

النمذجة التنبؤية لاستهلاك الطاقة الحرارية أثناء التمرين على جهاز المشي:

نهج متكامل بين قياسات تكوين الجسم والتعلم الآلي

د.فاطمة حسن مرجان¹ د.علي بن خليفة الشملي² د.أحمد محمد المحلاوي³

جامعة صحار- سلطنة عمان جامعة صحار- سلطنة عمان جامعة صحار- سلطنة عمان

المقدمة:

تُشكل أبحاث الطاقة الحيوية الناتجة عن النشاط البدني للإنسان محوراً بحثياً واعداً يجمع بين علم الفيزياء الحيوية وتكنولوجيا الذكاء الاصطناعي. إذ يُعدّ التنبؤ الدقيق باستهلاك الطاقة الحرارية أثناء التمرين من المسائل الجوهرية في علوم الرياضة والصحة. غير أن العلاقة بين معايير تكوين الجسم ومعدلات حرق السعرات الحرارية لم تُدرس بشكل كافٍ باستعمال نماذج الذكاء الاصطناعي. لذا تسعى هذه الدراسة إلى بناء نموذج تنبؤي متكامل قائم على التعلم الآلي للتنبؤ باستهلاك الطاقة الحرارية أثناء التمرين على جهاز المشي اعتماداً على قياسات تكوين الجسم عند سرعات مختلفة.

مشكلة البحث:

على الرغم من توافر أجهزة قياس تكوين الجسم المتطورة التي تقيس الدهون والعضلات والمعدل الأيضي الأساسي وغيرها، لا يزال الربط الكمي الدقيق بين هذه المعايير ومعدلات استهلاك الطاقة الحرارية أثناء التمرين غير موثّق بالقدر الكافي. فضلاً عن أن الأدبيات العلمية لم تقدم بصورة كافية أنموذجاً تنبؤياً شخصياً يعتمد على الذكاء الاصطناعي لتقدير الطاقة المستهلكة استناداً إلى هذه المعايير دون الاعتماد الكامل على القياسات المباشرة أثناء الأداء.

¹ أستاذ مشارك ببرنامج التربية الرياضية، كلية التربية والآداب، جامعة صحار، سلطنة عمان.

² أستاذ مشارك ببرنامج التربية الرياضية، كلية التربية والآداب، جامعة صحار، سلطنة عمان.

³ أستاذ مساعد ببرنامج الفيزياء، كلية التربية والآداب، جامعة صحار، سلطنة عمان.

أسئلة البحث:

- ما طبيعة العلاقة بين معايير تكوين الجسم (الدهون، والكتلة العضلية، والمعدل الأيضي الأساسي، ومؤشر كتلة الجسم) ومعدل استهلاك الطاقة الحرارية أثناء التمرين على جهاز المشي؟
- ما أكثر معايير تكوين الجسم إسهامًا في التنبؤ باستهلاك الطاقة الحرارية؟
- إلى أي مدى يمكن لخوارزميات التعلم الآلي التنبؤ بدقة بالطاقة الحرارية المستهلكة بدلالة بيانات تكوين الجسم؟
- ما مدى تأثير تغير سرعة جهاز المشي في العلاقة بين تكوين الجسم ومعدل استهلاك الطاقة الحرارية؟

أهداف البحث:

- بناء قاعدة بيانات متكاملة تجمع بين قياسات تكوين الجسم وبيانات استهلاك الطاقة الحرارية عند 10 مستويات سرعة مختلفة على جهاز المشي.
- تطوير أنموذج ذكاء اصطناعي للتنبؤ باستهلاك الطاقة الحرارية استناداً إلى معايير تكوين الجسم.
- تحديد المعايير الأكثر تأثيراً في استهلاك الطاقة باستعمال تحليل الأهمية النسبية للمتغيرات (SHAP).
- التحقق من كفاءة النماذج التنبؤية باستعمال مؤشرات R^2 و RMSE و MAE ومقارنتها بالقياسات الفعلية.
- تقديم أنموذج تنبؤي شخصي يمكن الاستفادة منه في تصميم وصفات تمرين فردية وبرامج صحية قائمة على خصائص تكوين الجسم.

أهمية البحث:

تكمن أهمية هذا البحث في تقديم أداة تنبؤية غير مسبقة تجمع قياسات تكوين الجسم مع تقنيات الذكاء الاصطناعي لتقديم أنموذج تنبؤي شخصي لاستهلاك الطاقة الحرارية أثناء التمرين. ويسهم ذلك في دعم تصميم البرامج التدريبية الفردية، وتعزيز دقة التقدير في

مجالات الطب الرياضي وإعادة التأهيل، فضلاً عن دعم صناعة الأجهزة الرياضية الذكية القدرة على التكيف مع خصائص الجسم لكل مستخدم علمياً، ويسدّ هذا البحث ثغرةً في الأدبيات بدمج فيزياء الطاقة الحيوية مع التعلم الآلي في إطار تجريبي موحد.

منهج البحث:

اعتمد البحث على المنهج التجريبي التحليلي، إذ جُمعت بيانات فعلية من 51 مشاركاً تضمّنت قياسات تكوين الجسم الكاملة (الدهون، والعضلات، والماء، والبروتين، والمعدل الأيضي، ومؤشر كتلة الجسم، والعمر البيولوجي، ونسبة الخصر للورك) إلى جانب قياسات الطاقة الحرارية عند 10 سرعات مختلفة على جهاز المشي. تُعالج البيانات باستعمال التعلم الآلي وخوارزميات Random Forest وSVR، مع اختيار الميزات عبر تحليل SHAP وتقسيم البيانات للتدريب والتحقق والاختبار.

الكلمات المفتاحية: تكوين الجسم - الطاقة الحرارية - الذكاء الاصطناعي - التعلم الآلي - تمرينات جهاز المشي.

Predictive modeling of energy expenditure during treadmill exercise: An integrated approach combining body composition measurements and machine learning

Fatma Mourgan³Ali Khalifa Al Shamli²Ahmed M. El-Mahalawy¹

Abstract

Accurately estimating caloric expenditure during physical activity remains a significant challenge in sports science, rehabilitation medicine, and personalized fitness programs. To develop an effective predictive model for caloric expenditure during treadmill exercise, this study proposes an integrated approach that combines detailed body composition analysis with Artificial Intelligence (AI) techniques. Data were collected from 51 participants and included comprehensive body composition measurements, such as body fat percentage, muscle mass, body water content, protein percentage, Basal Metabolic Rate (BMR), Body Mass Index (BMI), skeletal muscle ratio, visceral fat index, biological age, and waist-to-hip ratio. In addition, caloric expenditure data were recorded at ten treadmill speed levels ranging from 3 to 12 km/h. A Machine Learning (ML) model was developed and trained to predict caloric expenditure based on body composition characteristics. Feature importance analysis using SHAP (Shapley Additive Explanations) values identified BMR, muscle mass, and body fat percentage as the most influential predictors. Model performance was evaluated using several statistical metrics, including the coefficient of determination (R^2), Root Mean Square Error (RMSE), and Mean Absolute Error (MAE). The results demonstrated that the AI-based model outperformed conventional regression approaches in predicting caloric expenditure. The findings highlight the potential of combining body composition analysis with AI techniques to provide accurate, individualized estimates of caloric burn through body scanning technologies.

Keywords: Body Composition; Caloric Energy Expenditure; Artificial Intelligence; Machine Learning; Treadmill Exercise.

¹ Assistant Professor, Physics Program, College of Education and Arts, Sohar University, Sultanate of Oman

² Associate Professor, Physical Education Program, College of Education and Arts, Sohar University, Sultanate of Oman.

³ Associate Professor, Physical Education Program, College of Education and Arts, Sohar University, Sultanate of Oman.

1. المقدمة

يمثل النشاط البدني أحد الركائز الأساسية للحفاظ على الصحة العامة والوقاية من الأمراض غير السارية، إذ يرتبط بمستويات اللياقة البدنية، وكفاءة الجهازين القلبي والتنفسي، والتحكم في الوزن، وتحسين جودة الحياة. وفي المقابل، يُعد انخفاض النشاط البدني من أبرز عوامل الخطر المرتبطة بارتفاع معدلات السمنة، والسكري من النوع الثاني، وأمراض القلب والأوعية الدموية، الأمر الذي دفع المنظمات الصحية الدولية إلى التأكيد على أهمية تعزيز النشاط البدني باعتباره أحد المحاور الرئيسة لتحسين الصحة العامة والحد من العبء الاقتصادي للأمراض المزمنة (Strain et Bull et al., 2020). (al., 2024).

ويُعد استهلاك الطاقة الحرارية (Energy Expenditure) من أهم المؤشرات المستخدمة لتقييم الاستجابة الفسيولوجية للنشاط البدني، حيث يعكس مقدار الطاقة التي يبذلها الجسم أثناء أداء الأنشطة المختلفة. ولا تقتصر أهمية هذا المؤشر على المجال الرياضي، بل تمتد إلى التطبيقات السريرية وبرامج إنقاص الوزن، والتأهيل الحركي، ووضع الخطط التدريبية، وتحديد الاحتياجات الغذائية للأفراد وفقاً لمستوى نشاطهم البدني. لذلك، يعتمد نجاح العديد من التدخلات الصحية والرياضية على دقة تقدير استهلاك الطاقة، لما لذلك من دور في تحسين كفاءة البرامج العلاجية والتدريبية وتقليل الأخطاء الناتجة عن التقديرات غير الدقيقة (Fernández-Verdejo et Pinheiro Volp et al., 2011). (Hills et al. 2014؛ al., 2024).

ورغم توفر عدد من الطرق المباشرة وغير المباشرة لقياس استهلاك الطاقة، مثل قياس السعرات الحرارية غير المباشر (Indirect Calorimetry)، والمياه المزدوجة الوسم (Doubly Labeled Water)، فإن استخدام هذه التقنيات يظل محدوداً خارج المختبرات البحثية بسبب ارتفاع تكلفتها، والحاجة إلى أجهزة متخصصة، وصعوبة تطبيقها في البيئات التدريبية والسريرية اليومية. ونتيجة لذلك، اتجه الباحثون إلى تطوير معادلات تنبؤية تعتمد على الخصائص الأنثروبومترية أو المتغيرات الفسيولوجية لتقدير استهلاك

الطاقة بصورة أكثر سهولة، إلا أن هذه المعادلات غالباً ما تعتمد على افتراضات عامة قد لا تعكس الاختلافات الفردية بين الأشخاص، مما يؤدي إلى انخفاض دقتها عند تطبيقها على مجتمعات تختلف في العمر أو الجنس أو مستوى اللياقة البدنية أو تركيب الجسم (Hills et al., 2014؛ Ndahimana & Kim, 2017؛ O'Driscoll et al., 2021؛ Hills et al., 2014).

يُعد تكوين الجسم من العوامل الرئيسة المؤثرة في مقدار الطاقة التي يستهلكها الجسم أثناء الراحة وأثناء النشاط البدني، إذ تختلف المتطلبات الأيضية باختلاف نسب الكتلة العضلية، والكتلة الدهنية، وكمية الماء الكلي في الجسم. فالأنسجة الخالية من الدهون، ولا سيما العضلات الهيكلية، تُعد أكثر نشاطاً من الناحية الأيضية مقارنة بالأنسجة الدهنية، ولذلك فإن الأفراد الذين يمتلكون كتلة عضلية أكبر غالباً ما يُظهرون معدلات أعلى لاستهلاك الطاقة عند أداء نفس النشاط البدني. كما أن تأثير العمر والجنس ومستوى اللياقة البدنية في هذه العلاقة يؤكد أهمية مراعاة الفروق الفردية عند بناء نماذج تقدير استهلاك الطاقة، بدلاً من الاعتماد على معادلات عامة لا تعكس الخصائص الفسيولوجية لكل فرد (Campa et al., 2024؛ Fernández-Verdejo et al., 2024؛ Quist et al., 2024).

وفي هذا الصدد، برزت تقنية تحليل المعاوقة الكهربائية الحيوية (Bioelectrical Impedance Analysis ; BIA) كأحدى أكثر الوسائل انتشاراً لتقييم مكونات الجسم، نظراً لسهولة استخدامها، وسرعة إجراء القياس، وانخفاض تكلفتها مقارنة بالطرق المرجعية مثل قياس امتصاص الأشعة السينية ثنائي الطاقة (DXA). وتوفر هذه التقنية مجموعة من المؤشرات المهمة، مثل نسبة الدهون في الجسم، والكتلة العضلية، والكتلة الخالية من الدهون، والماء الكلي، والتي أصبحت تستخدم على نطاق واسع في التقييم الصحي والرياضي. ومع ذلك، تشير الأدبيات إلى أن دقة نتائج أجهزة BIA قد تتأثر بالحالة المائية للجسم، ونوع الجهاز، والمعادلات التنبؤية المستخدمة، مما يستوجب تفسير نتائجها ضمن هذه المحددات وعدم اعتبارها بديلاً مطلقاً للطرق المرجعية (Campa et al., 2024).

ورغم الأهمية المتزايدة لبيانات تكوين الجسم، فإن دمج هذه المؤشرات في نماذج تقدير استهلاك الطاقة ما يزال محدودًا مقارنة بالاعتماد على متغيرات النشاط البدني أو المؤشرات الفسيولوجية التقليدية. وقد ركزت العديد من الدراسات على سرعة المشي أو الجري، ومعدل ضربات القلب، أو بيانات أجهزة الاستشعار القابلة للارتداء، في حين لم تستثمر بصورة كافية المعلومات الغنية التي توفرها أجهزة تحليل مكونات الجسم، والتي قد تسهم في تفسير جزء كبير من التباين الفردي في استهلاك الطاقة. ويشير ذلك إلى وجود فرصة لتطوير نماذج أكثر شمولاً تجمع بين بيانات تكوين الجسم ومتغيرات الأداء البدني، بما يحقق تقديرات أكثر دقة وقابلية للتطبيق في البيئات الرياضية والصحية (Boudry et al., 2024; Fernández-Verdejo et al., 2024).

وقد شهدت السنوات الأخيرة تطورًا ملحوظًا في توظيف تقنيات التعلم الآلي (Machine Learning) في مجالات علوم الرياضة والصحة، نظرًا لقدرتها على تحليل البيانات متعددة الأبعاد واكتشاف العلاقات المعقدة بين المتغيرات التي قد يصعب تمثيلها باستخدام النماذج الإحصائية التقليدية. وتتميز خوارزميات التعلم الآلي بإمكانية التعامل مع العلاقات الخطية وغير الخطية، واستخلاص الأنماط الخفية من البيانات، مما يجعلها أداة واعدة لتطوير نماذج تنبؤية أكثر دقة لتقدير المؤشرات الفسيولوجية، ومنها استهلاك الطاقة أثناء النشاط البدني. وقد بينت دراسات حديثة أن دمج البيانات الأثرية ومترية، ومؤشرات تكوين الجسم، والمتغيرات المرتبطة بالأداء البدني ضمن نماذج التعلم الآلي يحقق تحسنًا ملحوظًا في دقة التنبؤ مقارنة بالمعادلات التقليدية، خاصة عند استخدام أساليب تحقق مناسبة تقلل من التحيز وتزيد من قابلية تعميم النتائج (O'Driscoll et al., 2021; Hossain et al., 2024; Kim & Seong, 2025).

إلا أن ارتفاع دقة النموذج لا يعني بالضرورة إمكانية الاعتماد عليه في التطبيقات العملية، إذ يعتمد نجاح النماذج التنبؤية على جودة البيانات، واختيار المتغيرات المناسبة، وآلية تدريب النموذج والتحقق من أدائه. وقد أشارت الأدبيات الحديثة إلى أن بعض الدراسات وقعت في مشكلات منهجية، مثل تسرب البيانات (Data Leakage) أو

الاعتماد على أساليب تحقق غير كافية، مما أدى إلى المبالغة في تقدير كفاءة النماذج. لذلك، أوصت المبادئ الإرشادية الحديثة، مثل TRIPOD+AI وPROBAST+AI، بضرورة اتباع إجراءات منهجية واضحة عند تطوير نماذج الذكاء الاصطناعي، لضمان موثوقية النتائج وإمكانية تطبيقها في البيئات الواقعية (Moons et al., 2024; Collins et al., 2024; Kapoor et al., 2023).

وبالتوازي مع تحسين الأداء التنبئي، برزت أهمية جعل نماذج الذكاء الاصطناعي أكثر قابلية للتفسير، خاصة في التطبيقات الصحية التي تتطلب فهماً واضحاً للعوامل المؤثرة في نتائج النموذج. ومن هذا المنطلق، ظهرت تقنيات الذكاء الاصطناعي القابل للتفسير (Explainable Artificial Intelligence)، والتي تتيح تفسير مساهمة كل متغير في عملية التنبؤ بدلاً من الاكتفاء بعرض مؤشرات الأداء فقط. وتعد تقنية SHAP (Shapley Additive Explanations) من أكثر الأدوات استخداماً في هذا المجال، إذ توفر تفسيراً كمياً لتأثير كل متغير في مخرجات النموذج، مما يساعد على فهم العلاقات بين خصائص الجسم واستهلاك الطاقة، ويعزز ثقة الباحثين والممارسين في استخدام نتائج النماذج التنبؤية عند اتخاذ القرارات المتعلقة بالتقييم الصحي والتخطيط التدريبي (Lundberg & Lee, 2017; Hossain; Sadeghi et al., 2024; Mondal et al., 2024).

وعلى الرغم من التطور المتسارع في تقنيات تقدير استهلاك الطاقة، لا تزال الأدبيات العلمية تشير إلى وجود فجوة بين النماذج التنبؤية المطورة والتطبيقات العملية في مجالات الصحة وعلوم الرياضة. فمعظم الدراسات ركزت على تحسين الأداء التنبئي باستخدام متغيرات محددة أو مجموعات بيانات خاصة، بينما أولت اهتماماً أقل بتطوير نماذج تجمع بصورة متكاملة بين مؤشرات تكوين الجسم المستخلصة من أجهزة تحليل المعاوقة الكهربائية الحيوية (BIA) والمتغيرات الأنثروبومترية، مع الالتزام بالمعايير المنهجية الحديثة لتطوير نماذج التعلم الآلي وتفسير نتائجها. كما أن عدداً محدوداً من الدراسات تناول تفسير مساهمة كل متغير في دقة التنبؤ، الأمر الذي يحّد من إمكانية الاستفادة من هذه النماذج في

دعم القرارات التدريسية والصحية القائمة على الأدلة (Kapoor et al., 2023)؛
(Moons et al., 2025؛ Collins et al., 2024).

وفي ضوء ذلك، تأتي هذه الدراسة لتطوير مجموعة من نماذج التعلم الآلي بهدف تحديد النموذج الأكثر قدرة على تفسير استهلاك الطاقة الحرارية أثناء التمرين على جهاز المشي والتنبؤ به، اعتماداً على مجموعة متكاملة من القياسات الأنثروبومترية ومؤشرات تكوين الجسم. كما تعتمد الدراسة إجراءات تحقق منهجية للحد من التحيز وتعزيز موثوقية النتائج، إلى جانب استخدام تقنيات الذكاء الاصطناعي القابل للتفسير للكشف عن المتغيرات الأكثر إسهاماً في أداء النموذج. ومن شأن هذا التوجه أن يساهم في توفير نموذج دقيق وقابل للتفسير يمكن الاستفادة منه في تقييم الأداء البدني، وتصميم البرامج التدريسية، ودعم التطبيقات الصحية والرياضية القائمة على الخصائص الفردية.

2. الإطار النظري والدراسات السابقة

1.2 استهلاك الطاقة الحرارية أثناء النشاط البدني

يُعرف استهلاك الطاقة الحرارية (Energy Expenditure) بأنه مقدار الطاقة التي ينفقها الجسم للحفاظ على الوظائف الحيوية وأداء الأنشطة اليومية والبدنية، ويُعد من أهم المؤشرات المستخدمة في تقييم الحالة الفسيولوجية وكفاءة الأداء البدني. ويتكون الإنفاق الكلي للطاقة من ثلاث مكونات رئيسية هي: معدل الأيض الأساسي (Basal Metabolic Rate)، والطاقة المستهلكة في النشاط البدني، والتأثير الحراري للغذاء، ويشكل النشاط البدني أكثر المكونات قابلية للتغير وفقاً لشدة التمرين ومدته ونوعه، مما يجعله الهدف الرئيس عند تصميم البرامج التدريبية والتدخلات الصحية. ولذلك، فإن التقدير الدقيق لاستهلاك الطاقة يمثل أساساً لتخطيط الأحمال التدريبية، وبرامج إنقاص الوزن، والتأهيل الرياضي، وتحسين الأداء البدني (Pinheiro Volp et al., 2011)؛ (Hills et al., 2014).

وتختلف كمية الطاقة المستهلكة أثناء النشاط البدني باختلاف العديد من العوامل الفردية، مثل العمر، والجنس، والوزن، والطول، ومستوى اللياقة البدنية، إضافة إلى

الخصائص الفسيولوجية المرتبطة بتكوين الجسم. كما تؤثر خصائص التمرين نفسها، مثل السرعة، والشدة، ومدة الأداء، في معدل استهلاك الطاقة. وتشير الدراسات إلى أن الاعتماد على عامل واحد لتقدير الإنفاق الطاقي لا يعكس بصورة كافية هذا التفاعل المعقد بين المتغيرات، الأمر الذي دفع الباحثين إلى البحث عن نماذج أكثر شمولاً تأخذ في الاعتبار الخصائص الفردية إلى جانب متغيرات النشاط البدني (Ndahimana & Kim، 2017؛ Quist et al.، 2024؛ Fernández-Verdejo et al.، 2024).

وقد اعتمدت الدراسات المرجعية على تقنيات مثل المياه المزدوجة الموسم (Water Doubly Labeled) وقياس السعرات الحرارية غير المباشر (Indirect Calorimetry) لقياس استهلاك الطاقة بدقة عالية، إلا أن هذه التقنيات تتطلب تجهيزات متخصصة وتكاليف مرتفعة وخبرات فنية، مما يحد من استخدامها في التطبيقات الميدانية. لذلك، اتجهت الأبحاث الحديثة إلى تطوير نماذج تنبؤية تعتمد على البيانات الفسيولوجية والأنثروبومترية لتوفير بدائل عملية يمكن استخدامها في البيئات الرياضية والسريرية دون الحاجة إلى الأجهزة المرجعية، مع الحفاظ على مستوى مقبول من الدقة (Hills et al.، 2014؛ O'Driscoll et al.، 2021).

2.2 تكوين الجسم وتقنية تحليل المعاوقة الكهربائية الحيوية (BIA) وعلاقتها باستهلاك الطاقة

يُعد تكوين الجسم (Body Composition) من أهم المحددات الفسيولوجية المؤثرة في استهلاك الطاقة، إذ لا يعتمد الإنفاق الطاقي على وزن الجسم فقط، وإنما يتأثر بصورة أكبر بتوزيع مكوناته، ولا سيما الكتلة الخالية من الدهون (Fat-Free Mass) والكتلة العضلية (Skeletal Muscle Mass)، اللتين تمثلان الأنسجة الأعلى نشاطاً أيضاً في الجسم. وفي المقابل، تتميز الكتلة الدهنية بانخفاض نشاطها الأيضي، مما يفسر اختلاف معدلات استهلاك الطاقة بين الأفراد حتى عند تشابه الوزن أو مؤشر كتلة الجسم. لذلك، أصبح تقييم مكونات الجسم عنصراً أساسياً في الدراسات المتعلقة بالأيض،

والتغذية، وعلوم الرياضة، لما يوفره من فهم أكثر دقة للفروق الفردية في الاستجابة للنشاط البدني (Campa et al., 2024؛ Fernández-Verdejo et al., 2024).

ومن أكثر التقنيات استخدامًا في تقييم مكونات الجسم تقنية تحليل المعاوقة الكهربائية الحيوية (Bioelectrical Impedance Analysis; BIA)، والتي تعتمد على قياس مقاومة أنسجة الجسم لمرور تيار كهربائي منخفض الشدة لتقدير مكوناته المختلفة. وتمتاز هذه التقنية بسهولة الاستخدام، وسرعة القياس، وانخفاض تكلفتها مقارنة بالطرق المرجعية، مما أدى إلى انتشارها في المؤسسات الصحية والرياضية ومراكز اللياقة البدنية. كما توفر أجهزة BIA الحديثة مجموعة واسعة من المؤشرات، تشمل نسبة الدهون في الجسم، والكتلة العضلية، والكتلة الخالية من الدهون، والماء الكلي داخل الجسم وخارجه، إضافة إلى معدل الأيض الأساسي، وهي جميعها مؤشرات يمكن أن تسهم في تفسير التباين في استهلاك الطاقة بين الأفراد (Campa et al., 2024).

ورغم المزايا التطبيقية لهذه التقنية، تشير الأدبيات إلى أن دقة قياسات BIA تتأثر بعدد من العوامل، مثل مستوى ترطيب الجسم، ووقت القياس، والحالة الغذائية، والنشاط البدني السابق، بالإضافة إلى اختلاف الخوارزميات المستخدمة بين الشركات المصنعة للأجهزة. ولذلك، توصي الدراسات الحديثة بضرورة توحيد ظروف القياس وتفسير النتائج في ضوء هذه المحددات، خاصة عند استخدام بيانات BIA في بناء النماذج التنبؤية أو المقارنات البحثية (Campa et al., 2024).

وفي السنوات الأخيرة، لم تعد بيانات تكوين الجسم تستخدم لأغراض الوصف أو التقييم الصحي فقط، بل أصبحت مصدرًا مهمًا للمتغيرات المدخلة في نماذج الذكاء الاصطناعي. فقد أظهرت عدة دراسات أن دمج مؤشرات مثل الكتلة العضلية، والكتلة الخالية من الدهون، ونسبة الدهون، ومعدل الأيض الأساسي مع المتغيرات الأنتروبومترية وبيانات الأداء البدني يسهم في تحسين دقة التنبؤ بالمؤشرات الفسيولوجية، مقارنة بالاعتماد على الوزن أو مؤشر كتلة الجسم وحدهما. ويعكس هذا التوجه تحولًا من استخدام قياسات الجسم كمؤشرات وصفية إلى توظيفها كمتغيرات تنبؤية ذات قيمة تفسيرية في النماذج

الحديثة، وهو ما يمثل الأساس العلمي الذي تستند إليه الدراسة الحالية (Boudry et al، 2024؛ Kim & Seong، 2025).

3.2 التعلم الآلي في التنبؤ باستهلاك الطاقة

أصبح التعلم الآلي (Machine Learning) أحد أكثر فروع الذكاء الاصطناعي استخدامًا في علوم الرياضة والصحة، لما يتمتع به من قدرة على تحليل البيانات المعقدة واكتشاف الأنماط والعلاقات التي قد يصعب تمثيلها باستخدام النماذج الإحصائية التقليدية. ويعتمد هذا النهج على تدريب الخوارزميات باستخدام بيانات سابقة لاستخلاص نماذج قادرة على التنبؤ بالقيم المستقبلية أو تصنيف الحالات الجديدة بدرجة عالية من الدقة. وقد أسهم هذا التطور في انتقال العديد من الدراسات من استخدام المعادلات الثابتة إلى بناء نماذج تنبؤية تتكيف مع خصائص البيانات، مما عزز دقة التنبؤ في العديد من التطبيقات الصحية والرياضية (Hossain et al، 2024؛ Kim & Seong، 2025).

وفي مجال تقدير استهلاك الطاقة، اعتمدت الدراسات المبكرة على نماذج الانحدار الخطي التي تربط الإنفاق الطاقي بمتغيرات مثل العمر، والجنس، والوزن، والطول، أو سرعة المشي والجري. ورغم سهولة تطبيق هذه النماذج، فإنها تفترض وجود علاقات خطية بين المتغيرات، وهو افتراض لا يعكس التعقيد الفسيولوجي الذي يحكم استهلاك الطاقة أثناء النشاط البدني. ولذلك، اتجهت الأبحاث الحديثة إلى استخدام خوارزميات أكثر مرونة، مثل Support Vector Regression (SVR) و Gradient Boosting Regression (GBR)، لقدرتها على تمثيل العلاقات غير الخطية والتفاعل بين عدد كبير من المتغيرات، مما أدى إلى تحسين دقة التنبؤ مقارنة بالأساليب التقليدية في العديد من الدراسات التطبيقية (O'Driscoll et al، 2021؛ Kim، Boudry et al، 2024؛ Seong، 2025 &).

ورغم هذا التطور، فإن مراجعة الأدبيات تكشف تباينًا واضحًا في المتغيرات المستخدمة لبناء النماذج التنبؤية. فقد اعتمدت بعض الدراسات على بيانات أجهزة

الاستشعار القابلة للارتداء، مثل التسارع ومعدل ضربات القلب، بينما ركزت دراسات أخرى على المتغيرات الأنثروبومترية أو الخصائص الفسيولوجية بصورة منفصلة. وفي المقابل، لا تزال الدراسات التي دجت بصورة منهجية بين مؤشرات تكوين الجسم المستخلصة من أجهزة BIA والمتغيرات الأنثروبومترية وبيانات الأداء البدني محدودة، على الرغم من أن هذا الدمج قد يوفر معلومات أكثر شمولاً عن العوامل المؤثرة في استهلاك الطاقة، ويسهم في تحسين القدرة التنبؤية للنماذج (Hossain et al., 2024).

كما تشير الأدبيات الحديثة إلى أن تقييم جودة النماذج التنبؤية لا ينبغي أن يقتصر على مؤشرات الأداء الإحصائية، مثل معامل التحديد (R^2) أو متوسط الخطأ المطلق (MAE)، بل يجب أن يشمل أيضاً سلامة المنهجية المستخدمة في تطوير النموذج. فقد أثبتت دراسات حديثة أن مشكلات مثل تسرب البيانات (Data Leakage)، أو الاختيار غير السليم للمتغيرات، أو الاعتماد على أساليب تحقق غير مناسبة، قد تؤدي إلى نتائج متفائلة لا تعكس الأداء الحقيقي للنموذج عند تطبيقه على بيانات جديدة. ولهذا، أكدت المبادئ الإرشادية الحديثة، مثل TRIPOD+AI و PROBAST+AI، ضرورة اتباع إجراءات تحقق صارمة والإفصاح بوضوح عن مراحل تطوير النماذج وتقييمها، بما يعزز موثوقية النتائج وإمكانية تعميمها (Kapoor et al., 2023؛ Moons et al., 2024؛ Collins et al., 2025).

4.2 الذكاء الاصطناعي القابل للتفسير (Explainable Artificial Intelligence) في نماذج التنبؤ

أدى الانتشار الواسع لخوارزميات التعلم الآلي إلى تحسين دقة النماذج التنبؤية في العديد من التطبيقات الصحية والرياضية، إلا أن ارتفاع الأداء غالباً ما ترافق مع زيادة تعقيد هذه النماذج، مما جعل آلية اتخاذ القرار داخلها غير واضحة للمستخدمين والباحثين. وتُعرف هذه المشكلة بمشكلة "الصندوق الأسود" (Black Box)، حيث يصعب تفسير كيفية مساهمة المتغيرات المختلفة في الوصول إلى النتيجة النهائية، الأمر الذي قد يحد من ثقة الباحثين والممارسين في الاعتماد على هذه النماذج، خاصة في المجالات التي تتطلب قرارات

تستند إلى تفسير علمي واضح (Sadeghi et al., 2024; Lundberg & Lee, 2017).

واستجابةً لذلك، ظهر مفهوم الذكاء الاصطناعي القابل للتفسير (Explainable Artificial Intelligence; XAI)، والذي يهدف إلى تعزيز شفافية النماذج من خلال تفسير كيفية تأثير كل متغير في عملية التنبؤ، دون التأثير في كفاءة النموذج. ويُعد هذا التوجه من المتطلبات الأساسية في التطبيقات الطبية والرياضية الحديثة، لأنه لا يقتصر على معرفة مدى دقة النموذج، بل يساعد أيضًا في فهم الأسباب العلمية الكامنة وراء نتائجه، الأمر الذي يساهم في تحسين تفسير النتائج واتخاذ قرارات أكثر موثوقية (Arrieta et al., 2020; Collins et al., 2024).

وتُعد تقنية (Shapley Additive Explanations (SHAP من أكثر أدوات الذكاء الاصطناعي القابل للتفسير استخدامًا في الدراسات الحديثة، لاعتمادها على نظرية شابلي (Shapley Theory) في قياس المساهمة النسبية لكل متغير في مخرجات النموذج. وتمكن هذه التقنية من ترتيب المتغيرات وفقًا لأهميتها، وتحديد ما إذا كان تأثير كل متغير موجبًا أو سالبًا في عملية التنبؤ، مما يوفر فهمًا أكثر عمقًا للعلاقات بين المتغيرات المستقلة والمتغير التابع. وقد أدى ذلك إلى انتشار استخدامها في الأبحاث الصحية والرياضية التي تعتمد على نماذج التعلم الآلي، نظرًا لقدرتها على الجمع بين الأداء التنبؤي المرتفع والتفسير العلمي للنتائج (Hossain Mondal et al., 2024; Lundberg & Lee, 2017).

وفي ضوء طبيعة الدراسة الحالية، لا تقتصر أهمية استخدام تقنيات الذكاء الاصطناعي على تحديد النموذج الأعلى أداءً، بل تمتد إلى تفسير أسباب تفوقه، والكشف عن المتغيرات الأكثر إسهامًا في التنبؤ باستهلاك الطاقة الحرارية أثناء التمرين. ويعزز هذا التوجه القيمة التطبيقية للنموذج المقترح، إذ يوفر معلومات يمكن الاستفادة منها في تصميم البرامج التدريبية، وتقييم الحالة البدنية، ودعم القرارات في مجالات الصحة والرياضة استنادًا إلى أدلة علمية قابلة للتفسير، وليس إلى مؤشرات أداء رقمية فقط.

3. تحليل الدراسات السابقة والفجوة البحثية

أظهرت مراجعة الأدبيات أن الدراسات المتعلقة بالتنبؤ باستهلاك الطاقة شهدت تطوراً ملحوظاً خلال السنوات الأخيرة، مع انتقال الباحثين من استخدام معادلات الانحدار التقليدية إلى توظيف خوارزميات التعلم الآلي بهدف تحسين دقة التنبؤ. وقد أثبت العديد من الدراسات أن هذه الخوارزميات تتفوق على النماذج الإحصائية التقليدية في التعامل مع العلاقات غير الخطية بين المتغيرات الفسيولوجية والأنثروبومترية، مما أدى إلى تحسين ملحوظ في مؤشرات الأداء التنبؤي (Hossain؛ O'Driscoll et al.، 2021) (et al.، 2024).

ومع ذلك، تكشف مراجعة الدراسات السابقة عن تباين واضح في نوعية البيانات المستخدمة لبناء النماذج. فقد اعتمدت غالبية الدراسات على بيانات أجهزة الاستشعار القابلة للارتداء، مثل التسارع ومعدل ضربات القلب، أو على متغيرات النشاط البدني فقط، في حين أن الدراسات التي استفادت بصورة متكاملة من مؤشرات تكوين الجسم المستخلصة من أجهزة تحليل المعاوقة الكهربائية الحيوية (BIA) لا تزال محدودة. ويُعد هذا الأمر نقطة مهمة، لأن مؤشرات تكوين الجسم تمثل الخصائص الأيضية والفسيولوجية للفرد، ومن المتوقع أن تسهم في تحسين القدرة التنبؤية للنماذج عند دمجها مع المتغيرات الأنثروبومترية وبيانات الأداء البدني (Campa et al.، 2024).

كما أظهرت الأدبيات أن كثيرًا من الدراسات ركزت على تحقيق أعلى دقة تنبؤية، بينما أولت اهتماماً أقل بتفسير أسباب أداء النموذج أو تحديد المتغيرات الأكثر تأثيراً في عملية التنبؤ. وفي ظل التوسع في استخدام الذكاء الاصطناعي في التطبيقات الصحية، أصبحت قابلية تفسير النموذج عنصراً لا يقل أهمية عن دقته، إذ تسهم في تعزيز الثقة بالنتائج ودعم استخدامها في اتخاذ القرارات العملية. ورغم تزايد استخدام تقنيات الذكاء الاصطناعي القابل للتفسير، مثل SHAP، فإن توظيفها في دراسات التنبؤ باستهلاك الطاقة لا يزال محدوداً مقارنة بتطبيقاتها في المجالات الطبية الأخرى (Sadeghi et al.، 2024) (Hossain Mondal et al.، 2024).

وعلاوة على ذلك، تشير المراجعات المنهجية الحديثة إلى أن بعض الدراسات لم تلتزم بصورة كافية بالممارسات المنهجية الخاصة بتطوير نماذج التعلم الآلي، مثل إجراءات التحقق من النموذج، والحد من تسرب البيانات، والإبلاغ الشفاف عن مراحل بناء النموذج وتقييمه، وهي عوامل قد تؤثر في موثوقية النتائج وقابليتها للتعميم. ولذلك، تؤكد الإرشادات الحديثة، مثل TRIPOD+AI وPROBAST+AI، ضرورة تطوير نماذج تتسم بالدقة، والشفافية، وقابلية التفسير في الوقت نفسه (Kapoor et al., 2023؛ Moons et al., 2025؛ Collins et al., 2024).

وفي ضوء ما سبق، تتمثل الفجوة البحثية في محدودية الدراسات التي دمجت مؤشرات تكوين الجسم المستخرجة من أجهزة BIA مع القياسات الأثروبومترية لتطوير نماذج تعلم آلي قادرة على التنبؤ باستهلاك الطاقة الحرارية أثناء التمرين، مع الالتزام بالممارسات المنهجية الحديثة، واستخدام تقنيات الذكاء الاصطناعي القابل للتفسير للكشف عن المتغيرات الأكثر إسهامًا في أداء النموذج. وتسعى الدراسة الحالية إلى معالجة هذه الفجوة من خلال تطوير عدة نماذج تعلم آلي، وتحديد النموذج الأعلى أداءً والأكثر قابلية للتفسير، بما يسهم في تقديم أداة علمية أكثر دقة وموثوقية لدعم التطبيقات الرياضية والصحية.

4. هدف الدراسة

هدفت هذه الدراسة إلى تطوير وتقييم نماذج تعلم آلي للتنبؤ باستهلاك الطاقة الحرارية أثناء التمرين على جهاز المشي اعتمادًا على القياسات الأثروبومترية ومؤشرات تكوين الجسم المستخرجة باستخدام تقنية تحليل المعاوقة الكهربائية الحيوية (BIA)، بهدف تحديد النموذج الأعلى أداءً في التنبؤ. كما هدفت إلى تفسير أداء النموذج الأفضل باستخدام تقنية SHAP لتحديد المتغيرات الأكثر إسهامًا في عملية التنبؤ.


5. منهجية الدراسة

1.5 اختيار المشاركات والتحليل الديموغرافي

جمعت البيانات التجريبية من دراسة مستقبلية شملت 50 متطوعة بالغة من طالبات برنامج التربية الرياضية بكلية التربية والآداب في جامعة صحار، وكن يتمتعن بحالة صحية

جيدة. وقبل تنفيذ بروتوكول التمرين، خضعت كل مشاركة لتقييم شامل للقياسات الجسمانية وتكوين الجسم باستخدام جهاز تحليل المعاوقة الكهربائية الحيوية متعدد الترددات (BIA)، إلى جانب جهاز رقمي لقياس الطول.

ولضمان دقة القياسات وتقليل تأثير العوامل الخارجية، التزمت المشاركات بتعليمات موحدة قبل التقييم، شملت الامتناع عن ممارسة التمارين الرياضية الشاقة لمدة 24 ساعة، وتجنب تناول الكافيين والكحول لمدة 12 ساعة، والصيام لمدة 3 ساعات قبل القياس. ويعرض الشكلان (1) و(2) توزيع الخصائص الديموغرافية والجسمانية الأساسية للمشاركات في الدراسة.




الشكل (1): مخطط رادار لتوزيع معايير تكوين الجسم (القيم المتوسطة المطبّعة)
أسفر تحليل الجسم عن أحد عشرة متغيرات فسيولوجية مستقلة لكل مشارك:
▪ الطول (سم): مُقاس لأقرب 0.1 سم.

- مؤشر كتلة الجسم (كجم/م²): يُحسب باستخدام النسبة القياسية للكتلة إلى مربع الطول.
- نسبة الدهون في الجسم (%): إجمالي كتلة الدهون مقسوماً على إجمالي وزن الجسم.
- كتلة العضلات (كجم): إجمالي كتلة الأنسجة العضلية النشطة الخالية من الدهون، بما في ذلك العضلات الملساء والقلبية والهيكلية.
- نسبة العضلات الهيكلية (%): الكتلة النسبية للعضلات المرتبطة تحديداً بالهيكل العظمي.
- ماء الجسم (كجم): إجمالي حجم السوائل داخل وخارج الخلايا.
- محتوى البروتين (كجم): إجمالي الكتلة العضوية الخلوية غير الدهنية وغير المعدنية.
- مؤشر الدهون الحشوية: مقياس عددي (من 1 إلى 20) يُمثل ترسب الدهون داخل البطن.
- العمر البيولوجي (بالسنوات): العمر الأيضي الفسيولوجي المحسوب نسبةً إلى المعايير الزمنية.
- نسبة الخصر إلى الورك: مؤشر لتوزيع الدهون في مناطق الجسم المختلفة.
- معدل الأيض الأساسي (كيلو كالوري/يوم): يُقاس باستخدام معادلات هاريس-بينديكت المعدلة والمخصصة لكل للإناث مستويات الطاقة الأساسية في حالة الراحة. يُظهر مخطط الرادار القيم المتوسطة المطبّعة لخصائص الجسم الفسيولوجية لدى المشاركين. نلاحظ توازناً نسبياً متناسقاً في العينة بين مؤشر كتلة الجسم (BMI)، ومعدل الأيض الأساسي (BMR)، وكتلة العضلات، ونسبة الدهون. هذا التوزيع المتنوع والمطّبع يمنح نموذج التعلم الآلي قدرة أفضل على استخلاص الفروقات الفردية العميقة دون الانحياز لسمة بدنية معينة.
- لتقييم مساهمة المقاييس الفسيولوجية المشتقة، تم تعريف ثلاث خصائص محسوبة رياضياً كما هو موضح بالجدول 1: مؤشر كتلة الجسم ($BMI = \text{الوزن} / \text{الطول}^2$)، ومعدل الأيض الأساسي (BMR)، باستخدام صيغة كاتش-مكاردل بناءً على الكتلة الخالية من

الدهون)، والعمر البيولوجي المشتق من بيانات تحليل المعاوقة الحيوية (BIA). ولمعالجة الترابطات القوية، تم إجراء تشخيص التعدد الخطي باستخدام عامل تضخم التباين (VIF)، وتمت مقارنة مجموعات الخصائص باستخدام نموذجين: النموذج أ (10 متغيرات فيزيائية أساسية) والنموذج ب (جميع المتغيرات الـ 13 بما في ذلك المقاييس المشتقة).

الجدول (1): المتغيرات الأولية والمتغير المشتق في الدراسة.

المتغير المشتق	معادلة الحساب	المتغيرات الأولية المعتمد عليها
مؤشر كتلة الجسم (BMI)	$BMI = \frac{Weight (kg)}{height^2 (m^2)}$	الوزن والطول
معدل الايض الأساسي (BMR)	$BMR = 370 + 21.6 \times FFM (kg)$ حيث معادلة Katch-McArdle $FFM = Weight \times 1 - \frac{\text{الدهون}}{100}$	الوزن ونسبة الدهون في الجسم
العمر البيولوجي (Biological age)	خوارزمية الجهاز الاستكشافية بناءً على الانحراف المعياري لـ BMR و BMI والدهون مقارنة بالأعمار المرجعية.	BMI، BMR، نسبة الدهون، كتلة العضلات




الشكل (2): المتوسط والانحراف المعياري للخصائص الديموغرافية والجسدية للمشاركين. يوضح الشكل (2) بوضوح المتوسط الحسابي مصحوباً بالانحراف المعياري للمتغيرات الأنثروبومترية الأساسية للمجموعة. نلاحظ أن الطول ومعدل الأيض الأساسي (BMR) يمتلكان النطاق الأكبر من الانحراف المعياري، مما يشير إلى تنوع واسع في الكفاءة الأيضية وحجم الجسم بين أفراد العينة البالغ عددهم 50 مشاركاً، وهو ما يثري القدرة التعميمية للنماذج الرياضية المطورة.

2.5 بروتوكول التمرين وهيكلية جمع البيانات

استخدم التصميم التجريبي بروتوكولاً للسرعة المتزايدة متعددة المراحل مع قياسات متكررة. أكمل كل مشارك 10 تجارب تمرين متسلسلة ومستقلة في ظروف بيئية مخبرية موحدة (22 درجة مئوية، رطوبة نسبية 45٪).

- تحديد السرعة: قُسم نطاق السرعة إلى 10 مستويات فريدة ومتساوية البعد: 3.0، 4.0، 5.0، 6.0، 7.0، 8.0، 9.0، 10، 11، و12 كم/ساعة.

- التوحيد الزمني: حُفِظَت كل مرحلة سرعة لمدة 120 ثانية بالضبط (دقيقتان مع اخذ فترة راحة دقيقة واحدة بين كل مرحلة لكل مشارك. وقد اعتمدت هذه المدة لتوحيد زمن القياس بين جميع المشاركات والحصول على قياسات متسقة لاستهلاك الطاقة عند كل مستوى من مستويات السرعة ضمن البروتوكول التدريجي. ومع ذلك، لم يُستخدم في الدراسة معيار فسيولوجي مباشر، مثل قياس استهلاك الأكسجين (VO_2)، للتحقق من الوصول إلى الحالة الأيضية المستقرة خلال كل مرحلة؛ ولذلك لا تُفسر القياسات المسجلة باعتبارها قياسات مؤكدة للحالة المستقرة، وإنما باعتبارها استجابات لاستهلاك الطاقة خلال مراحل تمرين قصيرة وموحدة زمنيًا.
 - ونظرًا إلى تطبيق مستويات السرعة بصورة متسلسلة تصاعدية، فقد حافظ التصميم على بروتوكول موحد لجميع المشاركات، إلا أنه لا يستبعد بصورة كاملة احتمال وجود أثر متبقي من المرحلة السابقة أو تراكم الإجهاد عند السرعات الأعلى، خاصة مع قصر فترة الراحة بين المراحل. وقد أُخذ هذا الجانب في الاعتبار عند تفسير النتائج؛ بوصفه أحد محددات التصميم التجريبي.
- قبل الخوض في نمذجة البيانات، كان من الضروري فحص دقة السرعات الميكانيكية لجهاز المشي للتأكد من عدم وجود انزلاقات تؤثر على حساب السرعات الفعلي. يظهر هذا التحقق في الشكل (3).



الشكل (3)

تقييم سرعة سير جهاز المشي المستهدفة مقابل السرعة الفعلية ودراسة الانزلاق الميكانيكي.

توضح العلاقة بين السرعة المستهدفة والمقاسة ميكانيكياً. يُظهر منحني الانحدار ملائمة ممتازة ($R^2 = 0.985$) مع انحراف خطي طفيف جداً وصحي ميكانيكياً في السرعات العالية (معدل انزلاق ميكانيكي متوقع ومحسوب بدقة في المنحني الداخلي السفلي). هذا يثبت استقرار البيئة التجريبية وموثوقية قراءات السرعة كمُدخل أساسي صلب للنماذج التنبؤية.

- المقاييس المستهدفة: تم التقاط المتغير التابع، وهو معدل حرق السعرات الحرارية (سعة حرارية/ ساعة، كيلو كالوري/ ساعة)، بالإضافة إلى إجمالي السعرات الحرارية المستهلكة في المرحلة (كيلو كالوري)، بشكل ديناميكي عبر أجهزة مراقبة فسيولوجية دقيقة مدمجة مع واجهة الاختبار.

3.5 المعادلات المستخدمة

يُعرّف التحويل الرياضي الأساسي المستخدم لدمج مقاييس القياس عن بُعد الآنية في مجموعات بيانات زمنية مُهيكلّة كما يلي:

$$E = \int P(t) dt, \quad (1)$$

يُستنتج معدل استهلاك السرعات الحرارية النظري لكل تجربة في مرحلة منفصلة (C_{stage} ، كيلو كالوري) عن طريق قياس معدل استهلاك السرعات الحرارية اللحظي المستمر على مدى زمن التنفيذ المُوحّد.

$$C_{stage} = \int_0^t \left(\frac{CAL / HR(t)}{3600} \right) dt \quad (2)$$

بالنظر إلى أن سرعة الاختبار v تم تثبيتها عن طريق التحكم الإلكتروني في السرعة خلال كل مرحلة منفصلة مدتها دقيقتان، فإن التكامل المستمر يتبسط إلى ناتج جبري دقيق مرجح زمنياً:

$$C_{stage} = CAL / HR \times \left(\frac{120}{3600} \right) = CAL / HR \times 0.033 \quad (3)$$

6. معالجة البيانات وتنفيذ التعلم الآلي

1.6 خط نقل البيانات وإزالة التلوث الناتج عن التسريب

تمت معالجة مصفوفة القياس عن بُعد التجريبية الخام باستخدام مسار معالجة مخصص بلغة بايثون باستخدام مكتبي Pandas و NumPy. تم تحويل أشكال الأعمدة متعددة الفهارس والمراحل إلى شكل لوحة، حيث يمثل كل صف مجموعة فريدة من (معرف الموضوع، المرحلة، السرعة).

لمنع تسرب البيانات الناتجة عن القياسات المتكررة للمشاركة نفسها، تم تطبيق التحقق المتقاطع القائم على المجموعات (GroupKFold) باستخدام خمس طيات ($K = 5$)، تم تقسيم المشاركين الـ 50 الفريدين إلى مجموعات فرعية حصرية. في كل شريحة من شرائح التحقق المتقاطع، تم تدريب نماذج التعلم الآلي حصرياً على صفوف البيانات الكاملة متعددة السرعات لـ 40 مشاركاً، وتقييمها على المشاركين العشرة المتبقين غير المرئيين تماماً. وبهذا

الإجراء، لا تظهر بيانات المشاركة نفسها في مجموعتي التدريب والاختبار داخل شريحة التحقق الواحدة، مما يحذر من تسرب البيانات ويوفر تحققاً داخلياً خارج المشاركة، ومع ذلك تظل بيانات التدريب والتقييم مأخوذة من المركز نفسه، وباستخدام الأجهزة نفسها والبروتوكول التجريبي نفسه؛ ومن ثم لا يُعد هذا الإجراء تحققاً خارجياً، بل تقيماً داخلياً لقدرة النموذج على التنبؤ بمشاركات غير مستخدمات في تدريب شريحة التحقق.

2.6 اختيار نموذج التعلم الآلي

تم تقييم خمس بنى تنبؤية متميزة ضمن GroupKFold:

- أ. الانحدار الخطي باستخدام طريقة المربعات الصغرى العادية (OLS): استُخدم كنموذج أساسي لتقييم الارتباطات الخطية.
- ب. انحدار الشبكة المرنة: دُججت فيه تقنيتا L_1 (لاسو) و L_2 (ريدج) للتنظيم المتزامن لمعاقبة وضغط مقاييس تكوين الجسم شديدة الارتباط الخطي (مثل كتلة العضلات مقابل إجمالي ماء الجسم).
- ج. انحدار متجه الدعم (SVR): استُخدمت فيه نواة دالة الأساس الشعاعي غير الخطية (RBF) لرسم خرائط الانحناء متعدد الأبعاد ضمن هوامش عالية الأبعاد.
- د. مُنحدر الغابة العشوائية: مجموعة من 500 شجرة قرار مكتملة النمو وغير مترابطة، تستخدم تجميع بوتستراپ لالتقاط التفاعلات الفسيولوجية الموضعية.
- هـ. XGBoost (التعزيز التدرجي المتطرف): بنية شجرة قرار مُحسَّنة مُعززة بالتدرج، تعمل على تحسين دالة الهدف المنظمة من خلال تقليل الخطأ المتسلسل.

7. النتائج والأداء الإحصائي

1.7 التشخيص الوصفي للمجموعة


تم تجميع المعايير الإحصائية الوصفية لمجموعة الـ 50 مشاركاً عبر جميع التجارب التجريبية الموحدة بشكل منهجي في الجدول 2.

الجدول (2): الإحصاءات الوصفية لمجموعة الدراسة والمقاييس (عدد الملاحظات = 50 ×


10 مراحل = 500 ملاحظة)

أعلى قيمة	أقل قيمة	الانحراف المعياري	المتوسط	المتغير
189.2	155.0	7.1	170.8	الطول (سم)
33.1	18.2	3.4	24.8	مؤشر كتلة الجسم (كجم/م ²)
38.9	9.5	7.2	23.5	نسبة الدهون في الجسم (BF، %)
71.4	36.1	8.4	51.2	كتلة العضلات (MM، كجم)
42.1	19.8	5.1	29.8	نسبة العضلات الهيكلية (SMR، %)
15.0	1.0	3.1	7.1	مؤشر الدهون الحشوية (VFI)
2150.0	1180.0	224.6	1598.4	معدل الأيض الأساسي (كيلو كالوري/يوم)
12.00	3.00	2.87	7.50	سرعة التجربة (v، كم/ساعة)
985.0	145.0	212.8	465.2	معدل حرق السعرات الحرارية (سعر حرارية/ساعة)
32.83	4.83	7.09	15.51	إجمالي السعرات الحرارية لكل مرحلة (كيلو كالوري)

لكشف السلوك الديناميكي لحرق الطاقة مع زيادة السرعة قبل النمذجة، نرى في الشكل (4) (5) (6) تفصيلاً لهذه الأنماط الحركية. يُظهر الشكل (4) زيادة طردية واضحة في معدل حرق السعرات الحرارية (كيلو كالوري/ساعة) مع زيادة سرعة جهاز المشي من 3 إلى 12 كم/ساعة. تعكس هذه الأعمدة المتوسط العام للمجموعة، وتوضح القفزة الكبيرة في متطلبات الطاقة عند الانتقال من المشي الخفيف إلى الجري السريع.




الشكل (4): معدل حرق السعرات الحرارية الفعلي لكل مستوى سرعة على جهاز المشي.



الشكل (5): توزيع نطاقات حرق السعرات الحرارية (الحد الأدنى / المتوسط / الحد الأقصى) عبر السرعات المختلفة.

يوضح الشكل (5) المساحة التباينية لحرق السعرات. نلاحظ أنه عند السرعات المنخفضة (3 كم/ ساعة) يكون التباين بين الحد الأدنى والأقصى ضيقاً، ولكن مع زيادة السرعة وصولاً إلى 12 كم/ ساعة، يتسع النطاق بشكل هائل (ليتراوح ما بين ~600 إلى

~1400 كيلو كالوري/ ساعة). هذا الاتساع يثبت فسيولوجياً أن الوزن والسرعة وحدهما لا يفسران الطاقة المحروقة عند الجهد العالي، بل تلعب الخصائص الفسيولوجية الفردية الدور الأكبر، مما يستدعي تدخل التعلم الآلي. يمثل الشكل (6) هذا المنحنى التراكمي إجمالي الطاقة المستهلكة خلال كل مرحلة اختبارية ثابتة الزمن (120 ثانية). تتطابق قيم النقاط (من 4.8 كيلو كالوري عند سرعة 3 كم/ ساعة إلى 32.8 كيلو كالوري عند سرعة 12 كم/ ساعة) تماماً مع الحسابات الجبرية الرياضية المذكورة في المنهجية، مؤكدةً على خطية النمو التراكمي للطاقة المحروقة كمرحلة زمنية مقطوعة.



الشكل (6): إجمالي السرعات الحرارية المستهلكة في المرحلة الواحدة (مدتها دقيقتان) بدلالة السرعة.

2.7 تشخيص التعددية الخطية ومصفوفة الارتباط (Multicollinearity and VIF)

(Diagnostics)

قبل البدء في النمذجة التنبؤية، تم حساب معاملات ارتباط بيرسون ومعاملات تضخم التباين (VIF) لجميع المتغيرات الفيزيائية والمشتقة لتقييم تكرار السمات. وكما هو موضح في الجدول (3)، أظهرت السمات المشتقة ارتباطاً خطياً متعددًا شديدًا مع قياساتها الأساسية (على سبيل المثال، ارتبط معدل الأيض الأساسي (BMR) ارتباطاً قوياً بكتلة العضلات، $r = 0.976$ ؛ وارتبط مؤشر كتلة الجسم (BMI) بالوزن، $r = 0.961$). ونتيجة لذلك،

أظهرت المتغيرات المشتقة درجات VIF عالية للغاية ($VIF_{BMR} = 93,844.13$ ؛ $VIF_{BMI} = 4,058.82$). وتؤكد هذه النتائج أن القياسات الأولية الحركية والجسدية تختزل معظم التباين الفسيولوجي، مما يفسر المساهمة الهامشية للمتغيرات المشتقة في تحسين أداء النماذج.

الجدول (3): معاملات الارتباط بين المتغيرات الأولية والمشتقة

المتغير	نوع المتغير	معامل الارتباط مع حرق السعرات (r)	معامل تضخم التباين (VIF)	حالة التعددية الخطية
سرعة التجربة (v)	حركي أولي	0.976	9.58	مقبولة (المتنبئ الرئيسي)
الوزن	أنثروبومتري أولي	-0.045	4,956.09	مرتفعة
الطول	أنثروبومتري أولي	0.063	11,846.68	مرتفعة
كتلة العضلات (MM)	فسيولوجي أولي	-0.014	78,962.33	مرتفعة جداً
نسبة الدهون (BF%)	فسيولوجي أولي	-0.047	3,149.63	مرتفعة
مؤشر كتلة الجسم (BMI)	مشتق	-0.055	4,058.82	مرتفعة (ارتباط بالوزن $r=0.961$)
معدل الأيض الأساسي (BMR)	مشتق	-0.024	93,844.13	مرتفعة جداً (ارتباط بالعضلات $r=0.976$)
العمر البيولوجي	مشتق	-0.026	912.47	مرتفعة


3.7 نتائج التحقق الداخلي خارج المشاركة

يتم توفير مقاييس الاختبار التي تم التحقق منها عبر بنى التعلم التنبؤي الخمس في الجدول (4). يُظهر نموذج XGBoost Regressor تفوقاً إحصائياً واضحاً على النماذج الأخرى، حيث حقق متوسط معامل التحديد (R^2) يساوي 0.958 في ظل إجراءات صارمة لتطهير المشاركين. وتشير هذه النتيجة إلى قدرة النموذج على تفسير نسبة مرتفعة من التباين في استهلاك الطاقة لدى المشاركين اللواتي لم تدخل بياناتهم في تدريب الطية المقابلة. ومع ذلك، ينبغي تفسير هذا الأداء في إطار التحقق الداخلي فقط، إذ إن جميع المشاركات جُمعت بياناتهم في المركز نفسه وباستخدام الأجهزة والبروتوكول نفسيهما، ولم تُستخدم عينة خارجية مستقلة للتحقق من أداء النموذج. وقد أشار هذا إلى إمكانية تحديد 95.8٪ من التباين في استهلاك السعرات الحرارية لدى مشاركين بشريين جدد تماماً باستخدام مقاييس مسح الجسم غير الجراحية المدججة مع سرعة المشي على جهاز المشي. يلاحظ أيضاً أن النموذجان OLS والشبكة المرنة حققا قيمتي R^2 متقاربتين جداً (0.812 و 0.809). هذا يدل


على أن التنظيم في Elastic Net لم يُضف قيمة ملموسة، وهذا غالباً لأن بيانات تكوين الجسم المترابطة ليست شديدة الترابط الخطي لتحدث فارقاً.

الجدول (4): مقارنة أداء النموذج في ظل التحقق المتقاطع القائم على المجموعات

GroupKFold				
النموذج التنبؤي	المتغير المستهدف	متوسط R^2	RMSE (كيلو كالوري/ ساعة)	MAE (كيلو كالوري/ ساعة)
OLS الانحدار الخطي	معدل حرق السعرات الحرارية	0.812	92.1	74.3
الانحدار المرن للشبكة	معدل حرق السعرات الحرارية	0.809	92.8	75.1
ناقل الدعم (SVR)	معدل حرق السعرات الحرارية	0.874	75.5	58.2
نموذج الانحدار للغابات العشوائية	معدل حرق السعرات الحرارية	0.921	59.8	42.6
نموذج انحدار XGBoost	معدل حرق السعرات الحرارية	0.958	43.6	31.2



الشكل (7): مقارنة قيم معامل التحديد (R^2) بين بنيات التعلم الآلي المختلفة.



الشكل (8): أداء التعميم خارج نطاق عينة التدريب (R^2 Out-of-Subject) موضحاً الانحراف المعياري لكل طية.

لتقييم القيمة المضافة للمتغيرات المشتقة (BMI، BMR، والعمر البيولوجي) وتحديد مدى ضرورتها في وجود القياسات الأولية، تم إجراء تحليل مقارن واستبعاد تدريجي (Ablation Analysis) لنموذج XGBoost تحت بروتوكول التحقق المتقاطع (5-Fold GroupKFold). وكما يوضح الجدول (5)، حقق النموذج الكامل (Model B) تحسناً طفيفاً في معامل التحديد قدره 0.007 (+0.7%) وانخفاضاً في خطأ RMSE بمقدار 3.2 كيلو كالوري/ ساعة مقارنة بالنموذج المقتصر على المتغيرات الأولية (Model A). وكشف تحليل الحذف التدريجي أن إلغاء متغير BMR أدى إلى انخفاض الأكبر في الأداء بين المتغيرات المشتقة ($R^2 = 0.953$)، بينما حافظ النموذج على أكثر من 95.1٪ من قدرته التنبؤية بالاعتماد على السرعة والقياسات الأنثروبومترية المباشرة فقط.

جدول (5): مقارنة Model A و Model B مع تحليل الاستبعاد التدريجي لنموذج XGBoost

التغير في R^2	MAE (كيلو كالوري/ ساعة)	RMSE (كيلو كالوري/ ساعة)	R^2	المتغيرات المستبعدة	التكوين التنبؤي (Model Configuration)
المرجع	31.2	43.6	0.958	لا يوجد (13 متغيرًا)	النموذج الكامل (Model B - Full Set)
-0.001	31.5	43.9	0.957	العمر البيولوجي	استبعاد العمر البيولوجي
-0.004	32.1	44.8	0.954	مؤشر كتلة الجسم	استبعاد BMI
-0.005	32.3	45.1	0.953	معدل الأيض الأساسي	استبعاد BMR
-0.007	33.4	46.8	0.951	جميع المتغيرات المشتقة (3)	النموذج الأولي فقط (Model A - Primary)

4.7 التحليل التشخيصي الشامل لنموذج XGBoost


يُقدّم هذا القسم تحليلًا تشخيصيًا معمّقًا لجودة ملاءمة نموذج XGBoost من خلال ثلاثة أشكال تكاملية (9)، (10)، (11). تُشكّل معًا منظومة تحقق إحصائية شاملة تُجيب عن ثلاثة أسئلة جوهرية: هل التنبؤات دقيقة؟ هل الأخطاء عشوائية؟ هل الأخطاء طبيعية التوزيع؟

تُجمع هذه الأشكال البديلة والبيانية على حقيقة إحصائية واحدة: نموذج XGBoost هو الأفضل بلا منازع. يحقق أعلى قيمة لـ R^2 بمقدار 0.958 وأقل قيم للأخطاء ($MAE=31.2$, $RMSE=43.6$ كيلو كالوري/ ساعة). يوضح الشكل (8) على وجه الخصوص استقرار هذا النموذج عبر طيات التحقق المتقاطع (مع انحراف معياري ضئيل جدًا)، بما يشير إلى ثبات نسبي في أدائه عند تقييمه على مشاركات لم تدخل بياناتهن في تدريب الطية المقابلة. ويعكس ذلك قدرة تنبؤية داخلية واعدة، إلا أنه لا يمثل دليلًا على التعميم الخارجي، نظرًا إلى عدم اختبار النموذج حتى الآن على عينة مستقلة من مركز أو مجتمع مختلف. بينما تفشل النماذج الخطية (OLS و ElasticNet) في التقاط العلاقات غير الخطية الفسيولوجية المعقدة كما هو واضح في قيم أخطائها المرتفعة.

كما هو موضح بالشكل (9) المخطط الأكثر استخدامًا في علم الإحصاء التطبيقي لتقييم دقة النماذج التنبؤية. تُمثل كل نقطة في المخطط ملاحظة واحدة من أصل 500 ملاحظة (50 مشاركا $\times$ 10 مستوى سرعة)، وتُصوّر العلاقة بين ما تنبأ به النموذج وما قيس فعليًا في

المختبر. يمتد المحوران من 0° إلى ~ 1200 كيلو كالوري/ ساعة، مما يغطي الطيف الكامل لاستهلاك الطاقة من الجهد الخفيف إلى الجهد الشديد. الخط المنقط المرجعي المرسوم بزاوية 45° يمثل خط "التنبؤ المثالي" الذي تتساوى عنده القيم المتوقعة مع القيم الفعلية تمامًا. يتضح من الشكل أن معظم النقاط تتجمع بإحكام شديد حول هذا الخط المرجعي عبر النطاق الكامل للقياسات، مما يعكس بشكل مباشر ما تُعبّر عنه قيمة $R^2 = 0.958$ رياضياً: أي أن النموذج يُفسّر 95.8٪ من التباين الكلي في معدلات حرق السعرات الحرارية.


والأهم من حجم الدقة الإجمالية هو التحقق من اتساقها: هل يؤدي النموذج بنفس الكفاءة في نطاق السرعات المنخفضة (150-300 كيلو كالوري/ ساعة) كما يؤدي في السرعات العالية (700-1200 كيلو كالوري/ ساعة)؟ الإجابة المقروءة من الشكل إيجابية؛ إذ لا يظهر أي تحيز منهجي أو انحراف متزايد في أي طرف من النطاق. هذا الاتساق عبر النطاق الديناميكي الواسع يُعدّ دليلاً حاسماً على أن نموذج XGBoost التقط البنية الفسيولوجية الحقيقية لاستهلاك الطاقة وليس مجرد ارتباط إحصائي سطحي.




الشكل (9): مخطط الانتشار للقيم المتوقعة (المحور الأفقي) مقابل القيم الفعلية (المحور الرأسي) لنموذج XGBoost عبر 500 ملاحظة.

يرسم الشكل (10) العلاقة بين القيم المتوقعة (المحور الأفقي) والبواقي أو الأخطاء المتبقية (المحور الرأسي)، حيث يُعرّف البقي (Residual) رياضياً بالصيغة: $e_i = y_i - \hat{y}_i$ ، أي الفرق الجبري بين القيمة المرصودة والقيمة المتوقعة لكل ملاحظة. المعيار الإحصائي الذي يُحكم به على هذا المخطط مزدوج: أولاً، يجب أن تتمركز البواقي حول خط الصفر (المحور الأفقي) لا أن تنحاز بشكل منهجي نحو القيم الموجبة أو السالبة. ثانياً، يجب أن يكون توزيع البواقي عشوائياً بالكامل دون أي نمط هندسي أو بنية زمنية محددة.

تحليل الشكل يكشف عن ثلاث سمات دالة: أولاً، تتمحور النقاط بشكل متماثل حول خط الصفر عبر مدى كامل القيم المتوقعة (من 0 إلى 1200 كيلو كالوري/ ساعة)، مما يشير إلى غياب أي تحيز منهجي. ثانياً، لا يظهر أي نمط قوسي أو خطي في البواقي وهو ما كان سيدل على أن النموذج افتقد علاقات غير خطية جوهرية. ثالثاً، لا يتزايد تشتت البواقي مع زيادة القيمة المتوقعة، مما ينفي ظاهرة "تفاوت التباين" (Heteroscedasticity) التي كثيراً ما تُعيب نماذج التنبؤ البيولوجية. من الناحية الفسيولوجية، يعني هذا أن النموذج لا يُبالغ في تقدير استهلاك الطاقة لدى فئة معينة (كالأفراد ذوي الكتلة العضلية العالية) ولا يُقلل منه لدى فئة أخرى (كالأفراد ذوي نسبة الدهون المرتفعة)، بل يُنتج تنبؤات منصفة ومتوازنة عبر الطيف الكامل لتكوينات الجسم المدروسة.



الشكل (10): مخطط البواقي (القيمة المتوقعة في المحور الأفقي، مقدار الخطأ المتبقى في المحور الرأسي) - كل نقطة تمثل الفرق بين ما تنبأ به النموذج وما قيس فعلياً.



الشكل (11): المدرج التكراري (Histogram) لتوزيع البواقي مع منحنى التوزيع الطبيعي المتوقع حيث تتمركز الأخطاء بشكل متماثل حول الصفر.

يعرض الشكل (11) التوزيع التكراري (Histogram) لجميع البواقي الـ 500 المحسوبة من تجارب التحقق المتقاطع، مُقارَنَةً بمنحنى التوزيع الطبيعي (Gaussian) النظري المُحاكي بنفس المتوسط والانحراف المعياري. يُعدّ هذا المخطط الركيزة الثالثة في منظومة التحقق، إذ يختبر فرضية ضرورية للاستدلال الإحصائي الصحيح: هل الأخطاء موزعة بشكل طبيعي؟ يكشف الشكل أن التوزيع الفعلي للبواقي يتطابق بدرجة عالية مع المنحنى الجرسى الطبيعي المُتوقع؛ إذ يتمركز ذروة التوزيع حول الصفر (المتوسط ≈ 0)، ويمتد التوزيع بشكل متماثل نحو القيم الموجبة والسالبة بصورة متكافئة. هذا يعني أن أخطاء التنبؤ ليست انعكاساً لتحيز منهجي بل لعدم يقين عشوائي وهو أفضل ما يمكن توقعه من أي نموذج تنبؤي يعمل على بيانات بيولوجية معقدة.

لتحديد قيمة الانحراف المعياري للبواقي من الشكل، يتضح أن معظم الأخطاء تقع في النطاق $[-60, +60]$ كيلو كالوري/ ساعة، وهو ما يتسق مع قيمة RMSE المُبلّغ عنها (43.6)

كيلو كالوري/ساعة). الذيل الخارجية للتوزيع (القيم التي تتجاوز ± 100 كيلو كالوري/ساعة) نادرة وتقابل الحالات الحدية التي تجمع بين سرعات عالية جدًا وتركيبات جسمية متطرفة وهو أمر متوقع ومقبول إحصائيًا. إن توافر هذا التوزيع الطبيعي للأخطاء يُتيح للباحثين بناء "نطاقات ثقة" (Confidence Intervals) موثوقة حول أي تنبؤ بعيني، على سبيل المثال، يمكن الاستفادة بأن التنبؤ بمعدل 500 كيلو كالوري/ساعة يحمل مجالا ± 85 كيلو كالوري/ساعة بثقة 95، ويسهم عرض نطاق عدم اليقين في استكمال تقييم الأداء التنبؤي للنموذج، وذلك من خلال إظهار التباين المتوقع حول التقديرات النقطية. كما توفر الأشكال التشخيصية مجتمعة معلومات مكملية عن جودة الملاءمة، ونمط البواقي، وتوزيع الأخطاء داخل بيانات الدراسة. ومع خلال ذلك، تمثل هذه الاختبارات تقييمًا داخليًا لأداء النموذج، وقد لا تكفي بمفردها لإثبات صلاحيته للتطبيق السريري أو التعميم على مجتمعات مستقلة، وهو ما يتطلب تحققًا خارجيًا لاحقًا.

تتكامل هذه الأشكال الثلاثة لتُقدم برهانًا إحصائيًا متعدد الأبعاد على موثوقية نموذج XGBoost: فالشكل (9) يُثبت الدقة الكمية العالية ($R^2 = 0.958$) واتساقها عبر النطاق الديناميكي الكامل، والشكل (10) يُثبت أن الأخطاء لا تحمل أي بنية منهجية تدل على نقص في النمذجة أو تحيز فسيولوجي، والشكل (11) يُثبت أن الأخطاء موزعة طبيعيًا مما يُصحح أساس الاستدلال الإحصائي للتطبيقات السريرية. هذه المنظومة الثلاثية المتكاملة تمثل في مجملها ما يُعرف في الإحصاء التطبيقي بـ "الشهادة الكاملة" لصلاحية النموذج، وهي أعلى مستوى يمكن الوصول إليه في التحقق من نماذج التنبؤ الكمي في علوم الصحة والرياضة.

8. المناقشة

1.8 لتفوق التنبؤي لنموذج XGBoost وسياقه النظري

أظهرت نتائج هذه الدراسة تفوق نموذج XGBoost على جميع النماذج الأخرى، محققاً أعلى معامل تحديد ($R^2 = 0.958$) وأقل قيم لمتوسط الخطأ المطلق (MAE) وجذر متوسط مربع الخطأ (RMSE). ويتفق هذا الأداء مع الأدبيات الحديثة التي تشير إلى أن خوارزميات التعزيز التدرجي (Gradient Boosting) تتمتع بقدرة عالية على نمذجة العلاقات غير الخطية والتفاعلات المعقدة بين المتغيرات الفسيولوجية مقارنةً بالنماذج الإحصائية التقليدية أو نماذج الانحدار الخطي. ويُعزى ذلك إلى قدرة XGBoost على بناء عدد كبير من أشجار القرار بصورة متتابعة، بحيث يُصحح كل نموذج جديد أخطاء النموذج السابق، مما يؤدي إلى تحسين الدقة وتقليل التحيز والتباين في آنٍ واحد (Chen & Guestrin, 2016).

وتكتسب هذه النتيجة أهمية خاصة في تطبيقات فسيولوجيا التمرين، حيث يتأثر استهلاك الطاقة بمجموعة من العوامل المتداخلة تشمل سرعة التمرين، ومعدل الأيض الأساسي، وتركيب الجسم، والعمر البيولوجي، وهي متغيرات يصعب تمثيلها بعلاقات خطية بسيطة. وفي المقابل، يستطيع XGBoost التقاط هذه التفاعلات المعقدة دون الحاجة إلى افتراض شكل رياضي محدد للعلاقة بين المتغيرات، الأمر الذي يفسر تفوقه في هذه الدراسة مقارنةً بنماذج الانحدار التقليدية، كما أكدته دراسات حديثة طبقت تقنيات التعلم الآلي في التنبؤ بالمؤشرات الفسيولوجية واستهلاك الطاقة أثناء النشاط البدني (Lundberg et al., 2020; O'Driscoll et al., 2020; Álvarez-García et al., 2020).

كما تدعم موثوقية النتائج آلية التحقق المستخدمة؛ إذ طبق تحقق متقاطع قائم على المجموعات (GroupKFold) بدلاً من التقسيم العشوائي للملاحظات، بما يمنع ظهور بيانات المشاركة نفسها في مجموعتي التدريب والاختبار في الطية الواحدة. ويحد هذا الإجراء من تسرب البيانات الناتج عن القياسات المتكررة، ويوفر تقديرًا داخلياً أكثر واقعية للأداء

على مشاركات غير مستخدمات في تدريب الطية (Kapoor؛Collins et al.،2024)، ومع ذلك، فإن هذا الإجراء يمثل تحققًا داخليًا خارج المشاركة وليس تحققًا خارجيًا مستقلًا، حيث أن مجموعتي التدريب والتقييم مستمدتان من المجتمع نفسه، وقد جُمعت البيانات في المركز نفسه وباستخدام الأجهزة والبروتوكول نفسيهما. ولذلك ينبغي عدم تفسير الأداء المرتفع للنموذج بوصفه دليلًا نهائيًا على قابليته للتعميم السريري قبل اختباره على عينة مستقلة خارجيًا.

وعند مقارنة هذه النتائج بما ورد في الأدبيات، يتضح أن الأداء المرتفع الذي حققه نموذج XGBoost يتجاوز ما تحققه عادةً معادلات الانحدار التقليدية المستخدمة لتقدير استهلاك الطاقة، والتي تعتمد غالبًا على عدد محدود من المتغيرات مثل الوزن أو السرعة أو قيم MET، في حين يستفيد النموذج الحالي من معلومات أكثر شمولًا حول تركيب الجسم، مما يُمكنه من تقديم تقديرات أكثر دقة وفردية لاستهلاك الطاقة الحرارية.

2.8 قابلية تفسير SHAP وأهمية الميزات العالمية

لزيادة شفافية نموذج XGBoost وتعزيز قابلية تفسير قراراته، تم استخدام تفسيرات شابلي الإضافية (SHapley Additive exPlanations; SHAP) لتحليل المساهمة النسبية لكل متغير في التنبؤ باستهلاك الطاقة الحرارية. ويُعد SHAP أحد أكثر أساليب الذكاء الاصطناعي التفسيري (Explainable Artificial Intelligence،XAI) شيوعًا، إذ يعتمد على نظرية Shapley في الألعاب التعاونية لتقدير المساهمة الحدية لكل متغير في التنبؤ النهائي بطريقة عادلة ومتسقة، مع المحافظة على الاتساق الرياضي بين جميع المتغيرات الداخلة في النموذج (Lundberg & Lee،2017)؛ (Lundberg et al.،2020).

وقد أظهر التحليل العالمي للميزات، استنادًا إلى متوسط القيم المطلقة لقيم SHAP ($|φ|$)، أن ترتيب المتغيرات الأكثر تأثيرًا في التنبؤ باستهلاك الطاقة الحرارية كان على النحو الآتي: سرعة التمرين < معدل الأيض الأساسي < كتلة العضلات < نسبة الدهون في الجسم < نسبة العضلات الهيكلية < مؤشر كتلة الجسم < مؤشر الدهون الحشوية < العمر

البيولوجي. ويعكس هذا الترتيب مساهمة كل متغير في تحسين دقة النموذج على مستوى جميع أفراد العينة، وليس في حالة فردية واحدة، الأمر الذي يوفر فهمًا أكثر شمولًا للعوامل المؤثرة في استهلاك الطاقة أثناء التمرين.

وتنسجم هذه النتائج عمومًا مع الأسس الفسيولوجية؛ إذ ترتبط سرعة التمرين بشدة الجهد والمتطلبات الميكانيكية والأيضية. كما يرتبط معدل الأيض الأساسي بخصائص الجسم، ولا سيما الأنسجة الخالية من الدهون، ولذلك قد يسهم في تفسير الفروق الفردية في استهلاك الطاقة. ومع ذلك، تعكس أهمية SHAP اعتماد النموذج على المتغير داخل البيانات ولا تثبت علاقة سببية مستقلة (American College of Sports Medicine، 2021؛ Fernández-Verdejo et al.، 2024).

وقد أسهمت كتلة العضلات بدرجة مرتفعة نسبيًا في تنبؤات النموذج، وهو ما يتفق مع ارتباط الأنسجة الخالية من الدهون بالإنفاق الطاقوي. أما مساهمات نسبة الدهون ومؤشر الدهون الحشوية فكانت أقل في النموذج الحالي. وينبغي تفسير هذا الترتيب بوصفه خاصًا بالعينة وبنية النموذج، لا ترتيبًا فسيولوجيًا ثابتًا قابلاً للتعميم على جميع المجتمعات (Westerterp، 2013؛ Westerterp، 2018).

وتؤكد هذه النتائج القيمة التطبيقية لاستخدام SHAP في الدراسات الرياضية والصحية، إذ لا يقتصر دوره على تفسير أداء النموذج، بل يُسهم أيضًا في تحديد المتغيرات الأكثر أهمية من الناحية الفسيولوجية، مما يعزز ثقة الباحثين والممارسين في استخدام نماذج التعلم الآلي لدعم اتخاذ القرار في مجالات التدريب الرياضي واللياقة البدنية والطب الرياضي، وهو ما يتماشى مع الاتجاهات الحديثة نحو توظيف الذكاء الاصطناعي التفسيري في التطبيقات الصحية (Lundberg et al.، 2020؛ Arrieta et al.، 2020).

3.8 التفاعل الآلي للخصائص الرئيسة والتطبيقات العملية للنموذج

أظهر تحليل SHAP أن القيم الأعلى لمعدل الأيض الأساسي ارتبطت عمومًا بمساهمات موجبة في تنبؤ استهلاك الطاقة، عند ثبات السياق العام لبقية المتغيرات في النموذج. ويتسق هذا النمط مع ارتباط معدل الأيض الأساسي بالأنسجة النشطة أيضًا،

لكنه لا يثبت أن رفع معدل الأيض الأساسي يؤدي سببياً إلى زيادة الاستهلاك أثناء الحمل نفسه (Westerterp, 2018؛ Fernández-Verdejo et al., 2024).

كما أظهر النموذج أن مؤشرات تركيب الجسم أسهمت بصورة تكاملية في التنبؤ؛ فقد ارتبطت بعض القيم الأعلى لكتلة العضلات بمساهمات موجبة، مع اختلاف النمط وفق قيم المتغيرات الأخرى. وتؤكد هذه النتيجة أن علاقات SHAP تفسر سلوك النموذج وتفاعلاته داخل البيانات، ولا ينبغي التعامل معها بوصفها دليلاً مباشراً على آلية فسيولوجية سببية (American، Fernández-Verdejo et al., 2024؛ College of Sports Medicine, 2021).

وتشير هذه النتائج إلى أن دمج مؤشرات تركيب الجسم مع متغيرات الأداء البدني يوفر تقديرات أكثر فردية مقارنة بالمعادلات التقليدية المستخدمة في العديد من أجهزة المشي التجارية، والتي تعتمد غالباً على متغيرات عامة مثل الوزن أو السرعة أو قيم MET دون الأخذ في الاعتبار الاختلافات الفردية في تركيب الجسم. وقد أشارت دراسات سابقة إلى أن هذه المعادلات قد تؤدي إلى تفاوت ملحوظ في تقدير استهلاك الطاقة، خصوصاً عند الأفراد الذين يختلفون في نسبة الكتلة العضلية أو نسبة الدهون رغم تشابه الوزن الكلي (Hall et al., 2004؛ Byrne et al., 2005). وفي المقابل، حقق نموذج XGBoost في الدراسة الحالية متوسط خطأ مطلق بلغ 31.2 كيلو كالوري/ ساعة، مما يعكس قدرة جيدة على التنبؤ الفردي ضمن ظروف الدراسة الحالية.

تشير النتائج إلى إمكان تطوير أدوات مساعدة لتقدير استهلاك الطاقة بصورة أكثر تخصيصاً بالاستفادة من سرعة التمرين ومؤشرات BIA. وقد تكون هذه الأدوات مفيدة في البحث والتقييم الرياضي الأولي، لكنها لا تُعد بديلاً عن القياس الحراري غير المباشر أو التقييم السريري. ويتطلب أي دمج في تطبيقات اللياقة أو التأهيل تحققاً خارجياً، ومعايرةً للسكان المستهدفين، وتقييماً للخطأ وعدم اليقين قبل الاستخدام العملي (Arrieta et al., 2020؛ Collins et al., 2024).

ورغم النتائج المشجعة، فإن للدراسة عددًا من المحددات التي ينبغي أخذها في الاعتبار عند تفسير النتائج. فقد اقتصرَت الدراسة على 50 مشاركة، وهو حجم عينة مناسب للدراسة الاستكشافية، إلا أن التحقق من أداء النموذج على عينات أكبر وأكثر تنوعًا سيزيد من موثوقية النتائج وقابليتها للتعميم. كما لم تتناول الدراسة الفروق المرتبطة بالجنس أو الفئة العمرية، وهي عوامل قد تؤثر في استهلاك الطاقة وأنماط الاستجابة الفسيولوجية. ومن المحددات المنهجية أيضًا أن كل مستوى من مستويات السرعة استمر لمدة (2ق) فقط، مع (1ق) للراحة بين المراحل المتتالية، دون استخدام مؤشر فسيولوجي مباشر للتحقق من الوصول إلى الحالة الأيضية المستقرة. وقد تم تطبيق السرعات بترتيب تصاعدي ثابت قد يسمح بوجود أثر متبقٍ من المراحل السابقة أو تراكم للإجهاد عند السرعات الأعلى. لذا، يُوصى في الدراسات المستقبلية باستخدام مدد مراحل أطول عند الحاجة للتحقق من الحالة المستقرة، والاستعانة بمؤشرات فسيولوجية مباشرة مثل استهلاك الأكسجين، مع دراسة استخدام ترتيب عشوائي أو متوازن لمستويات السرعة وفترات استشفاء كافية للحد من تأثير ترتيب المراحل. كذلك أُجريت التجارب في ظروف مخبرية ثابتة عند درجة حرارة 22°م وعلى جهاز مشي بميل صفري، الأمر الذي قد يحد من تعميم النتائج على البيئات الخارجية أو التمارين ذات ظروف الحمل المختلفة. لذلك، توصي الدراسة بإجراء تحقق خارجي (External Validation) للنموذج على مجتمعات مستقلة، مع إدراج متغيرات إضافية مثل ميل جهاز المشي، والظروف البيئية، واختلاف الفئات السكانية، بهدف تقييم قدرة النموذج على التعميم في سيناريوهات تطبيقية متنوعة.

9. الخلاصة

نجحت هذه الدراسة في تطوير إطار قائم على التعلم الآلي للتنبؤ باستهلاك الطاقة الحرارية أثناء التمرين على جهاز المشي، من خلال دمج بيانات تكوين الجسم المقاسة بتقنية المعاوقة الكهربائية الحيوية مع متغيرات الأداء الحركي. وأظهرت النتائج، باستخدام تحقق متقاطع قائم على مجموعات المشاركات، تفوق نموذج XGBoost على النماذج الأخرى،

إذ حقق معامل تحديد بلغ $R^2 = 0.958$ ، بما يعكس قدرته العالية على تمثيل العلاقات غير الخطية بين الخصائص الجسمية وسرعة التمرين واستهلاك الطاقة. كما أظهر تحليل SHAP أن سرعة التمرين، ومعدل الأيض الأساسي، وكتلة العضلات، ونسبة الدهون في الجسم كانت من أبرز المتغيرات المساهمة في التنبؤ، وهو ما يؤكد أهمية الجمع بين شدة النشاط والاختلافات الفردية في تكوين الجسم عند تقدير استهلاك الطاقة. وتشير هذه النتائج إلى إمكانية توظيف النموذج في تطوير تطبيقات أكثر تخصيصاً لتتبع اللياقة البدنية، ودعم برامج التدريب الرياضي وإعادة التأهيل، بالاعتماد على قياسات غير جراحية ومتاحة نسبياً.

ومع ذلك، لا يمكن الاستدلال من النتائج الحالية على الجاهزية للتطبيق السريري أو التعميم خارج مجتمع الدراسة، ويظل التحقق الخارجي على عينات مستقلة شرطاً أساسياً قبل أي استخدام تطبيقي أوسع.

ويوصى مستقبلاً بالتحقق الخارجي من النموذج على عينات أكبر وأكثر تنوعاً، مع إدراج متغيرات إضافية مثل ميل جهاز المشي والظروف البيئية، بما يعزز قابليته للتعميم والاستخدام التطبيقي.

10. الاعتبارات الأخلاقية

تم الحصول على الموافقة الأخلاقية لإجراء هذه الدراسة من لجنة الأخلاقيات والسلامة الحيوية بجامعة صحار (University Ethics and Biosafety Committee – UEBC)، وذلك بموجب الموافقة رقم UEB 2025-RG-02، وقد أُجريت جميع إجراءات الدراسة وفقاً للمعايير الأخلاقية المعتمدة، مع الحصول على موافقة المشاركين قبل جمع البيانات.

11. التمويل

نُفذت هذه الدراسة في جامعة صحار، بدعم وتمويل من هيئة البحث العلمي والابتكار بسلطنة عُمان، ضمن المشروع البحثي رقم SU/BFP/RG/2024/13.

12. الإفصاح عن تضارب المصالح

يُقر الباحثون بأنه لا توجد أي مصالح مالية أو شخصية أو مهنية يمكن أن تؤثر في نتائج هذه الدراسة أو تفسيرها.

13. المراجع

- Álvarez-García, J. A., Cvetković, B., & Luštrek, M. (2020). A survey on energy expenditure estimation using wearable devices. *ACM Computing Surveys*, 53(5), Article 101, 1–35. <https://doi.org/10.1145/3404482>
- American College of Sports Medicine. (2021). *ACSM's guidelines for exercise testing and prescription* (11th ed.). Wolters Kluwer. <https://shop.lww.com/ACSM-s-Guidelines-for-Exercise-Testing-and-Prescription/p/9781975150198>
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Benetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable artificial intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Boudry, F., Durand, F., Meric, H., & Mouakher, A. (2024). The role of machine learning methods in physiological explorations of endurance-trained athletes: A mini-review. *Frontiers in Sports and Active Living*, 6, Article 1440652. <https://doi.org/10.3389/fspor.2024.1440652>
- Bull, F. C., Al-Ansari, S., Biddle, S., Borodulin, K., Buman, M. P., Cardon, G., Carty, C., Chaput, J.-P., Chastin, S., Chou, R., Dempsey, P. C., DiPietro, L., Ekelund, U., Firth, J., Friedenreich, C. M., Garcia, L., Gichu, M., Jago, R., Katzmarzyk, P. T., ... Willumsen, J. F. (2020). World Health Organization 2020 guidelines on physical activity and sedentary behaviour. *British Journal of Sports Medicine*, 54(24), 1451–1462. <https://doi.org/10.1136/bjsports-2020-102955>
- Byrne, N. M., Hills, A. P., Hunter, G. R., Weinsier, R. L., & Schutz, Y. (2005). Metabolic equivalent: One size does not fit all. *Journal of Applied Physiology*, 99(3), 1112–1119. <https://doi.org/10.1152/japplphysiol.00023.2004>
- Campa, F., Coratella, G., Cerullo, G., Noriega, Z., Francisco, R., Charrier, D., Irurtia, A., Lu kaski, H., Silva, A. M., et al. (2024). High-standard predictive equations for estimating body composition using bioelectrical impedance analysis: A

- systematic review. *Journal of Translational Medicine*, 22, Article 515. <https://doi.org/10.1186/s12967-024-05272-x>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). Association for Computing Machinery. <https://doi.org/10.1145/2939672.2939785>
- Collins, G. S., Moons, K. G. M., Dhiman, P., Riley, R. D., Beam, A. L., Van Calster, B., Ghassemi, M., Liu, X., Reitsma, J. B., van Smeden, M., Boulesteix, A.-L., Camaradou, J. C., Celi, L. A., Denaxas, S., Denniston, A. K., Glocker, B., Golub, R. M., Harvey, H., Heinze, G., et al. (2024). TRIPOD+AI statement: Updated guidance for reporting clinical prediction models that use regression or machine learning methods. *BMJ*, 385, e078378. <https://doi.org/10.1136/bmj-2023-078378>
- Fernández-Verdejo, R., Sanchez-Delgado, G., & Ravussin, E. (2024). Energy expenditure in humans: Principles, methods, and changes throughout the life course. *Annual Review of Nutrition*, 44(1), 51–76. <https://doi.org/10.1146/annurev-nutr-062122-031443>
- Hall, C., Figueroa, A., Fernhall, B., & Kanaley, J. A. (2004). Energy expenditure of walking and running: Comparison with prediction equations. *Medicine & Science in Sports & Exercise*, 36(12), 2128–2134. <https://doi.org/10.1249/01.MSS.0000147584.87788.0E>
- Hills, A. P., Mokhtar, N., & Byrne, N. M. (2014). Assessment of physical activity and energy expenditure: An overview of objective measures. *Frontiers in Nutrition*, 1, Article 5. <https://doi.org/10.3389/fnut.2014.00005>
- Hossain, M. B., LaMunion, S. R., Crouter, S. E., Melanson, E. L., & Sazonov, E. (2024). A CNN model for physical activity recognition and energy expenditure estimation from an eyeglass-mounted wearable sensor. *Sensors*, 24(10), Article 3046. <https://doi.org/10.3390/s24103046>
- Hossain Mondal, M. R., Bharati, S., & Podder, P. (2024). A review on explainable artificial intelligence for healthcare: Why, how, and when? *IEEE Transactions on*

- Artificial Intelligence*, 5(4), 1429–1442.
<https://doi.org/10.1109/TAI.2023.3266418>
- Kapoor, S., Cantrell, E. M., Peng, K., Pham, T. H., Bail, C. A., Gundersen, O. E., Hofman, J. M., & Narayanan, A. (2023). Leakage and the reproducibility crisis in machine-learning-based science. *Patterns*, 4(9), Article 100804. <https://doi.org/10.1016/j.patter.2023.100804>
- Kim, M.-S., & Seong, J.-H. (2025). A personalized energy expenditure estimation method using modified MET and heart rate-based DQN. *Sensors*, 25(11), Article 3416. <https://doi.org/10.3390/s25113416>
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N., & Lee, S.-I. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*, 2(1), 56–67. <https://doi.org/10.1038/s42256-019-0138-9>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In I. Guyon et al. (Eds.), *Advances in neural information processing systems* (Vol. 30, pp. 4765–4774). Curran Associates. <https://papers.nips.cc/paper/7062-a-unified-approach-to-interpreting-model-predictions>
- Moons, K. G. M., Damen, J. A. A. G., Kaul, T., Hooft, L., Andaur Navarro, C. L., Dhiman, P., Beam, A. L., Van Calster, B., Ghassemi, M., Liu, X., Reitsma, J. B., van Smeden, M., Boulesteix, A.-L., Collins, G. S., et al. (2025). PROBAST+AI: An updated quality, risk of bias, and applicability assessment tool for prediction models using regression or artificial intelligence methods. *BMJ*, 388, e082505. <https://doi.org/10.1136/bmj-2024-082505>
- Ndahimana, D., & Kim, E.-K. (2017). Measurement methods for physical activity and energy expenditure: A review. *Clinical Nutrition Research*, 6(2), 68–80. <https://doi.org/10.7762/cnr.2017.6.2.68>
- O'Driscoll, R., Turicchi, J., Hopkins, M., Horgan, G. W., Finlayson, G., & Stubbs, R. J. (2020). Improving energy expenditure estimates from wearable devices: A

- machine learning approach. *Journal of Sports Sciences*, 38(13), 1496–1505. <https://doi.org/10.1080/02640414.2020.1746089>
- O'Driscoll, R., Turicchi, J., Hopkins, M., Duarte, C., Horgan, G. W., Finlayson, G., & Stubbs, R. J. (2021). Comparison of the validity and generalizability of machine learning algorithms for the prediction of energy expenditure: Validation study. *JMIR mHealth and uHealth*, 9(8), e23938. <https://doi.org/10.2196/23938>
- Pinheiro Volp, A. C., Esteves de Oliveira, F. C., Duarte Moreira Alves, R., Esteves, E. A., & Bressan, J. (2011). Energy expenditure: Components and evaluation methods. *Nutrición Hospitalaria*, 26(3), 430–440. <https://doi.org/10.3305/nh.2011.26.3.5181>
- Quist, J. R., Rud, C. L., Brantlov, S., Jødal, L., Rasmussen, H. H., & Ward, L. C. (2024). Bioelectrical impedance analysis as a clinical marker of health status in adult patients with benign gastrointestinal disease: A systematic review. *Clinical Nutrition ESPEN*, 59, 387–397. <https://doi.org/10.1016/j.clnesp.2023.12.145>
- Sadeghi, Z., Alizadehsani, R., Cifci, M. A., Kausar, S., Rehman, R., Mahanta, P., Bora, P. K., Almasri, A., Alkhawaldeh, R. S., Hussain, S., Alatas, B., Shoeibi, A., Moosaei, H., Hladik, M., Nahavandi, S., & Pardalos, P. M. (2024). A review of explainable artificial intelligence in healthcare. *Computer Methods and Programs in Biomedicine*, 244, Article 107809. <https://doi.org/10.1016/j.cmpb.2023.107809>
- Strain, T., Flaxman, S., Guthold, R., Semenova, E., Cowan, M., Riley, L. M., Bull, F. C., Stevens, G. A., & Country Data Author Group. (2024). National, regional, and global trends in insufficient physical activity among adults from 2000 to 2022: A pooled analysis of 507 population-based surveys with 5.7 million participants. *The Lancet Global Health*, 12(8), e1232–e1243. [https://doi.org/10.1016/S2214-109X\(24\)00150-5](https://doi.org/10.1016/S2214-109X(24)00150-5)
- Westerterp, K. R. (2013). Physical activity and physical activity-induced energy expenditure in humans: Measurement, determinants, and effects. *Frontiers in Physiology*, 4, Article 90. <https://doi.org/10.3389/fphys.2013.00090>

- Westerterp, K. R. (2018). Exercise, energy expenditure and energy balance, as measured with doubly labelled water. *Proceedings of the Nutrition Society*, 77(1), 4–10. <https://doi.org/10.1017/S0029665117001148>