓ روبوتات قادرة على التفكير واتخاذ القرار بشكل مستقل.

✓ أنظمة ذكاء اصطناعي يمكنها إجراء محادثات مع البشر وكأنها كائنات واعية.

✓ أجهزة قادرة على التعلم والتكيف دون الحاجة إلى برمجة مسبقة.

بعض المشاريع الحالية تسعى للوصول إلى هذا المستوى، مثل روبوت صوفيا الذي يمكنه إجراء محادثات متقدمة، لكنه لا يزال ضمن نطاق الذكاء الاصطناعي الضيق، حيث يعتمد على برمجيات محددة سلفا لتحليل الإجابات والاستجابة للمستخدمين.

2-4-5- الفرق بين الذكاء الاصطناعي الضيق والقوي:

يمكن تلخيص الفرق بين الذكاء الاصطناعي الضيق والقوي في الجدول التالي:

المعيار	الذكاء الاصطناعي الضيق (Weak AI)	الذكاء الاصطناعي القوي (Strong AI)
القدرة على التفكير	محدود بمهام معينة	يمكنه التفكير والتكيف مثل الإنسان
الاستقلالية	يعتمد على برمجة مسبقة	لديه القدرة على التعلم الذاتي
الأمثلة	محركات البحث، المساعدات الذكية، التوصيات التلقائية	روبوتات مستقلة، ذكاء بشري اصطناعي
الوضع الحالي	متاح ويُستخدم يوميا	لا يزال نظريا و قيد البحث

الجدول رقم (2-1): يبين الفرق بين الذكاء الاصطناعي الضيق والقوي

3- تعلم الآلة (Machine Learning):

3-1- تعريف:

تعلم الآلة هو فرع مهم جدًا من الذكاء الاصطناعي، وهو مشتق من العديد من التخصصات مثل الإحصاء والتحسين وعلم الخوارزميات ومعالجة الإشارات. وصفه آرثر صموئيل في عام 1959 بأنه "مجال دراسة يمنح الحواسيب القدرة على التعلم دون أن يتم برمجتها بشكل صريح".

في عام 1998، قدم توم ميتشيل تعريفًا حديثًا لتعلم الآلة، مشيرًا إلى أن الآلة تتعلم عندما تتحسن أداؤها في تنفيذ مهمة معينة مع اكتسابها خبرات جديدة. هذا التعريف يؤكد على الجانب التحسيني لتعلم الآلة، حيث يتم تحسين النماذج بشكل مستمر من خلال التعلم من البيانات الجديدة.

ومن خلال هذا التعريف يظهر مصطلح النموذج (model) والذي يشير إلى خلاصة ما تعلمته الآلة من البيانات.

3-2- المكونات الرئيسية لبناء نموذج لتعلم الآلة (الحلح، 2020):

يحتاج أي نظام أو نموذج لتعلم الآلة إلى ثلاث مكونات أساسية: البيانات، الميزات والخوارزميات.

3-2-1- البيانات (Data أو Dataset):

البيانات هي العنصر الأساسي في تعلم الآلة، حيث يعتمد النموذج على تحليلها واستخلاص الأنماط منها، ويمكن تصنيفها إلى ثلاث أصناف: بيانات منظمة (Structured Data) والتي تكون على شكل جداول أو مصفوفات أي أعمدة وصفوف، بيانات غير منظمة (Unstructured Data) وتشمل النصوص، الصور، الفيديوها والمحتوي الصوتي وأخيرًا بيانات شبه منظمة (Semi- Structured Data) تكون بين الاثنين مثل بيانات XML و JSON.

3-2-2- الميزات (Features):


يطلق عليها أيضًا المتغيرات (Variables أو Parameters)، عندما تكون البيانات جداول أو مصفوفات يكون الأمر بسيط في تحديدها، حيث تتمثل الميزات في أعمدة المصفوفات، لكن يكون الأمر معقد لما يتعلق الأمر بأنصاف البيانات الأخرى.

3-2-3- الخوارزميات (Algorithms):

هو الجزء الأسهل والأوضح في عملية تعليم الآلة، إذ يمكن حل المشكل بطرق مختلفة، غير أن حجم النموذج وأدائه يتأثر بشكل كبير بطريقة اختيار الخوارزمية المناسبة، ومع ذلك يصعب إيجاد الخوارزمية الفعالة إذا كانت البيانات منخفضة الجودة أو الدقة، ولذلك ينصح بتحسين جودة البيانات قبل البدء في بناء النموذج.

3-3- طرق التعلم الآلي (SAINT-CIRGUE, 2024):

من أجل إعطاء الآلة القدرة على التعلم، يستخدم طرق مستوحاة من الكيفية التي يتعلم منها البشر، من بينها: التعلم الإشرافي، التعلم دون إشراف، التعلم بالتعزيز.



الشكل رقم (2-2) : أكثر أساليب التعلم الآلي استخداما (WASILEWSKA, et al., 2021)

3-3-1- التعلم الموجه أو التعلم تحت الإشراف (Supervised learning):

هي الطريقة الأكثر استخداما، حيث تركز على الإشراف على تعليم الآلة مثلما يشرف الأستاذ على تعليم تلامذته من خلال أسئلة ونماذج الإجابة عليها.

من أجل إتقان التعلم الإشرافي، يجب معرفة المفاهيم الأربعة التالية:

3-1-1-3- البيانات (Dataset أو Data):

هي جدول بيانات (X, Y)، أي يحوي نوعين من المتغيرات:

Y: الهدف (Target or Label)، وهي القيمة التي نحاول التنبؤ بها.

X: الميزات (Features)، يطلق عليها أيضا المتغيرات (Variables)، وهي المتغيرات التي تؤثر في المتغير الهدف، حيث تكون على العموم كثيرة وتجمع في مصفوفة.

3-2-1-3- النموذج (Model):

عبارة عن دالة رياضية تبين العلاقة بين الميزات X (Features) والهدف Y (Target). يقدم لنا النموذج الجيد تعميما جيدا، حيث تكون الأخطاء بين $f(x)$ و y صغيرة دون أن يكون عرضة للتحليل الزائد Over-Fitting.

3-3-1-3- دالة التكلفة (Fonction Coût):

يجدر الإشارة إلى أن النموذج يعيد لنا أخطاء بالنسبة لمجموعة البيانات الخاصة بنا. نسمي دالة التكلفة مجموع هذه الأخطاء (وفي أغلب الأحيان، نأخذ المتوسط التربيعي للأخطاء).

3-4-1-3- التعلم من دالة التكلفة:

التعلم هو تقليل دالة التكلفة، لذا الهدف الأساسي في التعلم الإشرافي هو إيجاد المعلمات التي تقلل من دالة التكلفة. لتحقيق ذلك، نستخدم خوارزمية تعلم، وأكثر الأمثلة شيوعا هي خوارزمية الهبوط التدريجي (Gradient Descent).

3-5-1-3- تطبيقات التعلم تحت الإشراف:

يستخدم التعلم الإشرافي لتصميم نماذج لحل نوعين من المشاكل:

مشاكل الانحدار (Regression): في هذا النوع من المشاكل نسعى للتنبؤ بقيمة متغير مستمر (يأخذ عدد غير منتهى من القيم)، أي أننا نسعى للتنبؤ بقيمة المتغير الهدف.

مشاكل التصنيف (Classification): في هذا النوع من المشاكل نسعى للتنبؤ بقيمة متغير منفصل (يأخذ عدد محدود من القيم) ، أي أننا نسعى لتصنيف المتغير الهدف في فئات مختلفة.

3-3-2- التعلم الغير موجه أو التعلم بدون إشراف (Unsupervised learning):

يُعتبر التعلم غير المشرف أحد أهم فروع تعلم الآلة الذي يعتمد على تحليل البيانات دون الحاجة إلى توجيه أو تصنيف مسبق. يتم استخدامه عندما تكون البيانات غير مصنفة أو عندما نرغب في اكتشاف أنماط خفية فيها دون أي إشراف خارجي. على سبيل المثال: في حالة تصنيف الصور تلقائياً، مثل التعرف على الحفلات في الشوارع، يصبح من المستحيل الاعتماد على التصنيف اليدوي بسبب الكم الهائل من البيانات. هنا يأتي دور التعلم غير المشرف لتحليل الميزات والعلاقات بينها، مما يسمح باكتشاف الهياكل المخفية في البيانات.

من أبرز تقنيات التعلم غير المشرف:

3-3-2-1- التجميع (Clustering):

تقوم هذه التقنية على تقسيم البيانات إلى مجموعات متشابهة بناءً على خصائصها دون أي معرفة مسبقة بالفئات. تُستخدم هذه التقنية في العديد من التطبيقات العملية، مثل تقسيم العملاء في التسويق أو ضغط الصور عن طريق تجميع الألوان المتشابهة. من أشهر خوارزميات التجميع خوارزمية K-Means التي تعمل بشكل جيد مع البيانات ذات التوزيع الدائري، وخوارزمية DBSCAN التي تتعامل مع البيانات ذات الأشكال غير المنتظمة وتكتشف القيم الشاذة تلقائياً.

3-3-2-2- تقليل الأبعاد (Dimensionality Reduction):

هي تقنية أخرى تستعمل لتبسيط البيانات المعقدة مع الحفاظ على المعلومات الأساسية، كما تستخدم في تطبيقات مثل أنظمة التوصية، حيث يتم تحليل بيانات المستخدمين لتقديم توصيات دقيقة. من بين الخوارزميات الشهيرة في هذا المجال خوارزمية PCA التي تعمل على استخلاص المكونات الرئيسية من البيانات، وخوارزمية t-SNE التي تساعد في تصور البيانات عالية الأبعاد.

3-2-3-3- تعلم قواعد الارتباط (Association Rule Learning):

تعد هذه الأداة من الأساليب التحليلية الأساسية في مجال استكشاف البيانات، حيث تركز على تحديد العلاقات الارتباطية بين العناصر في مجموعات البيانات الكبيرة. وتعتمد هذه التقنية على ثلاثة مقاييس رئيسية:

الدعم (Support): الذي يقيس تكرار حدوث مجموعة العناصر معا،

الثقة (Confidence): التي تحسب احتمالية ظهور عنصر عند وجود عنصر آخر،

رفع الارتباط (Lift): الذي يقيس قوة العلاقة بين العناصر مقارنة بالحدوث العشوائي.

من أهم تطبيقاتها العملية تحليل سلع السوبر ماركت، حيث تساعد في تحديد المنتجات التي يتم شراؤها معا بشكل متكرر، مما يمكن متاجر التجزئة من تحسين استراتيجيات العرض والتسويق. كما تستخدم في مجال الرعاية الصحية لتحليل العلاقات بين الأعراض والأمراض، وفي المجال الرياضي لتحسين الاستراتيجيات التكتيكية من خلال تحليل أنماط أداء اللاعبين. تواجه هذه التقنية بعض التحديات مثل الحاجة إلى معالجة كميات كبيرة من البيانات، واحتمالية ظهور قواعد ارتباط زائفة، مما يتطلب ضبطا دقيقا لمعايير الدعم والثقة وفقا لطبيعة كل تطبيق، ومن أشهر خوارزمياتها خوارزمية Apriori وخوارزمية FP-growth (TAN, STEINBACH, & KUMAR, 2014).

على الرغم من فوائده العديدة، يواجه التعلم غير المشرف بعض التحديات، مثل صعوبة تقييم الأداء بسبب عدم وجود إجابات صحيحة مسبقا، والحاجة إلى بيانات عالية الجودة ومنظمة بشكل جيد. بالإضافة إلى ذلك، فإن اختيار الخوارزمية المناسبة يعتمد بشكل كبير على طبيعة البيانات والهدف من التحليل.

كما يعد التعلم غير المشرف أداة قوية لاكتشاف الأنماط والهياكل الخفية في البيانات، مما يجعله حاسما في مجالات متعددة مثل التسويق والأمن السيبراني وأنظمة التوصية. نجاحه يعتمد بشكل أساسي على فهم طبيعة البيانات واختيار الأساليب التحليلية المناسبة لتحقيق النتائج المرجوة.

3-3-3- التعلم المعزز (Rienforcement learning):

التعلم المعزز هو أحد فروع تعلم الآلة الذي يعتمد على فكرة التعلم من خلال التفاعل المستمر مع البيئة، حيث يتخذ النظام الذي يمكن أن يكون روبوتا أو برنامجا (يسمى "الوكيل" أو "Agent") سلسلة من القرارات بهدف تحقيق أقصى قدر من المكافأة التراكمية (Cumulative Reward)، حيث تعتمد هذه التقنية على:

المحاولة والخطأ (Trial and Error): الوكيل يتعلم من خلال التجربة دون وجود بيانات مُصنفة مسبقا.

التغذية الراجعة (Feedback): يحصل على مكافآت (Rewards) أو عقوبات (Penalties) بناء على أفعاله.

إذن ما يميز هذا الأسلوب هو اعتماده الكبير على مبدأ المحاولة والخطأ، حيث يكتسب الوكيل خبراته من خلال التجربة العملية دون الحاجة إلى بيانات مسبقة التصنيف، معتمدا على نظام المكافآت والعقوبات الذي يوجهه نحو السلوك الأمثل

3-3-3-1 المكونات الرئيسية:

تتكون أنظمة التعلم المعزز من عدة عناصر أساسية تتفاعل مع بعضها البعض.

الوكيل (Agent): الكيان أو النظام الذي يتخذ القرارات (مثل روبوت أو سيارة ذاتية القيادة).

البيئة (Environment): العالم الذي يتفاعل معه الوكيل (مثل لعبة أو طريق مروري).

الحالة (State): الوضع الحالي للبيئة (مثال: موقع الروبوت في المتاهة).

الفعل (Action): الحركة أو القرار الذي يتخذه الوكيل (مثال: التحرك للأمام أو اليمين).

المكافأة (Reward): إشارة رقمية تُعطى للوكيل بعد كل فعل (مثال: +10 للخروج من المتاهة، -1 لكل حركة خاطئة).

السياسة (Policy): استراتيجية الوكيل في اختيار الأفعال (مثل: "إذا كنت في حالة X، افعل Y").

الوكيل هو الكيان الذي يتخذ القرارات، بينما تمثل البيئة العالم الذي يتفاعل معه هذا الوكيل. لكل لحظة في هذه العملية حالة معينة تصف الوضع الراهن، ويتخذ الوكيل فعلاً معيناً كاستجابة لهذه الحالة، ثم يحصل على مكافأة أو عقاب بناءً على مدى ملاءمة هذا الفعل. تعمل السياسة كدليل إرشادي للوكيل، تحدد له أفضل الإجراءات التي ينبغي اتخاذها في كل حالة. هذا الإطار العام يسمح بتطبيق التعلم المعزز في مجالات متنوعة تتراوح بين الألعاب الإلكترونية والروبوتات وحتى الأنظمة المالية المعقدة.

3-3-2- أنواع التعلم المعزز:

يمكن تصنيف أساليب التعلم المعزز إلى نوعين رئيسيين:

3-3-2-1- التعلم المعزز القائم على نموذج (Model-Based RL):

يقوم الوكيل ببناء نموذجاً داخلياً لمحاكاة البيئة التي يتعامل معها (مثل حفظ خريطة المتاهة)، مما يتطلب معرفة مسبقة بقواعد البيئة وآلية عملها. ولذلك يستخدم عندما تكون البيئة معروفة أو قابلة للنمذجة.

وكمثال عن الخوارزميات المستخدمة في هذا النوع:

- Dynamic Programming

- Value Iteration

3-3-2-1- التعلم المعزز الغير قائم على نموذج (Model-Free RL):

وهو الأكثر شيوعاً في التطبيقات العملية، حيث أن الوكيل لا يعرف نموذج البيئة بل يتعلم مباشرة من خلال التجربة دون الحاجة إلى فهم مسبق لآلية عمل البيئة. وأشهر الخوارزميات في هذا النوع: SARSA، Q-Learning، وDeep Q-Networks (DQN).

تواجه أنظمة التعلم المعزز عدة تحديات جوهرية في التطبيق العملي. أحد أهم هذه التحديات هو المعضلة الكلاسيكية بين الاستكشاف والاستغلال، حيث يجب على النظام أن يوازن بين تجربة خيارات جديدة قد تؤدي إلى نتائج أفضل، والاستفادة من الخبرات المتراكمة التي أثبتت فعاليتها. كما أن مشكلة المكافآت المتأخرة تشكل عقبة كبيرة، خاصة في المهام التي تتطلب سلسلة طويلة من القرارات قبل الحصول على أي تعزيز إيجابي. بالإضافة إلى ذلك،

تزداد التعقيدات عندما تتعامل الأنظمة مع بيانات ذات حالات مستمرة أو غير كاملة المراقبة. ومع ذلك يبقى التعلم المعزز مجال قوي في الذكاء الاصطناعي وتطوره المستمر يجعله حجر أساس في مستقبل الذكاء الاصطناعي.

3-3-4- الشبكات العصبية والتعلم العميق (Artificial Neural Networks and Deep Learning) (الحلح، 2020):

3-3-4-1- الشبكات العصبية الاصطناعية (Artificial Neural Networks - ANNs):

تعتبر الشبكات العصبية الاصطناعية نماذج حسابية مستوحاة من البنية البيولوجية للجهاز العصبي البشري. تتكون هذه الشبكات من وحدات أساسية تسمى الخلايا العصبية الاصطناعية (Artificial Neurons) والتي ترتبط عبر أوزان متغيرة (Trainable Weights). تعمل هذه الشبكات وفق مبدأ التغذية الأمامية (Forward Propagation)، حيث تنتقل البيانات من طبقة الإدخال (Input Layer) عبر الطبقات المخفية (Hidden Layers) إلى طبقة الإخراج (Output Layer). عملية التعلم تتم عبر خوارزمية الانتشار العكسي (Back Propagation Algorithm) التي تعدل الأوزان بناء على دالة الخسارة (Loss Function).

هناك العديد من الهياكل (Architectures) الشائعة للشبكات العصبية الاصطناعية التي تم تطويرها لمعالجة أنواع مختلفة من البيانات والمشاكل، حيث تتنوع هذه الهياكل وقدرتها على التعامل مع التطبيقات المختلفة، ومن أشهرها:

3-3-4-1-1- الشبكات العصبية متعددة الطبقات (Multilayer Perceptron - MPL):

تعتبر أكثر الهياكل بساطة وشيوعاً، تحتوي على طبقة إدخال، طبقة مخفية أو أكثر وطبقة إخراج. يتم تدريبها بالاعتماد على خوارزمية التغذية الرجعية (Back Propagation) لتحديث الأوزان وتقليل الخطأ. كما تعتمد على دوال تنشيط (Activation Functions) مثل ReLU (Rectified linear Unit) المناسبة للطبقات المخفية، و Sigmoid أو Softmax التي تستخدم في طبقة الإخراج خاصة في التصنيف.

تستخدم على العموم لحل مشاكل التصنيف والتنبؤ، وتعمل بشكل جيد مع البيانات المنظمة (Structured Data)، كما تعتبر الأساس للكثير من الشبكات العصبية

3-3-4-1-2- الشبكات العصبية التلافيفية (Convolutional Neural Networks - CNNs):

صممت خصيصا لمعالجة البيانات المكانية مثل الصور والفيديوهات. فهي تستخدم لتصنيف الصور، التعرف على الوجه وكشف الأشياء في الصور، حيث تحتوي على طبقات التفاف (Convolutional Layers) تستخدم المرشحات (Filters) لاكتشاف الميزات الهرمية (Hierarchical Features) تلقائيا، بدءا من الحواف البسيطة وحتى الأشكال المعقدة، كما تحتوي على طبقات التجميع (Pooling Layers) التي تقلل الأبعاد المكانية لتحسين الكفاءة الحسابية.

3-3-4-1-3- الشبكات العصبية المتكررة (Recurrent Neural Networks - RNNs):

مصممة لمعالجة البيانات التسلسلية (Sequential Data) مثل النصوص أو الصوت. تتميز بوجود حلقات تغذية راجعة (Feedback Loops) تسمح بالاحتفاظ بحالة مخفية (Hidden State) لمعلومات سابقة. طورت منها بنى متقدمة مثل خلايا الذاكرة طويلة المدى قصيرة المدى (Long Short-Term Memory - LSTM) والشبكات العصبونية ذات البوابات (Gated Recurrent Units - GRUs) لحل مشكلة اختفاء التدرج (Vanishing Gradient). عموما، يعتبر هذا النوع من الشبكات الخيار الأمثل للترجمة الآلية، توليد النصوص والتعرف على الكلام.

3-3-4-2- التعلم العميق (Deep Learning) (الحلج، 2020):

التعلم العميق هو مجال فرعي من تعلم الآلة يعتمد على شبكات عصبية اصطناعية كبيرة متعددة الطبقات. يتميز بقدرته على تعلم التمثيلات الهرمية للبيانات (Hierarchical Representation) التي تعد من أبرز سمات وقوى التعلم العميق، حيث تبني المعرفة تدريجيا عبر طبقات متعددة في الشبكة العصبية. في حالة معالجة الصور مثلا تتعلم الطبقة الأولى اكتشاف الميزات البسيطة كالحواف والخطوط، بعد ذلك تلتقط الطبقات التالية تركيبات أكثر تعقيدا مثل الزوايا والأشكال الأساسية. أما الطبقات الأعمق، فتمكن من التعرف على مكونات عالية المستوى مثل الأجسام الكاملة، كتمييز وجه أو سيارة. هذا التدرج في استخراج الميزات يتيح للنموذج فهما عميقا ومجردا للبيانات دون الحاجة إلى تدخل بشري مباشر في تحديد ما يجب تعلمه. من بين أنواع الشبكات المستخدمة بكثرة


في التعلم العميق، نجد الشبكات العصبية التلافيفية (CNN) التي تستخدم بشكل أساسي في معالجة الصور والفيديوهات، حيث تقوم هذه الشبكات باستخراج الميزات المعقدة بشكل هرمي من الصور. كما تعد الشبكات العصبية المتكررة (RNN) وذات الذاكرة طويلة وقصيرة الأجل (LSTM) من الشبكات المهمة في معالجة البيانات المتسلسلة مثل الصوت والنصوص، حيث تتمتع بقدرة على الاحتفاظ بالمعلومات الزمنية والروابط بين الأحداث المتتالية. ويجدر الإشارة إلى أن الاعتماد على التعلم العميق يكون في إطار استخدام التقنيات والأساليب لتعلم البيانات واتخاذ القرارات التي ذكرناها سابقاً، أي التعلم الموجه أو تحت الإشراف لتصنيف البيانات، حيث يعتمد على وجود بيانات مدخلة مع تسميات صحيحة لتدريب النموذج على التنبؤ بالتصنيفات الدقيقة، ويعتمد على التعلم الغير موجه أو بدون إشراف عليه لاكتشاف الأنماط والهيكليات ضمن البيانات، حيث يتيح للنموذج التعرف على التجمعات أو العلاقات المخفية دون الحاجة لتسميات مسبقة، أما في حالات اتخاذ القرارات المعقدة، يعتمد على التعلم المعزز العميق الذي يستخدم مفهوم المكافآت والعقوبات لتعزيز القرارات عبر التجربة، مما يجعله مناسباً لحل مشكلات معقدة مثل الألعاب أو القيادة الذاتية.

3-3-4-2-1- تحديات التعلم العميق:

يحتاج التعلم العميق بشكل كبير إلى توفر كميات كبيرة من البيانات (Big Data). كلما زاد حجم البيانات، تحسنت دقة النماذج وظهرت نتائج أفضل. ويتطلب ذلك أجهزة حاسوبية قوية تمتلك قدرات حسابية عالية (High Computational Cost) بسبب التعقيد الحسابي لهذه الشبكات. كما تعد ظاهرة التجهيز الزائد (Overfitting) من أهم التحديات في تدريب نماذج التعلم الآلي وخصوصاً الشبكات العصبية. فهي تحدث عندما يتعلم النموذج تفاصيل ووضوءاء البيانات التدريبية بشكل مفرط، لدرجة أنه يفقد القدرة على التعميم عند مواجهة بيانات جديدة (بيانات الاختبار). حيث يظهر النموذج دقة عالية جداً على بيانات التدريب، دقة ضعيفة على بيانات الاختبار، ومنحنى التعلم يظهر تباعداً واضحاً بين الأداء على التدريب والاختبار.

3-3-4-2-2- الفرق بين التعلم العميق والشبكات العصبية التقليدية:

التعلم العميق هو امتداد للشبكات العصبية التقليدية، لكنه يتميز بعدد أكبر من الطبقات، مما يسمح له بتعلم ميزات أكثر تعقيداً وتجريداً. بينما تعتمد الشبكات التقليدية على ميزات محددة مسبقاً، يستطيع التعلم العميق.



الشكل رقم (2-3) : الفرق بين الشبكات العصبية التقليدية والتعلم العميق

(<https://www.dilepix.com/blog/difference-intelligence-artificielle-deep-learning-agriculture>, 2021)

4- مجالات استخدام الذكاء الاصطناعي (سعود، 2023):

أصبح الذكاء الاصطناعي (AI) عنصراً جوهرياً في العديد من القطاعات الحيوية، حيث يساهم في تحسين الكفاءة، دعم اتخاذ القرار، وتقديم حلول ذكية للتحديات المعقدة. فيما يلي أبرز مجالات استخدامه:

4-1- الذكاء الاصطناعي في الرعاية الصحية:

أحدث الذكاء الاصطناعي تحولاً جذرياً في القطاع الصحي من خلال في تشخيص الأمراض، تحليل صور الأشعة، وتطوير الأدوية، الكشف المبكر عن السرطان، وتتبع حالة المرضى، والتنبؤ بمضاعفات العلاج. كما تستغل الروبوتات المساعدة وتطبيقات الدردشة الذكية لتقديم استشارات طبية فورية، وإدارة المواعيد، وإنجاز المهام الإدارية. بالإضافة إلى ذلك، يساهم الذكاء الاصطناعي في التنبؤ بانتشار الأوبئة وتحليل أنماطها، مما يعزز الاستجابة السريعة للتهديدات الصحية.

4-2- الذكاء الاصطناعي في الأعمال والتسويق:

يستخدم الذكاء الاصطناعي لتحسين تجارب العملاء وزيادة كفاءة العمليات التجارية. ومن خلال تحليل بيانات العملاء، التنبؤ بالسلوك الشرائي، وتخصيص الحملات التسويقية. يستخدم أيضا في التجارة الإلكترونية لتحسين تجربة العملاء عبر توصيات مخصصة استنادا إلى سلوكهم. كما تستخدم روبوتات الدردشة في المواقع الإلكترونية لتقديم دعم فوري للعملاء، مما يقلل من الحاجة إلى التدخل البشري في المهام الروتينية.

4-3- الذكاء الاصطناعي في التعليم والترجمة:

يسهم الذكاء الاصطناعي في تطوير أساليب التعليم من خلال توفير تجارب تعليمية مخصصة تتناسب مع احتياجات كل طالب. حيث تستخدم التقنيات الذكية لتصنيف الطلاب وتقييم أدائهم وتقديم الدعم بناء على سرعتهم في التعلم. أما في مجال الترجمة، ساعد الذكاء الاصطناعي في تحسين الدقة وتقليل الأخطاء، حيث تقدم بعض المنصات ترجمة فورية عالية الجودة.

4-4- الذكاء الاصطناعي في التمويل:

يستخدم الذكاء الاصطناعي على نطاق واسع في القطاع المالي، بدءا من تقديم المشورة المالية الشخصية وحتى إجراء عمليات التداول الآلي، حيث تقوم التطبيقات بتحليل البيانات المالية لتقديم توصيات دقيقة واتخاذ قرارات استثمارية مدروسة. كما تستخدم في أسواق الأوراق المالية لاتخاذ قرارات الشراء والبيع بسرعة وكفاءة، بالإضافة إلى اعتماد البنوك على الروبوتات المساعدة لتقديم خدمات سريعة للعملاء، مثل الإجابة على الاستفسارات وإنجاز المعاملات الروتينية.

4-5- الذكاء الاصطناعي في القانون:

يساعد الذكاء الاصطناعي في تبسيط الإجراءات القانونية وتحسين الخدمات المقدمة. فمن خلال تقنيات التعلم الآلي، يمكن تصنيف الوثائق واستخراج المعلومات المهمة منها، مما يقلل الوقت والجهد المطلوبين لتحليل البيانات يدويا.

4-6- الذكاء الاصطناعي في التصنيع:

يعد التصنيع من أوائل المجالات التي تبنت الذكاء الاصطناعي، حيث تستخدم الروبوتات الصناعية لأداء مهام دقيقة ومتكررة بكفاءة عالية، حيث تساهم هذه التقنيات في زيادة الإنتاجية، خفض التكاليف، والحفاظ على جودة المنتجات.

4-7- الذكاء الاصطناعي في النقل والمركبات الذاتية:

الذكاء الاصطناعي هو أساس تطوير السيارات ذاتية القيادة، حيث تستخدم خوارزميات الرؤية الحاسوبية والتعلم العميق لتحليل البيئة المحيطة بالسيارة واتخاذ قرارات فورية، مما يقلل من الحوادث ويزيد من الأمان. كما يستخدم الذكاء الاصطناعي في إدارة حركة المرور، والتنبؤ بالتأخيرات في الرحلات الجوية، فتساهم بذلك هذه التطبيقات في تحسين كفاءة النقل وتقليل الحوادث .

4-8- الذكاء الاصطناعي في الأمن:

أصبح الذكاء الاصطناعي أداة رئيسية في الأمن السيبراني، حيث يستخدم لرصد التهديدات والهجمات الإلكترونية وتحليل الأنماط غير المعتادة في الشبكات، حيث تعتمد أنظمة الكشف الحديثة على تعلم الآلة لاكتشاف البرمجيات الخبيثة والتصدي للهجمات في الوقت الفعلي. كما تستخدم أنظمة التعرف على الصور لمراقبة المنشآت المهمة وحمايتها من الاختراقات.

4-9- الذكاء الاصطناعي في الزراعة:

تستخدم تقنيات الذكاء الاصطناعي لمراقبة المحاصيل، اكتشاف الآفات، وتحليل جودة التربة، مما يساعد في تحسين الغلة الزراعية وتقليل التكاليف. تعتمد الزراعة الذكية على الذكاء الاصطناعي والطائرات المسييرة لجمع وتحليل البيانات الميدانية.

4-10- الذكاء الاصطناعي في الزراعة (GUDMUNDSSON & HORTON, 2017):

يلعب الذكاء الاصطناعي دوراً متزايد الأهمية في عالم الرياضة، حيث يساهم الذكاء الاصطناعي في تحليل الأداء الرياضي من خلال تحليل مقاطع الفيديو من المباريات والتدريبات، حيث يمكن للأنظمة المدعومة بالذكاء الاصطناعي تتبع تحركات اللاعبين، تحليل تفاعلاتهم، وتقديم تقارير مفصلة حول الأداء ، فيسمح ذلك بتحديد نقاط القوة

والضعف لكل لاعب وللفريق ككل ، مما يساعد المدربين في اتخاذ قرارات مستنيرة حول تشكيلات الفريق واستراتيجيات اللعب، أو تحديد التمارين التي تحتاج إلى التركيز عليها، مما يساعد في تحسين اللياقة البدنية والأداء العام. كما يمكن للذكاء الاصطناعي تحليل الاستراتيجيات المستخدمة من قبل الفرق المنافسة، وتحديد النقاط الضعيفة في دفاع الفريق المنافس وتقديم توصيات واقتراح استراتيجيات هجومية لاستغلال هذه النقاط. يساعد الذكاء الاصطناعي أيضا في تحليل أنماط الحركة والتوترات البدنية التي قد تؤدي إلى الإصابات، وبالتالي يمكن للمدربين والأطباء الرياضيين تحديد اللاعبين الذين يحتاجون إلى اهتمام خاص وتقديم نصائح للوقاية من الإصابات. كما يساهم الذكاء الاصطناعي في تحسين تجربة المشجعين من خلال تقديم محتوى مخصص، من خلال تحليل تفضيلات المشجعين وتقديم لهم تحديثات وتحليلات شخصية حول فرقهم المفضلة، مما يزيد من التفاعل والانخراط.

الخلاصة:

تطرقنا خلال هذا الفصل إلى الذكاء الاصطناعي، الذي يعد من أبرز مجالات علوم الحاسوب الحديثة التي أصبحت تدخل في مختلف المجالات، حيث يهدف إلى محاكاة القدرات الذهنية البشرية كالاستنتاج والتعلم واتخاذ القرار. كما تطرقنا لأنواع الذكاء الاصطناعي، ومن بينها الذكاء الاصطناعي الضيق والقوي والفرق بينهما. بالإضافة إلى فروع المهمة مثل تعلم الآلة، الذي يعتمد على خوارزميات تمكن الأنظمة من التعلم من البيانات دون برمجة صريحة. كما كشفنا عن أهمية الشبكات العصبية والتعلم العميق في تطوير التطبيقات الذكية.

و تم استخلاص بعض المفاهيم، أهمها:

- تعلم الآلة يتعلق بتمكين الآلات من أداء مهام معينة من خلال التعلم من البيانات، بدلا من البرمجة الصريحة للقواعد.
- هناك أنواع عديدة من أنظمة تعلم الآلة، ولا يمكننا الادعاء بأن هناك طريقة واحدة هي الأفضل في جميع الحالات، فهذا الادعاء خاطئ تماما، والأمر يعتمد على الحالة التي تواجهها، مع مراعاة البيانات أولا، وما نريد من الآلة أن تتعلمه ثانيا، والسرعة المطلوبة للخوارزمية، وما إلى ذلك من العوامل المحددة.
- من الأفضل دائما تحليل كيفية التعامل مع التحديات الموجودة في البيانات والخوارزميات، لأن ذلك سيوفر الكثير من الوقت والجهد في النهاية.

كما خالصنا بشكل عام إلى أن خطوات بناء أي نظام يعتمد على تعلم الآلة تكون كما يلي:

- جمع البيانات وإعدادها: بدءا من اختيار مصدر البيانات، مع التركيز على تناسقها وشمولييتها.
- اختيار الميزات المناسبة: وتعرف أيضا بهندسة الميزات، وهي التعديلات على البيانات من تنظيفها وإعادة هيكلتها حتى إدخالها في نموذج تعلم الآلة.
- اختيار خوارزمية تعلم الآلة المناسبة وتدريب النموذج الأولي.
- تقييم النموذج: ويشمل اختيار المقاييس المناسبة والتقييم الفعلي.
- تعديل النماذج وتحسينها: لتحسين أداء النموذج إلى أقصى حد ممكن.

الباب الثاني

الجانب التطبيقي

الفصل الثالث

الإجراءات المنهجية

والتطبيقية للدراسة

تمهيد:

إن طبيعة المشكلة التي يطرحها بحثنا، والفرضيات التي قدمناها خلال الدراسة النظرية، تستوجب علينا القيام بإجراءات منهجية وميدانية للتأكد من صحة تلك الفرضيات من عدمها، وهذا ما يلزم الباحث باختيار منهج علمي ملائم ومناسب لطبيعة الموضوع قيد الدراسة، والأدوات المناسبة لجمع المعلومات، والأساليب الإحصائية لتحليلها والوصول إلى نتائج يمكن الوثوق بها، وفي هذا الفصل سنحاول أن نوضح الإجراءات المنهجية التي اتبعناها في هذه الدراسة مما ذكر سالفًا.

1- منهج البحث:

منهج البحث العلمي هو الطريقة التي يتبعها الباحث للوصول إلى هدفه المنشود في تحقيق حل مشكلته البحثية (عبيدو، 2014)، ويتميز كل بحث بمشكلته ومنهجيته، وهما مرتبطان ارتباطاً وثيقاً، فالمشكلة هي التي تحدد المنهج، وحيث ما كانت هذه الدراسة تبحث في إمداد الآلة بنماذج تمكنها من التعلم، فقد اعتمدت على المنهج الوصفي بنمطه المسحي، و الذي يتم من خلاله جمع البيانات الظاهرة بقصد التعرف عليها ودراستها وتحديد الوضع الحالي من خلال التحليل، كما يسمح لنا بجمع عدد كبير من البيانات التي تسمح بتعليم فعال للآلة.

2- الدراسة الاستطلاعية:

2-1- أدوات الدراسة الاستطلاعية:

إن ضمان السير الحسن لأي بحث ميداني يوجب القيام بدراسة استطلاعية، وكانت هذه أول خطوة قمنا بها لمعرفة مدى ملائمة ميدان الدراسة لإجراءات البحث الميدانية والتأكد من صلاحية الأدوات المستخدمة والصعوبات التي قد تعترضنا قبل الشروع في الدراسة الميدانية، وعليه قمنا بزيارة ميدانية إلى المركب الأولي محمد بومزراق الخاص بفريق أولي الشلف لفنتي أقل من 17 سنة وأقل من 19 سنة كان الغرض:

- الاتصال بمدربي الفريقين وأخذ موافقتهم من أجل القيام بالدراسة الميدانية وتطبيق الاختبارات.

- أخذ نظرة شاملة عن واقع التدريبات اليومية والأجهزة والوسائل المتاحة للعمل.

- ضبط الاختبارات التي تساهم في قياس العناصر البدنية وترتيبها.

- تحديد موعد القيام بالقياسات والاختبارات البدنية

- التعرف على اللاعبين.

2-2- إجراءات الدراسة الاستطلاعية:

تمت الدراسة الاستطلاعية في الفترة الممتدة بين 25 - 31 أوت 2023 وفق الإجراءات العملية التالية:

- حضور بعض الحصص التدريبية للتعرف على ظروف العمل الميداني.

- إجراء مقابلات قصيرة مع المدربين لجمع معلومات أولية حول مستوى اللاعبين وإمكانياتهم البدنية.

- اختبار فعلي لعينة صغيرة من اللاعبين للتأكد من وضوح تعليمات الاختبارات وسهولة تطبيقها.
- مراقبة مدى تعاون اللاعبين والتزامهم بالتعليمات أثناء التجريب الأولي.
- تسجيل الملاحظات الميدانية المتعلقة بزم الاختبار، الأدوات المستعملة، وعدد القائمين على عملية القياس.

2-3- أهداف الدراسة الاستطلاعية:

سعت الدراسة الاستطلاعية إلى تحقيق جملة من الأهداف أهمها:

- التأكد من مدى صلاحية الاختبارات البدنية المختارة لقياس المتغيرات قيد الدراسة.
- الوقوف على الترتيبات التنظيمية واللوجستية اللازمة قبل البدء في البحث الميداني.
- تحديد الصعوبات والعوائق التي قد تعترض عملية التطبيق واقتراح حلول مناسبة لها.
- اكتساب تصور شامل عن طبيعة البيئة الرياضية الخاصة بعينة البحث.
- تعزيز الثقة والتواصل بين الباحث والمدرين واللاعبين لضمان نجاح الدراسة الأساسية.

2-4- نتائج الدراسة الاستطلاعية:

بعد الانتهاء من تنفيذ الدراسة الاستطلاعية وجمع الملاحظات الميدانية، تبين أن الاختبارات البدنية المطبقة على فتي أقل من 17 سنة وأقل من 19 سنة بفريق أولمبي الشلف لم توفر بيانات دقيقة أو كافية يمكن الاعتماد عليها في تصميم التطبيق الذكي المعتمد على تقنيات تعلم الآلة. فقد أظهرت النتائج ما يلي:

- المعطيات الناتجة عن الاختبارات لا تُمكن من إنشاء قاعدة بيانات ثرية ومتنوعة تساعد على تدريب نماذج تعلم الآلة بكفاءة.
- طبيعة العينة (فئات أقل من 17 وأقل من 19 سنة) لا تعكس المستوى العالي المطلوب لتغذية خوارزميات الذكاء الاصطناعي، إذ تحتاج هذه النماذج إلى بيانات لاعبين ذوي خبرة ومستوى أداء متقدم.
- هناك حاجة ملحة إلى إعادة النظر في مجتمع البحث واختيار عينة بديلة أكثر ملاءمة، بحيث تضم لاعبين من مستويات عليا يمكن أن تقدم مؤشرات واقعية وذات قيمة تطبيقية في عملية التوجيه والانتقاء الرياضي.

- ضرورة البحث عن وسائل وطرق قياس بديلة (مثل الأجهزة الحديثة للتحليل الحركي والفيزيولوجي، أو البيانات الرقمية المسجلة عبر أنظمة التتبع GPS والـ Wearable sensors) بما يضمن دقة المعطيات وقابليتها للاستعمال في بناء تطبيق تعلم الآلة.

وبناءً على ما سبق، أكدت الدراسة الاستطلاعية أنَّ الخطوة الأساسية التالية هي توسيع نطاق البحث نحو مجتمع آخر، واختيار اختبارات وأدوات أكثر تخصصاً في جمع البيانات الرقمية الدقيقة، بما يتوافق مع متطلبات الذكاء الاصطناعي وتعلم الآلة في المجال الرياضي.

3-مجتمع الدراسة :

مجتمع الدراسة هو جميع مجموعة الوحدات التي يتم اختيارها العينة منها بالفعل (الشريبي، صادق، القرني، و مطحنة، 2013)، وشمل مجتمع هذه الدراسة لاعبي حيث تمثل المجتمع في لاعبي كرة القدم رجال لفرق البطولة الفرنسية ليغ 1 وليغ 2، المسجلين في الموسم الرياضي 2023/2022 والبالغ عددهم (1060) لاعب ينتمون إلى (40).

تم اختيار بيانات الدوري الفرنسي لعدة أسباب علمية ورياضة :

1- لأن هذه البطولات تمتلك قواعد بيانات كبيرة ودقيقة للاعبين، وهو أمر مهم عند بناء نماذج تعلم الآلة التي تحتاج إلى كمية كافية من البيانات.

2- لأن الدوري الفرنسي يُعرف بتركيزه الكبير على الجانب البدني في تكوين اللاعبين، وهو ما يتوافق مع هدف الدراسة التي تعتمد على عناصر اللياقة البدنية لتوجيه اللاعبين نحو مراكز اللعب.

3- توجد علاقة تاريخية ورياضية قوية بين كرة القدم الجزائرية والفرنسية، حيث أن عددًا كبيرًا من لاعبي Algeria national football team تكوّنوا في مراكز التكوين التابعة للأندية الفرنسية.

لذلك يمكن القول إن النموذج البدني للاعب في الدوري الفرنسي قريب نسبيًا من خصائص اللاعب الجزائري مقارنة ببعض البطولات الأخرى. وبالتالي فإن استخدام هذه البيانات يسمح ببناء نموذج أولي واقعي يمكن لاحقًا تطويره باستخدام بيانات خاصة باللاعبين المحليين.

الفريق	عدد اللاعبين	الفريق	عدد اللاعبين	الفريق	عدد اللاعبين	الفريق	عدد اللاعبين
أجاسيو	26	تروا	30	مونبولي	26	روديز	30
أوكسير	29	أنسي	27	نيم	24	باستيا	24
أميان	23	بورديو	26	نيس	26	براست	23
أنجي	29	لوريون	27	مارسيليا	31	رامس	28
موناكو	27	ماتز	25	ليون	31	لافال	27
سانت ايتيان	29	نانت	28	أف سي باريس	28	كون	27
شاموا نيور	26	سوشو	28	باريس سان	26	ران	26
كليرمون فوت	25	غرونوبل	28	أف سي بوو	28	تولوز	25
ديجون	28	لوهافر	27	لانس	24	كوفيلي	24
جانجون	22	ليل	23	ستراسبورغ	23	فالنسيان	26

الجدول 3-1: توزيع المجتمع حسب كل فريق - المصدر: موقع *Sofifa* (Sofifa, 2023)

4- عينة الدراسة :

العينة عن مجموعة الأفراد أو المفردات أو الوحدات التي يتم اختيارها من مجتمع الدراسة لتمثيل هذا المجتمع في البحث محل الدراسة (الشربيني، صادق، القرني، و مطحنة، 2013)، وقد تمثلت عينة الدراسة في (938) لاعب من البطولة الفرنسية الأولى والثانية للموسم الرياضي 2022-2023 موزعة على 40 فريق، حيث تم استبعاد حراس المرمى نظرا لتمييز هذا المنصب بمتطلبات ومواصفات خاصة، وبذلك مثل مجتمع الدراسة (88.49%) من المجتمع الأصلي ليمثلوا بذلك العينة الأساسية للدراسة معدل أعمارهم (24.61 ± 4.55) سنة، والذين توزعوا على مناصب اللعب، كما هو موضح في الجدول رقم (02).

توزيع أفراد العينة		النسبة المئوية	عدد	
حسب منصب اللعب		100 %	1060	المجتمع الأصلي للبحث
209	وسط الدفاع	88.49 %	938	عينة البحث
275	لاعب الرواق			
295	وسط الميدان			
159	قلب هجوم			

الجدول 2-3 توزيع أفراد عينة البحث حسب متغير منصب اللعب في كرة القدم

رأينا عدم جدوى من إجراء التجانس داخل العينة، حيث أن العينة تشمل كل مفردات المجتمع التي تشملها الدراسة وقد أشار (علاوي و راتب، 1999) إلى أنه إذا كان حجم العينة يساوي حجم المجتمع فلا يكون هناك ما يسمى بأخطاء المعاينة لأنه لا توجد عينة.

5-مجالات الدراسة:

5-1-المجال المكاني: قمنا بإجراء الدراسة النظرية، الاستطلاعية والتطبيقية في كل من مكتبة جامعة حسية بن بوعلي بالشلف، مكتبة معهد التربية البدنية والرياضية بالشلف وملعب محمد بومزراق بالشلف.

5-2-المجال الزمني: تمت هذه الدراسة النظرية والتطبيقية في الفترة الزمنية من 01-11-2022 إلى غاية 31-08-2024.

6-متغيرات البحث:

6-1-المتغير المستقل: يعرف على " أنه المتغير الذي يفسر لنا الظاهرة (دويدري، 2000)، وتمثل حسب متطلبات الدراسة في:

- عناصر اللياقة البدنية

6-2-المتغيرات التابعة: " هي المتغيرات التي يرغب الباحث في شرحها (دويدري، 2000)، وتمثل حسب متطلبات الدراسة في:

- منصب اللعب.

7- أدوات البحث::

7-1- قاعدة البيانات:

تم تحميل قاعدة البيانات Fifa 23 من موقع Kaggle الذي يحوي الكثير من قواعد البيانات (NAIK, 2023) ، وهي نفسها البيانات المتواجدة على مستوى موقع Sofifa (Sofifa, 2023).

7-2- أجهزة الأداء والتتبع الالكترونية EPTS (FIFA, 2022) :

هي أجهزة وتقنيات يلبسها اللاعب بسهولة ولا تسبب أي إزعاج أو إعاقة له، حيث تسمح بمتابعة أداء اللاعب والفريق ككل ، ونجدها في ثلاث أشكال:

-أنظمة الكاميرات المعتمدة على التقنيات البصرية.

-أنظمة تحديد المواقع المحلية.

- أنظمة التوضع العالمي/الملاحة عبر الأقمار الاصطناعية

7-3- الشروط العلمية للأجهزة:

تمكنت الاتحادية الدولية لكرة القدم Fifa من تطوير برنامج الجودة لأجهزة الأداء والتتبع الالكترونية من خلال أبحاث واستشارات مكثفة ليكون بمثابة منهجية لتقييم دقة مختلف الأنظمة المتاحة، حيث يتكون البرنامج من اختبارين مختلفين:

- اختبار سلامة الأجهزة الملبوسة: يسمح الاختبار بتقييم أثر الأجهزة وسلامتها فقط دون تبني جودة المعلومات، حيث تعطى علامة " معيار المباريات الدولي " للأجهزة المصادق عليها.

- اختبار الأداء المعياري: حيث يشمل اختبار عمليات متعلقة بنظامين، الأول معيار ذهبي معترف به عالميا لالتقاط الحركة (Vicon)، والثاني هو نظام (Vision Kit) لمتابعة اللاعبين في مساحة الملعب ككل، حيث يسمح النظامان بتقييم دقة النظام.

7-4-4. الوسائل الإحصائية ومعالجة البيانات:

7-4-1- المتوسط الحسابي

7-4-2- الانحراف المعياري

7-4-3- تطبيع البيانات Data Normalization

المقصود بـ Data Normalization أو تطبيع البيانات هو عملية إعادة تحويل القيم العددية للمتغيرات إلى مجال أو مقياس موحد، بهدف تقليل تأثير اختلاف الوحدات أو نطاقات القيم بين الخصائص (features) على أداء خوارزميات التعلم الآلي، خاصة تلك الحساسة للمسافات مثل KNN أو SVM. فعلى سبيل المثال، قد تكون لدينا قاعدة بيانات تضم الطول بالسنتيمتر (150-200)، والوزن بالكيلوغرام (50-100)، وسرعة الجري بالثواني (10-20)، فإذا تركت القيم كما هي ستعتبر بعض الخوارزميات الوزن أكثر تأثيراً لمجرد أن أعدداه أكبر، لذلك يساعد التطبيع على وضع جميع الخصائص ضمن نفس النطاق وضمان عدالة المقارنة بينها.

ومن بين الطرق الأكثر شيوعاً في التطبيع:

- **Min-Max Scaling**: التطبيع إلى $[0,1]$ وفق الصيغة $X' = \frac{X - X_{min}}{X_{max} - X_{min}}$

- **Z score Normalization** (التوحيد/Standardization) حسب الصيغة

$$X' = (X - \mu) / \sigma$$

- **Min-Max Scaling** إلى نطاق عام $[a,b]$ وفق الصيغة

$$X' = \frac{(b - a)(X - X_{min})}{X_{max} - X_{min}} + a$$

- **التطبيع اللوغاريتمي (Log Transformation)** المستخدم عند وجود بيانات غير موزعة طبيعياً أو

ذات فروقات كبيرة جداً بين القيم، حيث تُستعمل الصيغة


$$X' = \log(1 + X)$$

يُضاف 1 لتجنب مشكلة $\log(0)$

الخلاصة: اختيار نوع التطبيع يعتمد على طبيعة البيانات والخوارزمية المستعملة؛ ف Min-Max مناسب للبيانات ذات الحدود الواضحة، و Z-score للتوزيعات الطبيعية تقريباً، بينما التطبيع اللوغاريتمي فعال مع البيانات المنحرفة أو غير المتوازنة.

7-5- توزيع Anaconda3 Distribution


تُعد Anaconda توزيعاً مفتوح المصدر متخصصاً في تسهيل استخدام لغة Python وإدارة مكتباتها، حيث توفر بيئة متكاملة تضم أدوات أساسية لتحليل البيانات، التعلم الآلي، والإحصاء التطبيقي. وتتميز بقدرتها على إنشاء بيئات افتراضية (Virtual Environments) تتيح للباحثين إدارة الاعتماديات البرمجية دون تعارض، إضافةً إلى توفير واجهة رسومية تُعرف بـ Anaconda Navigator تمكّن من تثبيت الحزم وتشغيل المنصات التفاعلية بسهولة. ويمثل هذا النظام مدخلاً عملياً لتبسيط العمل البحثي، لا سيما بالنسبة للباحثين في المجالات العلمية التي تعتمد على النمذجة والتحليل الإحصائي (Rolon-Mérette, Ross, Rolon-Mérette, & Church, 2020).



الشكل رقم (3-1) يمثل واجهة توزيع Anaconda distribution

7-6- منصة Jupyter Notebook


تُعتبر Jupyter Notebook إحدى الأدوات المدججة في توزيع Anaconda ، وتُستخدم على نطاق واسع في البحث العلمي والتعليم. فهي بيئة برمجية تفاعلية عبر المتصفح تسمح بدمج النصوص التوضيحية (Markdown) ، الأكواد البرمجية، والمخرجات (رسوم بيانية، جداول، نتائج) في ملف واحد قابل للمشاركة. وتُسهّل هذه المنصة عملية التوثيق وإعادة إنتاج النتائج (Reproducibility) مما يجعلها خيارًا مفضلًا في البحوث الأكاديمية. كما تدعم لغات برمجية متعددة، غير أن استخدامها الأكثر شيوعًا يرتبط بلغة Python ، ما جعلها أداة محورية في مجالات تحليل البيانات والتعلم الآلي (Rolon-Mérette, Ross, Rolon-Mérette, & Church, 2020) .



الشكل رقم (3-2) يمثل واجهة منصة Jupyter Notebook

7-7- لغة Python3

تُعد Python لغة برمجة مفتوحة المصدر، تتسم بالبساطة والمرونة، مما يجعلها مناسبة لمجالات متعددة في البحث العلمي. وتتميز بوجود مكتبات قوية مثل: *NumPy*، *Pandas*، *Matplotlib*، و *Scikit-learn*، التي توفر إمكانيات متقدمة للتحليل الإحصائي، النمذجة، والتعلم الآلي. وقد أشار Rolón-Mérette وزملاؤه (Rolón-Mérette, Church, Ross, & Rolón-Mérette, 2020) إلى أن Python أصبحت أداة مركزية في المجتمع الأكاديمي، نظرًا لقدرتها على تسهيل الأتمتة، تحليل البيانات، ودعم مبدأ إعادة إنتاج النتائج. وهو ما يجعلها لغة أساسية للباحثين الراغبين في استغلال تقنيات الذكاء الاصطناعي ومعالجة البيانات الضخمة في مجالاتهم العلمية.



الشكل رقم (3-3) يمثل واجهة مشروع بلغة Python باستخدام منصة Jupyter Notebook

7-8- خوارزمية أقرب الجيران (KNeighborsClassifier (KNN

هي إحدى الطرق البسيطة في الذكاء الاصطناعي، تستعمل للتصنيف والتنبؤ، تقوم بتصنيف أي عينة (نقطة جديدة) بناءً على أقرب K جيران لها في فضاء البيانات. أي أنها لا تُنشئ نموذجًا رياضيًا صريحًا (non-parametric) وإنما تعتمد على مقارنة المثال الجديد مع البيانات المخزنة مسبقًا. (developers, Scikit-learn, 2025). تعتمد هذه الخوارزمية على فكرة شبيهة بما يقوم به الإنسان في حياته اليومية: فإذا أردنا الحكم على شخص جديد (مثلاً: ما الرياضة التي قد يجيدها)، فإننا نقارن صفاته مع صفات أشخاص آخرين نعرفهم من قبل. بعد ذلك ننظر إلى أقرب مجموعة من الأشخاص (عدددهم يرمز له بـ K) يشبهونه أكثر. فإذا كان أغلب هؤلاء الأشخاص مدافعين في كرة القدم، فتتوقع أن اللاعب الجديد سيكون مدافعًا أيضًا.

7-9- خوارزمية آلة متجه الدعم (Support Vector Machine (SVM

هي إحدى الطرق البسيطة في الذكاء الاصطناعي، تستعمل للتصنيف والتنبؤ. تعتمد هذه الخوارزمية على فكرة رسم خط أو حاجز يفصل بين مجموعتين مختلفتين بشكل واضح. (developers, Scikit-learn, 2025) فمثلاً، إذا كان عندنا لاعبو كرة قدم: بعضهم معروف بأنهم مدافعون، وآخرون معروفون كمهاجمين، فإن خوارزمية SVM تبحث عن "خط وهمي" في الملعب يجعل المدافعين في جهة والمهاجمين في الجهة الأخرى، مع ترك أكبر مسافة ممكنة بين المجموعتين. وعندما يظهر لاعب جديد، ننظر إلى أي جهة من الخط يقف: إذا كان في جهة المدافعين نعتبره مدافعًا، وإذا كان في جهة المهاجمين نصنفه مهاجمًا. بعبارة أخرى: خوارزمية SVM تحاول دائماً أن تضع "أوضح حد ممكن" بين المجموعات المختلفة، مما يجعلها دقيقة وفعالة في التمييز.

7-10- خوارزمية الغابة العشوائية (Random Forest

هي إحدى الطرق الذكية في الذكاء الاصطناعي، تستعمل للتصنيف والتنبؤ. تعتمد هذه الخوارزمية على فكرة تشبه ما يقوم به مجموعة من الخبراء عند اتخاذ قرار: بدلاً من الاعتماد على "شخص واحد فقط" ليقرر، يتم إنشاء عدد كبير من "أشجار القرار" الصغيرة، وكل شجرة تعطي رأيها بشكل مستقل. (developers, Scikit-learn, 2025)

عندما نريد معرفة النتيجة (مثلاً: المركز الأنسب للاعب كرة قدم جديد)، تسأل الخوارزمية جميع الأشجار، ثم تختار القرار الذي يحصل على أكبر عدد من الأصوات.

بعبارة أخرى، Random Forest يعمل مثل لجنة من الحكّام: كل واحد يعطي رأيه، والقرار النهائي يكون للأغلبية. وهذا يجعلها خوارزمية قوية ودقيقة، لأنها لا تعتمد على نموذج واحد فقط، بل على "غابة" كاملة من الأشجار.

7-11- تقنية تقسيم البيانات إلى تدريب واختبار Train Test Split

هي إحدى التقنيات البسيطة في تعلم الآلة، تستعمل لتقسيم البيانات إلى جزئين (developers, Scikit-learn, 2025):

- **مجموعة التدريب (Train Set):** تُستعمل لتعليم النموذج.
 - **مجموعة الاختبار (Test Set):** تُستعمل لقياس دقة النموذج على بيانات جديدة لم يرها من قبل.
- بعبارة أخرى، هذه التقنية تضمن أن النموذج لا يحفظ البيانات فقط، بل يستطيع التعميم والتنبؤ بشكل صحيح عند مواجهة بيانات جديدة.

7-12- تقنية التحقق المتقاطع Cross Validation

هي تقنية في تعلم الآلة تهدف إلى تقييم دقة النموذج بشكل أفضل. بدل أن نقسم البيانات مرة واحدة فقط إلى تدريب واختبار (كما في *Train Test Split*)، نقوم بتقسيمها إلى عدة أجزاء (يطلق عليها طيات Folds) في كل مرة نختار جزءاً مختلفاً ليكون للاختبار، والبقية للتدريب. نكرر هذه العملية عدة مرات، ثم نحسب متوسط النتائج. بهذا الشكل نقلل من تأثير الصدفة (مثلاً إذا كان التقسيم الأول غير متوازن)، ونحصل على تقييم أكثر موثوقية للنموذج. (developers, Scikit-learn, 2025)

بعبارة أخرى، Cross Validation = اختبار النموذج عدة مرات على تقسيمات مختلفة لنفس البيانات، لضمان أنه قوي وموثوق.

وبما أنه لا يمكن استخدام بيانات عمود المركز أو المنصب المفضل لكونها ليست بيانات رقمية، وما يهمنا هو منصب أو مركز المدافع المحوري، فقد قمنا بإعطاء القيمة 1 لمركز المدافع المحوري (لاعب وسط الدفاع)، و 0 لباقي المراكز.

8- تصميم التطبيق

8-1- واجهة التطبيق

الواجهة الأولى خاصة بإدخال بيانات اللاعب المتعلقة بعناصر اللياقة البدنية (السرعة، التسارع، الرشاقة، سرعة رد الفعل، التوازن، الارتقاء، القوة والتحمل)، حيث ان القيم محصورة بين 1 و 100.

الشكل رقم (3-4) يمثل واجهة التطبيق لإدخال البيانات

8-2- زر اختيارات التطبيق

من خلال زر الاختيارات يمكن اختيار عملية التقييم التي نريدها، حيث لدينا 5 اختيارات: اكتشاف أفضل مركز ملائم للاعب، تقييم ملائمة اللاعب لمركز وسط الدفاع، تقييم ملائمة اللاعب لمركز لاعب رواق، تقييم ملائمة اللاعب لمركز وسط ميدان، تقييم ملائمة اللاعب لمركز قلب هجوم، وكل ذلك حسب عناصر اللياقة البدنية.

تقييم ملائمة اللاعب

التسارع: 84	السرعة: 77
سرعة رد الفعل: 83	الرشاقة: 92
الارتقاء: 56	التوازن: 88

— اختر نوع التقييم —


اكتشاف أفضل مركز ملائم


تقييم كوسط دفاع


تقييم كلاعب رواق


تقييم كوسط ميدان


تقييم كقلب هجوم

— اختر نوع التقييم —

بدء التقييم

الشكل رقم (3-5) يمثل اختيارات نوع التقييم

8-3- زر بدء التقييم

بعد اختيار نوع التقييم، نضغط على زر بدء التقييم ليعطينا النتيجة حسب النوع الذي تم اختياره.

84	77
سرعة رد الفعل:	الرشاقة:
83	92
الارتقاء:	التوازن:
56	88
التحمل:	القوة:
75	57
اختر نوع التقييم:	
☐ اكتشف أفضل مركز ملائم	
بدء التقييم	
🏆 أفضل مركز ملائم للاعب المركز: وسط الميدان متوسط! يمكن للاعب التألق في هذا المركز.	

الشكل رقم (3-6) يبين زر بدء التقييم

واجه الباحث خلال تنفيذ هذه الدراسة جملة من الصعوبات المنهجية والعملية التي كان لها تأثير واضح على مسار الإنجاز، ويمكن عرضها على النحو الآتي:

- **عدم توفر وسائل قياس عالية الدقة:** تمثلت إحدى الصعوبات في عدم توفر أدوات أو تقنيات قياس دقيقة وموثوقة تسمح بتقييم بعض القدرات البدنية ميدانيًا بدرجة عالية من الدقة، مما دفع الباحث إلى الاعتماد على القيم الرقمية المستخرجة من موقع sofifa كمصدر بديل للتحليل.
- **ندرة الدراسات السابقة:** واجه الباحث نقصًا بيّنًا في الأدبيات العلمية ذات الصلة بموضوع الدمج بين التربية البدنية والرياضية وتقنيات الإعلام الآلي، مما حدّ من إمكانية بناء إطار نظري ثري وداعم للمقاربات المقترحة.
- **ازدواجية المجال المعرفي:** مثل الجمع بين مجالين مختلفين—التربية البدنية والرياضية من جهة، والإعلام الآلي من جهة أخرى—تحدّيًا منهجيًا؛ إذ تطلّب الأمر التوفيق بين أسس نظرية وإجرائية تنتمي إلى حقول معرفية متباينة.
- **غياب قاعدة بيانات وطنية:** اصطدم الباحث بغياب شبه تام لقاعدة بيانات وطنية يمكن الاعتماد عليها في المجال المدروس، مما فرض اللجوء إلى مصادر خارجية لا تغطي جميع المتغيرات بالدقة المطلوبة.
- **عدم وضوح منهجية معالجة البيانات في قاعدة بيانات FIFA23:** تمثلت إحدى الصعوبات التقنية في غياب المعلومات التفصيلية حول الآليات الإحصائية والمنهجيات المعتمدة في إنتاج البيانات داخل قاعدة FIFA23، وهو ما جعل تفسير بعض المؤشرات وتحليلها تحدّيًا إضافيًا.

خلاصة :

جاء الفصل لعرض إجراءات البحث الميداني، فقد اشتمل على التعريف بمنهج الدراسة ونوعه ووصف مجتمع الدراسة من حيث مصدره وحجمه وخصائصه وكيفية اختياره ليتم التعرّيج بعد ذلك إلى الدراسة الاستطلاعية ونتائجها، كما تم التعرف في هذا الفصل إلى أدوات الدراسة التي استعملت في عملية جمع المعطيات إلى جانب توضيح الإجراءات التطبيقية للدراسة الأساسية بالإضافة إلى ذكر الأساليب الإحصائية التي تم الاعتماد عليها في تحليل البيانات الخاصة بهذه الدراسة قصد المرور إلى عرضها و تحليلها.

الفصل الرابع

عرض، تحليل

ومناقشة النتائج

تمهيد:

بعد التطرق في الفصل السابق لإجراءات البحث الميداني، خصص هذا الفصل للمعالجة الإحصائية للبيانات التي تم جمعها، واستخلاص النتائج وقراءتها ومن ثم تحليلها قصد التأكد من صحة الفرضيات التي طرحت في الفصل التمهيدي، ولذلك يعتبر هذا الفصل أهم فصول هذه الدراسة ففي نهايته نصل إلى إجابات عن أسئلة البحث، ووضع استنتاج عام ثم خاتمة .

1- عرض وتحليل النتائج:

	الطول	الوزن	التسارع	السرعة	الرشاقة	سرعة رد الفعل	التوازن	الارتقاء	التحمل	القوة
المتوسط الحسابي	180.62	73.51	67.95	67.76	66.72	63.07	67.20	66.03	66.58	65.72
الانحراف المعياري	6.60	6.99	12.58	12.52	12.84	9.08	13.08	12.78	12.54	13.44

جدول رقم (1-4) خصائص الطول، الوزن وعناصر اللياقة البدنية لدى أفراد عينة البحث

حسب الجدول رقم (1-4) فإن المتوسط الحسابي لطول لاعبي البطولة الفرنسية بقسميها الأول والثاني ليغ 1 وليغ 2 بلغ على التوالي (180.62) و (73.51)، بانحراف معياري (6.60) للطول و (6.99) للوزن. بالنسبة لعناصر اللياقة البدنية، فإن متوسط تسارع لاعبي البطولة الفرنسية ليغ 1 و ليغ 2 فقد بلغ 67.95 بانحراف معياري 12.58، ومتوسط السرعة 67.76 بانحراف معياري 12.52، أما متوسط الرشاقة 66.72 بانحراف معياري 12.84، في حين بلغ متوسط سرعة رد فعل اللاعبين 63.07 بانحراف معياري 9.08، كما بلغ متوسط التوازن 67.20 بانحراف معياري 13.08، وقدر متوسط الارتقاء 66.03 بانحراف معياري 12.78، كما قدر متوسط التحمل 66.58 بانحراف معياري 12.54، أما عنصر القوة فقد بلغ متوسطه 65.72 بانحراف معياري 13.44.

1-1- عرض وتحليل نتائج الفرضية الأولى:

يستطيع التعلم الآلي (Machine learning) التعرف على لاعبي وسط الدفاع في البطولة الفرنسية المحترفة ليغ 1 و 2 من خلال عناصر اللياقة البدنية ":

الوزن	الطول	منصب
6.12±79.15	5.25±187.03	وسط الدفاع
6.37±71.89	5.75±178.78	المناصب الأخرى

جدول رقم (4-2) يبين فروقات الطول والوزن بين لاعبي وسط الدفاع والمناصب الأخرى


حسب الجدول رقم (4-2) فإن المتوسط الحسابي لطول ووزن لاعبي وسط الدفاع في البطولة الفرنسية بقسميها الأول والثاني ليغ 1 وليغ 2 بلغ (187.03) و (79.15) بانحراف معياري (5.25) و (6.12)، في المقابل بلغ طول ووزن لاعبي المناصب الأخرى (178.78) و (71.89) بانحراف معياري (5.75) و (6.37).

التسارع	السرعة	الرشاقة	سرعة رد الفعل	التوازن	الارتقاء	التحمل	القوة	
56.24	58.07	52.79	62.28	53.55	71.98	64.47	76.20	لاعبو وسط الدفاع
±	±	±	±	±	±	±	±	
11.98	12.95	11.61	8.98	11.70	10.69	10.80	9.08	
71.30	70.54	70.71	63.30	71.11	64.33	67.18	62.72	لاعبو المناصب الأخرى
±	±	±	±	±	±	±	±	
10.58	10.92	10.10	9.10	10.60	12.83	12.94	12.98	

جدول رقم (4-3) يبين الفروقات في عناصر اللياقة البدنية بين لاعبي وسط الدفاع والمناصب الأخرى


حسب الجدول رقم (4-3) بالنسبة لعناصر اللياقة البدنية، فإن متوسط تسارع لاعبي وسط دفاع البطولة الفرنسية ليغ 1 و ليغ 2 فقد بلغ 56,24 بانحراف معياري 11,98، مقابل 71.30 لباقي المناصب الأخرى بانحراف معياري 10.58 . وبلغ متوسط سرعة لاعبي وسط الدفاع 58.07 بانحراف معياري 12.95 مقابل

متوسط حسابي 70.54 لباقي المناصب الأخرى بانحراف معياري 10.92 . أما متوسط رشاقة لاعبي وسط الدفاع 52.79 بانحراف معياري 11.61 مقابل متوسط 70.71 وانحراف معياري 10.10 لباقي المناصب. في حين بلغ متوسط سرعة رد فعل لاعبي وسط الدفاع 62.28 بانحراف معياري 8.98 قابله متوسط 63.30 وانحراف معياري 9.10 للمناصب الأخرى. كما بلغ متوسط التوازن لدى لاعبي وسط الدفاع 53.55 بانحراف معياري 11.70، في المقابل بلغ المتوسط الحسابي والانحراف المعياري لدى باقي المناصب 71.11 و 10.60 على التوالي. وقدر متوسط ارتقاء لاعبي وسط الدفاع 71.98 بانحراف معياري 10.69 مقابل 64.33 و 12.83 كمتوسط حسابي وانحراف معياري على التوالي لباقي المناصب الأخرى. كما قدر متوسط تحمل لاعبي وسط الدفاع 64.47 بانحراف معياري 10.80، قابله متوسط حسابي 67.18 وانحراف معياري 12.94 للمناصب الأخرى. أما عنصر القوة فقد بلغ متوسطه 76.20 وانحرافه المعياري 9.08 لدى لاعبي وسط الدفاع مقابل متوسط حسابي وانحراف معياري قدرا ب 62.72 و 12.98 للمناصب الأخرى.




الشكل رقم (4-1): يمثل مقارنة النموذج البدني بين لاعبي محور الدفاع والمناصب الأخرى في الليغ 2و1

من خلال الشكل البياني رقم (4-1) فإن لاعبي وسط الدفاع يمتلكون أفضلية في القوة والارتقاء مقارنة بباقي مراكز اللعب الأخرى، في حين تمتلك هذه الأخيرة الأفضلية في السرعة، التسارع، الرشاقة، التوازن والتحمل، بينما لا توجد بينهم فروق في سرعة رد الفعل.




الشكل البياني رقم (4-2) يمثل مصفوفة تقييم أداء نموذج KNN

من خلال الشكل البياني رقم (4-2) يتبين لنا أن نموذج KNN أصاب في 55 لاعب مدافع محوري 281 لاعب من المراكز الأخرى، بينما أخطأ في 22 لاعب مدافع محوري 18 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعبي وسط الدفاع قدر بـ 71.43%، في المقابل نسبة صحة تصنيفه للاعبي المناصب الأخرى بلغت 93.98%.



الشكل البياني رقم (3-4) يمثل مصفوفة تقييم أداء نموذج SVM

من خلال الشكل البياني رقم (3-4) يتبين لنا أن نموذج SVM أصاب في 51 لاعب مدافع محوري 284 لاعب من المراكز الأخرى، بينما أخطأ في 26 لاعب مدافع محوري 15 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعبي وسط الدفاع قدر بـ 66.23%، في المقابل نسبة صحة تصنيفه للاعبي المناصب الأخرى بلغت 94.98%.



الشكل البياني رقم (4-4) يمثل مصفوفة تقييم أداء نموذج Random Forest

من خلال الشكل البياني رقم (4-4) يتبين لنا أن نموذج Random Forest أصاب في 61 لاعب مدافع محوري 270 لاعب من المراكز الأخرى، بينما أخطأ في 23 لاعب مدافع محوري و 22 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعبين وسط الدفاع قدر بـ 72.62%، في المقابل نسبة تصنيفه للاعبين المناصب الأخرى بلغت 92.46%.

وعليه جاءت نتائج النماذج الثلاث كما يلي:

النموذج	دقة النموذج
خوارزميات أقرب الجيران (KNeighborsClassifier (KNN)	0.8936
آلة المتجه الداعم (Support Vector Machine (SVM)	0.8910
الغابة العشوائية (Random Forest)	0.8803

الجدول رقم (4-4) يبين نسب دقة نماذج تعلم الآلة

من خلال الجدول رقم (04) يتبين دقة كل من النماذج الثلاث لتعلم الآلة KNN، SVM و Random Forest على التوالي 89.36%، 89.10%، 88.03% في التعرف على لاعبي وسط الدفاع مقابل المناصب الأخرى.

1-2- عرض وتحليل نتائج الفرضية الثانية:

يستطيع التعلم الآلي (Machine learning) التعرف على لاعبي وسط الميدان في البطولة الفرنسية المحترفة ليغ 1 و 2 من خلال عناصر اللياقة البدنية ":

جدول رقم (03) خصائص الطول والوزن لدى أفراد عينة البحث.

الوزن	الطول	منصب اللعب
6.36±71.19	5.90±178.57	وسط الميدان
7.02±74.58	6.70±181.56	المناصب الأخرى

جدول رقم (4-5) يبين فروقات الطول والوزن بين لاعبي وسط الميدان والمناصب الأخرى


حسب الجدول رقم (4-5) فإن المتوسط الحسابي لطول ووزن لاعبي وسط الميدان في البطولة الفرنسية بقسميها الأول والثاني ليغ 1 وليغ 2 بلغ (178.57) و (71.19) بانحراف معياري (5.90) و (6.36)، في المقابل بلغ طول ووزن لاعبي المناصب الأخرى (181.56) و (74.58) بانحراف معياري (6.70) و (7.02).

التسارع	السرعة	الرشاقة	سرعة رد الفعل	التوازن	الارتقاء	التحمل	القوة	
66.66	65.09	70.58	65.02	71.65	61.50	67.43	61.90	لاعبو وسط الميدان
±	±	±	±	±	±	±	±	
10.19	10.09	10.26	8.75	10.76	12.66	14.21	13.22	
68.53	68.98	64.95	62.18	65.16	68.12	66.19	67.48	لاعبو المناصب الأخرى
±	±	±	±	±	±	±	±	
13.50	13.32	13.50	9.09	13.54	12.30	11.69	13.19	

جدول رقم (4-6) يبين لفروقات في عناصر اللياقة البدنية بين لاعبي وسط الميدان والمناصب الأخرى


حسب الجدول رقم (4-6) بالنسبة لعناصر اللياقة البدنية، فإن متوسط تسارع لاعبي وسط الميدان في البطولة الفرنسية ليغ 1 وليغ 2 فقد بلغ 66.66 بانحراف معياري 10.19، مقابل 68.53 لباقي المناصب الأخرى بانحراف معياري 13.50 . وبلغ متوسط سرعة لاعبي وسط الميدان 65.09 بانحراف معياري 10.09 مقابل

متوسط حسابي 68.98 لباقي المناصب الأخرى بانحراف معياري 13.32 . أما متوسط رشاقة لاعبي وسط الميدان 70.58 بانحراف معياري 10.26 مقابل متوسط 64.95 وانحراف معياري 13.50 لباقي المناصب. في حين بلغ متوسط سرعة رد فعل لاعبي وسط الميدان 65.02 بانحراف معياري 8.75 قابله متوسط 62.18 وانحراف معياري 9.09 للمناصب الأخرى. كما بلغ متوسط التوازن لدى لاعبي وسط الميدان 71.65 بانحراف معياري 10.76، في المقابل بلغ المتوسط الحسابي والانحراف المعياري لدى باقي المناصب 65.16 و 13.54 على التوالي. وقدر متوسط ارتقاء لاعبي وسط الميدان 61.50 بانحراف معياري 12.66 مقابل 68.12 و 12.30 كمتوسط حسابي وانحراف معياري على التوالي لباقي المناصب الأخرى. كما قدر متوسط تحمل لاعبي وسط الميدان 67.43 بانحراف معياري 14.21، قابله متوسط حسابي 66.19 وانحراف معياري 11.69 للمناصب الأخرى. أما عنصر القوة فقد بلغ متوسطه 61.90 وانحرافه المعياري 13.22 لدى لاعبي وسط الميدان مقابل متوسط حسابي وانحراف معياري قدرا بـ 67.48 و 13.19 للمناصب الأخرى.




الشكل رقم (4-5): يمثل مقارنة النموذج البدني بين لاعبي وسط الميدان والمناصب الأخرى في الليغ 201

من خلال الشكل البياني رقم (4-5) فإن لاعبي وسط الميدان يمتلكون أفضلية في الرشاقة، سرعة رد الفعل، التوازن والتحمل مقارنة بباقي مراكز اللعب الأخرى، في حين تمتلك هذه الأخيرة الأفضلية في التسارع، السرعة، القوة والارتقاء.




الشكل البياني رقم (4-6) يمثل مصفوفة تقييم أداء نموذج KNN

من خلال الشكل البياني رقم (4-6) يتبين لنا أن نموذج KNN أصاب في 69 لاعب وسط ميدان و 201 لاعب من المراكز الأخرى، بينما أخطأ في 36 لاعب وسط ميدان و 70 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعبي وسط الميدان قدر بـ 65.71%، في المقابل نسبة صحة تصنيفه للاعبي المناصب الأخرى بلغت 74.17%.



الشكل البياني رقم (7-4) يمثل مصنوفة تقييم أداء نموذج SVM

من خلال الشكل البياني رقم (7-4) يتبين لنا أن نموذج SVM أصاب في 94 لاعب وسط ميدان و196 لاعب من المراكز الأخرى، بينما أخطأ في 24 لاعب وسط ميدان و62 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعبين وسط الميدان قدر بـ 79.66%، في المقابل نسبة صحة تصنيفه للاعبين المناصب الأخرى بلغت 75.97% .



الشكل البياني رقم (4-8) يمثل مصفوفة تقييم أداء نموذج Random Forest

من خلال الشكل البياني رقم (4-8) يتبين لنا أن نموذج Random Forest أصاب في 73 لاعب وسط ميدان 222 لاعب من المراكز الأخرى، بينما أخطأ في 45 لاعب وسط ميدان و36 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعب وسط الميدان قدر بـ 61.86%، في المقابل نسبة صحة تصنيفه للاعب المناصب الأخرى بلغت 86.05%.

وعليه جاءت نتائج النماذج الثلاث كما يلي:

النموذج	دقة النموذج
KNeighborsClassifier (KNN) خوارزميات أقرب الجيران	0.7181
Support Vector Machine (SVM) آلة المتجه الداعم	0.7713
(Random Forest) الغابة العشوائية	0.7846

الجدول رقم (4-7) يبين نسب دقة نماذج تعلم الآلة

من خلال الجدول رقم (4-7) يتبين دقة كل من النماذج الثلاث لتعلم الآلة KNN، SVM و Random Forest على التوالي 71.81 %، 77.13 %، 78.46 % في التعرف على لاعبي وسط الميدان مقابل المناصب الأخرى.

1-3- عرض وتحليل نتائج الفرضية الثالثة:

يستطيع التعلم الآلي (Machine learning) التعرف على لاعبي الأروقة في البطولة الفرنسية المحترفة ليغ 1 و 2 من خلال عناصر اللياقة البدنية ":

الوزن	الطول	منصب اللعب
6.12±70.38	5.24±176.78	لاعبو الأروقة
6.37±74.80	5.75±182.21	المناصب الأخرى


جدول رقم (4-8) يبين فروقات الطول والوزن بين لاعبي الأروقة والمناصب الأخرى

حسب الجدول رقم (03) فإن المتوسط الحسابي لطول ووزن لاعبي الأروقة في البطولة الفرنسية بقسميها الأول والثاني ليغ 1 وليغ 2 بلغ (176.78) و (70.38) بانحراف معياري (5.24) و (5.75)، في المقابل بلغ طول ووزن لاعبي المناصب الأخرى (182.21) و (74.80) بانحراف معياري (6.12) و (6.37).

	التسارع	السرعة	الرشاقة	سرعة رد الفعل	التوازن	الارتقاء	التحمل	القوة
لاعبو الأروقة	76.35	75.81	73.00	61.67	73.97	63.92	68.74	59.94
	±	±	±	±	±	±	±	±
	7.85	7.82	9.37	8.92	8.95	12.98	12.01	11.53
لاعبو المناصب الأخرى	64.46	64.42	64.11	63.66	64.39	66.91	65.68	68.12
	±	±	±	±	±	±	±	±
	12.52	12.58	13.18	9.08	13.49	12.60	12.66	13.45


جدول رقم (4-9) يبين الفروقات في عناصر اللياقة البدنية بين لاعبي الأروقة والمناصب الأخرى

حسب الجدول رقم (4-9) بالنسبة لعناصر اللياقة البدنية، فإن متوسط تسارع لاعبي الأروقة البطولة الفرنسية ليغ 1 و ليغ 2 فقد بلغ 76.35 بانحراف معياري 7.85، مقابل 64.46 لباقي المناصب الأخرى بانحراف معياري 12.52 . وبلغ متوسط سرعة لاعبي الأروقة 75.81 بانحراف معياري 7.82 مقابل متوسط حسابي 64.42 لباقي المناصب الأخرى بانحراف معياري 12.58 . أما متوسط رشاقة لاعبي الأروقة 73.00 بانحراف معياري 9.37 مقابل متوسط 64.11 وانحراف معياري 13.18 لباقي المناصب . في حين بلغ متوسط سرعة رد فعل لاعبي الأروقة 61.67 بانحراف معياري 8.92 قابله متوسط 63.66 وانحراف معياري 9.08 للمناصب الأخرى. كما بلغ متوسط التوازن لدى لاعبي الأروقة 73.97 بانحراف معياري 8.95، في المقابل بلغ المتوسط الحسابي والانحراف المعياري لدى باقي المناصب 64.39 و 13.49 على التوالي. وقدر متوسط ارتقاء لاعبي وسط الدفاع 63.92 بانحراف معياري 12.98 مقابل 66.91 و 12.60 كمتوسط حسابي وانحراف معياري على التوالي لباقي المناصب الأخرى. كما قدر متوسط تحمل لاعبي الأروقة 68.74 بانحراف معياري 12.01، قابله متوسط حسابي 65.68 وانحراف معياري 12.66 للمناصب الأخرى. أما عنصر القوة فقد بلغ متوسطه 59.94 وانحرافه المعياري 11.53 لدى لاعبي الأروقة مقابل متوسط حسابي وانحراف معياري قدرا ب 68.12 و 13.45 للمناصب الأخرى.




الشكل رقم (4-9): يمثل مقارنة النموذج البدني بين لاعبي الأروقة والمناصب الأخرى في الـ 20

من خلال الشكل البياني رقم (4-9) فإن لاعبي الأروقة يمتلكون أفضلية في التسارع، السرعة، الرشاقة، التوازن والتحمل مقارنة بباقي مراكز اللعب الأخرى، في حين تمتلك هذه الأخيرة الأفضلية في سرعة رد الفعل، القوة والارتقاء.




الشكل البياني رقم (4-10) يمثل مصفوفة تقييم أداء نموذج KNN

من خلال الشكل البياني رقم (4-10) يتبين لنا أن نموذج KNN أصاب في 105 لاعب رواق 159 لاعب من المراكز الأخرى، بينما أخطأ في 17 لاعب رواق و 95 لاعب من المراكز الأخرى، أي أن نسبة صحته تصنيفه للاعب الأروقة قدر بـ 86.06%، في المقابل نسبة صحته تصنيفه للاعب المراكز الأخرى بلغت 62.60% .



الشكل البياني رقم (4-11) يمثل مصفوفة تقييم أداء نموذج SVM

من خلال الشكل البياني رقم (4-11) يتبين لنا أن نموذج SVM أصاب في 96 لاعب رواق و180 لاعب من المراكز الأخرى، بينما أخطأ في 14 لاعب رواق و86 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعب الأروقة قدر بـ 87.27%، في المقابل نسبة صحة تصنيفه للاعب المراكز الأخرى بلغت 67.67% .



الشكل البياني رقم (4-12) يمثل مصفوفة تقييم أداء نموذج Random Forest

من خلال الشكل البياني رقم (4-12) يتبين لنا أن نموذج Random Forest أصاب في 78 لاعب رواق و 203 لاعب من المراكز الأخرى، بينما أخطأ في 32 لاعب رواق و 63 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعبين الأروقة قدر بـ 70.91%، في المقابل نسبة صحة تصنيفه للاعبين المناصب الأخرى بلغت 76.31%.

وعليه جاءت نتائج النماذج الثلاث كما يلي:

النموذج	دقة النموذج
KNeighborsClassifier (KNN) خوارزميات أقرب الجيران	0.7021
Support Vector Machine (SVM) آلة المتجه الداعم	0.7340
(Random Forest) الغابة العشوائية	0.7473

جدول رقم (4-10) يبين نسب دقة نماذج تعلم الآلة

من خلال الجدول رقم (4-10) يتبين دقة كل من النماذج الثلاث لتعلم الآلة KNN، SVM و Random Forest على التوالي 70.21 %، 73.40 %، 74.73 % في التعرف على لاعبي الأروقة مقابل المناصب الأخرى.

1-4- عرض وتحليل نتائج الفرضية الرابعة:

يستطيع التعلم الآلي (Machine learning) التعرف على لاعبي قلب الهجوم في البطولة الفرنسية المحترفة ليغ 1 و 2 من خلال عناصر اللياقة البدنية ":

الوزن	الطول	منصب اللعب
6.36±75.81	5.30±182.61	قلب الهجوم
7.02±73.04	6.77±180.21	المناصب الأخرى


جدول رقم (4-11) يبين فروقات الطول والوزن بين لاعبي قلب الهجوم والمناصب الأخرى

حسب الجدول رقم (4-11) فإن المتوسط الحسابي لطول ووزن لاعبي قلب الهجوم في البطولة الفرنسية بقسميها الأول والثاني ليغ 1 وليغ 2 بلغ (182.61) و (75.81) بانحراف معياري (5.30) و (6.36)، في المقابل بلغ طول ووزن لاعبي المناصب الأخرى (180.21) و (73.04) بانحراف معياري (6.77) و (7.02).

	التسارع	السرعة	الرشاقة	سرعة رد الفعل	التوازن	الارتقاء	التحمل	القوة
لاعبو قلب الهجوم	71.18 ± 11.46	71.50 ± 12.20	67.00 ± 9.93	62.92 ± 9.52	65.17 ± 10.62	70.30 ± 10.79	64.02 ± 11.47	69.04 ± 12.86
لاعبو المناصب الأخرى	67.29 ± 12.70	66.99 ± 12.45	66.66 ± 13.36	63.10 ± 8.99	67.61 ± 13.50	65.16 ± 12.99	67.10 ± 12.70	65.04 ± 13.47


جدول رقم (4-12) يبين الفروقات في عناصر اللياقة البدنية بين لاعبي قلب الهجوم والمناصب الأخرى

حسب الجدول رقم (4-12) بالنسبة لعناصر اللياقة البدنية، فإن متوسط تسارع لاعبي قلب الهجوم البطولة الفرنسية ليغ 1 وليغ 2 فقد بلغ 71,18 بانحراف معياري 11,46، مقابل 67,29 لباقي المناصب الأخرى بانحراف معياري 12,70 . وبلغ متوسط سرعة لاعبي قلب الهجوم 71,50 بانحراف معياري 12,20 مقابل متوسط حسابي 66,99 لباقي المناصب الأخرى بانحراف معياري 12,45 . أما متوسط رشاقة لاعبي قلب الهجوم 67,00 بانحراف معياري 9,93 مقابل متوسط 66,66 وانحراف معياري 13,36 لباقي المناصب. في حين بلغ متوسط سرعة رد فعل لاعبي قلب الهجوم 62,92 بانحراف معياري 9,52 قابله متوسط 63,10 وانحراف معياري 8,99 للمناصب الأخرى. كما بلغ متوسط التوازن لدى لاعبي قلب الهجوم 65,17 بانحراف معياري 10,62، في المقابل بلغ المتوسط الحسابي والانحراف المعياري لدى باقي المناصب 67,61 و 13,50 على التوالي. وقدر متوسط ارتقاء لاعبي قلب الهجوم 70,30 بانحراف معياري 10,79 مقابل 65,16 و 12,99 كمتوسط حسابي وانحراف معياري على التوالي لباقي المناصب الأخرى. كما قدر متوسط تحمل لاعبي قلب الهجوم 64,02 بانحراف معياري 11,47، قابله متوسط حسابي 67,10 وانحراف معياري 12,70 للمناصب الأخرى. أما عنصر القوة فقد بلغ متوسطه 69,04 وانحرافه المعياري 12,86 لدى لاعبي قلب الهجوم مقابل متوسط حسابي وانحراف معياري قدرا ب 65,04 و 13,47 للمناصب الأخرى.




الشكل رقم (4-13): يمثل مقارنة النموذج البدني بين لاعبي قلب الهجوم والمناصب الأخرى في الليغ 201

من خلال الشكل البياني رقم (4-13) فإن لاعبي قلب الهجوم يمتلكون أفضلية في التسارع، السرعة، القوة والارتفاع مقارنة بباقي مراكز اللعب الأخرى، في حين تمتلك هذه الأخيرة الأفضلية في التوازن والتحمل، بينما لا توجد بينهم فروق في الرشاقة وسرعة رد الفعل.




الشكل البياني رقم (14-4) يمثل مصفوفة تقييم أداء نموذج KNN

من خلال الشكل البياني رقم (14-4) يتبين لنا أن نموذج KNN أصاب في 55 لاعب قلب هجوم و201 لاعب من المراكز الأخرى، بينما أخطأ في 17 لاعب قلب هجوم و103 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعبين قلب الهجوم قدر بـ 76.39%، في المقابل نسبة صحة تصنيفه للاعبين المناصب الأخرى بلغت 66.19% .



الشكل البياني رقم (4-15) يمثل مصفوفة تقييم أداء نموذج SVM

من خلال الشكل البياني رقم (4-15) يتبين لنا أن نموذج SVM أصاب في 46 لاعب قلب هجوم و229 لاعب من المراكز الأخرى، بينما أخطأ في 18 لاعب قلب هجوم و83 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعبين قلب الهجوم قدر بـ 71.87%، في المقابل نسبة صحة تصنيفه للاعبين المناصب الأخرى بلغت 73.40%.



الشكل البياني رقم (4-16) يمثل مصفوفة تقييم أداء نموذج Random Forest

من خلال الشكل البياني رقم (4-16) يتبين لنا أن نموذج Random Forest أصاب في 32 لاعب قلب هجوم و259 لاعب من المراكز الأخرى، بينما أخطأ في 32 لاعب قلب هجوم و53 لاعب من المراكز الأخرى، أي أن نسبة صحة تصنيفه للاعبين قلب الهجوم قدر بـ 50.00%، في المقابل نسبة صحة تصنيفه للاعبين المناصب الأخرى بلغت 83.01%.

وعليه جاءت نتائج النماذج الثلاث كما يلي:

النموذج	دقة النموذج
KNeighborsClassifier (KNN) خوارزميات أقرب الجيران	0.6808
Support Vector Machine (SVM) آلة المتجه الداعم	0.7314
(Random Forest) الغابة العشوائية	0.7739

الجدول رقم (4-13) يبين نسب دقة نماذج تعلم الآلة

من خلال الجدول رقم (4-13) يتبين دقة كل من النماذج الثلاث لتعلم الآلة KNN، SVM و Random Forest على التوالي 68.08 %، 73.14 %، 77.39 % في التعرف على لاعبي قلب الهجوم مقابل المناصب الأخرى.

2- مناقشة النتائج:

2-1- مناقشة الفرضية الأولى: بالنسبة للفرضية الأولى ومن خلال الجدول رقم (4-3) والشكل رقم (4-1) الذي يبين تميز لاعبي وسط الدفاع بالقوة والارتقاء وذلك ما يتفق مع ذكره (Vermeulen، 2004) في شقه الأول، على أن لاعبي وسط الدفاع يعتمدون بشكل أكبر على عنصر القوة للتفوق في الالتحامات العلوية أو الأرضية من باقي المراكز، ويختلف مع شقه الثاني حيث يذكر اعتماد لاعبي وسط الدفاع على عنصر التوازن بينما الجدول والشكل يبينان تفوق باقي المراكز على مركز لاعب وسط الدفاع في عنصر التوازن. كما يتفق مع دراسة (عراجي، 2012) التي وصفت لاعبي وسط الدفاع بالقوة العضلية وقوة الارتقاء وذلك ظهر جليا من خلال الجدول والشكل. بينما اختلفت دراسة (أركان حسن جبار وآخرون، 2018) حيث ذكرت تميز خط الدفاع بالسرعة عن باقي المراكز، ويمكن تفسير ذلك لكون الدراسة قسمت مراكز اللعب إلى ثلاثة بدل أربعة، وجمعت لاعبي وسط الدفاع مع اللاعبين المدافعين على الأروقة الذين يتميزون فعليا بسرعة كبيرة. في حين الجدول رقم (4-4) يبين فعالية نماذج تعلم الآلة خوارزمية أقرب الجيران KNN، آلة الدعم الموجه SVM والغابة العشوائية Random Forest في تمييز لاعبي مركز وسط الدفاع في البطولة الفرنسية ليغ 1 و 2 عن باقي المراكز في نفس البطولة، أو باقي المراكز في البطولة الفرنسية ليغ 1 و 2 عن لاعبي وسط الدفاع في نفس البطولة وحصولها على نتائج جيدة جدا مع تفوق طفيف لخوارزمية KNN. لكن من خلال الأشكال (4-2)، (4-3) و (4-4) يتبين لنا مدى فعالية النماذج على حدى، أي فعالية تصنيف لاعبي وسط الدفاع البطولة الفرنسية لوحدها، وتصنيف باقي المراكز نفس البطولة لوحدها. وكانت فعالية النماذج الثلاثة مقبولة مع تفوق طفيف لخوارزمية Random Forest على خوارزمية KNN، أما خوارزمية SVM فقد كانت أقلهم فعالية في تصنيف لاعبو وسط الدفاع. في حين كانت فعالية النماذج الخوارزميات الثلاثة ممتازة في تصنيف لاعبو المراكز المتبقية بتفوق طفيف لخوارزمية SVM، وقد وافقت هذه النتائج دراسة عشيظ هني محمد الأمين وآخرون (2024) التي

أظهرت الخوارزميات الثلاثة في التعرف على لاعبي وسط الدفاع في البطولة الألمانية البوندسليغا 2011 من خلال عناصر اللياقة البدنية، وبذلك ثبتت صحة الفرضية التي تنص على استطاعة تعلم الآلة التعرف على لاعبي وسط الدفاع في البطولة الفرنسية ليغ 2011 من خلال عناصر اللياقة البدنية، وهذا ما يتفق أيضا مع دراسة Salim, A., Kemmotsu, T., & Chen, L. (2021) تحت عنوان: "Optimal Playing Position Prediction in Football" التي خلصت إلى أن تقنيات تعلم الآلة يمكن أن تسهم في تحسين عملية الانتقاء والتوجيه الرياضي في كرة القدم، وأوصى الباحثون بدمج هذه النماذج في أنظمة دعم القرار لدى المدربين والأكاديميات لتسهيل توجيه اللاعبين وفقاً لقدراتهم وخصائصهم الفردية.

2-2- مناقشة الفرضية الثانية: بالنسبة للفرضية الثانية ومن خلال الجدول رقم (4-6) والشكل رقم (4-5) الذي يبين تميز لاعبي وسط الميدان بالرشاقة، سرعة رد الفعل، التوازن والتحمل وذلك ما يتفق مع ذكره (Lago-Peñas وآخرون، 2011) على أن اللعب في وسط الميدان يتطلب قدرات بدنية عالية خاصة في جانب التحمل الهوائي، كما يحتاج المنصب إلى رشاقة عالية من تغيير الاتجاه في كل مرة، بالإضافة إلى سرعة رد الفعل للتغلب على اللعب تحت الضغط، كما بينت دراسة (عراجي، 2012) أهمية امتلاك لاعبي وسط الميدان للسعة والقدرة الهوائيتين، في حين ذكرت دراسة (بلغول، 2011) أن لاعبي وسط الميدان هم من يقطعون أكبر مسافة خلال المباريات بالمقارنة مع باقي المناصب، وذلك أيضا ما ذكرته دراسة (أركان حسن جبار وآخرون، 2018) حيث يتميز خط الوسط بصفة التحمل عن باقي المراكز.

الجدول رقم (4-7) يبين فعالية نماذج تعلم الآلة خوارزمية أقرب الجيران KNN، آلة الدعم الموجه SVM والغابة العشوائية Random Forest في تمييز لاعبي مركز وسط الميدان في البطولة الفرنسية ليغ 2011 عن باقي المراكز في نفس البطولة، أو باقي المراكز في البطولة الفرنسية ليغ 2011 عن لاعبي وسط الدفاع في نفس البطولة وحصولها على نتائج جد مقبولة مع تفوق طفيف لخوارزمية Random Forest. أما من خلال الأشكال (4-6)، (4-7) و (4-8) يتبين لنا مدى فعالية النماذج على حدى، أي فعالية تصنيف لاعبي وسط الميدان في البطولة الفرنسية لوحدها، وتصنيف باقي المراكز لنفس البطولة لوحدها. وكانت فعالية خوارزمية SVM جد مقبولة بينما كانت خوارزمية Random Forest وخوارزمية KNN أقل فعالية في تصنيف لاعبو وسط الميدان. في حين كانت كانت فعالية خوارزمية Random Forest جيدة جدا في تصنيف لاعبو المراكز المتبقية مقارنة بالنموذجين الآخرين، وقد وافقت هذه النتائج دراسة Wiradinata, T. وآخرون (2021) والتي أظهرت قدرة الخوارزميات الثلاثة في التنبؤ بمراكز اللاعبين بدقة معتبرة، وبذلك ثبتت صحة الفرضية التي تنص على استطاعة تعلم الآلة التعرف على لاعبي وسط الميدان في البطولة الفرنسية ليغ 2011 من خلال عناصر اللياقة البدنية، وهذا ما يتفق أيضا مع دراسة Salim, A., Kemmotsu, T., & Chen, L. (2021) تحت عنوان: "Optimal Playing Position Prediction in Football" التي خلصت إلى أن تقنيات

تعلم الآلة يمكن أن تُسهم في تحسين عملية الانتقاء والتوجيه الرياضي في كرة القدم، وأوصى الباحثون بدمج هذه النماذج في أنظمة دعم القرار لدى المدربين والأكاديميات لتسهيل توجيه اللاعبين وفقاً لقدراتهم وخصائصهم الفردية.

2-3- مناقشة الفرضية الثالثة: بالنسبة للفرضية الثالثة ومن خلال الجدول رقم (4-9) والشكل رقم (4-9) الذي يبين تميز لاعبي الأروقة بالتسارع، السرعة، الرشاقة، التوازن والتحمل. وقد أشارت دراسة (Di Salvo, et al., 2010) إلى أن لاعبي الأجنحة يقومون بعدد مرتفع من الجهود اللاهوائية المتكررة مقارنة ببقية المراكز، وذلك ما يجعل مركز لاعب رواق أكثر المراكز تطلبا للسرعة القصوى، الرشاقة، والقدرة على تغيير الاتجاهات بشكل متكرر وسريع، كما يحتاج المنصب إلى تحمل تكرار السرعة RSA. الجدول رقم (4-10) يبين فعالية نماذج تعلم الآلة خوارزمية أقرب الجيران KNN، آلة الدعم الموجه SVM والغابة العشوائية Random Forest في تمييز لاعبي مركز لاعب رواق في البطولة الفرنسية ليغ 1 و2 عن باقي المراكز في نفس البطولة، أو باقي المراكز في البطولة الفرنسية ليغ 1 و2 عن لاعبي الأروقة في نفس البطولة وحصولها على نتائج مقبولة مع تفوق طفيف لخوارزمية Random Forest. أما من خلال الأشكال (4-10)، (4-11) و(4-12) يتبين لنا مدى فعالية النماذج على حدى، أي فعالية تصنيف لاعبي الأروقة في البطولة الفرنسية لوحدها، وتصنيف باقي المراكز لنفس البطولة لوحدها. وكانت فعالية خوارزمية SVM وخوارزمية KNN جيدة جدا بينما كانت خوارزمية Random Forest أقل فعالية في تصنيف لاعبي الأروقة. في حين كانت كانت فعالية خوارزمية Random Forest جد مقبولة في تصنيف لاعبي المراكز المتبقية مقارنة بالنموذجين الآخرين، وقد وافقت هذه النتائج دراسة Wiradinata, T. وآخرون (2021) والتي أظهرت قدرة الخوارزميات الثلاثة في التنبؤ بمراكز اللاعبين بدقة معتبرة، وبذلك ثبتت صحة الفرضية التي تنص على استطاعة تعلم الآلة التعرف على لاعبي الأروقة في البطولة الفرنسية ليغ 1 و2 من خلال عناصر اللياقة البدنية، وهذا ما يتفق أيضا مع دراسة Salim, A., Kemmotsu, T., & Chen, L. (2021) تحت عنوان: "Optimal Playing Position Prediction in Football" التي خلصت إلى أن تقنيات تعلم الآلة يمكن أن تُسهم في تحسين عملية الانتقاء والتوجيه الرياضي في كرة القدم، وأوصى الباحثون بدمج هذه النماذج في أنظمة دعم القرار لدى المدربين والأكاديميات لتسهيل توجيه اللاعبين وفقاً لقدراتهم وخصائصهم الفردية.

2-4- مناقشة الفرضية الرابعة: بالنسبة للفرضية الرابعة ومن خلال الجدول رقم (4-12) والشكل رقم (4-13) الذي يبين تميز لاعبي قلب الهجوم بالسرعة، الارتقاء والقوة، وذلك ما Vermeulen على أن لاعب قلب الهجوم يحتاج إلى سرعة عالية وقوة انفجارية كبيرة تسمح له بكسب الصراعات الأرضية والهوائية، كما أشارت أيضا دراسة (عراجي، 2012) لأهمية امتلاك لاعب قلب الهجوم للقوة العضلية والارتقاء، في حين ذكرت دراسة (بلغول، 2011) أن المهاجمين في البطولتين الإنجليزية والاسبانية يقومون بأكبر عدد من السبرناتات بالمقارنة مع باقي المناصب، وقد أظهرت النتائج دراسة (أركان حسن جبار وآخرون، 2018) أفضلية لاعبي خط الهجوم في صفات الرشاقة، القوة الانفجارية والقوة المميزة بالسرعة.

الجدول رقم (4-13) يبين فعالية نماذج تعلم الآلة خوارزمية أقرب الجيران KNN، آلة الدعم الموجه SVM والغابة العشوائية Random Forest في تمييز لاعبي مركز قلب الهجوم في البطولة الفرنسية ليغ 1 و2 عن باقي المراكز في نفس البطولة، أو باقي المراكز في البطولة الفرنسية ليغ 1 و2 عن لاعبي قلب الهجوم في نفس البطولة وحصولها على نتائج جد مقبولة مع تفوق لخوارزمية Random Forest. أما من خلال الأشكال (4-14)، (4-15) و(4-16) يتبين لنا مدى فعالية النماذج على حدى، أي فعالية تصنيف لاعبي قلب الهجوم في البطولة الفرنسية لوحدها، وتصنيف باقي المراكز لنفس البطولة لوحدها. وكانت فعالية خوارزمية KNN جد مقبولة بينما كانت خوارزمية Random Forest أقل فعالية في تصنيف لاعبو قلب الهجوم. في حين كانت كانت فعالية خوارزمية Random Forest جيدة في تصنيف لاعبو المراكز المتبقية مقارنة بالنموذجين الآخرين، وقد وافقت هذه النتائج دراسة Wiradinata, T. وآخرون (2021) والتي أظهرت قدرة الخوارزميات الثلاثة في التنبؤ بمراكز اللاعبين بدقة معتبرة، وبذلك ثبتت صحة الفرضية التي تنص على استطاعة تعلم الآلة التعرف على لاعبي قلب الهجوم في البطولة الفرنسية ليغ 1 و2 من خلال عناصر اللياقة البدنية، وهذا ما يتفق أيضا مع دراسة Salim, A., Kemmotsu, T., & Chen, L. (2021) تحت عنوان: "Optimal Playing Position Prediction in Football" التي خلصت إلى أن تقنيات تعلم الآلة يمكن أن تُسهم في تحسين عملية الانتقاء والتوجيه الرياضي في كرة القدم، وأوصى الباحثون بدمج هذه النماذج في أنظمة دعم القرار لدى المدربين والأكاديميات لتسهيل توجيه اللاعبين وفقاً لقدراتهم وخصائصهم الفردية.

خلاصة

في هذا الفصل تم عرض نتائج الدراسة الميدانية ومعالجتها إحصائياً من خلال الجداول والأشكال البيانية، ثم مناقشتها في ضوء الفرضيات المطروحة والدراسات السابقة.

أظهرت النتائج المتعلقة بالفرضية الأولى أن لاعبي وسط الدفاع في البطولة الفرنسية (ليغ 1 وليغ 2) يتفوقون في القوة البدنية والارتقاء، بينما كان لاعبو المراكز الأخرى أفضل في السرعة، التسارع، الرشاقة، التوازن والتحمل. وقد أكدت نماذج تعلم الآلة الثلاثة (KNN، SVM، Random Forest) قدرتها على التمييز بين لاعبي هذا المركز وبقية المراكز بدقة معتبرة تجاوزت 88%.

أما الفرضية الثانية الخاصة بلاعبي وسط الميدان فقد أوضحت أنهم يتميزون بقدرات واضحة في الرشاقة، سرعة رد الفعل، التوازن والتحمل، مما يتماشى مع ما ذكرته الأدبيات حول متطلبات هذا المركز من جهد بدني مستمر وتغييرات متكررة للاتجاهات. وقد أثبتت النماذج الإحصائية والذكاء فعاليتها في التعرف على هذا المركز، حيث تراوحت نسب الدقة بين 71% و 78%.

وفيما يخص الفرضية الثالثة، فقد أظهرت النتائج أن لاعبي الأروقة (الأجنحة) يمتلكون أفضلية كبيرة في التسارع، السرعة، الرشاقة، التوازن والتحمل مقارنة ببقية المراكز، وهو ما يتفق مع طبيعة المهام التكتيكية لهذا المركز التي تعتمد على الانطلاقات السريعة والقدرة على التوغل على الأطراف. كما بينت نماذج تعلم الآلة أن دقتها في التنبؤ بهذا المركز جيدة، حيث تراوحت ما بين 70% و 75%.

أما الفرضية الرابعة والمتعلقة بلاعبي قلب الهجوم، فقد بينت النتائج تفوقهم في التسارع، السرعة، القوة والارتقاء، مقابل أفضلية لبقية المراكز في التوازن والتحمل، بينما لم تُسجل فروق جوهرية في الرشاقة وسرعة رد الفعل. وحقت نماذج التعلم الآلي دقة مقبولة في التعرف على هذا المركز تراوحت بين 68% و 77%.

بوجه عام، فقد توافقت هذه النتائج مع ما ورد في الجانب النظري والدراسات السابقة، سواء العربية منها أو الأجنبية، حيث أكدت جميعها خصوصية كل مركز لعب من حيث المتطلبات البدنية. كما أثبتت هذه الدراسة أن استخدام تقنيات تعلم الآلة يمثل إضافة نوعية لعملية الانتقال والتوجيه الرياضي، إذ أظهرت الخوارزميات الثلاث قدرة معتبرة على تصنيف اللاعبين حسب مراكزهم بدقة مرتفعة، مما يعزز إمكانية دمجها في أنظمة دعم القرار الفني والتكتيكي لدى المدربين.

وعليه، يمكن القول إن الفرضيات التي صيغت في البداية قد تم تأكيدها بدرجات متفاوتة، وأن الذكاء الاصطناعي قادر على المساهمة الفعالة في التوجيه الدقيق للاعبين نحو المراكز التي تتلاءم مع صفاتهم البدنية. وهو ما يفتح آفاقاً عملية لتطوير تطبيقات ذكية يمكن أن تدعم عملية الانتقال الرياضي وتزيد من موضوعيتها وفعاليتها مقارنة بالطرق التقليدية المعتمدة على الخبرة الشخصية فقط.

الختامة

خاتمة:

خلصت هذه الأطروحة إلى أن مسألة الانتقاء والتوجيه الرياضي للاعبي كرة القدم لم تعد مجرد عملية تقليدية قائمة على الخبرة الانطباعية والمدرجات الذاتية للمدربين، بل أضحت في ضوء التطور العلمي والتكنولوجي الحديث عملية علمية دقيقة تستوجب اعتماد أدوات كمية وتقنيات ذكية قادرة على معالجة البيانات الضخمة وتقديم مخرجات دقيقة وموضوعية. لقد أظهرت المراجعة النظرية والنتائج التطبيقية أن توجيه اللاعبين إلى المراكز الملائمة لخصائصهم البدنية والمهارية يمثل أحد أهم مفاتيح النجاح في كرة القدم الحديثة، إذ ينعكس بشكل مباشر على الأداء الفردي والجماعي للفريق.

وقد بينت الدراسة أن تقنيات الذكاء الاصطناعي، لا سيما خوارزميات تعلم الآلة مثل K-Nearest Neighbors (KNN)، وSupport Vector Machine (SVM)، وRandom Forest، تُوفر إمكانيات معتبرة في التنبؤ بمراكز اللاعبين استنادًا إلى بياناتهم البدنية. إذ حققت هذه النماذج نسب دقة مرتفعة في التعرف على خصائص اللاعبين وتمييزهم حسب المراكز (وسط دفاع، وسط ميدان، أروقة، قلب هجوم)، وهو ما يؤكد صلاحيتها كأدوات داعمة لاتخاذ القرار الفني والتكتيكي داخل الأندية ومراكز التكوين.

كما أبرزت النتائج أهمية المؤشرات البدنية - مثل السرعة، القوة، الرشاقة، والتحمل - باعتبارها محددات رئيسية في عملية التوجيه، مع ضرورة دمجها في نظم معلوماتية ذكية تسمح ببناء قاعدة بيانات موحدة وشاملة عن اللاعبين. هذا الدمج بين المعرفة العلمية والتطبيقات التقنية يُشكل خطوة نوعية نحو تحديث طرق الانتقاء الرياضي في السياق المحلي، خاصة في ظل النقائص التي يعاني منها واقع كرة القدم الجزائرية من حيث غياب المعايير الموضوعية والاعتماد المفرط على الخبرة الشخصية.

وعليه، تُسهم هذه الأطروحة في تقديم إضافة علمية وميدانية مزدوجة: فمن الناحية النظرية، أرست إطارًا مفاهيميًا يوضح العلاقة بين الصفات البدنية والتوجيه نحو المراكز، ومن الناحية التطبيقية، قدمت نموذجًا ذكيًا قائمًا على خوارزميات تعلم الآلة يمكن أن يُستخدم كأداة لتوجيه اللاعبين بدقة وموضوعية.

وفي ضوء ما سبق، توصي هذه الدراسة بضرورة:

✓ إدماج أنظمة الذكاء الاصطناعي ضمن برامج التكوين والتدريب على مستوى الأندية والأكاديميات.

✓ إنشاء قواعد بيانات وطنية دقيقة تشمل الخصائص البدنية، المهارية، والنفسية للاعبين.

- ✓ الاستمرار في تطوير تطبيقات ذكية متخصصة تراعي الفروق الفردية وتتكيف مع المستويات العمرية المختلفة.
- ✓ توسيع نطاق الدراسات المستقبلية لتشمل المتغيرات المهارية، النفسية والفسولوجية، بما يعزز من شمولية النماذج التنبؤية.

إن مستقبل كرة القدم الحديثة بات مرهوناً بمدى قدرة الفاعلين على تسخير التكنولوجيا والذكاء الاصطناعي في خدمة الانتقاء والتوجيه الرياضي، بما يضمن حسن استثمار المواهب الكروية وتحقيق أقصى درجات الفعالية في الأداء.

المراجع العربية

1. Blay Whitbay (2008). *النكاء الاصطناعي*. القاهرة: قسم الترجمة بدار الفاروق.
2. O Papini ، P Marquis و H Prade (2014). *Panorama de l'intelligence artificielle. Ses bases méthodologiques, ses développements*. Toulouse: Editions Cépaduès.
3. ابراهيم الشنقيطي. (2020). بحث عن: النكاء الاصطناعي. مكتبة نور.
4. أشرف محمود. (2016). *الاعداد البدني والاحماء في التدريب الرياضي*. عمان: دار من المحيط إلى الخليج للنشر والتوزيع.
5. جميل صليبا. (1982). *المعجم الفلسفي*. لبنان: دار الكتاب اللبناني.
6. رجاء وحيد دويدري. (2000). *البحث العلمي: أساسياته النظرية وممارسته العلمية*. دمشق: دار الفكر.
7. زكريا أحمد الشربيني، يسرية أنور صادق، محمد سالم محمد القرني، و السيد خالد مطحنة. (2013). *مناهج البحث في العلوم التربوية والنفسية والاجتماعية*. مكتبة الشقري.
8. عادل عبد النور. (2005). *مدخل إلى علم النكاء الاصطناعي*. السعودية: مدينة الملك عبدالعزيز للعلوم والتقنية KACST.
9. عبد الحميد محمود. (2002). *الانتقاء الرياضي والتوجيه نحو التخصص*. القاهرة: مكتبة الأنجلو المصرية.
10. عبد الحميد شوقي محمود. (2002). *الانتقاء الرياضي والتوجيه نحو التخصص*. القاهرة: مكتبة الأنجلو المصرية.
11. عبدالمالك فريد كريميش. (2020). *مطبوعة دروس مقياس الانتقاء والتوجيه الرياضي*. المسيلة: جامعة محمد بوضياف.
12. عبدالهادي زين. (2000). *النكاء الاصطناعي والنظم الخبيرة في المكتبات - مدخل تجريبي للنظم الخبيرة في مجال المراجع*. القاهرة: المكتبة الأكاديمية.
13. علي ابراهيم علي عبيدو. (2014). *جودة البحث العلمي*. دار الوفاء.
14. علي بن صالح. (2010). *الانتقاء الرياضي: الأسس النظرية والتطبيقية*. الجزائر: دار الهدى للنشر والتوزيع.
15. علي بن صالح. (2022). *مطبوعة مقياس الانتقاء والتوجيه الرياضي (غير منشورة)*. قسم علوم وتقنيات النشاطات البدنية والرياضية. الجزائر: جامعة الجزائر 3.
16. عمار نويوة، محمد زروال، و مصطفى ولد حمو. (2018). *السرعة في كرة القدم. مجلة علوم وتقنيات النشاطات البدنية والرياضية*، 1(1)، 191-201.
17. محمد بن مكرم ابن منظور. (2003). *لسان العرب*. بيروت: دار إحياء التراث العربي.
18. محمد حسانين علاوي. (1998). *مبادئ علم التدريب الرياضي*. القاهرة: دار الفكر العربي.
19. محمد حسن علاوي، و أسامة كامل راتب. (1999). *البحث العلمي في التربية الرياضية وعلم النفس الرياضي*. القاهرة: دار الفكر العربي.
20. محمد صبحي حسانين. (1995). *الاختبارات والمقاييس في التربية الرياضية والنفسية*. القاهرة: دار الفكر العربي.
21. محمد صبحي حسانين. (1999). *الاختبارات والمقاييس في التربية الرياضية*. القاهرة: دار الفكر العربي.
22. محمد عبد المجيد. (2004). *التوجيه والإرشاد النفسي*. القاهرة: دار المعرفة الجامعية.
23. محمد عبد المجيد. (2004). *التوجيه والإرشاد النفسي*. القاهرة: دار المعرفة الجامعية.
24. محمد فيصل خروبي. (2019). *محاضرات مقياس إختصاص كرة القدم*. الجزائر: معهد التربية البدنية والرياضية جامعة الجزائر 3.
25. محمد لحج. (2020). *مدخل إلى النكاء الاصطناعي وتعلم الآلة*. أكاديمية حاسوب.

26. مزيان بوحاج. (2012). بطارية اختبارات لتقويم بعض القدرات البدنية والمهارية أثناء انتقاء لاعبي كرة القدم صنف الأواسط 17-19 سنة. *طروجة*. زرالدة، الجزائر: جامعة الجزائر 3.
27. مصطفى حسن،. (2001). *القدرات البدنية الأساسية*. القاهرة: دار الفكر العربي.
28. وسيلة سعود. (31 ديسمبر، 2023). الذكاء الاصطناعي وتحديات الممارسة الأخلاقية. *مجلة نماء للاقتصاد والتجارة*، الصفحات 1-13.

المراجع الانجليزية

1. (FIFA), F. I. (2025, 06 فيفري). *Talent development scheme – Technical report*. Retrieved from FIFA Training Centre: <https://www.fifatrainingcentre.com/en/environment/guide/high-performance/find/talent-identification-guide-module-4.php>
2. Abbott, A., & Collins, D. (2002). A Theoretical and Empirical Analysis of a “State of the Art” Talent Identification Model. *High Ability Studies*, 13(2), 157–178.
3. Bangsbo, J., Mohr, M., & Krstrup, P. (2006). Physical and metabolic demands of training and match-play in the elite football player. *Journal of Sports Sciences*, 24(7):665-674.
4. BELLMAN, R. (1978). *An introduction to artificial intelligence: Can computers think?*. Boyd & Fraser Publishing Company.
5. Bishop, D. J., Girard, O., & Villanueva, A. M. (2011). Repeated-Sprint Ability – Part II Recommendations for Training. *Sports Medicine*, 41(9), 741–756.
6. BODEN, M. (1977). *Artificial intelligence and natural man*. New York: Basic Books.
7. Bompa, T. O. (2009). *Talent Identification and Development in Sport*. Toronto: Human Kinetics.
8. Bradley, P. (2023, May 24). *A contextualised physical analysis of the FIFA World Cup Qatar 2022*. Retrieved from FIFA Training Centre: <https://www.fifatrainingcentre.com/en/fwc2022/physical-analysis/background-and-method.php>
9. Bradley, P. S. (2023, Septembre 07). Setting the benchmark: The contextualised physical demands of positional roles in the FIFA World Cup Qatar 2022. *Biology of Sport*, pp. 41(1), 3–15.
10. BROWN, T., MANN, B., RYDER, N., & and All. (2020, 12 06). Language models are few-shot learners. *Advances in neural information processing systems v33*, 33, pp. p. 1877-1901.
11. Carling, C., Reilly, T., & Williams, A. M. (2008). *Performance Assessment for Field Sports (1st ed.)*. London: Routledge.
12. Carling, C., Reilly, T., & Williams, A. M. (2008). *Performance Assessment for Field Sports (1st ed.)*. London: Routledge.
13. CHAMIAK, E., & McDERMOTT, D. V. (1985). *Introduction to artificial intelligence*. Boston: Addison-Wesley.
14. Côté, J., Baker, J., & Abernethy, B. (2007). Practice and play in the development of sport expertise. *Handbook of Sport Psychology*, 3rd ed., pp. 184–202.

15. Côté, J., Lidor, R., & Hackfort, D. (2009). ISSP Position Stand: To Sample or to Specialize? Seven Postulates about Youth Sport Activities that Lead to Continued Participation and Elite Performance. *International Journal of Sport and Exercise Psychology*, 7(1), 7–17.
16. Dellal, A., Chamari, K., Wong, D., Ahmaidi, S., Keller, D., Barros, R., . . . Carling, C. (2011). Comparison of physical and technical performance in European soccer match-play: FA Premier League and La Liga. *European Journal of Sport Science*, 11(1), 51–59.
17. developers, Scikit-learn. (2025). *Scikit-learn: Machine learning in Python*. Retrieved from Scikit-learn.org: <https://scikit-learn.org>
18. Di Salvo, V., Baron, R., Gonzalez-Haro, C., Gormasz, C., Pigozzi, F., & Bachl, N. (2010). Sprinting analysis of elite soccer players during European Champions League and UEFA Cup matches. *Journal of Sports Sciences*, 28(14), 1489–1494.
19. FIFA. (2022, 08 16). *البحث والتطوير / نمط معايير بيانات أنظمة الأداء والتتبع الإلكترونية*. Retrieved from fifa.com: <https://www.fifa.com/ar/technical/football-technology/standards/epts/research-development-epts-standard-data-format>
20. GARDNER, H. (1999). *Intelligence Reframed: Multiple Intelligences for the 21st Century*. New York: Basic Books.
21. GUDMUNDSSON, J., & HORTON, M. (2017, April 11). Spatio-Temporal Analysis of Team Sports. *ACM Computing Surveys (CSUR)*, 50(2), Article 22, 1-34.
22. HINTON, G. E., OSINDERO, S., & TEH, Y. (2006, july 01). A fast learning algorithm for deep belief nets. *Neural Computation*, pp. 1527-1554.
23. Hoare, D. G. (2000). Predicting success in junior elite basketball players—The contribution of anthropometric and physiological attributes. *Journal of Science and Medicine in Sport*, 3(4), 391–405.
24. Hughes, M., & Franks, I. (2005). Analysis of passing sequences, shots and goals in soccer. *Journal of Sports Sciences*, 23(5), 509–514.
25. Katanic, B., Radakovic, R., Djordjevic, S., Govindasamy, K., Geantă, V. A., Bălțean, A. I., & Stankovic, M. (2025). Differences in match running performance of elite male. *Journal of Men's Health*, vol.21(4), 89-94.
26. Kenney, W. L., Wilmore, J., & Costill, D. (2011). *Physiology of Sport and Exercise*. Champaign, Illinois: Human Kinetics.
27. Kunz, P., Engel, F. A., Holmberg, H.-C., & Sperlich, B. (2019). A Meta-Comparison of the Effects of High-Intensity Interval Training to Those of Small-Sided Games and Other Training Protocols on Parameters Related to the Physiology and Performance of Youth Soccer Players. *Sports medicine-open*, Volume 5, article number 7.
28. Lago-Peñas, C., Rey, E., Lago-Ballesteros, J., Casáis, L., & Domínguez, E. (2011). The influence of a congested calendar on physical performance in elite soccer. *Journal of Strength and Conditioning Research*. *Journal of Strength and Conditioning Research*, (8):2111-2117.
29. Lidor, R., & Ziv, G. (2015). On the stability and validity of fitness tests in soccer players. *Journal of Sports Sciences*, 33(12), 1219–1232.

30. LUGER, G. F., & STUBBLEFIELD, W. A. (1993). *Artificial intelligence: Structures and strategies for complex problem solving*. San Fransisco: Benjamin-Cummings.
31. Malina, R. M., Bouchard, C., & Bar-Or, O. (2004). *Growth, maturation, and physical activity (2nd ed.)*. Human Kinetics.
32. MINSKY, M. L. (1969). *Semantic information processing*. The MIT Press.
33. Mujika, I., Halson, S., Burke, L. M., Balagué, G., & Farrow, D. (2017). An Integrated, Multifactorial Approach to Periodization for Optimal Performance in Individual and Team Sport. *An Integrated, Multifactorial Approach to Periodization International Journal of Sports Physiology and Performance*, 13(5), 538–561.
34. NAIK, S. S. (2023, 05 16). *Fifa 23 Players Dataset*. Retrieved from <https://www.kaggle.com/datasets: https://www.kaggle.com/datasets/sanjeetsinghnaik/fifa-23-players-dataset/data>
35. Pitsiladis, Y. P., Tanaka, M., Eynon, N., Bouchard, C., North, K. N., Williams, A. G., . . . Alsayrafi, M. (2016). Athlome Project Consortium: A concerted effort to discover genomic and other "omic" markers of athletic performance. *Physiological Genomics*, 48(3), 183–190. .
36. Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). Improving language understanding by generative pre-training.
37. Reilly, T., & Williams, A. M. (2003). *Science and Soccer (2nd ed.)*. London: Routledge.
38. Reilly, T., Williams, A. M., Nevill, A., & Franks, A. (2000). A multidisciplinary approach to talent identification in soccer. *Journal of Sports Sciences*, 18(9), 695–702.
39. RICH, E., & KNIGHT, K. (1991). *Artificial intelligence*. McGraw-Hill.
40. Rolon-Mérette, D., Church, K., Ross, M., & Rolon-Mérette, T. (2020). Python for research in psychology: Introduction and purpose of the tutorial series. . *The Quantitative Methods for Psychology*, 16(5), S001–S003.
41. Rolon-Mérette, D., Ross, M., Rolon-Mérette, T., & Church, K. (2020). Introduction to Anaconda and Python: Installation and setup. *The Quantitative Methods for Psychology*, 16(5), S3-S11.
42. RUSSELL, S. J., & NORVIG, P. (2021). *Artificial Intelligence - A Modern Approach*. Pearson Education.
43. Sheppard, J. M., & Young, W. B. (2006). Agility literature review: Classifications, training and testing. *Journal of Sports Sciences*, 24(9), 919–932.
44. SILVER, D., HUANG, A., MADDISON, C. J., & and All. (2016, January 28). Mastering the game of Go with deep neural networks and tree search. *nature*, pp. p. 484-489.
45. Sofifa. (2023, 05 16). *Sofifa*. Retrieved from Sofifa.com: <https://sofifa.com/players?showCol%5B0%5D=ae&showCol%5B1%5D=oa&showCol%5B2%5D=pt&showCol%5B3%5D=to&showCol%5B4%5D=ac&showCol%5B5%5D=sp&showCol%5B6%5D=ag&showCol%5B7%5D=ba&showCol%5B8%5D=re&showCol%5B9%5D=ju&showCol%5B10%5D=st&showCol%5B11%5D=sr&r=230034&s>

46. TAN, P.-N., STEINBACH, M., & KUMAR, V. (2014). *Introduction to Data Mining*. London: Pearson.
47. Vaeyens, R., Lenoir, M., Williams, A., & Philippaerts, R. M. (2008). Talent identification and development programmes in sport: Current models and future direction. *Sports Medicine*, 38(9), 703–714.
48. WASILEWSKA, M., KLIKS, A., BOGUCA, H., CICHON, K., RUSECKAS, J., MOLIS, G., . . . Krilavičius, T. (2021). Artificial intelligence for radio communication context-awareness. *IEEE Access*, 144820-144856.
49. Williams, A. G., & Folland, J. P. (2008). Similarity of polygenic profiles limits the potential for elite human physical performance. *The Journal of Physiology*, 586(1), 113–121.

المراجع الفرنسية

1. Aradji, A. (2012). Dynamique des indices de developpement physique et des qualités physico-techniques sous l'effet d'un programme d'entrainement (cas des footballeurs de mois de 17 ans). *THESE DE DOCTORAT*. Alger: Université Alger 3. Institut d'éducation physique et sport.
2. BOMPA, T. O., & BUZZICHELLI, C. (2018). *Periodization: Theory and methodology of training (6th ed.)*. Human Kinetics.
3. Bompa, T. O., & Haff, G. (2009). *Periodization: Theory and Methodology of Training (5th ed.)*. Human Kinetics.
4. Di Giacomo, U., Mercaldo, F., Santone, A., & Capobianco, G. (2022). Machine Learning on Soccer Player Positions. *International Journal of Decision Support System Technology*, pp. 14(1) 286-304.
5. GACOGNE, L. (2015). *Intelligence Artificielle - Cours, Exercices Corrigés et Projets*. Paris: Ellipses.
6. <https://www.dilepix.com/blog/difference-intelligence-artificielle-deep-learning-agriculture>. (2021, Janvier 18). Récupéré sur <https://www.dilepix.com>: <https://www.dilepix.com/hs-fs/hubfs/blog/Reseau-neurones-Dilepix.png?width=728&name=Reseau-neurones-Dilepix.png>
7. MATHIVET, V. (2019). *L'intelligence Artificielle pour le développeurs - concepts et implémentations en Java*. France: Editions ENI.
8. Pradet, M. (2012). *La préparation Physique*«. Paris: INSEP-Publications.
9. Rossi, A., Pappalardo, L., Cintia, P., Iaia, M., Fernández, J., & Medina, D. (2018, July 25). Effective injury forecasting in soccer with GPS training data and machine learning. *PloS one*, pp. 13(7) 1-15.
10. SAINT-CIRGUE, G. (2024). *Apprendre le MACHINE LEARNING en une semaine*. Londres: MACHINE LEARNIA.
11. Utomo , K. S., & Wiradinata, T. (2023, December 08). Optimal Playing Position Prediction in Football Matches: A Machine Learning Approach. *International Journal of Information Engineering and Electronic Business*, pp. 6, 30-47.

12. Verheijen, R. (1997). *Manuel, La condition physique des joueurs de football*. Eisma Édition. Brakel: M. Broodcoorens.
13. Vermeulen, H., & Sollied, T. (2004). *Football: entraînement à la zone*. Paris: Editions Amphora.
14. Weineck, J. (1999). *Manuel d'entraînement 4^e Edition*. Paris: Edition Vigot.
15. Williams, A. M., & REILLY, T. (2000). Talent identification and development in soccer. *Journal of Sports Sciences*, 18 (9), 657-667.
16. Ziv, G., & Lidor, R. (2011). Physical characteristics, physiological attributes, and on-field performances of soccer goalkeepers. *International Journal of Sports Physiology and Performance*, 6(4), 509–524.

الملاحق

قاعدة البيانات المستخدمة للخصائص البدنية للاعبين البطولة الفرنسية 1 و 2 من موقع Sofifa بتاريخ 2023-09-11

Known As	Best Position	Age	Height (in cm)	Weight (in kg)	Club Name	Acceleration	Sprint Speed	Agility	Reactions	Balance	Jumping	Stamina	Strength
L. Messi	CAM	35	169	67	Paris Saint-Germain	87	76	91	92	95	68	70	68
K. Mbappé	ST	23	182	73	Paris Saint-Germain	97	97	93	93	81	77	87	76
Neymar Jr	LW	30	175	68	Paris Saint-Germain	88	86	93	88	82	62	79	52
G. Donnarumma	GK	23	196	90	Paris Saint-Germain	50	55	64	85	38	72	34	72
Marquinhos	CB	28	183	75	Paris Saint-Germain	77	81	68	88	66	92	82	78
K. Navas	GK	35	185	80	Paris Saint-Germain	54	53	60	85	61	74	39	75
M. Verratti	CM	29	165	60	Paris Saint-Germain	65	55	90	87	93	66	75	53
Sergio Ramos	CB	36	184	82	Paris Saint-Germain	66	56	66	85	65	91	56	81
W. Ben Yedder	CF	31	170	68	AS Monaco	82	81	91	85	91	77	72	68
A. Hakimi	RB	23	181	73	Paris Saint-Germain	91	93	82	81	78	79	92	72
P. Kimpembe	CB	26	189	80	Paris Saint-Germain	79	80	68	80	59	79	79	88
Fabián	CM	26	189	70	Paris Saint-Germain	67	56	71	81	67	46	90	67
Carlos Soler	CM	25	180	76	Paris Saint-Germain	78	82	76	83	73	58	84	71
K. Schmeichel	GK	35	189	89	OGC Nice	42	49	60	82	47	60	34	63
D. Payet	CAM	35	175	77	Olympique de Marseille	71	69	81	79	74	34	67	71
K. Volland	ST	29	179	85	AS Monaco	71	70	73	83	79	76	85	86
A. Lopes	GK	31	184	81	Olympique Lyonnais	63	64	67	82	62	82	36	73
M. Terrier	ST	25	184	78	Stade Rennais FC	84	86	73	78	70	72	73	75
A. Lacazette	ST	31	175	73	Olympique Lyonnais	72	68	81	82	82	76	68	76
Pablo Sarabia	RW	30	174	70	Paris Saint-Germain	74	73	81	79	80	31	71	59
T. Savanier	CAM	30	172	69	Montpellier Hérault SC	68	61	85	80	90	32	77	62
G. Laborde	ST	28	181	78	OGC Nice	73	74	80	80	62	87	87	77
N. Tagliafico	LB	29	172	65	Olympique Lyonnais	79	80	77	81	82	88	86	75
C. Tolisso	CM	27	181	81	Olympique Lyonnais	69	69	76	83	76	83	72	76
S. Fofana	CM	27	185	74	Racing Club de Lens	73	73	69	82	67	62	91	87
B. Bourigeaud	RW	28	178	70	Stade Rennais FC	75	76	72	81	72	72	86	72
A. Lafont	GK	23	196	90	FC Nantes	48	45	60	71	53	73	40	70

Renato Sanches	CAM	24	176	70	Paris Saint-Germain	85	82	84	80	90	84	86	83
M. Guendouzi	CDM	23	185	68	Olympique de Marseille	72	73	81	76	72	72	88	75
Nuno Mendes	LB	20	176	70	Paris Saint-Germain	90	89	81	78	82	70	80	69
L. Majer	CAM	24	178	76	Stade Rennais FC	76	63	84	79	69	57	77	64
J. Clauss	RWB	29	178	69	Olympique de Marseille	85	83	83	78	70	62	88	63
Danilo Pereira	CDM	30	188	83	Paris Saint-Germain	47	63	53	75	49	76	83	89
A. Delort	ST	30	181	83	OGC Nice	79	84	71	75	72	78	78	85
José Fonte	CB	38	191	81	LOSC Lille	31	31	37	83	48	72	76	82
H. Traoré	RB	30	175	70	Stade Rennais FC	81	85	75	76	79	85	89	73
M. Dembélé	ST	25	183	79	Olympique Lyonnais	69	75	65	80	62	84	74	83
A. Gouiri	CAM	22	181	83	Stade Rennais FC	81	75	76	77	72	69	72	71
J. David	ST	22	180	77	LOSC Lille	81	85	75	76	70	86	83	77
A. Sánchez	CAM	33	168	62	Olympique de Marseille	75	69	84	76	88	85	66	67
J. Boateng	CB	33	190	94	Olympique Lyonnais	38	55	49	77	50	73	47	85
Y. Fofana	CDM	23	176	69	AS Monaco	68	68	70	77	75	59	83	75
Vitinha	CAM	22	172	64	Paris Saint-Germain	76	70	90	74	84	56	75	45
M. Caqueret	CM	22	174	63	Olympique Lyonnais	75	71	86	78	84	42	85	56
L. Blas	CAM	24	180	70	FC Nantes	78	69	79	73	76	66	73	63
N. Mukiele	CB	24	187	84	Paris Saint-Germain	77	79	67	73	65	90	79	79
N. Piché	LW	27	183	73	OGC Nice	87	88	86	74	75	66	66	68
A. Golovin	CAM	26	180	69	AS Monaco	76	78	86	77	77	65	80	56
J. Omlin	GK	28	189	80	Montpellier Hérault SC	52	51	32	74	51	75	35	72
S. Mandanda	GK	37	185	82	Stade Rennais FC	53	43	52	80	36	69	31	61
C. Lønder	RW	24	173	66	Olympique de Marseille	82	75	82	78	80	42	72	49
H. Aouar	CAM	24	175	70	Olympique Lyonnais	72	71	82	76	81	65	72	66
Pau López	GK	27	189	77	Olympique de Marseille	45	52	40	63	57	71	42	52
J. Veretout	CDM	29	177	67	Olympique de Marseille	78	75	77	76	81	74	78	79
Ismaily	LB	32	177	82	LOSC Lille	84	80	72	79	82	63	84	75
M. Sels	GK	30	190	88	RC Strasbourg Alsace	37	35	36	78	34	70	26	67
B. André	CDM	31	180	76	LOSC Lille	62	67	70	78	71	93	90	79
L. Ajarque	ST	28	197	92	RC Strasbourg Alsace	69	76	55	79	31	74	78	90

C. Mbemba	CB	27	182	78	Olympique de Marseille	70	74	67	79	64	90	80	80
S. Diop	CAM	22	175	65	OGC Nice	74	69	82	76	85	48	78	37
J. Todibo	CB	22	190	88	OGC Nice	68	81	51	73	55	76	70	81
R. Faivre	CAM	23	180	69	Olympique Lyonnais	80	70	79	76	73	64	80	63
S. Gigot	CB	28	187	75	Olympique de Marseille	63	70	61	77	57	81	73	84
G. Maripán	CB	28	193	83	AS Monaco	32	33	30	78	32	67	57	91
Juan Bernat	LB	29	170	67	Paris Saint-Germain	75	73	80	80	87	74	53	53
V. Rongier	CDM	27	172	70	Olympique de Marseille	70	72	74	80	88	73	82	79
A. N'Zébel	GK	25	193	88	AS Monaco	49	46	34	73	58	61	39	70
K. Toko Ekambi	LM	29	185	74	Olympique Lyonnais	81	85	76	79	68	71	75	73
Andrei Giretto	CB	30	186	79	FC Nantes	63	54	63	75	54	76	70	71
Caio Henrique	LWB	24	179	70	AS Monaco	79	72	73	78	74	69	78	51
J. Ito	RW	29	177	68	Stade de Reims	91	88	82	75	77	87	89	61
P. Rosario	CDM	25	188	73	OGC Nice	61	67	68	76	65	75	79	81
Gerson	CDM	25	184	76	Olympique de Marseille	67	71	78	76	79	66	80	78
Dante	CB	38	189	91	OGC Nice	32	32	43	75	59	65	68	85
F. Tait	CM	29	176	73	Stade Rennais FC	74	67	72	77	78	53	82	60
A. Gomis	GK	28	196	80	Stade Rennais FC	43	41	60	73	54	78	33	65
N. Pallois	CB	34	189	89	FC Nantes	33	40	50	67	33	78	66	92
A. Djiku	CB	27	182	81	RC Strasbourg Alsace	57	78	66	75	63	83	79	82
S. Boufal	CAM	28	175	67	Angers SCO	81	77	88	71	85	35	61	57
M. Simon	LM	26	168	69	FC Nantes	89	90	90	72	92	88	74	68
F. Honorat	LM	25	180	70	Stade Brestois 29	82	81	79	72	67	80	80	55
B. Embolo	ST	25	187	88	AS Monaco	83	85	67	76	70	76	79	85
R. Aguilar	RB	29	172	71	AS Monaco	78	68	77	75	76	80	92	65
Pedro Chirivella	CDM	25	178	66	FC Nantes	58	60	72	79	64	48	80	65
M. Sissoko	CDM	32	187	91	FC Nantes	63	75	64	75	58	69	83	90
K. Gameiro	ST	35	172	69	RC Strasbourg Alsace	77	79	77	77	71	83	67	64
K. Thuram	CM	21	192	81	OGC Nice	73	74	71	78	69	74	78	80
M. Camara	CDM	22	169	65	AS Monaco	84	80	88	77	91	80	90	69
B. Badiashile	CB	21	194	75	AS Monaco	54	66	42	76	35	78	64	84

J. Ferri	CDM	30	173	73	Montpellier Hérault SC	59	55	69	77	83	64	78	69
A. Disasi	CB	24	190	86	AS Monaco	46	54	31	75	34	72	66	92
Gelson Martins	RM	27	173	74	AS Monaco	91	89	90	73	84	65	87	44
A. Thomasson	CM	28	177	72	RC Strasbourg Alsace	69	69	72	77	81	72	77	67
H. Diallo	ST	27	186	79	RC Strasbourg Alsace	70	72	66	76	68	87	69	79
S. Mavididi	ST	24	182	71	Montpellier Hérault SC	88	88	74	72	71	73	72	74
Thiago Mendes	CDM	30	177	75	Olympique Lyonnais	66	69	72	74	76	71	76	72
Vanderson	RM	21	180	74	AS Monaco	79	78	76	74	74	56	75	67
M. Bizot	GK	31	193	88	Stade Brestois 29	45	47	50	75	40	67	32	64
R. Barkley	CAM	28	186	76	OGC Nice	67	69	65	73	61	64	58	76
M. Gonalons	CDM	33	187	76	Clermont Foot 63	54	35	54	75	59	77	58	70
P. Bernardoni	GK	25	190	78	Angers SCO	31	27	21	67	34	70	36	68
A. Ramsey	CM	31	183	76	OGC Nice	47	55	68	73	78	63	54	65
G. Kakuta	CAM	31	173	72	Racing Club de Lens	73	68	83	75	84	76	59	61
B. Meling	LB	27	173	67	Stade Rennais FC	84	80	85	72	86	86	90	50
B. Santamaria	CM	27	183	81	Stade Rennais FC	50	48	67	76	66	71	83	70
G. Nyamsi	CB	25	195	94	RC Strasbourg Alsace	48	47	48	74	36	72	70	91
F. Medina	CB	23	184	77	Racing Club de Lens	70	75	62	75	66	71	69	78
E. Bailly	CB	28	186	77	Olympique de Marseille	65	74	61	73	60	83	45	83
J. Bamba	LM	26	175	72	LOSC Lille	85	83	80	73	80	73	76	63
Sergio Rico	GK	28	196	90	Paris Saint-Germain	48	46	51	71	43	63	36	53
Y. Abdelhamid	CB	34	190	83	Stade de Reims	33	32	31	72	39	77	75	83
S. Prigent	CDM	28	181	75	RC Strasbourg Alsace	54	56	70	75	65	54	79	71
Tetou	CAM	22	175	72	Olympique Lyonnais	80	83	83	68	75	65	71	56
H. Boudaoui	CAM	22	175	61	OGC Nice	75	74	78	74	77	71	83	66
Y. Belalili	LM	30	178	75	Stade Brestois 29	78	80	75	69	79	44	68	70
P. Gueye	CDM	23	187	79	Olympique de Marseille	62	64	55	76	52	73	79	79
A. Kalimuendo	ST	20	175	79	Stade Rennais FC	83	80	75	75	85	57	58	72
J. Gastien	CDM	34	179	69	Clermont Foot 63	49	50	75	72	81	69	85	71
P. Frankowski	RM	27	175	70	Racing Club de Lens	93	92	74	74	75	74	81	69
H. Ekitike	ST	20	189	70	Paris Saint-Germain	74	74	68	76	67	74	68	72

C. Lukeba	CB	19	184	73	Olympique Lyonnais	71	75	69	76	64	75	72	75
M. Sakho	CB	32	187	83	Montpellier Hérault SC	37	42	49	70	53	74	59	90
J. Cabot	RM	28	164	64	Racing Club de Lens	86	90	87	70	92	69	83	54
Rony Lopes	RW	26	174	68	ESTAC Troyes	82	73	83	67	88	55	68	62
A. Elis	ST	26	183	77	FC Girondins de Bordeaux	90	92	84	74	66	84	80	75
E. Le Floc'h	CM	22	170	58	FC Lorient	57	60	68	72	89	62	63	36
J. Doku	CAM	20	173	77	Stade Rennais FC	94	89	89	70	87	75	61	67
Jean Lucas	CM	24	181	78	AS Monaco	75	73	74	73	71	55	78	72
Tiago Djalo	CB	22	190	82	LOSC Lille	79	83	65	73	45	68	67	84
L. Balerdi	CB	23	187	76	Olympique de Marseille	64	72	64	69	56	74	68	78
L. Openda	ST	22	174	78	Racing Club de Lens	94	93	79	74	79	92	77	75
J. Martin	CM	32	184	77	LOSC Lille	56	59	68	78	68	61	75	73
A. Buksa	ST	25	191	77	Racing Club de Lens	68	67	62	77	49	85	74	80
J. Leca	GK	36	180	75	Racing Club de Lens	41	41	40	75	45	65	24	69
J. Lotomba	RWB	23	177	71	OGC Nice	79	79	73	73	73	75	76	63
M. Sarr	CB	23	182	75	AS Monaco	65	69	67	73	69	77	68	79
J. Bellegarde	CM	24	172	70	RC Strasbourg Alsace	77	79	82	75	85	69	79	68
B. Costil	GK	34	187	82	AJ Auxerre	47	51	38	72	45	49	28	65
I. Sissoko	CDM	24	193	90	RC Strasbourg Alsace	61	63	40	76	33	67	82	89
Y. Mvogo	GK	28	189	93	FC Lorient	43	41	58	71	57	71	28	74
D. Lénier	CM	34	181	77	RC Strasbourg Alsace	53	53	66	75	68	68	73	71
M. Bayo	ST	24	188	76	LOSC Lille	69	70	67	77	54	57	60	73
Y. Atal	RM	26	175	66	OGC Nice	87	88	79	75	78	69	67	64
M. Boadu	ST	21	183	67	AS Monaco	90	87	84	77	74	83	74	67
K. Danso	CB	23	190	85	Racing Club de Lens	68	88	57	69	48	80	57	86
W. Omari	CB	22	188	74	Stade Rennais FC	63	66	48	71	54	72	70	75
A. Truffert	LWB	20	176	70	Stade Rennais FC	71	74	71	71	75	71	76	65
K. Sulemana	RM	20	175	70	Stade Rennais FC	92	93	89	62	88	77	70	60
M. Bard	LB	21	173	65	OGC Nice	72	80	74	70	79	68	73	68
A. Theate	CB	22	185	78	Stade Rennais FC	67	76	49	72	46	70	68	84
M. Gusto	RB	19	179	74	Olympique Lyonnais	84	87	72	70	75	68	82	65

T. Minamino	CAM	27	174	67	AS Monaco	84	73	89	74	86	76	73	55
F. Sotoca	ST	31	187	77	Racing Club de Lens	70	77	71	79	52	88	86	78
P. Lees-Melou	CM	29	186	70	Stade Brestois 29	66	65	72	74	60	66	84	72
F. Centonze	RWB	26	182	75	FC Metz	80	81	72	70	75	79	85	77
A. Harit	CAM	25	180	67	Olympique de Marseille	77	71	84	74	73	43	70	40
J. Aholou	CDM	28	186	71	RC Strasbourg Alsace	67	61	64	71	56	65	70	82
T. Foket	RB	27	177	67	Stade de Reims	75	70	71	69	71	82	88	70
R. Thomas	CB	34	193	84	Stade Malherbe Caen	33	33	38	71	41	69	46	83
S. Kolašinac	LB	29	183	85	Olympique de Marseille	67	77	59	71	55	75	72	90
B. Chardonnet	CB	27	181	74	Stade Brestois 29	53	55	56	72	69	80	68	80
André Gomes	CM	28	188	84	LOSC Lille	52	51	60	74	60	59	68	77
L. Abergel	CDM	29	170	65	FC Lorient	74	64	74	72	83	78	88	67
L. Perrin	CB	23	188	81	RC Strasbourg Alsace	49	52	41	71	52	70	70	73
Rubén Blanco	GK	26	189	80	Olympique de Marseille	54	52	52	66	57	62	44	35
J. Reine-Adélaïde	CAM	24	184	75	Olympique Lyonnais	72	71	75	73	65	63	64	68
A. Zedadka	RB	27	173	72	LOSC Lille	83	80	76	73	76	32	84	59
X. Chavalerin	CM	31	178	66	ESTAC Troyes	58	59	67	73	73	60	89	70
E. Zhegrova	CAM	23	181	66	LOSC Lille	86	73	84	70	80	71	69	61
K. Diatta	RM	23	175	69	AS Monaco	90	91	89	70	76	90	83	61
G. Gallon	GK	29	186	79	ESTAC Troyes	40	40	38	66	54	59	29	64
M. Haïdara	LWB	29	179	76	Racing Club de Lens	73	78	69	73	71	81	81	77
Pedro Mendes	CB	31	186	78	Montpellier Hérault SC	63	55	52	68	48	71	65	77
C. Jullien	CB	29	196	88	Montpellier Hérault SC	62	65	38	64	33	82	49	82
M. Munetsi	CDM	26	188	83	Stade de Reims	65	53	55	71	50	63	80	80
B. Dieng	ST	21	178	72	Olympique de Marseille	77	82	67	69	71	74	64	67
R. Cabella	CAM	32	172	68	LOSC Lille	71	71	83	70	78	35	69	48
A. Claude-Maurice	CAM	24	175	64	Racing Club de Lens	79	81	88	71	79	70	69	68
A. Gravillon	CB	24	185	80	Stade de Reims	57	61	54	68	46	77	61	86
A. Souquet	RB	30	179	74	Montpellier Hérault SC	66	66	68	71	63	72	75	65
D. Bertaud	GK	24	180	85	Montpellier Hérault SC	52	55	35	67	61	65	42	65
F. Sacko	RB	27	179	68	Montpellier Hérault SC	91	93	82	70	74	84	92	65

H. Belkebla	CDM	28	177	68	Stade Brestois 29	60	51	59	72	69	44	84	68
M. Schneiderlin	CDM	32	186	79	OGC Nice	50	40	63	73	66	66	74	74
C. Dagba	RB	23	170	62	RC Strasbourg Alsace	78	76	81	69	85	65	67	52
T. Weah	CAM	22	185	66	LOSC Lille	85	87	86	72	70	68	60	64
B. Samba	GK	28	186	79	Racing Club de Lens	49	60	39	70	54	57	37	70
J. Berthomier	CAM	32	177	74	Valenciennes FC	67	65	76	75	73	86	67	49
Mama Baldi©	ST	26	176	69	ESTAC Troyes	87	91	80	74	76	82	78	76
D. Da Silva	CB	34	184	83	Olympique Lyonnais	35	37	46	73	56	80	55	79
J. Chotard	CDM	20	179	70	Montpellier H©rault SC	67	68	76	73	70	69	77	61
J. Castelletto	CB	27	185	76	FC Nantes	69	67	63	68	46	88	71	74
A. Matusiwa	CDM	24	173	72	Stade de Reims	61	51	74	73	78	85	82	76
A. Gomes	CAM	21	168	56	LOSC Lille	78	77	86	70	89	51	64	56
P. Capelle	RM	35	181	73	Angers SCO	61	67	72	74	64	68	75	65
Nuno Tavares	LWB	22	183	75	Olympique de Marseille	83	87	77	70	60	58	83	79
G. Gudmundsson	LB	23	180	74	LOSC Lille	85	87	74	68	67	69	75	65
M. Mohamed	ST	24	185	78	FC Nantes	67	72	65	67	62	91	75	86
B. van den Boomen	CM	26	188	75	Toulouse Football Club	60	64	64	72	40	68	73	78
N. Cozza	CB	23	178	72	Montpellier H©rault SC	76	74	60	75	72	77	69	70
E. Wahi	ST	19	184	74	Montpellier H©rault SC	84	81	79	72	71	76	61	69
T. Delaine	RWB	30	180	71	RC Strasbourg Alsace	81	84	77	70	65	63	75	70
Jubal	CB	28	190	80	AJ Auxerre	45	55	54	71	53	90	58	78
Henrique	LB	28	173	72	Olympique Lyonnais	78	77	71	70	77	58	74	59
R. Kouam©	CM	25	177	68	ESTAC Troyes	71	67	74	75	72	71	87	75
R. Ripart	ST	29	181	73	ESTAC Troyes	66	72	67	74	66	72	90	85
M. Dup©	GK	29	188	88	Toulouse Football Club	48	42	35	67	39	54	21	71
A. Zeneli	LM	27	176	72	Stade de Reims	74	74	78	71	77	30	60	54
R. Hamouma	CAM	35	178	76	AC Ajaccio	69	68	78	74	74	57	63	68
J. Laporte	CB	28	185	82	FC Lorient	45	43	41	66	53	86	80	85
Y. M'Changama	RM	31	175	69	AJ Auxerre	85	87	90	68	87	68	93	69
D. Appiah	RB	30	179	68	FC Nantes	70	72	73	69	69	82	87	68
S. Spierings	CDM	26	188	83	Toulouse Football Club	59	41	68	71	66	62	71	74

Lí©o Jardim	GK	27	188	82	LOSC Lille	40	43	35	69	54	54	42	56
C. Hountondji	CB	28	195	81	Angers SCO	38	50	51	74	32	65	48	81
G. Larssonneur	GK	25	181	70	Valenciennes FC	51	53	60	69	65	70	38	59
J. Duverne	CB	24	184	71	Stade Brestois 29	60	65	66	69	65	78	75	75
V. Manceau	CB	32	176	70	En Avant de Guingamp	50	36	68	74	74	80	77	66
A. Ounas	CAM	25	172	65	LOSC Lille	86	80	89	62	81	61	71	53
J. Bryan	LB	28	173	75	OGC Nice	77	75	76	65	86	90	79	71
G. Charbonnier	ST	33	188	80	AJ Auxerre	30	32	46	76	47	46	54	82
W. Saíd	CF	27	171	72	Racing Club de Lens	75	73	84	75	84	61	66	60
M. Autret	LM	31	179	71	AJ Auxerre	62	64	72	70	78	67	54	62
P. Pentz	GK	25	182	81	Stade de Reims	52	55	62	68	54	68	42	63
I. Ganago	ST	23	179	82	FC Nantes	80	82	77	67	78	67	67	75
T. Mangani	CDM	35	183	79	AC Ajaccio	44	37	63	71	57	67	75	74
A. Nordin	CAM	24	170	69	Montpellier Hí©rault SC	83	83	74	68	80	64	62	64
L. Diony	ST	29	183	82	Angers SCO	69	72	63	69	72	72	66	78
W. Farítez	GK	24	180	77	Racing Club de Lens	51	54	69	67	65	75	41	51
Y. Benrahou	CAM	23	170	68	Ní©mes Olympique	74	75	90	69	89	50	65	59
David Costa	CAM	21	168	64	Racing Club de Lens	75	70	85	71	84	40	51	39
I. Kebbal	LM	23	169	60	Paris FC	82	73	90	68	90	53	72	47
E. Green	GK	21	192	78	AS Saint-Í©tienne	28	22	38	68	29	37	34	74
M. Blalí©z	CB	29	185	81	Angers SCO	57	65	58	72	55	72	59	80
C. Hí©relle	CB	29	188	79	Stade Brestois 29	48	63	56	69	60	77	67	76
S. Mouní©	ST	27	190	83	Stade Brestois 29	56	62	57	69	51	92	67	84
R. Healey	ST	27	180	72	Toulouse Football Club	79	73	79	65	74	74	77	65
M. Bulí©ka	GK	22	199	90	OGC Nice	28	25	42	62	28	43	30	70
Rafael Ratí©o	LW	26	183	82	Toulouse Football Club	80	72	81	69	79	68	76	72
S. Doumbia	LWB	25	175	64	Angers SCO	81	88	68	66	82	71	74	68
C. Kaborí©	CDM	34	183	78	Chamois Niortais Football Club	68	67	69	70	61	73	83	70
M. Niang	ST	27	184	75	AJ Auxerre	70	78	70	68	65	74	49	84
N. Bentaleb	CM	27	187	78	Angers SCO	56	52	73	68	69	81	65	73

B. Leroy	GK	33	184	75	AC Ajaccio	46	46	37	69	40	55	28	40
R. Pierre-Gabriel	RB	24	177	80	RC Strasbourg Alsace	69	76	68	69	71	89	72	72
J. Onana	CDM	22	187	90	Racing Club de Lens	57	60	56	72	55	64	77	87
V. Germain	ST	32	181	75	Montpellier Hérault SC	63	66	76	74	69	84	72	61
I. Niane	ST	23	187	73	FC Metz	86	80	78	67	56	76	69	72
R. Cherki	CAM	18	176	71	Olympique Lyonnais	73	68	82	69	83	31	53	65
S. Diomande	CB	21	184	74	Olympique Lyonnais	59	70	57	70	57	91	65	78
R. Del Castillo	CAM	26	172	65	Stade Brestois 29	77	72	85	69	81	75	65	62
I. Amadou	CDM	29	183	81	Angers SCO	58	70	67	73	67	81	82	81
A. Aouchiche	CAM	19	181	72	FC Lorient	69	68	74	69	68	65	64	63
D. Machado	LWB	28	173	75	Racing Club de Lens	82	85	75	62	78	82	77	66
A. Bamba	LM	28	177	74	FC Nantes	84	84	74	65	68	59	71	60
E. Kawashima	GK	39	185	82	RC Strasbourg Alsace	43	42	61	70	45	69	30	60
H. Magnetti	CDM	24	180	75	Stade Brestois 29	54	51	60	68	83	63	70	76
M. van Bergen	RM	22	170	62	Stade de Reims	87	86	84	67	77	51	71	49
L. Fomba	CB	24	188	68	Nîmes Olympique	65	70	82	69	79	81	86	79
G. Courtet	ST	33	180	73	En Avant de Guingamp	65	65	72	68	74	81	71	72
E. Matazo	CAM	20	174	67	AS Monaco	74	72	77	69	81	69	69	69
V. Nsimba	LB	28	169	69	FC Girondins de Bordeaux	82	83	83	72	92	92	80	40
M. Cafaro	CAM	25	178	74	AS Saint-Étienne	79	72	81	70	83	59	76	56
D. Alemdar	GK	19	189	73	Stade Rennais FC	38	39	35	69	42	56	33	65
G. Weissbeck	CAM	25	177	70	FC Sochaux-Montbéliard	63	68	78	65	74	67	77	68
J. Le Douaron	ST	24	189	78	Stade Brestois 29	71	70	63	69	57	66	71	77
I. Ugbo	ST	23	185	73	ESTAC Troyes	72	79	69	74	62	74	63	74
T. Monconduit	CDM	31	184	83	AS Saint-Étienne	43	55	61	67	59	71	75	74
M. Lis	GK	25	192	83	ESTAC Troyes	27	27	37	54	35	33	26	70
L. Da Cunha	CAM	21	176	69	OGC Nice	77	75	79	65	76	54	62	54
Y. Court	RM	32	172	70	Stade Malherbe Caen	70	66	75	71	86	80	72	69
M. Estève	CB	20	193	87	Montpellier Hérault SC	61	72	33	68	37	65	64	82
F. Maouassa	LM	23	170	73	Montpellier Hérault SC	82	74	76	70	84	75	72	75
Y. Maïson	RWB	23	176	74	AS Saint-Étienne	87	88	78	67	73	63	82	68

T. Moffi	ST	23	188	82	FC Lorient	67	76	58	69	55	76	65	86
Y. Salmier	CB	29	188	85	ESTAC Troyes	39	35	39	65	42	73	71	88
F. Tardieu	CDM	30	184	70	ESTAC Troyes	51	45	66	69	71	73	91	67
M. Le Marchand	CB	32	185	77	RC Strasbourg Alsace	57	63	61	69	63	76	59	70
J. Rodon	CB	24	193	88	Stade Rennais FC	54	62	47	73	55	66	67	77
S. Moutoussamy	CDM	25	176	72	FC Nantes	72	65	80	66	79	47	79	67
A. Oukidja	GK	33	184	80	FC Metz	48	45	54	68	58	55	31	70
R. Nicolaisen	CB	25	191	81	Toulouse Football Club	47	66	56	73	52	76	68	78
B. Kouyaté	CB	25	192	78	FC Metz	68	63	64	63	43	83	70	80
S. Corchia	RB	31	175	67	FC Nantes	69	67	69	71	72	68	63	53
R. Nouri	CAM	37	178	73	AC Ajaccio	68	64	80	70	77	79	43	64
J. Uronen	LB	27	177	69	Stade Brestois 29	66	69	70	69	71	73	84	69
A. Sima	ST	21	188	74	Angers SCO	86	89	70	71	61	78	81	70
Fábio	LB	31	172	74	FC Nantes	73	74	74	71	81	75	61	60
J. Cajuste	CM	22	188	77	Stade de Reims	70	79	77	68	74	61	80	78
D. Ndong	CDM	28	180	75	Dijon FCO	71	70	69	65	74	71	90	78
L. Brassier	CB	22	186	78	Stade Brestois 29	68	69	60	68	56	70	71	76
P. Lasne	CDM	33	186	77	Paris FC	52	38	60	68	62	67	65	73
I. Cardona	ST	24	185	76	Stade Brestois 29	72	70	69	69	62	79	69	70
N. Mbuku	CAM	20	170	65	Stade de Reims	80	75	87	65	87	33	62	53
A. Rouault	CB	21	186	77	Toulouse Football Club	66	58	55	68	58	80	65	73
M. Pereira Lage	LM	25	180	69	Stade Brestois 29	73	72	77	66	72	85	79	64
A. Onaiwu	ST	26	180	75	Toulouse Football Club	84	84	63	68	62	87	64	73
I. Jakobs	LM	22	184	75	AS Monaco	86	84	72	68	67	49	77	66
H. Sakhi	CAM	26	176	69	AJ Auxerre	70	69	73	67	70	57	69	58
R. Guitane	LM	23	170	64	Stade de Reims	74	77	85	67	92	56	66	32
C. Michelin	RWB	25	178	65	FC Girondins de Bordeaux	69	71	65	67	70	70	80	63
L. Gueye	RM	24	178	74	FC Metz	76	78	71	62	74	68	70	65
M. Koné	ST	25	175	68	Nîmes Olympique	92	92	85	71	80	80	74	69
Q. Bernard	LB	32	184	83	AJ Auxerre	56	61	62	63	63	85	92	76
I. Kaboré	RWB	21	180	72	Olympique de Marseille	87	90	79	65	72	83	72	66

V. Le Goff	LB	32	177	69	FC Lorient	68	66	77	67	73	64	81	63
D. Lopy	CM	20	184	79	Stade de Reims	67	67	65	72	62	72	73	75
J. Dossou	RM	30	180	75	Clermont Foot 63	81	84	81	71	71	80	63	69
M. Desler	RB	27	184	73	Toulouse Football Club	78	74	69	68	76	85	85	62
Y. Barbet	CB	29	187	81	FC Girondins de Bordeaux	67	69	61	68	54	62	79	77
B. Dejaegere	CM	31	173	71	Toulouse Football Club	72	68	76	69	77	76	79	65
J. Deminguet	CAM	24	178	74	Stade Malherbe Caen	71	73	79	68	77	46	85	68
G. Mikautadze	CAM	21	178	72	FC Metz	78	79	83	71	76	73	71	67
E. Rashani	LM	29	181	71	Clermont Foot 63	79	83	78	70	62	57	76	64
R. Ilie	CAM	19	183	73	OGC Nice	77	83	80	61	76	60	68	61
B. Touré	CDM	30	183	73	AJ Auxerre	42	31	62	67	61	75	84	77
Y. Valery	RB	23	180	85	Angers SCO	72	67	66	68	67	69	72	71
A. Briançon	CB	27	185	79	AS Saint-Étienne	59	39	51	65	65	79	69	86
A. Flips	CAM	22	173	68	Stade de Reims	71	70	67	68	77	56	65	64
Neto Borges	LB	25	183	84	Clermont Foot 63	71	72	70	74	59	66	77	84
O. El Hajjam	CB	31	181	72	Le Havre AC	66	65	63	68	66	60	80	72
A. Mendy	ST	28	185	84	Stade Malherbe Caen	71	72	69	68	56	83	74	91
M. Dreyer	GK	33	188	81	AS Saint-Étienne	47	53	45	59	40	76	27	68
E. Agbadou	CB	25	192	86	Stade de Reims	58	75	53	64	41	67	68	86
I. Sylla	LB	28	180	75	Toulouse Football Club	73	69	67	68	65	71	84	69
A. Bobichon	CAM	26	178	75	Angers SCO	63	66	66	66	67	58	66	65
S. Abdul Samed	CDM	22	180	61	Racing Club de Lens	43	56	43	71	68	66	64	54
S. Gregersen	CB	27	192	83	FC Girondins de Bordeaux	68	81	33	68	48	88	76	90
J. Maja	ST	23	181	76	FC Girondins de Bordeaux	74	77	68	72	71	56	62	65
L. Agoum	CM	20	188	72	ESTAC Troyes	69	60	66	69	60	55	74	69
Gabriel Silva	LB	31	179	75	AS Saint-Étienne	66	65	76	69	73	75	73	65
M. Nadir	CB	23	188	80	AS Saint-Étienne	33	36	43	69	68	71	71	91
E. Palmer-Brown	CB	25	187	88	ESTAC Troyes	59	70	61	67	47	80	58	89
M. Viti	CB	20	190	82	OGC Nice	65	75	60	67	53	70	67	73
M. Coco	RM	26	184	78	FC Nantes	80	81	81	69	68	62	46	64
Y. Touzghar	ST	35	179	75	AC Ajaccio	64	66	78	64	73	81	64	72

J. Faussurier	CM	35	173	70	FC Sochaux-Montbéliard	55	45	60	69	73	82	71	62
Y. Benzia	CAM	27	179	77	Dijon FCO	68	64	77	67	72	86	61	59
A. Rami	CB	36	190	90	ESTAC Troyes	33	41	48	70	53	67	52	86
A. Abdi	LWB	28	180	73	Stade Malherbe Caen	83	88	72	71	68	71	88	70
N. Benezet	LM	31	170	60	Nîmes Olympique	77	75	82	70	86	61	58	59
S. Thioub	RM	27	179	75	Angers SCO	77	79	67	69	77	52	70	81
D. Bain	CB	28	181	74	AJ Auxerre	55	55	38	68	51	79	65	81
T. Mauricio	RM	28	169	67	FC Sochaux-Montbéliard	84	77	87	65	92	54	73	59
Z. Aboukhlaïl	LM	22	178	73	Toulouse Football Club	87	85	85	67	76	62	77	70
O. Gonzalez	CB	24	187	87	AC Ajaccio	60	59	50	68	51	70	68	84
T. Didillon	GK	26	193	88	AS Monaco	57	54	55	66	33	57	25	67
S. Khaoui	CAM	27	180	68	Clermont Foot 63	64	58	74	67	66	61	69	61
V. Demarconnay	GK	39	180	71	Paris FC	36	52	45	68	45	60	27	69
J. Cuffaut	CB	34	180	74	Valenciennes FC	69	66	76	70	73	90	90	76
T. Dallinga	ST	21	180	70	Toulouse Football Club	70	73	55	69	65	73	76	64
M. Udol	CB	26	178	68	FC Metz	71	71	72	65	76	70	69	71
D. Congré	CB	37	186	82	Dijon FCO	33	35	57	66	62	76	65	80
G. Mensah	LWB	23	178	64	AJ Auxerre	78	76	72	67	79	77	75	60
J. Benet	CM	27	186	75	Amiens SC	54	64	71	68	69	66	88	78
S. Sow	CB	19	185	78	AS Saint-Étienne	62	64	51	68	57	76	48	77
H. Mal'ga	CDM	26	181	80	FC Metz	65	54	62	71	71	69	78	82
I. Pettersson	GK	25	181	84	Toulouse Football Club	42	47	37	72	52	69	34	54
L. Mothiba	ST	26	182	78	RC Strasbourg Alsace	67	65	60	65	65	66	63	70
D. Lison	GK	29	187	94	AJ Auxerre	48	46	42	63	53	64	29	79
J. Bela	LM	29	173	71	Clermont Foot 63	90	90	91	64	80	84	79	56
A. Beka Beka	CDM	21	178	75	OGC Nice	78	74	71	69	78	48	76	69
J. Lepenant	CDM	19	176	71	Olympique Lyonnais	73	72	79	65	77	69	78	62
J. Allevinah	RW	27	172	70	Clermont Foot 63	85	82	75	62	71	47	59	44
G. Kalulu	CB	24	176	74	FC Lorient	79	81	78	64	74	89	69	79
F. Hanin	LB	32	177	73	Paris FC	81	78	80	67	75	74	81	70
F. Ogier	CB	33	183	73	Clermont Foot 63	29	35	57	67	62	89	80	73

Igor Silva	RB	25	173	66	FC Lorient	76	78	80	62	80	64	74	59
E. Guessand	ST	21	185	79	FC Nantes	73	74	66	66	58	64	62	76
V. Mannone	GK	34	189	77	FC Lorient	54	56	42	70	44	75	31	67
M. Busi	RB	22	182	75	Stade de Reims	71	72	69	63	68	69	69	65
Y. Cimignani	RM	20	176	68	AC Ajaccio	74	76	70	58	74	65	64	64
M. Alphonse	RB	32	182	79	AC Ajaccio	72	73	57	65	62	88	72	69
T. Pembé	RM	19	182	76	Paris Saint-Germain	86	88	78	66	66	66	67	64
D. Ignatenko	CDM	25	190	80	FC Girondins de Bordeaux	50	52	56	72	52	56	75	87
Q. Merlin	LM	20	173	67	FC Nantes	72	68	71	61	80	62	74	50
G. Hein	RM	25	170	65	AJ Auxerre	81	78	90	59	90	67	57	48
B. Reynet	GK	31	185	90	Dijon FCO	42	45	43	68	28	62	35	68
M. Barreto	LM	31	175	67	AC Ajaccio	80	79	88	60	76	78	72	62
R. Salin	GK	37	189	76	Stade Rennais FC	28	34	50	72	45	58	38	60
T. Tsingaras	CDM	21	175	70	Toulouse Football Club	72	69	72	62	78	66	80	65
F. Mayembo	CB	26	184	86	AC Ajaccio	45	45	46	67	34	69	78	92
Nuno da Costa	ST	31	182	70	AJ Auxerre	78	79	75	66	76	83	69	65
Y. Magnin	CDM	25	183	71	Clermont Foot 63	67	68	70	67	56	69	66	55
Q. Laïš	RM	26	175	67	AC Ajaccio	76	69	83	66	68	81	89	70
A. Palaversa	CDM	22	187	77	ESTAC Troyes	55	60	56	71	60	54	73	72
B. Mendy	CB	22	191	82	Angers SCO	55	64	32	62	50	69	68	88
V. Henry	RB	28	178	73	FC Sochaux-Montbéliard	81	78	81	62	75	48	81	72
A. Ounahi	CM	22	182	62	Angers SCO	55	59	70	67	67	61	81	63
J. Jeanvier	CB	29	185	84	AJ Auxerre	62	63	66	69	64	72	62	77
Sergi Palencia	RWB	26	172	68	AS Saint-Étienne	74	73	72	65	74	59	79	72
J. Giraudon	CB	30	184	66	AS Saint-Étienne	60	42	60	62	43	76	77	74
A. Mandrea	GK	25	186	78	Stade Malherbe Caen	41	49	33	63	55	51	28	61
M. Prévot	GK	25	187	81	FC Sochaux-Montbéliard	43	26	29	63	46	66	27	57
M. Debuchy	CB	36	176	76	Valenciennes FC	62	61	70	73	69	80	67	70
R. Dugimont	ST	36	182	75	AJ Auxerre	53	57	77	58	61	78	91	83
B. Locko	LB	20	180	65	Stade de Reims	74	76	64	65	69	64	68	67
V. Birmančević	CAM	24	179	67	Toulouse Football Club	83	80	88	66	76	52	78	58

I. Sissokho	CDM	20	174	67	FC Girondins de Bordeaux	68	71	66	68	84	61	92	56
M. Le Bihan	ST	32	185	85	Dijon FCO	58	42	64	70	64	82	64	80
J. Pollersbeck	GK	27	195	87	Olympique Lyonnais	36	39	22	68	24	51	22	63
B. Brahimi	LM	22	183	73	OGC Nice	76	77	69	60	68	64	63	76
V. Pajot	CM	31	180	70	FC Annecy	63	40	69	71	71	73	77	71
T. Dingomé	CM	31	174	71	ESTAC Troyes	58	58	78	70	76	43	71	65
V. Marchetti	CDM	24	181	71	AC Ajaccio	68	68	78	68	68	61	73	71
Q. Boisgard	CM	25	174	75	FC Lorient	60	53	61	63	72	54	71	69
M. Konaté	ST	29	183	78	Dijon FCO	69	81	72	67	69	90	65	76
M. El Idrissy	ST	23	181	72	AC Ajaccio	74	76	69	62	64	69	69	68
B. Moussiti-Oko	ST	27	184	88	AC Ajaccio	58	59	45	65	46	76	75	91
Y. Koné	LB	26	174	71	AC Ajaccio	74	75	71	63	78	70	63	70
T. Kongolo	CB	28	188	70	Le Havre AC	62	58	62	64	54	80	49	75
L. Assignon	RB	22	181	76	Stade Rennais FC	75	75	71	63	74	62	66	59
B. Maubleu	GK	32	192	83	Grenoble Foot 38	40	39	31	67	33	65	25	62
C. Avinel	CB	35	187	85	AC Ajaccio	68	69	67	65	59	74	73	82
M. Chahiri	LM	25	180	76	Paris FC	75	73	70	67	63	52	64	70
L. Nestor	CB	33	179	70	Grenoble Foot 38	61	39	67	67	74	91	88	78
A. Desmas	GK	28	196	87	Le Havre AC	37	35	26	62	37	32	24	60
J. Moulin	GK	36	184	80	ESTAC Troyes	50	52	48	62	56	42	32	54
G. Perrin	LM	26	169	63	AJ Auxerre	83	82	80	61	89	68	69	59
G. Kyei	ST	26	188	90	Clermont Foot 63	58	69	66	69	63	82	73	90
S. Diarra	LM	23	173	58	FC Lorient	86	84	83	57	84	58	70	35
A. Dari	CB	23	188	75	Stade Brestois 29	55	68	49	65	56	74	61	74
C. Traoré	LB	30	180	74	FC Nantes	67	69	66	58	61	84	76	74
C. Mandouki	CDM	30	179	76	Paris FC	49	53	69	68	71	85	82	74
D. Louiserre	CAM	27	172	63	En Avant de Guingamp	66	62	82	67	87	71	80	67
I. Lihadji	CAM	20	177	70	LOSC Lille	80	75	76	65	76	32	55	44
O. Kanté	CB	32	182	81	Paris FC	34	35	48	66	57	82	79	88
O. Djoco	GK	24	188	90	Clermont Foot 63	30	22	21	62	23	55	29	67
J. Lopy	CDM	30	181	68	FC Sochaux-Montbéliard	73	70	75	67	58	89	91	78

M. Sørensen	CB	23	193	92	OGC Nice	51	54	51	73	54	69	64	79
L. Pélissier	CB	25	188	81	AS Saint-Étienne	63	65	58	64	55	67	62	78
S. Fortes	CB	30	192	85	Racing Club de Lens	34	38	58	62	45	53	75	90
M. Diaw	GK	29	197	98	Clermont Foot 63	44	42	33	54	36	65	31	72
A. Hunou	ST	28	179	70	Angers SCO	75	74	74	70	73	66	70	69
R. Riou	GK	34	189	81	Olympique Lyonnais	45	53	39	69	51	61	32	75
U. Bonnet	ST	28	181	73	Valenciennes FC	71	77	70	65	69	81	83	76
C. Bayala	RM	26	181	68	AC Ajaccio	77	81	74	60	63	60	76	72
A. Leautey	RW	26	172	66	Amiens SC	89	90	84	63	81	56	68	45
Abdu Conté	LWB	24	183	78	ESTAC Troyes	73	73	67	66	65	71	73	80
J. Lefort	LB	28	184	81	Paris FC	65	66	57	70	56	70	77	71
S. Coulibaly	CB	27	193	80	Dijon FCO	69	74	31	61	34	73	67	83
M. Michel	GK	30	189	84	Chamois Niortais Football Club	50	48	30	68	59	63	35	63
B. Boutobba	CAM	23	172	65	Chamois Niortais Football Club	76	72	92	49	90	34	49	34
R. Boissier	CM	28	181	73	Rodez Aveyron Football	71	70	71	68	67	70	83	71
C. Vidal	CB	22	181	76	AC Ajaccio	52	55	46	64	59	77	64	69
M. Guilavogui	RM	24	188	81	Paris FC	77	82	82	68	35	36	61	71
J. Lopez	RM	30	173	68	Paris FC	85	77	86	68	83	61	72	61
B. Diakité	CB	21	185	74	LOSC Lille	69	62	60	65	61	76	74	71
I. Boura	LWB	21	173	68	Racing Club de Lens	77	72	73	66	81	69	69	62
J. Grélin	CDM	25	183	79	Amiens SC	42	47	50	64	59	73	58	68
D. Genreau	CM	23	175	75	Toulouse Football Club	70	64	64	67	70	59	78	62
Fali Candé	LWB	24	184	77	FC Metz	82	86	70	64	61	79	80	70
R. Gurtner	GK	35	182	82	Amiens SC	39	46	32	74	32	68	38	68
C. Matsima	CB	20	193	80	FC Lorient	46	62	39	64	33	73	51	81
K. Spadanuda	RM	25	177	72	AC Ajaccio	74	73	72	53	71	61	59	57
R. Descamps	GK	26	196	82	FC Nantes	45	39	29	61	24	32	20	63
L. Deaux	CDM	33	188	82	Dijon FCO	32	50	60	68	49	75	79	82
V. Lobry	LM	27	181	72	AS Saint-Étienne	77	72	64	62	69	70	83	63

F. Chalabi	RM	19	183	79	Toulouse Football Club	73	70	64	69	63	63	74	71
K. Andrijaš	ST	27	189	86	Clermont Foot 63	65	63	66	62	44	76	69	77
A. Grbic	ST	25	188	82	FC Lorient	67	72	63	65	61	52	71	78
M. Fofana	CB	24	186	75	Amiens SC	68	61	68	66	56	82	80	75
T. Lacoux	CDM	20	175	66	FC Girondins de Bordeaux	70	67	71	67	82	66	77	53
A. Ndour	LB	28	186	70	FC Sochaux-Montbéliard	72	72	71	60	69	76	58	72
F. Balogun	ST	20	178	70	Stade de Reims	79	76	74	66	64	56	63	67
A. Badji	ST	24	189	75	FC Girondins de Bordeaux	83	88	70	52	57	80	83	85
R. Raveloson	CM	25	182	73	AJ Auxerre	75	74	77	66	69	79	81	72
A. Dobre	CAM	23	178	71	Dijon FCO	78	78	85	62	72	68	72	69
K. Haug	GK	24	187	85	Toulouse Football Club	43	49	47	58	41	58	27	59
M. Zeffane	RB	30	176	71	Clermont Foot 63	71	73	72	65	77	67	70	62
S. Sadzoute	LWB	24	172	56	Nîmes Olympique	70	82	74	61	86	83	73	56
K. Boutalib	ST	35	193	82	Paris FC	58	44	65	68	58	74	61	86
J. Porozo	CB	21	192	84	ESTAC Troyes	61	63	39	62	42	72	64	81
M. Sahi	ST	20	175	68	FC Annecy	70	70	64	59	69	67	57	68
Yohan Tavares	CB	34	188	83	Stade Lavallois Mayenne FC	54	58	47	69	49	62	69	73
A. Jakubech	GK	25	188	85	LOSC Lille	36	44	35	63	24	60	29	70
T. Pellenard	CB	28	182	78	AJ Auxerre	59	54	61	63	59	74	66	74
M. Tchokounti	ST	33	191	90	Nîmes Olympique	36	44	57	59	52	69	68	91
K. Dabila	CB	25	183	80	Paris FC	54	52	43	60	65	69	61	69
P. Hamel	ST	28	189	76	Paris FC	57	44	53	69	68	87	64	70
G. Lloris	CB	26	191	87	Le Havre AC	41	43	51	62	44	70	63	82
Y. Maziz	CAM	24	175	68	FC Metz	67	61	72	64	74	60	69	56
V. Lekhal	CDM	28	187	72	Le Havre AC	78	73	80	64	58	92	81	80
B. Guillaume	ST	27	191	86	En Avant de Guingamp	61	41	72	65	57	77	68	81
W. Geubbels	ST	20	185	72	AS Monaco	81	86	74	63	58	60	35	60
Y. Diouf	GK	22	184	74	Stade de Reims	45	44	35	54	38	62	44	52
M. Doumbia	LM	27	173	68	FC Sochaux-Montbéliard	77	78	78	65	82	70	63	62
F. Ayiti	LM	33	175	73	Valenciennes FC	79	82	81	68	75	73	72	71

A. Bruus	RM	23	183	67	ESTAC Troyes	89	84	69	57	66	70	79	73
J. Thiarí©	ST	29	180	68	Le Havre AC	84	87	89	63	80	83	81	75
C. Wooh	CB	20	191	91	Stade Rennais FC	61	78	54	63	42	73	66	80
B. Innocent	CDM	26	178	80	FC Lorient	78	69	74	62	79	81	74	86
L. Ugochukwu	CM	18	191	88	Stade Rennais FC	69	67	69	69	68	70	68	73
K. Sierhuis	ST	24	180	83	Stade de Reims	54	66	50	64	71	65	73	84
D. Chambost	CAM	24	177	70	AS Saint-Étienne	67	60	68	62	68	58	71	67
J. Iglesias	CM	33	170	69	Paris FC	57	51	65	69	73	43	75	61
H. Bandí©	LW	23	178	72	Amiens SC	83	85	82	66	70	73	60	58
P. Cissé©	ST	37	181	73	Amiens SC	53	48	69	65	71	69	49	65
K. Fila	RB	24	183	76	RC Strasbourg Alsace	77	79	71	60	66	53	74	70
H. Vandermersch	RWB	23	180	72	Stade Malherbe Caen	77	76	66	54	69	70	70	66
M. Yattara	ST	28	185	78	Pau FC	72	78	72	60	69	86	61	78
A. Monfray	CB	31	185	76	Grenoble Foot 38	60	69	74	66	63	82	86	83
A. Seidu	RB	22	173	68	Clermont Foot 63	69	55	63	69	69	66	47	43
M. Caillard	GK	28	191	87	FC Metz	48	39	34	62	45	54	33	75
M. Coutadeur	CDM	36	169	67	AC Ajaccio	43	48	75	72	78	68	69	69
J. Livolant	RM	24	175	70	En Avant de Guingamp	77	75	81	61	79	62	75	69
A. Letellier	GK	31	193	93	Paris Saint-Germain	37	39	32	67	25	57	31	72
S. Alakouch	RWB	23	175	66	FC Metz	73	71	77	64	77	43	68	60
J. Le Cardinal	CB	24	182	73	Paris FC	67	70	56	63	66	74	76	73
M. Wieteska	CB	25	187	82	Clermont Foot 63	55	66	65	64	56	87	68	77
D. Petriġġ	GK	34	187	80	FC Nantes	44	43	34	67	41	57	30	57
I. Koní©	ST	23	190	83	FC Lorient	76	78	65	60	74	77	69	87
P. Burner	RWB	26	170	61	Nîmes Olympique	82	76	74	60	83	77	81	72
A. Anani	ST	27	179	68	Grenoble Foot 38	90	90	77	67	78	73	73	68
J. Pi	CDM	28	179	76	Dijon FCO	57	68	83	66	76	53	91	75
A. Coeff	CDM	30	185	74	AJ Auxerre	41	55	73	68	61	90	90	80
O. Thioune	CDM	28	180	72	Dijon FCO	56	49	71	64	69	76	77	70
M. Noubissi	ST	25	180	87	Valenciennes FC	79	78	74	58	72	77	63	85
L. Phiri	CDM	27	173	63	Paris FC	76	79	82	66	84	85	78	57

M. Abline	ST	19	182	81	Stade Rennais FC	80	76	76	63	76	60	57	52
A. Jallow	CAM	23	166	62	FC Metz	78	75	85	62	91	45	66	29
M. Caufriez	CB	25	186	83	Clermont Foot 63	58	60	43	64	53	59	66	76
G. Poussin	GK	23	184	85	FC Girondins de Bordeaux	17	25	22	57	46	58	22	59
A. Gory	ST	25	182	75	Paris FC	82	91	85	63	70	77	59	71
A. Bassi	CAM	24	173	69	FC Metz	72	67	76	66	83	57	67	56
D. Yongwa	LB	21	174	65	FC Lorient	81	89	86	55	84	53	81	67
H. Ćabranović	RB	22	182	75	Angers SCO	68	69	55	58	62	63	69	68
E. Ntim	CB	26	179	72	Stade Malherbe Caen	82	80	72	60	69	87	72	77
F. Bambock	CB	27	181	76	Grenoble Foot 38	66	65	71	60	64	77	81	83
K. Kouao	RB	24	173	65	FC Metz	73	77	72	61	84	73	70	62
L. Leroy	CM	22	187	82	Montpellier Hérault SC	55	60	61	62	60	60	73	67
L. Tchaouna	LM	18	180	67	Dijon FCO	75	76	64	65	69	55	55	55
B. Passi	CB	24	189	78	Chamois Niortais Football Club	31	32	34	60	51	76	46	89
B. Santelli	ST	30	180	77	SC Bastia	89	81	84	62	70	51	74	68
A. Batisse	CB	27	186	87	Pau FC	42	48	58	61	59	76	79	84
I. Aaneba	CB	23	182	75	FC Sochaux-Montbéliard	72	71	68	58	65	76	53	70
T. Baldé	RB	20	182	68	ESTAC Troyes	80	84	70	62	68	69	67	62
C. Diakité	CM	19	173	63	Le Havre AC	72	66	76	65	83	56	70	45
L. Mafouta	ST	27	181	70	US Quevilly Rouen Métropole	76	78	69	59	68	72	70	71
M. Youssouf	RB	34	169	65	AC Ajaccio	64	69	80	69	86	60	71	64
K. Sidibé	CB	23	200	85	US Quevilly Rouen Métropole	45	37	47	63	35	57	71	79
J. Adéoti	CDM	33	183	81	Stade Lavallois Mayenne FC	40	50	65	64	70	69	76	72
Q. Lecoeuche	LB	28	172	65	Valenciennes FC	80	79	83	57	81	71	83	64
R. Strzemiński	GK	23	188	80	FC Girondins de Bordeaux	24	25	31	54	50	50	27	53
Z. Davitashvili	RM	21	175	63	FC Girondins de Bordeaux	78	73	72	65	79	43	65	64
H. Mbock	CM	22	186	82	Stade Malherbe Caen	65	52	63	61	67	57	64	72
F. Wadja	CB	27	185	83	Stade Malherbe Caen	66	66	66	63	67	76	89	87

J. Gaspar	RWB	25	172	58	Grenoble Foot 38	79	83	87	61	89	86	84	59
E. Í"marsson	ST	27	180	73	Ní®mes Olympique	87	82	77	59	65	72	85	70
Alexsandro Ribeiro	CB	22	189	82	LOSC Lille	55	69	45	62	32	76	63	81
S. Salles-Lamonge	CAM	26	170	67	SC Bastia	61	70	66	63	89	53	79	49
S. Allagbí©	GK	28	189	79	Dijon FCO	31	28	59	56	32	41	28	45
A. Olliero	GK	26	193	85	Pau FC	47	45	39	59	41	59	23	75
A. Kalulu	RW	26	166	68	FC Sochaux-Montbí©liard	91	91	92	61	92	81	61	44
N. Penneteau	GK	41	185	78	Stade de Reims	24	26	36	57	41	51	26	58
S. Quemper	LB	29	178	75	En Avant de Guingamp	75	80	72	56	72	70	85	69
V. Jacob	LM	28	171	67	Dijon FCO	81	73	76	48	85	53	68	40
E. Koffi	RB	27	174	68	Pau FC	85	84	76	56	71	56	83	73
M. Barthelmí©	RM	33	172	73	En Avant de Guingamp	62	69	60	70	83	55	63	60
L. Ní©ry	RB	31	174	73	Grenoble Foot 38	69	73	82	61	78	89	84	74
S. Agouzoul	CB	24	192	75	FC Sochaux-Montbí©liard	44	49	34	65	43	67	45	74
J. Krasso	ST	24	187	90	AS Saint-Í%otienne	65	61	57	66	54	69	52	69
M. Diarra	CB	24	184	70	Grenoble Foot 38	53	59	49	64	52	70	60	65
G. Sangarí©	CDM	25	180	76	US Quevilly Rouen Mí©tropole	55	62	60	65	66	55	68	61
M. Baudry	CB	32	187	85	Stade Lavallois Mayenne FC	43	41	36	65	56	39	73	79
L. Chevalier	GK	20	189	78	LOSC Lille	42	40	32	59	38	53	34	43
A. GonÍşalves	RWB	36	179	83	Stade Lavallois Mayenne FC	36	54	70	71	76	81	91	83
A. Bosetti	RW	29	170	65	FC Annecy	74	74	80	66	76	77	61	60
A. Maraval	GK	28	184	79	Ní®mes Olympique	42	40	33	55	56	55	18	58
I. Cissí©	CB	26	185	70	Stade Malherbe Caen	71	73	70	62	73	85	76	79
E. Basilio	GK	27	187	75	En Avant de Guingamp	44	49	30	67	65	54	26	58
M. Talbi	CB	24	190	81	FC Lorient	55	62	60	62	68	71	60	77
J. Roye	CM	33	175	72	Stade Lavallois Mayenne FC	61	68	73	64	75	60	82	60
D. Bakwa	RM	19	179	77	FC Girondins de Bordeaux	79	80	78	62	70	47	68	67
J. Ponceau	CAM	21	170	62	FC Lorient	75	75	80	63	83	60	80	44

S. Chergui	CB	23	185	78	Paris FC	58	49	71	66	68	72	43	71
A. Sissoko	RB	25	178	68	US Quevilly Rouen Métropole	78	75	62	61	76	56	68	62
J. Marité	CM	30	177	73	Dijon FCO	44	31	68	71	61	63	63	56
A. Virginus	RM	19	175	65	LOSC Lille	90	90	87	55	72	58	53	35
A. Moueffek	CAM	21	179	71	AS Saint-Étienne	69	66	77	66	66	56	60	63
F. Sollacaro	GK	28	182	76	AC Ajaccio	42	46	37	55	59	64	28	47
F. El Melali	CAM	25	168	65	Angers SCO	70	69	71	53	91	32	33	34
T. Sainte-Luce	LWB	23	181	72	Montpellier Hérault SC	74	76	72	63	69	66	70	60
I. Touré	CB	19	204	75	Olympique de Marseille	63	70	53	60	47	74	65	91
T. Vargas	RWB	22	175	73	Nîmes Olympique	72	72	67	65	71	76	69	56
J. Masson	CDM	24	182	76	Valenciennes FC	57	64	64	62	59	74	87	79
A. Bonnet	LM	35	173	65	US Quevilly Rouen Métropole	73	67	85	62	82	32	61	65
G. Durbant	ST	30	183	75	Stade Lavallois Mayenne FC	60	60	71	72	59	68	81	66
R. Assalé	RW	28	167	65	Dijon FCO	91	78	92	67	91	41	80	42
P. Yade	ST	22	185	76	ESTAC Troyes	84	80	69	53	58	55	56	76
S. D'Almeida	CDM	26	178	78	Pau FC	80	77	77	63	75	80	91	81
G. Paquiez	RB	28	182	72	Grenoble Foot 38	68	70	68	60	68	65	77	73
H. Sy	LWB	26	170	75	Amiens SC	73	77	76	57	82	75	83	71
L. Mpasi	GK	27	182	78	Rodez Aveyron Football	45	46	35	66	58	60	21	68
M. Merghem	LM	24	185	75	En Avant de Guingamp	75	72	77	53	74	59	71	69
B. Goncalves	CB	25	190	72	Stade Lavallois Mayenne FC	68	69	63	56	53	75	80	76
I. Filipović	GK	27	197	92	Paris FC	21	32	36	59	20	37	24	71
J. Maggiotti	CAM	26	186	86	Stade Lavallois Mayenne FC	63	64	62	64	60	62	69	67
C. Zady Sery	RM	22	177	72	Stade Malherbe Caen	92	84	83	50	81	46	64	59
S. Ben Seghir	RW	19	174	57	Olympique de Marseille	70	63	64	72	76	51	37	31
C. Abi	ST	22	187	71	AS Saint-Étienne	77	76	69	60	40	69	68	75
S. Ngapandouetnbu	GK	19	186	74	Olympique de Marseille	28	15	36	47	43	59	26	55

L. Delaurier-Chaubet	LM	20	173	60	FC Girondins de Bordeaux	73	67	56	53	83	47	57	34
W. Caddy	ST	25	183	83	Paris FC	79	82	73	64	78	64	51	75
B. Roux	CB	22	190	79	En Avant de Guingamp	56	61	53	61	45	73	62	75
N. Diliberto	CAM	20	175	65	Valenciennes FC	68	68	75	68	83	56	66	47
M. Jakolij	ST	25	182	74	Angers SCO	70	67	70	67	67	67	54	66
A. Richardson	CM	20	195	79	Le Havre AC	57	58	67	64	60	65	73	70
K. Guessoum	CB	23	176	70	Nîmes Olympique	69	66	60	63	72	72	51	66
N. Ueda	CB	27	186	77	Nîmes Olympique	43	48	65	63	66	60	69	75
S. Ben Youssef	CB	33	189	82	US Quevilly Rouen Métropole	36	53	28	55	32	77	37	77
Z. Touré	CB	32	183	79	Dijon FCO	51	55	49	72	59	75	66	80
N. Lemaitre	GK	25	185	83	US Quevilly Rouen Métropole	34	32	24	58	37	32	28	26
M. Akliouche	CAM	20	175	63	AS Monaco	72	75	76	64	75	36	58	59
A. Musaba	ST	21	182	72	FC Metz	85	89	79	59	68	75	64	69
N. Alioui	CAM	23	175	64	Le Havre AC	59	79	76	62	76	83	60	61
X. Kouassi	CDM	32	174	69	Pau FC	63	57	67	65	75	87	80	72
L. Pintor	RW	21	179	66	AS Saint-Étienne	78	77	79	47	75	57	55	58
J. Obiang	LWB	28	170	64	Stade Malherbe Caen	84	83	80	61	88	81	72	58
M. Perez	CDM	31	182	78	Grenoble Foot 38	60	81	84	65	78	66	73	77
A. Sauvage	GK	30	186	82	Stade Lavallois Mayenne FC	45	43	41	52	34	58	34	71
I. Chetti	LB	27	176	70	Angers SCO	68	69	54	59	74	63	63	49
Q. Daubin	CDM	26	183	74	Stade Malherbe Caen	49	58	56	55	61	65	74	80
W. Tchimbembé	CAM	24	180	76	En Avant de Guingamp	80	88	75	62	59	34	68	61
A. Abdenmour	CB	32	187	84	Rodez Aveyron Football	51	48	56	63	51	69	61	75
B. Jeannot	ST	30	183	78	Stade Malherbe Caen	63	54	77	70	67	77	40	70
Y. Armougom	LWB	24	173	71	FC Sochaux-Montbéliard	80	77	73	62	82	61	72	62
N. Fadiga	LM	22	187	76	Stade Brestois 29	87	88	74	59	67	58	72	68
R. Spano	ST	27	182	76	FC Annecy	72	69	60	60	53	56	62	63
K. Ruiz-Atil	CAM	19	177	60	AJ Auxerre	69	66	81	59	80	50	54	32

R. Pereira de Sa	CAM	25	177	71	FC Sochaux-Montbéliard	73	71	72	54	69	47	53	62
M. Gorgelin	GK	31	187	83	Le Havre AC	47	48	40	65	46	58	30	70
C. Rocchia	LWB	24	172	70	Dijon FCO	75	79	79	64	81	72	78	63
A. Sanyang	LM	23	173	69	Grenoble Foot 38	88	82	91	51	80	84	70	49
M. Bernauer	CDM	24	186	77	Paris FC	65	63	61	66	64	62	61	68
P. Ba	ST	29	174	68	Pau FC	71	75	68	62	80	68	76	78
C. Operi	LB	25	183	78	Le Havre AC	72	80	66	61	63	54	74	68
F. Kanouté	CDM	23	186	78	FC Sochaux-Montbéliard	60	61	67	61	67	73	64	77
Buatu	CB	28	187	83	Valenciennes FC	62	54	42	59	44	72	65	79
M. Adeline	CAM	18	180	63	Stade de Reims	65	64	60	63	70	60	59	58
N. Opoku	CB	24	190	78	Amiens SC	64	60	59	60	44	71	65	85
T. De Smet	CB	24	182	65	Stade de Reims	67	72	61	60	69	69	70	68
C. Sabaly	RM	23	168	56	FC Metz	80	84	86	56	88	54	67	32
B. Danger	CDM	24	182	73	Rodez Aveyron Football	76	73	64	67	63	66	80	74
M. El Arouch	CAM	18	172	64	Olympique Lyonnais	78	73	88	58	87	45	57	56
H. Abdelli	CAM	22	188	81	Angers SCO	72	65	60	63	42	69	66	74
Vandenabeele .%o	CB	30	184	77	Rodez Aveyron Football	46	34	53	62	61	84	70	76
K. N'Doram	CB	26	185	77	FC Metz	64	59	62	62	58	77	70	75
G. Kyeremeh	RM	22	175	60	Stade Malherbe Caen	89	78	75	47	82	67	45	33
D. Doucoure	CAM	17	181	79	Stade Rennais FC	77	79	77	58	75	56	53	54
Nguyễn Quang Hải	CAM	25	169	63	Pau FC	85	87	80	60	88	58	75	47
S. Cibois	GK	24	192	83	Rodez Aveyron Football	36	30	31	57	54	59	30	65
M. Do Couto	LM	25	172	62	FC Sochaux-Montbéliard	75	76	79	52	84	63	61	30
J. Tell	ST	25	185	74	Grenoble Foot 38	65	54	65	64	60	70	60	67
Q. Cornette	RW	28	172	75	Le Havre AC	86	73	88	62	82	62	39	56
N. Holm	ST	21	186	87	Stade de Reims	76	72	64	55	81	82	76	81
K. Boto	LWB	26	183	71	AJ Auxerre	74	72	71	61	63	76	86	73
B. Poulain	CB	34	189	82	Nîmes Olympique	33	31	47	62	40	33	62	78
Y. Clementia	GK	24	188	80	Stade Malherbe Caen	39	37	44	59	38	59	29	65
Y. Kitala	ST	24	186	83	Le Havre AC	70	72	63	51	57	76	58	80

A. Ngouyamsa	RB	21	176	75	Dijon FCO	76	75	80	55	75	63	69	66
O. Camara	CB	19	197	90	Angers SCO	34	44	46	62	45	41	69	84
J. Placide	GK	34	181	89	SC Bastia	53	56	38	68	38	55	27	70
P. Lemonnier	CB	28	184	81	En Avant de Guingamp	55	59	55	61	60	81	80	76
Y. Larouci	LWB	21	176	68	ESTAC Troyes	76	74	64	62	68	70	59	55
C. Vincent	CM	29	178	74	SC Bastia	61	70	70	62	70	53	74	61
Y. Kaabouni	CM	27	179	66	FC Sochaux-Montbéliard	64	70	81	64	77	56	89	69
I. Gomis	CAM	22	175	66	Amiens SC	72	71	67	60	70	48	63	70
J. Chougrani	CB	31	185	82	Rodez Aveyron Football	73	71	62	61	59	88	74	75
C. Alhadhur	RB	30	172	65	AC Ajaccio	64	68	77	62	83	66	68	55
Xande Silva	CAM	25	177	74	Dijon FCO	74	70	75	62	71	65	51	59
T. Muyumba	CDM	25	165	60	En Avant de Guingamp	76	74	72	62	92	68	74	62
D. Guidi	CB	26	177	75	SC Bastia	67	62	71	55	75	91	86	75
O. Zandén	LB	20	179	74	Toulouse Football Club	72	60	57	54	61	60	77	59
K. N'Chobi	ST	26	177	76	Stade Lavallois Mayenne FC	87	91	64	68	81	60	72	56
D. Ouattara	ST	20	177	71	FC Lorient	75	77	55	57	70	61	48	55
C. Diedhiou	CB	34	191	76	US Quevilly Rouen Métropole	59	64	44	53	49	83	66	82
L. Vallier	LM	23	178	72	Chamois Niortais Football Club	80	79	74	53	44	58	73	68
K. Dembélé	RW	19	168	65	Stade Brestois 29	87	82	90	54	89	37	56	33
L. Buades	RM	24	180	75	Rodez Aveyron Football	76	74	65	59	62	50	70	70
N. Ouammou	LWB	29	181	73	Rodez Aveyron Football	73	72	75	55	69	33	72	57
J. Blázquez	GK	21	193	87	Stade Brestois 29	22	25	33	60	45	65	26	55
A. Kashi	CDM	33	178	76	FC Annecy	59	44	75	62	72	75	64	69
Y. Demoncy	CM	26	181	75	Paris FC	65	62	65	66	70	32	88	64
B. Barcola	ST	19	186	70	Olympique Lyonnais	71	76	75	61	61	41	53	52
J. Moutachy	RB	24	175	68	Chamois Niortais Football Club	85	87	79	50	80	67	80	66
M. de Gevigney	CB	22	186	77	Nîmes Olympique	64	64	43	65	55	66	68	65
A. Teikeu	CB	32	189	85	Stade Malherbe Caen	37	33	47	51	49	91	67	80

E. Salles	GK	28	187	78	Grenoble Foot 38	25	26	31	62	28	40	41	64
I. Lomami	RB	18	180	75	Olympique Lyonnais	77	78	79	59	81	66	61	61
Z. Diallo	CB	35	194	91	Le Havre AC	34	34	32	60	33	46	51	90
J. Mwanga	CB	19	184	72	FC Girondins de Bordeaux	67	68	55	65	62	68	68	66
B. Bouanani	CAM	17	172	64	OGC Nice	74	73	72	45	77	51	54	46
V. Ozornwafor	CB	23	194	85	FC Sochaux-Montbéliard	67	55	38	58	31	79	57	83
B. Makouana	RM	19	181	73	Montpellier Hérault SC	82	82	70	64	72	65	57	59
I. Conti	CB	26	191	82	Chamois Niortais Football Club	62	38	64	51	55	78	70	92
J. Ekomf	LB	18	179	73	FC Girondins de Bordeaux	73	69	51	63	65	63	67	58
H. Saivet	CAM	31	174	76	Pau FC	70	61	75	52	73	82	36	59
M. Phakton	ST	22	185	75	Grenoble Foot 38	80	85	72	58	61	70	77	78
M. Zemzemi	CAM	22	186	73	Chamois Niortais Football Club	72	67	74	46	64	54	69	74
Z. Naidji	ST	27	177	71	Stade Lavallois Mayenne FC	74	70	76	63	72	64	72	58
F. Eboa Eboa	CB	25	186	80	En Avant de Guingamp	43	45	56	52	68	88	72	84
Y. Merdji	LM	28	175	69	Chamois Niortais Football Club	78	81	80	50	80	81	78	73
M. Kaba	CDM	20	185	71	Valenciennes FC	64	59	58	63	53	48	76	69
F. David	CAM	29	180	67	Rodez Aveyron Football	81	74	83	59	70	62	76	67
L. Rajot	CM	24	179	68	Rodez Aveyron Football	76	71	78	62	71	51	67	68
T. Arokodare	ST	21	197	97	Amiens SC	61	53	49	60	39	75	70	91
F. Michel	CAM	30	172	63	Grenoble Foot 38	82	77	91	65	88	69	84	52
A. Ngando	CAM	28	177	71	Grenoble Foot 38	72	56	81	58	81	56	34	38
Z. Boucher	GK	30	181	78	SC Bastia	54	58	57	64	64	82	42	75
C. Boli	CAM	23	175	65	Pau FC	72	64	79	62	73	35	44	45
F. Escales	GK	26	184	78	FC Annecy	19	33	23	48	44	63	32	69
S. Beusnard	CAM	30	170	62	Pau FC	82	81	64	65	90	54	60	48
G. Barf's	CM	21	187	70	Montpellier Hérault SC	61	60	60	60	61	56	68	67
C. Depres	ST	27	188	80	Rodez Aveyron Football	34	32	33	59	52	73	31	79
J. Hadjam	LM	19	184	83	Paris FC	76	78	68	58	64	68	75	74

T. Ducrocq	CM	22	176	62	SC Bastia	68	74	80	62	80	78	74	64
F. Magri	ST	22	178	70	SC Bastia	76	74	69	51	73	69	66	64
L. Joseph	ST	21	183	73	FC Metz	77	77	66	56	72	65	56	57
A. Barry	CB	22	185	78	Amiens SC	72	80	60	60	61	82	64	76
A. Boutoutaou	CAM	21	169	56	Valenciennes FC	79	72	91	55	91	49	31	31
J. Ruiz	CB	24	188	82	Pau FC	67	66	60	59	49	72	68	73
M. Lachuer	CAM	21	170	65	Amiens SC	81	80	81	60	86	34	48	43
N. Mbemba	CAM	27	182	75	Le Havre AC	63	69	72	63	69	82	70	71
J. Nijigiz	CAM	24	177	71	Pau FC	71	77	74	65	77	63	71	58
A. Sangante	CB	20	189	76	Le Havre AC	50	61	52	62	56	74	64	74
L. Lumeka	CAM	23	170	71	ESTAC Troyes	77	75	81	57	73	32	44	51
G. Kilama	CB	23	182	80	Chamois Niortais Football Club	72	64	82	54	65	84	84	72
J. Pendant	LB	25	177	64	US Quevilly Rouen M1@tropole	72	72	66	59	70	64	71	62
Y. Thuram	GK	33	187	85	US Quevilly Rouen M1@tropole	39	39	70	65	46	67	34	77
Y. Begraoui	ST	20	178	70	Toulouse Football Club	73	73	68	65	80	71	70	60
J. Thomasen	CM	26	177	65	Nîmes Olympique	59	58	61	61	85	70	79	58
W. Taïbi	CM	20	184	70	Angers SCO	60	48	58	49	75	45	78	63
J. Sainati	CB	33	183	83	SC Bastia	66	60	68	60	61	80	75	77
Z. Ould Khaled	CDM	22	195	79	Angers SCO	51	50	53	58	36	55	63	72
B. Straalman	CB	25	193	74	Grenoble Foot 38	46	58	55	54	33	72	77	78
J. Danley	CDM	22	180	75	FC Metz	66	67	64	58	68	71	66	68
K. Schur	RWB	31	179	76	SC Bastia	79	78	72	55	67	71	77	67
P. Diaw	CB	27	196	91	Stade Lavallois Mayenne FC	73	76	70	61	34	78	68	83
Y. Cassubie	CDM	21	184	78	Chamois Niortais Football Club	68	72	65	56	58	69	67	72
I. Wadji	ST	27	175	74	AS Saint-Étienne	87	87	80	58	83	81	63	67
K. Rocheteau	CF	28	179	71	Chamois Niortais Football Club	71	69	59	60	61	69	59	50

M. Bokele	CB	22	189	78	FC Girondins de Bordeaux	64	60	49	54	68	68	62	67
R. Ndiaye	CDM	20	179	70	FC Sochaux-Montbéliard	73	71	73	55	76	71	73	70
A. Fofana	LWB	22	173	63	Dijon FCO	86	85	83	54	80	59	66	51
A. Gersbach	LB	25	183	73	Grenoble Foot 38	83	81	80	57	71	70	71	71
S. Renel	CAM	20	183	71	Chamois Niortais Football Club	81	72	78	53	71	62	44	59
K. Tapoko	CDM	28	196	90	Stade Lavallois Mayenne FC	47	44	48	58	38	49	77	83
Y. Lagha	ST	18	185	78	Olympique Lyonnais	67	73	68	59	65	64	55	69
J. Rocchi	LM	33	170	64	FC Annecy	74	74	88	60	86	49	80	50
I. Gharbi	CAM	18	167	58	Paris Saint-Germain	72	64	80	55	87	43	33	35
K. Perrot	RB	33	170	65	Stade Lavallois Mayenne FC	67	64	75	64	78	60	78	59
A. Abdallah	LB	24	170	68	Rodez Aveyron Football	82	77	89	54	88	87	77	64
E. Sylvestre	LM	22	173	69	Pau FC	73	62	73	55	79	47	47	50
G. Gbelli	CM	29	179	75	US Quevilly Rouen Métropole	68	66	57	63	67	78	87	66
Y. Boling-Kane	CB	31	185	76	US Quevilly Rouen Métropole	56	52	65	58	61	78	70	76
E. Dieye	RM	20	182	75	AS Saint-Étienne	89	90	79	58	63	50	63	61
P. Cros	CB	30	185	77	Stade Lavallois Mayenne FC	58	56	56	62	62	70	70	73
A. Linguet	RWB	22	176	69	Valenciennes FC	66	70	67	56	70	68	66	60
Y. Baldi	CB	29	190	86	Stade Lavallois Mayenne FC	55	54	51	56	47	73	76	77
T. Arconte	ST	18	181	76	Stade Brestois 29	74	73	69	52	67	57	60	65
S. Laiton	GK	22	190	85	AJ Auxerre	50	44	64	67	51	72	42	71
M. Ahlinvi	CAM	22	183	68	Dijon FCO	65	61	72	63	69	63	72	66
K. Testud	LM	30	180	66	FC Annecy	69	59	58	54	66	41	47	56
M. Jeannin	GK	31	187	81	FC Sochaux-Montbéliard	49	50	37	55	57	59	27	71
A. Fillon	CDM	27	176	70	FC Annecy	55	55	58	55	66	61	66	56
M. Sivi	RB	24	173	73	En Avant de Guingamp	69	75	61	52	64	68	62	69

S. Loric	LB	21	183	73	FC Lorient	66	69	61	53	73	66	58	45
L. Bury	LB	26	184	77	Pau FC	74	70	68	53	69	78	76	69
K. Doumbia	CAM	19	170	53	Stade de Reims	69	68	60	59	74	59	62	52
B. Pierret	CDM	22	186	82	US Quevilly Rouen MÍ@tropole	70	62	64	59	53	66	65	66
ba™ؤPor .إپ	CDM	22	180	70	Racing Club de Lens	66	62	73	58	68	72	83	71
A. Pembأأأ	RM	21	180	70	Rodez Aveyron Football	87	85	76	58	68	42	53	56
S. Raux-Yao	CB	23	197	86	Rodez Aveyron Football	38	53	48	48	36	82	64	90
Y. Ndiaye	CB	24	190	75	Paris FC	47	38	32	58	32	70	47	82
T. Cissokho	CB	22	200	88	US Quevilly Rouen MÍ@tropole	51	42	39	54	30	72	66	88
W. Younoussa	CDM	20	174	66	Rodez Aveyron Football	71	70	85	54	89	65	76	34
L. Sinayoko	ST	22	186	81	AJ Auxerre	58	53	59	60	58	70	45	76
A. Temanfo	RB	29	183	82	FC Annecy	62	65	52	60	62	71	60	66
G. Mutombo	CB	26	191	75	ESTAC Troyes	38	34	31	55	52	49	62	82
F. Da Silva	CAM	19	178	67	Olympique Lyonnais	64	67	76	60	77	55	59	60
J. Ruque	RB	22	176	65	FC Annecy	67	59	58	58	68	64	70	61
Y. Soumarأ	RW	22	173	55	Olympique Lyonnais	68	76	84	54	83	54	49	57
R. Saأ-d	CAM	22	178	73	Nأmes Olympique	80	79	79	44	77	38	43	30
A. Philiponeau	CDM	22	176	65	FC Annecy	49	45	50	63	65	65	66	72
M. Doucourأ	ST	22	181	75	Nأmes Olympique	67	75	63	54	60	71	61	82
S. Ring	LWB	27	178	74	Amiens SC	73	68	71	54	70	59	73	65
M. George	ST	28	189	89	Pau FC	80	83	65	60	54	84	60	83
B. Nokoue	RB	20	180	70	AS Saint-أotienne	72	74	59	59	68	62	72	66
K. Nagera	ST	20	177	65	Paris Saint-Germain	87	79	72	54	68	79	54	45
K. Kaأ-bouأ	LWB	23	182	65	SC Bastia	62	72	68	58	70	65	68	54
L. Mouyokolo	CB	21	194	85	Rodez Aveyron Football	61	58	51	53	39	70	64	86
I. Doukourأ	CB	18	183	80	RC Strasbourg Alsace	61	67	44	61	62	68	53	70
M. Xantippe	LWB	20	183	70	Amiens SC	69	68	67	52	74	70	48	53
G. Kokhreidze	CAM	23	171	73	Grenoble Foot 38	77	76	73	55	85	64	51	43
Y. Okou	CB	19	180	75	AS Monaco	71	73	68	59	67	68	54	70

M. de Iriondo	CDM	29	179	75	Grenoble Foot 38	71	62	76	62	75	73	84	78
S. Yatabarí	CDM	33	190	83	FC Sochaux-Montbéliard	35	56	39	70	38	63	60	76
D. Dianessy	CAM	26	182	66	Pau FC	70	74	76	55	65	71	32	58
A. Talal	CAM	26	176	65	SC Bastia	72	69	69	56	75	79	66	53
A. Robic	RM	36	181	73	SC Bastia	71	66	74	65	62	47	67	69
F. Lemar	CM	18	181	73	AS Monaco	63	64	57	62	64	57	71	65
M. Riou	CB	21	181	77	En Avant de Guingamp	49	57	45	59	54	68	68	73
F. Martin	CAM	32	180	84	Valenciennes FC	61	57	68	67	79	61	33	70
T. Boulhendi	GK	21	185	77	OGC Nice	49	48	51	58	48	59	34	64
S. Essende	ST	24	192	87	Stade Malherbe Caen	68	71	56	46	43	66	57	83
L. Palun	RWB	33	184	73	SC Bastia	62	69	62	62	70	74	72	71
K. Van Den Kerkhof	RWB	26	190	82	SC Bastia	68	68	58	58	56	67	68	64
D. Gomis	LM	29	173	68	Pau FC	71	69	67	56	72	45	45	58
J. Flemmings	LW	26	183	77	Toulouse Football Club	66	65	57	47	59	37	40	60
H. Konaté	GK	27	182	77	Valenciennes FC	54	52	55	59	61	70	22	57
A. Val	CAM	22	185	75	Rodez Aveyron Football	69	63	70	59	61	69	61	63
P. Mboup	LW	19	175	70	Olympique Lyonnais	82	83	78	52	80	45	50	55
L. Dias	GK	23	185	80	Nîmes Olympique	27	30	36	55	49	64	27	43
M. Cham	CAM	21	180	67	Clermont Foot 63	82	74	81	45	61	51	40	43
C. Billemaz	LM	23	175	70	FC Annecy	77	79	74	45	80	42	59	56
J. Mendes	ST	31	186	80	Rodez Aveyron Football	65	75	62	53	63	78	73	86
M. Saban	CAM	20	177	68	AS Saint-Étienne	83	82	78	57	73	46	49	44
Dylan Tavares	LWB	25	172	60	SC Bastia	71	73	65	58	70	69	70	60
K. Corredor	ST	21	182	72	Rodez Aveyron Football	84	80	75	53	61	71	60	63
M. Alfarela	ST	24	173	67	SC Bastia	75	70	77	60	78	56	58	50
H. Mouali	LB	24	175	69	Stade Lavallois Mayenne FC	67	60	58	55	73	60	65	49
S. Sanna	CAM	23	170	65	Stade Lavallois Mayenne FC	72	69	62	64	82	41	33	42
K. Farade	ST	26	188	80	FC Annecy	68	71	52	54	52	64	66	74

A. Hountondji	ST	19	175	64	US Quevilly Rouen Métropole	69	72	60	59	77	64	65	63
J. Louis-Jean	RB	18	177	68	FC Girondins de Bordeaux	71	67	54	57	73	64	60	45
D. Bansais	RB	28	177	71	US Quevilly Rouen Métropole	73	73	67	47	78	77	75	69
L. Calodat	LM	20	171	64	AS Saint-Étienne	77	75	75	57	86	60	72	58
B. Elmaz	CAM	19	173	65	Olympique de Marseille	61	65	68	58	84	65	58	40
J. Escartin	CB	19	185	76	Stade Brestois 29	62	68	56	58	58	72	58	66
H. Camara	CB	20	197	82	En Avant de Guingamp	44	61	44	59	37	67	53	81
J. Botuël	ST	19	184	74	AC Ajaccio	73	70	70	49	67	75	49	59
G. Jean	CB	22	191	80	FC Annecy	58	56	44	52	47	70	60	68
B. Baiye	CB	21	177	75	Clermont Foot 63	64	36	58	62	74	66	63	74
G. Coelho	RWB	22	180	75	Rodez Aveyron Football	71	69	66	57	67	71	68	71
B. Fall	GK	21	198	80	AS Saint-Étienne	24	29	37	50	28	36	27	63
M. Senaya	RB	21	179	65	Rodez Aveyron Football	66	70	55	59	69	57	61	61
F. Fumu Tamuzo	RW	27	180	73	Stade Lavallois Mayenne FC	87	89	81	55	77	67	61	66
T. Ismaheel	LW	21	170	65	FC Lorient	81	82	87	46	85	35	57	36
O. Gene	CDM	19	180	75	Amiens SC	67	65	62	64	64	64	65	65
R. Ferhaoui	CAM	25	183	74	Stade Lavallois Mayenne FC	64	62	61	52	62	60	60	58
S. da Silva	ST	31	185	75	Stade Lavallois Mayenne FC	48	54	59	55	57	70	60	71
R. Duterte	LB	28	178	69	Stade Lavallois Mayenne FC	61	60	57	56	66	62	75	56
A. Nazih	GK	20	192	76	Nîmes Olympique	38	45	34	54	28	47	34	57
M. Hautbois	GK	31	181	75	Stade Lavallois Mayenne FC	39	49	35	56	42	52	29	55
E. Bitshiabu	CB	17	196	96	Paris Saint-Germain	35	43	32	56	32	48	58	91
D. Diani	CB	24	195	78	Stade Malherbe Caen	56	69	58	53	39	59	74	86
L. Costa	CB	21	188	87	Toulouse Football Club	55	54	33	59	39	72	66	80
P. Charruau	GK	28	187	87	Amiens SC	42	52	37	53	43	58	17	82

B. Bouchouari	CAM	20	165	65	AS Saint-Étienne	68	63	66	63	69	57	66	48
A. Georgen	RB	23	172	69	AJ Auxerre	68	71	77	50	81	59	47	58
F. Lajugie	CB	26	187	72	FC Annecy	64	61	56	58	57	61	62	66
M. Picouleau	CAM	22	171	63	Valenciennes FC	69	62	59	61	84	58	34	39
D. Jean	ST	19	175	70	RC Strasbourg Alsace	83	81	78	60	78	56	57	51
J. N'Guessan	RM	19	177	80	Nîmes Olympique	70	70	66	60	65	52	67	59
E. Seidou	LB	30	182	87	Stade Lavallois Mayenne FC	65	67	73	50	60	66	80	77
I. Soumaré	ST	21	182	78	US Quevilly Rouen Métropole	81	82	60	59	81	61	65	42
M. Bastian	LB	21	173	65	FC Annecy	69	73	60	51	69	59	68	51
J. Olaitan Ishola	RM	20	174	72	Chamois Niortais Football Club	80	76	74	47	66	58	73	76
Park Jung Bin	LM	28	175	73	Rodez Aveyron Football	74	75	79	54	76	51	50	43
J. Belocian	CB	17	182	73	Stade Rennais FC	59	69	65	59	67	61	56	69
B. M'Bondo	CB	20	184	75	Chamois Niortais Football Club	59	57	40	47	57	75	71	72
E. Depussay	CDM	20	177	71	FC Girondins de Bordeaux	64	56	56	64	71	57	68	54
Matis Carvalho	GK	23	186	80	Montpellier Hérault SC	37	38	36	52	43	59	29	62
G. Manvelyan	CAM	20	180	68	FC Nantes	76	66	69	41	71	35	31	31
S. Delaye	CAM	20	171	60	Montpellier Hérault SC	62	60	75	60	84	64	37	37
D. Rouyard	GK	22	194	90	FC Girondins de Bordeaux	22	33	38	52	56	55	27	56
J. Affamah	ST	20	175	70	FC Nantes	76	73	74	52	64	72	46	52
U. Bertelli	CM	18	168	62	Olympique de Marseille	55	52	72	54	64	54	60	51
T. Tamas	LB	21	178	68	Montpellier Hérault SC	64	66	61	51	69	64	62	50
S. Cissé	CM	30	172	70	Grenoble Foot 38	59	65	63	55	67	80	78	80
E. Gebreyesus	RM	18	187	71	Olympique de Marseille	69	71	62	57	49	42	52	51
J. Evan's	LM	23	180	70	Pau FC	72	69	66	52	55	44	60	48
K. Mouanga	CB	21	190	85	FC Annecy	39	37	42	49	41	73	63	82
I. Hamache	CAM	19	178	74	Valenciennes FC	73	70	68	52	81	42	45	47
S. Doucouré	ST	20	193	75	FC Lorient	50	56	49	56	45	71	62	74
M. Sitti	CDM	22	182	73	FC Annecy	64	52	65	54	67	67	61	64

R. Labonne	RWB	24	180	76	Nîmes Olympique	78	75	59	52	66	59	68	57
A. Kamardin	CB	20	183	72	Olympique de Marseille	63	71	48	55	60	74	60	60
A. Salama	ST	21	192	78	Angers SCO	57	63	51	53	46	59	51	69
M. Diongue	CF	30	179	66	SC Bastia	66	55	73	61	70	56	68	57
S. Benchamma	RM	22	185	71	Chamois Niortais Football Club	73	71	67	51	62	64	65	60
N. Monzango	CB	21	184	72	Pau FC	68	53	49	48	75	75	33	56
D. Youfeigane	GK	22	188	84	En Avant de Guingamp	42	37	38	54	27	36	22	59
S. Shamal	RW	26	182	73	FC Annecy	74	75	71	60	67	62	58	56
A. Sanaia	CB	32	181	70	Rodez Aveyron Football	40	56	64	57	70	80	72	68
A. Sagna	RM	23	172	70	Chamois Niortais Football Club	83	79	73	57	81	81	58	35
M. Sangaré	ST	23	195	80	Amiens SC	70	68	62	48	51	65	54	78
A. Dia Ndiaye	ST	22	186	78	FC Metz	73	74	58	60	61	70	61	63
E. Mahmoud	RM	21	177	68	Le Havre AC	75	75	79	56	77	54	64	60
K. Bonnevie	GK	20	191	76	Olympique Lyonnais	22	17	28	58	23	45	20	62
G. Bentil	ST	21	185	73	Chamois Niortais Football Club	73	76	62	55	62	75	70	74
T. Tormin	RM	21	177	67	Chamois Niortais Football Club	85	81	80	51	75	60	57	54
L. Delpech	CM	19	178	68	Nîmes Olympique	65	58	63	59	73	60	71	41
A. Wahib	LWB	22	177	68	Le Havre AC	69	72	63	58	72	71	73	59
R. Bourlès	CAM	19	186	74	FC Lorient	60	60	58	58	55	48	43	57
J. Gonçalves	CB	33	170	61	FC Annecy	52	53	45	66	56	62	56	64
P. Sciortino	CDM	18	177	70	Olympique de Marseille	52	46	47	53	57	51	57	55
A. Roncaglia	CB	22	180	70	SC Bastia	42	52	50	52	59	73	67	73
W. Odobert	ST	17	180	75	ESTAC Troyes	71	67	59	57	61	47	45	40
A. Chibozo	CAM	19	172	68	Amiens SC	62	69	58	64	83	50	59	43
E. Tchato	RB	19	182	75	Montpellier Hérault SC	72	72	58	51	62	58	57	60
A. Caprice	RB	17	175	70	Olympique de Marseille	76	65	56	64	76	63	58	42
A. Benyahia-Tani	ST	16	175	70	Olympique de Marseille	68	55	71	63	72	54	53	32
J. Fabri	GK	28	184	80	SC Bastia	49	54	34	63	60	61	20	60

B. Pereira	RB	19	172	70	AJ Auxerre	74	70	77	58	81	72	45	36
N. Kutateladze	ST	21	184	71	Rodez Aveyron Football	69	70	61	49	66	65	62	60
J. Bahoya	CAM	17	180	75	Angers SCO	60	65	59	59	68	60	51	54
L. Sy	RB	19	171	65	Stade Malherbe Caen	78	79	65	49	82	74	67	44
K. Boma	CB	19	187	73	Rodez Aveyron Football	42	41	35	54	43	62	52	63
A. Wam	CB	20	183	75	Le Havre AC	57	67	55	59	52	65	71	64
M. Achi	CAM	20	181	72	FC Nantes	67	63	61	59	69	61	43	46
M. El Jaouhari	CAM	23	181	71	FC Annecy	51	66	50	48	64	51	42	57
E. Damergy	GK	19	187	76	Stade Rennais FC	38	32	46	57	33	54	28	66
M. Toure	ST	18	186	89	Stade de Reims	89	91	79	52	76	78	41	83
S. Kumbedi	RB	17	175	63	Olympique Lyonnais	81	79	77	55	82	56	59	56
M. Sans	CB	34	191	86	FC Annecy	31	30	33	47	31	42	59	66
M. Bangri©	LM	21	171	65	US Quevilly Rouen MÍ©tropole	65	64	65	58	80	61	55	38
M. De Lima	RM	18	170	65	FC Girondins de Bordeaux	68	67	57	59	85	40	51	39
G. Restes	GK	17	186	82	Toulouse Football Club	31	35	31	45	39	44	23	61
O. Ba	GK	20	185	72	FC Metz	23	20	26	48	50	58	17	53
O. Bunjaku	CAM	20	180	75	Grenoble Foot 38	69	67	73	49	71	63	70	62
Y. Lienard	GK	19	192	80	AS Monaco	23	22	33	45	26	39	27	66
P. MÍ©liande	CAM	20	181	72	Pau FC	62	68	67	57	72	61	57	58
B. Nadir	CDM	18	179	62	Olympique de Marseille	66	62	66	62	60	68	70	54
Y. Gomes	ST	19	174	67	Le Havre AC	67	69	74	59	83	52	59	46
S. Nsimba	ST	26	183	83	Stade Lavallois Mayenne FC	77	74	64	58	60	66	61	64
F. Chabrolle	CAM	24	171	65	AC Ajaccio	59	42	72	69	80	47	68	38
P. Joly	CB	22	182	75	AJ Auxerre	60	53	47	50	64	71	62	65
A. Louveau	CB	22	189	86	Racing Club de Lens	59	62	60	48	52	63	43	61
G. Coudert	GK	23	188	83	Stade Brestois 29	30	27	25	52	24	50	25	66
Y. Cathline	CAM	19	176	68	FC Lorient	74	74	75	53	76	44	58	48
R. Bakayoko	ST	20	196	85	Chamois Niortais Football Club	47	61	43	52	37	72	65	75

T. Himeur	GK	21	187	72	Toulouse Football Club	55	30	38	50	38	47	17	52
I. Dramić	CB	23	197	80	SC Bastia	69	66	65	51	49	61	58	70
K. Dong	ST	17	178	68	ESTAC Troyes	68	66	57	60	61	56	57	47
Y. Pandor	GK	21	178	79	Racing Club de Lens	19	22	26	54	41	57	23	51
L. Doucet	CDM	19	180	75	FC Nantes	63	64	59	56	72	71	62	51
S. Yepie Yepie	LM	19	171	62	FC Nantes	81	80	79	43	86	51	31	27
S. Karamoko	CB	22	192	81	Paris FC	62	68	50	45	45	67	60	70
I. Baldić	ST	19	185	76	FC Annecy	65	67	62	54	48	37	31	41
T. Malbec	GK	20	185	72	FC Annecy	23	23	23	48	33	49	22	56
Y. Baï	ST	25	181	75	SC Bastia	66	65	56	44	64	56	50	59
C. Gomez	ST	21	183	75	Amiens SC	77	76	77	49	46	57	36	50
J. Gaudin	CAM	22	180	71	En Avant de Guingamp	67	68	67	56	62	44	60	48
I. Eckenfelder	ST	21	174	70	FC Annecy	69	69	57	49	69	64	58	59
O. Boissy	ST	23	191	80	Grenoble Foot 38	39	60	51	48	44	65	57	83
M. Bassouamina	ST	24	173	68	Pau FC	76	74	66	56	71	57	52	67
D. Sylla	RWB	19	175	68	Stade Lavallois Mayenne FC	75	71	73	56	75	55	70	45
A. Aiki	RM	17	180	75	AS Saint-Étienne	72	67	58	56	68	49	49	35
T. Zoukrou	CB	19	189	78	ESTAC Troyes	49	51	35	56	51	73	59	66
J. Casimir	ST	20	178	74	Le Havre AC	80	83	64	50	72	72	55	70
L. Margueron	GK	21	194	85	Clermont Foot 63	19	21	30	40	24	34	27	72
A. Zinga	ST	21	185	70	Valenciennes FC	66	48	59	62	70	72	57	65
N. Savignac	RM	19	173	67	Rodez Aveyron Football	68	69	55	41	70	57	58	51
Y. Assogba	RB	20	173	70	Amiens SC	77	72	63	54	82	64	64	60
U. Eneme-Ella	CAM	21	184	75	Angers SCO	64	63	64	60	57	52	34	64
N. Innocenti	CB	20	187	75	Valenciennes FC	55	59	57	54	59	67	55	67
N. Sow	CDM	23	180	65	Pau FC	52	57	42	51	65	64	58	58
W. Jarmouni	ST	22	188	82	Pau FC	63	60	62	50	54	62	59	75
M. Ros	RB	20	176	75	Pau FC	69	66	56	58	71	63	58	57
N. Cissé	CB	21	188	79	US Quevilly Rouen Métropole	48	56	34	47	43	39	37	77

O. Nkambadio	GK	19	185	78	Paris FC	31	28	39	57	41	59	20	47
K. Fayad	CAM	18	172	61	Montpellier Hérault SC	66	65	63	52	84	52	46	35
P. Pagis	ST	19	181	67	Nîmes Olympique	61	57	58	58	67	61	52	41
H. Diarra	CDM	18	179	74	RC Strasbourg Alsace	55	55	67	58	66	56	50	53
R. Voisine	CB	20	192	82	FC Nantes	60	47	58	49	30	33	41	69
I. Camara	LW	24	179	75	Dijon FCO	82	79	81	38	71	36	42	31
V. Molchan	CB	21	188	72	Stade Malherbe Caen	60	51	44	43	57	67	71	70
N. Jaby	CAM	21	175	68	Clermont Foot 63	69	63	71	56	73	63	46	35
H. Tebily	ST	20	182	75	FC Sochaux-Montbéliard	76	68	61	48	62	64	61	62
D. Mazou-Sacko	CM	17	175	65	ESTAC Troyes	62	63	54	55	67	61	58	51
T. Luvambo	RM	22	180	75	En Avant de Guingamp	87	77	75	45	74	52	41	64
M. Ben Fredj	ST	22	176	61	AJ Auxerre	54	49	54	59	63	62	51	39
T. Secchi	GK	25	185	75	Rodez Aveyron Football	31	31	24	48	45	56	27	41
E. N'Jo	CB	18	187	80	ESTAC Troyes	62	55	42	55	59	74	58	50
Y. Belkhdim	CDM	20	175	70	Angers SCO	59	58	61	56	67	59	47	54
L. Mouton	CM	20	180	66	AS Saint-Étienne	67	65	59	61	63	63	64	57
T. Callens	GK	23	182	81	FC Annecy	15	19	35	36	49	61	18	53
J. Ngouabi	CB	19	197	83	Stade Malherbe Caen	51	59	47	48	33	76	66	81
A. Diyaeddine	LB	23	185	75	Pau FC	64	69	58	57	57	59	61	57
T. Roche	GK	20	189	82	Dijon FCO	30	33	28	41	34	55	29	61
R. Benchaa	CB	20	188	78	Dijon FCO	58	68	48	46	54	70	57	76
A. Ahmed Fatah	RM	18	183	73	ESTAC Troyes	71	74	62	41	64	49	49	53
Y. Kechta	CAM	20	175	68	Le Havre AC	62	58	67	56	74	48	42	46
T. Bartouche-Selbonne	GK	25	178	70	FC Lorient	19	38	37	39	46	60	30	51
J. Mbock	CAM	22	174	67	Angers SCO	78	74	74	60	73	56	51	34
T. Atallah	CB	19	175	67	FC Girondins de Bordeaux	63	56	48	56	56	66	57	57
Q. Galvez-Diarra	GK	20	188	78	Pau FC	15	16	37	41	34	51	24	37
L. Nomel	RM	24	182	74	Valenciennes FC	68	67	59	49	63	40	49	55
W. Nassi	RM	21	180	60	Dijon FCO	72	70	59	39	66	43	48	43
P. Bourdelle	GK	21	191	78	Grenoble Foot 38	54	50	58	53	25	35	17	61
Buni Jorge	LM	21	168	60	Rodez Aveyron Football	78	77	74	54	91	58	60	49

S. Ewange	RB	21	172	70	Stade Malherbe Caen	73	74	53	56	70	72	68	57
N. Djiga	CB	19	189	84	Nîmes Olympique	68	72	54	47	52	68	62	75
O. Kamdem	RWB	19	176	70	Clermont Foot 63	77	69	71	51	76	53	41	27
A. Penin	CB	19	180	69	Valenciennes FC	61	59	51	49	48	60	62	56
J. Jeno	CB	22	183	75	Grenoble Foot 38	52	60	56	49	63	64	55	68
M. Touri©	CB	20	189	74	Valenciennes FC	63	58	51	54	51	62	49	59
Y. Korí©	CB	17	187	75	Paris FC	56	66	61	57	51	61	47	65
T. Nkada	ST	22	177	68	Stade de Reims	69	68	64	52	70	83	53	52
T. Le Bris	CDM	19	165	60	FC Lorient	62	50	54	57	94	64	51	36
N. Raveyre	GK	17	182	75	AS Saint-Étienne	22	18	19	45	53	56	20	49
T. De Percin	GK	21	185	81	AJ Auxerre	25	18	39	35	44	56	27	63
A. Tchaptchet	CB	20	193	95	Grenoble Foot 38	63	49	45	53	55	70	55	72
L. Rocrou	ST	19	179	67	FC Girondins de Bordeaux	72	73	55	48	71	46	59	52
L. Pirringuel	RM	18	176	72	FC Girondins de Bordeaux	70	67	58	52	72	52	56	50
N. El Hassani	CAM	22	176	68	Chamois Niortais Football Club	72	65	71	47	73	45	39	37
B. Diallo	LB	21	176	70	Clermont Foot 63	71	75	71	51	81	47	34	31
Z. Labyad	ST	22	180	74	Grenoble Foot 38	61	62	60	56	72	68	52	51
A. Vitelli	CB	22	189	81	En Avant de Guingamp	35	43	34	54	60	72	49	70
J. N'Duquidi	CM	17	185	74	FC Metz	66	69	63	55	59	64	60	59
H. Far	ST	20	179	73	Rodez Aveyron Football	63	65	59	55	73	71	52	45
J. Janneh	CB	19	178	72	SC Bastia	65	64	58	55	69	64	62	61
N. Bassette	ST	17	184	74	Stade Malherbe Caen	70	66	58	55	67	66	63	59
J. Vetro	CAM	18	178	70	FC Girondins de Bordeaux	68	64	51	55	70	54	67	53
G. Quilichini	GK	19	185	79	AC Ajaccio	29	20	23	39	43	40	25	30
C. Etoga	CB	19	186	71	Dijon FCO	51	59	51	50	56	65	62	56
J. Louchet	GK	26	190	73	Chamois Niortais Football Club	15	29	32	48	29	33	20	42
M. Rabuel	CB	22	180	73	Valenciennes FC	54	59	43	51	61	72	60	54
D. Meddah	CAM	19	187	78	FC Sochaux-Montbéliard	63	71	70	53	62	63	48	72

Y. Maronne	GK	20	183	75	Chamois Niortais Football Club	25	36	30	45	39	50	16	45
A. L'É	CB	22	183	76	FC Metz	55	53	32	50	68	75	49	53
S. Faraj	CAM	20	178	64	FC Sochaux-Montbéliard	68	69	64	58	64	60	44	52
Y. Massolin	CB	19	197	78	Clermont Foot 63	59	54	32	37	37	42	47	71
R. El Khamali	CAM	20	183	68	Dijon FCO	74	71	70	41	51	42	32	40
M. Viltard	CDM	19	176	68	FC Sochaux-Montbéliard	59	65	63	58	62	62	63	62
H. Morales	RB	20	179	71	Pau FC	66	56	61	49	67	73	69	58
Y. Dukuly	LM	19	176	71	Stade de Reims	91	93	79	35	61	43	45	39
O. Ngom	CDM	18	184	75	Chamois Niortais Football Club	60	61	58	56	69	66	57	52
Y. El Amri	RM	17	180	74	Valenciennes FC	65	63	62	41	64	43	49	52
D. G'Beuly	CAM	21	185	67	US Quevilly Rouen Métropole	68	63	62	48	51	57	46	49
I. Mohamed	CB	21	191	80	Stade Malherbe Caen	51	54	56	53	43	58	36	67
T. Chatelain	GK	22	187	75	Stade Lavallois Mayenne FC	23	15	31	41	49	64	16	41
M. Rongier	GK	20	185	75	Amiens SC	32	24	29	45	47	55	24	46
J. Diaz	CB	18	183	78	FC Nantes	67	61	62	35	51	46	39	48
S. Soumah	ST	18	174	68	SC Bastia	70	70	56	50	68	65	59	57
M. Douane	CAM	19	175	72	FC Metz	59	59	55	51	69	51	49	44
S. El Khia	CAM	21	175	64	US Quevilly Rouen Métropole	67	61	61	35	71	41	42	31
S. Alvero	CB	20	202	93	FC Sochaux-Montbéliard	56	62	59	48	28	62	49	93
A. Delphis	CAM	19	178	68	FC Sochaux-Montbéliard	60	64	62	56	68	49	44	47
Logbo .%â	CAM	18	188	75	Le Havre AC	66	59	59	54	64	50	54	48
S. Ngoura	ST	17	185	75	Le Havre AC	55	51	57	48	57	62	57	44
Y. Gomis	CB	16	180	65	Le Havre AC	63	56	42	52	62	69	58	56
S. Ebonog	RM	17	180	70	Le Havre AC	69	68	57	37	62	47	47	40
D. Moussadek	CB	20	185	82	Le Havre AC	63	57	47	52	54	66	60	68
E. Mayenda	ST	17	180	75	FC Sochaux-Montbéliard	57	56	56	51	65	67	56	55
M. Bariki	ST	22	180	64	Amiens SC	60	67	51	35	71	42	43	40

H. Ozí@e	CB	22	184	77	US Quevilly Rouen Mí@tropole	60	63	51	44	58	51	41	43
K. Corenthin	CDM	21	180	69	US Quevilly Rouen Mí@tropole	62	61	61	46	61	56	45	47
T. Sako	CB	19	185	78	Chamois Niortais Football Club	61	64	47	48	57	67	65	63
R. Boulais	GK	20	188	75	US Quevilly Rouen Mí@tropole	27	33	21	43	34	41	22	44
T. Gardies	GK	21	197	87	Paris FC	16	30	21	41	27	37	26	67
S. Touray	CM	22	175	74	Grenoble Foot 38	63	56	50	54	72	62	48	52
K. Agro	GK	20	191	90	FC Sochaux-Montb@liard	29	15	34	33	24	31	26	70
E. Viegbe	CDM	18	178	65	Valenciennes FC	55	58	55	50	67	56	48	44
M. Baaloudj	ST	21	183	80	En Avant de Guingamp	54	57	56	54	61	62	57	39
D. Durivaux	RB	21	178	69	Chamois Niortais Football Club	69	63	59	51	71	62	61	46
A. Gauthier	CAM	18	176	66	AS Saint-@tienne	66	61	60	54	65	53	45	41
N. Lebreton	RB	18	180	70	Stade Malherbe Caen	63	68	56	54	67	57	61	49