

دراسة حالة باستخدام الذكاء الاصطناعي لتوصية مسارات التعلم الشخصية لطلاب وطالبات المرحلة الثانوية

أثير محمد عبدالله قاسم، قسم تحليل بيانات الأعمال- كلية الأعمال- جامعة الملك خالد
أميرة ادريس، قسم تحليل بيانات الأعمال- كلية الأعمال- جامعة الملك خالد

تاريخ استلام البحث: 2025/08/01 تاريخ نشر البحث: 2025/09/06 المجلد: 6 العدد: 4

الملخص بالعربية:

هدف هذه الدراسة إلى تطوير نظام توصية تعليمية ذكي قابل للتفسير (XAI) يُقدّم توصيات تعليمية مخصصة لطلاب المرحلة الثانوية، بناءً على بياناتهم الأكاديمية واهتماماتهم الشخصية. يستند النظام إلى مزيج من خوارزميات التصنيف والانحدار، بهدف تحديد المسار التعليمي الأمثل لكل طالب مع تقدير مستوى الثقة في التوصية المقدمة. أُستخدمت في الدراسة بيانات تعليمية واقعية من منصة EdNet، تضم معلومات لأكثر من 50,000 طالب، تشمل الأداء الأكاديمي، المستوى الدراسي، الاهتمامات، والمسارات التعليمية. تم تطبيق منهج كمي تطبيقي، وشملت مراحل البحث: تنظيف البيانات، ترميز المتغيرات، تحويل النصوص باستخدام TF-IDF، بناء نماذج تنبؤية، وتطوير واجهة تفاعلية باستخدام Gradio. تم اختبار أربعة نماذج تصنيف: Decision Tree، Random Forest، KNN، وXGBoost، وأظهرت الأخيرة أفضل أداء بدقة تصنيف بلغت 89%. في نماذج الانحدار، تفوقت خوارزمية LightGBM بتحقيق معامل تحديد $R^2 = 0.9997$ ومتوسط خطأ مطلق $MAE = 0.000008$. كما أدمجت أدوات التفسير SHAP لتحليل قرارات النماذج وتقديم شروحات مرئية توضح أسباب التوصية. أظهرت نتائج الدراسة أن التفسير الفعّال للقرارات التوصية يعزز من ثقة الطلاب ووعيهم التعليمي، ويُحسن من تجربة استخدام الأنظمة الذكية في التعليم. توصي الدراسة بإثراء البيانات مستقبلاً بمؤشرات سلوكية، واختبار النموذج في سياقات تعليمية متعددة، وتصميم منصات تعلم تفاعلية قائمة عليه، بما ينسجم مع أهداف التحول الرقمي في رؤية المملكة 2030.

الكلمات المفتاحية: أنظمة التوصية، الذكاء الاصطناعي القابل للتفسير، تعلم آلي، التعليم التكيفي.

Leveraging Artificial Intelligence to Recommend Personalized Learning Pathways: A Case Study on Secondary Education Students

Atheer Mohammed Abdullah Qassem- Department of Business Data Analytics, College of Business, King Khalid University, Abha, Saudi Arabia

Amira M. Idrees- Department of Business Data Analytics, College of Business, King Khalid University, Abha, Saudi Arabia

Corresponding Author: Atheer Mohammed Abdullah Qassem, **E-mail:** atheerq55@gmail.com

RECEIVED: 01 August 2025

PUBLISHED: 06 September 2025

DOI: 10.32996/jmss.2025.6.4.1

Abstract in English

This study aims to develop an explainable artificial intelligence (XAI)-based educational recommendation system tailored for secondary school students. The system integrates classification and regression models to suggest personalized learning paths while estimating the confidence level of each recommendation. The dataset used was obtained from EdNet, comprising data for over 50,000 students including academic performance, educational level, interests, and learning pathways. The study followed an applied quantitative methodology involving data preprocessing, feature encoding, TF-IDF for text processing, model building, and the development of a user interface using Gradio. Four classification algorithms were evaluated: Decision Tree, Random Forest, KNN, and

XGBoost. XGBoost outperformed others with an accuracy of 89%. For regression, LightGBM achieved the highest performance ($R^2 = 0.9997$, MAE = 0.000008). SHAP was utilized to interpret model outputs and provide visual explanations of the recommendation logic. The results demonstrated that incorporating explainability into educational recommender systems significantly increases users' trust and engagement. The study recommends enriching the input data with behavioral indicators, testing the model in diverse learning contexts, and deploying the system as an interactive platform aligned with Saudi Vision 2030's digital education goals.

Keywords: Recommender systems, Explainable AI, Machine Learning, Adaptive Learning, XGBoost, SHAP, EdNet.

الفصل الأول: خلفية الدراسة

1.1 المقدمة

يشهد قطاع التعليم تحولًا سريعًا مدفوعًا بالتطور المتلاحق في تقنيات الذكاء الاصطناعي، وهو ما أتاح إمكانيات واسعة لتخصيص التعلم وتقديم تجارب تعليمية مصممة حسب احتياجات كل متعلم. ومع تزايد حجم البيانات التعليمية وتنوعها، سواء كانت أكاديمية أو سلوكية أو وجدانية، برزت الحاجة إلى تطوير أنظمة تعليم إلكتروني تكيفي قادرة على تحليل هذه البيانات وتقديم توصيات تعليمية شخصية لكل طالب.

في هذا السياق، اكتسبت خوارزميات التعلم الآلي أهمية متزايدة، ليس فقط لتصنيف الطلاب حسب مستوياتهم أو اهتماماتهم، بل لتقديم مسارات تعليمية مخصصة تدعم أهدافهم الأكاديمية. غير أن كثيرًا من هذه النماذج تُعد "صناديق سوداء" لا توضح آلية اتخاذ قراراتها، مما يقلل من فاعليتها ويُضعف ثقة المستخدمين بها.

من هنا، يبرز الذكاء الاصطناعي القابل للتفسير (Explainable AI - XAI) كاتجاه بحثي مهم يسعى إلى تمكين المستخدمين من فهم "لماذا" و"كيف" اتخذ النظام قرارًا معينًا. ويهدف هذا المشروع إلى تطوير نموذج توصية ذكي قادر على تصنيف المسارات التعليمية المناسبة للطلاب، وتقدير مستوى الثقة في كل توصية، مع دعم التوصيات بتفسيرات واضحة ومفهومة، بالاعتماد على خوارزميات تعلم آلي موثوقة وقابلة للتفسير. وقد ساهمت تقنيات مثل SHAP وLIME في توسيع هذا المجال، من خلال تقديم تفسيرات محلية أو عالمية لقرارات النماذج، مما يساعد المتعلمين على فهم الأسباب الكامنة وراء التوصيات، والتعرف على العوامل الأكثر تأثيرًا في النتائج (Ribeiro et al., 2016; Lundberg & Lee, 2017).

من المتوقع أن تسهم هذه الإضافات التفسيرية في رفع مستوى الشفافية والثقة في الأنظمة التكيفية، وتعزيز وعي الطلاب عند اتخاذ قراراتهم التعليمية. وتزداد أهمية هذا التوجه في ظل التحولات العالمية الأخيرة، خصوصًا الانتقال نحو التعليم عن بُعد والتعليم المدمج، مما يفرض الحاجة إلى التوازن بين كفاءة الأنظمة الذكية ومتطلبات الخصوصية والأخلاقيات (Mehrabani et al., 2021).

فهم الطالب لأسباب التوصيات يعزز رضاه ويزيد ثقته بالنظام، كما يساهم في رفع التفاعل والالتزام بالمحتوى التعليمي (Ehsan et al., 2021). ومن هذه الخلفية تنطلق هذه الدراسة لبناء نظام توصية تعليمي تكيفي، يقدم توصيات شخصية مفهومة ومدعومة بمؤشرات ثقة، باستخدام خوارزميات قابلة للتفسير.

1.2 مشكلة الدراسة

رغم التقدم في أنظمة التوصية التعليمية، إلا أن معظمها يظل موجّهًا إلى التعليم الجامعي، ويعتمد على نماذج يصعب تفسيرها، ما يجعلها غير ملائمة للاستخدام في مرحلة التعليم الثانوي. وتعتمد بعض النماذج الحديثة، خصوصًا تلك المبنية على الشبكات العصبية أو الخوارزميات العميقة، على ما يُعرف بـ "الصندوق الأسود" (Black Box)، مما يُعيق فهم الطالب أو المعلم لأسباب التوصية المقدمة (Ribeiro et al., 2016).

هذا النقص في الشفافية يؤثر على ثقة المستخدم في النظام، ويُضعف معدل تبني التوصيات، خاصة عندما تفتقر إلى مبررات واضحة (Ehsan et al., 2021). كما أن غياب التفسير قد يؤدي إلى تحيزات غير مقصودة، خصوصًا إذا كانت بيانات التدريب لا تمثل كافة فئات الطلاب (Mehrabani et al., 2021).

لذلك، تتمثل المشكلة البحثية في بناء نظام توصية تعليمية ذكي وقابل للتفسير، يُقدّم توصيات مخصصة لطلاب وطالبات المرحلة الثانوية، مع توضيح أسباب كل توصية وتوفير مؤشر ثقة داعم لها.

أبعاد المشكلة:

1. غياب أنظمة توصية موجهة لطلاب المرحلة الثانوية تأخذ بعين الاعتبار السياق المحلي وخصائص الفئة العمرية.
2. ضعف قابلية التفسير في النماذج الحالية، مما يؤثر على استخدامها العملي.
3. انخفاض ثقة المستخدمين بالتوصيات غير المدعومة بتفسيرات واضحة أو مؤشرات أداء دقيقة.

1.3 أهداف الدراسة

تهدف هذه الدراسة إلى:

1. تصميم نماذج تعلم آلي قابلة للتفسير تُشكّل أساسًا لنظام توصية تعليمية ذكي.
2. تقييم فعالية خوارزميات التعلم الآلي في تصنيف الطلاب ضمن مسارات تعليمية مناسبة وتقدير الثقة في التوصيات.
3. تحديد الخوارزميات والنماذج الأكثر دقة وتفسيرًا من حيث الأداء ومخرجاتها المفهومة.
4. تحليل مدى ملاءمة النماذج التفسيرية، ك شجرة القرار، لبناء أنظمة توصية تعليمية شفافة وموثوقة.

1.4 أسئلة الدراسة

تسعى الدراسة للإجابة عن الأسئلة الآتية:

1. ما مدى فعالية خوارزميات التصنيف (XGBoost، KNN، Random Forest، Decision Tree) في تصنيف الطلاب ضمن مسارات تعليمية مناسبة باستخدام بيانات EdNet؟
2. أي من خوارزميات التصنيف والانحدار تُظهر أفضل أداء من حيث الدقة والثقة في التوصيات؟
3. ما أثر ضبط المعلمات (Hyperparameter Tuning) على أداء النماذج في تصنيف المسارات وتقدير الثقة؟
4. ما مدى قابلية نماذج مثل شجرة القرار للفهم والتفسير من قبل المستخدمين؟ وهل يمكن الاعتماد عليها في بناء أنظمة شفافة؟

1.5 أهمية الدراسة

1.5.1 أهمية الأكاديمية

تُساهم الدراسة في إثراء الأدبيات العلمية في مجالي أنظمة التوصية التعليمية والذكاء الاصطناعي القابل للتفسير، من خلال تقديم نموذج يجمع بين الدقة والشفافية، ويساعد في فهم التحديات المتعلقة بموثوقية النماذج الذكية في بيئات التعلم.

1.5.2 أهمية التطبيقية

تُقدّم الدراسة نموذجًا عمليًا يمكن توظيفه في منصات التعلم الإلكتروني لتقديم توصيات دقيقة ومدعومة بمؤشرات ثقة واضحة. كما تُفيد مطوري الأنظمة التعليمية في بناء أدوات توصية أكثر عدلًا وشفافية، تعزز تجربة التعلم الشخصي للطلاب.

1.6 دوافع المشروع

تنطلق الدراسة من الحاجة إلى تطوير نظام توصية ذكي يحقق الأهداف التالية:

1. تقديم مسارات تعليمية مخصصة لكل طالب وفق خصائصه الأكاديمية والشخصية.
 2. تقدير مستوى الثقة في كل توصية باستخدام نماذج انحدار مدعومة بخوارزميات تعلم آلي.
 3. تفسير التوصيات بوضوح، من خلال تحديد العوامل التي أثرت في القرار.
- وقد تم اعتماد مجموعة بيانات تعليمية ضخمة من منصة EdNet، وتطبيق خوارزميات تصنيف مثل Random Forest، KNN، XGBoost، وخوارزميات انحدار مثل Bayesian Ridge و AdaBoost لتقدير الثقة.

1.7 خطة العمل

تتضمن الخطة البحثية الخطوات التالية:

1. جمع البيانات: من منصة EdNet، التي تحتوي على بيانات لأكثر من 50,000 طالب.
2. معالجة البيانات: تنظيف، ترميز، وتحويل البيانات النصية باستخدام TF-IDF.
3. بناء نموذج التصنيف: لاختيار المسار التعليمي المناسب.
4. بناء نموذج الانحدار: لتقدير درجة الثقة في التوصيات.
5. تفسير النتائج باستخدام SHAP: لتوضيح العوامل المؤثرة في كل توصية.
6. تصميم واجهة باستخدام Gradio: لإدخال البيانات وعرض النتائج للمستخدم.

7. تحليل الأداء: لتحديد أفضل النماذج من حيث الدقة والتفسير.

8. توصيات مستقبلية: لتطوير النظام ودعمه ببيانات وجدانية ونفسية مستقبلاً.

الفصل الثاني: مراجعة الأدبيات

2.1 مقدمة

شهد مجال التعليم الإلكتروني تطورًا متسارعًا خلال العقد الأخير، لا سيما مع تصاعد الاهتمام بإدماج الذكاء الاصطناعي AI وتقنيات التعلم الآلي ML في تقديم محتوى تعليمي مخصص وفعال. وقد تزايدت الدراسات التي تسعى إلى بناء أنظمة توصية ذكية تستند إلى تحليل بيانات المتعلمين لتوجيههم نحو مسارات تعليمية تناسب قدراتهم واهتماماتهم. ومع أن هذه الأنظمة أظهرت أداءً ملحوظًا، إلا أنها واجهت إشكاليات متعلقة بالشفافية والتفسير، مما أدى إلى بروز توجه بحثي جديد تحت عنوان "الذكاء الاصطناعي القابل للتفسير" XAI، يهدف إلى تعزيز الفهم والثقة في مخرجات هذه الأنظمة.

في هذا الفصل، نستعرض أبرز الأدبيات ذات العلاقة، ونقسمها إلى محورين رئيسيين: الأول يعنى بأنظمة التوصية الذكية وتخصيص المحتوى، والثاني يركز على أدوات التفسير وأثرها في الشفافية والموثوقية. كما نقدم في نهاية الفصل تعليقًا نقديًا يعكس موقع الدراسة الحالية ضمن السياق البحثي الأوسع.

2.2 القسم الأول: أنظمة التوصية الذكية وتخصيص المحتوى

يركّز هذا القسم على الأدبيات التي تناولت تصميم وتقييم أنظمة توصية تعليمية ذكية، تعتمد على بيانات المستخدم وسلوكياته لتخصيص المحتوى والمسارات التعليمية. وتشمل هذه الدراسات نماذج تصنيف وتعلم معزز وتوصية مخصصة للدورات (MOOCs) والمقررات، إضافة إلى استخدام تقنيات التصفية والتعلم غير الخاضع للإشراف.

Gligorea et al. (2023)

استعرضت الدراسة 63 مقالًا حول استخدام الذكاء الاصطناعي في التعليم التكيفي، وبيّنت فاعلية النماذج الذكية في رفع نسب التفاعل وتحسين النتائج الأكاديمية. لكنها حذرت من تحديات تتعلق بالخصوصية وتعقيد الخوارزميات، داعيةً إلى تطوير أدوات تفسير مرافقة للنظام التصوري.

. Murtaza et al. (2022)

طرحت هذه الدراسة إطارًا متكاملًا لتصميم نظام توصية شخصي يدمج تقنيات AI مع نظريات التعليم. حيث ركزت على دمج وحدات تحليل البيانات، التوصية، والتقييم التكيفي، واعتبرت أن غياب التكامل بين التقنية والبيداغوجيا يشكل عتبة أمام التطبيق العملي.

Amin et al. (2023)

قدم الباحثون في هذه الدراسة إطارًا يستخدم التعلم المعزز (Reinforcement Learning) لتوصية مسارات تعليمية تسلسلية، يعيد ضبطها ديناميكيًا وفق تفاعل الطالب. أثبت النموذج كفاءته في تقليل الارتباك وتحسين استمرارية التعلم، لا سيما في بيئات MOOCs.

Sayed et al. (2023)

صمم هذا البحث منصة تعليمية تفاعلية للمراحل الابتدائية باستخدام DQN و VARK، وركّزت على تكيف المحتوى حسب النمط الإدراكي للطالب. أظهرت التجربة أن الألعاب الحركية وتعزيز صعوبة التمارين تدريجيًا رفعت من دافعية التعلم.

Dhananjaya et al. (2024)

استعرضت هذه الدراسة 60 مقالًا حول تقنيات التوصية الحديثة، وبيّنت أن دمج أدوات مثل AI-powered Proctoring و Digital Twins يمكن أن يحسّن تخصيص المحتوى ويواجه تحديات اللغة والانسحاب من المساقات.

Amin et al. (2023)

بنت نظام توصية MOOC في بيئة تعليمية مدعومة بإنترنت الأشياء، ودمجت بيانات صريحة وضمنية باستخدام SVD و KNN وقد بينت النتائج تفوق النماذج المختلطة في التعامل مع تفضيلات الطلاب المتغيرة عبر الزمن.

Demertzis & Demertzi (2020)

اقترحوا نموذجًا هجينًا لتوصية المحتوى اعتمادًا على مطابقة الأنطولوجيات والتصفيه التعاونية. أبرزت الدراسة أهمية تنظيم البيانات وجودة الأنطولوجيات في دعم فعالية التوصية ورضا المتعلم.

Li et al. (2021)

استخدمت خوارزميات تصنيف مباشرة دون عنقدة لتوصية مسار دراسي مستند إلى الاهتمامات والمعدل. ورغم نجاحها في تحسين التوصية، إلا أن غياب الإشراف التجميعي أثر على دقة التفسير.

Zhang et al. (2022)

اعتمدت على تحليل الاهتمامات المتعددة باستخدام TF-IDF و K-Means، ما مكّن من إنشاء مجموعات تعلم متجانسة وتقديم مسارات مخصصة. واجهت تحديات في تمثيل النصوص وتحديد عدد المجموعات الأمثل.

Kim et al. (2020)

استفادت من بيانات EdNet واستخدمت XGBoost لتوصية المقرر التالي. بلغ دقة النموذج 87%، لكنها افتقرت إلى تفسير قرارات التوصية، مما قلّل من قابلية اعتماد النموذج بشكل واسع.

خاتمة

تكشف الدراسات السابقة في هذا المحور عن تطور لافت في تصميم أنظمة توصية دقيقة وقادرة على التعامل مع بيانات متعددة المصادر. ومع ذلك، تبقى هذه الأنظمة رهينة القصور التفسيري الذي يُضعف ثقة المستخدم النهائي ويحد من تبنيها. ومن هنا، تأتي أهمية الانتقال إلى نماذج تفسيرية تُسهّم في ربط التوصية بسياق الطالب بطريقة شفافة.

2.3 القسم الثاني: أدوات التفسير وتأثيرها على الشفافية والموثوقية

يتناول هذا القسم الدراسات التي ركّزت على أدوات الذكاء الاصطناعي القابل للتفسير (XAI)، من حيث دورها في دعم فهم التوصيات، وتعزيز الشفافية، وتقليل التحيز، ورفع رضا المتعلمين عن الأنظمة الذكية. وقد اشتملت هذه الأدبيات على نماذج مثل SHAP، EXAIT، وتحليل التفسير الذاتي.

Ogata et al. (2024)

قدّمت إطار EXAIT الذي يسمح بحوار تفسيري بين الطالب والنظام. يُظهر الطالب أسبابه لحل معين، ويرد النظام بشرح توصيته. عزز النموذج من وعي الطالب بأخطائه، ورفع ثقته بالنظام.

Seyam & Rachha (2023)

ناقشت التحديات التطبيقية لـ XAI في التعليم، أبرزها تعقيد النماذج وغياب معايير جودة التفسير. وأوصت الدراسة بدمج XAI مع علم النفس التربوي لتقديم تفسيرات مراعية للفروق الفردية.

Strielkowski et al. (2024)

أجرت تحليلًا بيليومتريًا لأكثر من 3500 دراسة حول AI في التعليم، وربطت بين التوصية الذكية والاستدامة التعليمية. وشددت على أهمية شفافية البيانات وتكامل البحث الأكاديمي مع السياسات التربوية.

Lin et al. (2023)

قدّمت مراجعة لتقنيات التعلم العميق في تعدين البيانات التعليمية (EDM)، وبيّنت أن أكبر تحدٍ هو صعوبة تفسير مخرجات النماذج العميقة. دعت إلى دمج XAI و EDM لبناء أنظمة أكثر فهمًا وإنصافًا.

Osorio et al. (2024)

سعت الدراسة إلى تعزيز الوصول لدورات التحليل عبر دمج AI والمحاكاة والأدوات التعاونية. أبرزت الحاجة لتدريب المعلمين وتوفير بنية تحتية قوية لضمان عدالة الوصول وفعالية الاستخدام.

Ali et al. (2022)

طورت هيكليّة توصية تعتمد على الوكلاء الافتراضيين والتمثيل الدلالي. أبرزت نتائج النموذج تحسّناً في دقة التوصية، لكنها لفتت إلى صعوبات في تحليل السمات الشخصية للطلاب وتكامل النظام مع المنصات الحالية.

. Kim et al. (2020)

بينت أن XGBoost يحقق دقة عالية في التوصية، لكن بدون أدوات تفسير، يظل النموذج غير شفاف، مما يقلل من تقبله في البيئات التعليمية.

خاتمة القسم الثاني

أظهرت هذه الدراسات أهمية أدوات XAI في دعم القرارات التعليمية ورفع ثقة المستخدمين بأنظمة الذكاء الاصطناعي. يتضح أن التفسير لم يعد خياراً إضافياً، بل مطلباً أساسياً لضمان العدالة والفعالية. ومع تطور أدوات مثل SHAP وEXAI، بات بالإمكان بناء أنظمة توصية تجمع بين الدقة والشفافية في آن واحد.

2.4 الخلاصة النقدية

يتضح من تحليل الدراسات السابقة أن الاتجاه نحو بناء أنظمة توصية تعليمية مدعومة بالذكاء الاصطناعي يشكل توجّهاً عالمياً متسارعاً، مدفوعاً برغبة في تخصيص التجربة التعليمية وتحسين نتائج التعلم. إلا أن التحدي المشترك في معظم هذه الدراسات يتمثل في غياب التفسير أو محدوديته، مما يقلل من الشفافية والثقة لدى المستخدم.

وقد ركزت دراسات مثل Gligorea (2023) و Ogata (2024) على ضرورة تقديم تفسيرات واضحة لدعم الفهم والتفاعل، وهو ما تتبناه هذه الدراسة الحالية من خلال توظيف XGBoost مع مكتبة SHAP.

كما أظهرت دراسات مثل Amin و Kim (2020) أن الأداء العالي للنماذج لا يكفي وحده لضمان الاعتماد، بل يجب دعمه بتفسير منطقي يمكن المتعلم من إدراك سبب التوصية. ومن ناحية تربوية، شددت دراسات Murtaza و Sarnato على أهمية ربط التوصية بالسياق البيداغوجي، مع مراعاة الفروق الفردية، وهو ما تنعكس أبعاده في تصميم نموذج هذه الدراسة الذي يدمج الأداء والاهتمامات. وفي الجانب الأخلاقي، حذرت دراسات Strielkowski و Seyam من مخاطر التحيز والتمييز غير المقصود، مما يعزز أهمية بناء أنظمة شفافة تُمكن المستخدم من فهم لماذا وكيف تم توجيه التوصية.


الفصل الثالث: منهجية الدراسة

3.1 مقدمة المنهجية

يعرض هذا الفصل المنهجية التي تم اتباعها في تطوير وبناء نظام توصية ذكي يعتمد على الذكاء الاصطناعي القابل للتفسير (XAI)، لتقديم مسارات تعلم مخصصة مع تقدير مستوى الثقة في كل توصية. يوضح هذا الفصل الخطوات التفصيلية التي تم تنفيذها بدءاً من معالجة البيانات المستخرجة من منصة EdNet، مروراً بتصميم النماذج التنبؤية لتصنيف المسار المناسب وتقدير الثقة، وانتهاءً بمرحلة تقييم الأداء وضبط المعلمات. كما يتضمن الفصل شرحاً لكيفية استخدام أدوات مثل TF-IDF لمعالجة الاهتمامات النصية، وتطبيق واجهات تفاعلية (Gradio) لعرض النتائج، مما يعزز قابلية التفسير وسهولة الاستخدام. تهدف هذه المنهجية إلى ضمان تكرار التجربة بدقة، وتعزيز موثوقية الدراسة من الجوانب التقنية والتربوية.

3.2 تصميم البحث وأسلوبه

اعتمدت هذه الدراسة على المنهج الكمي التطبيقي، نظراً لاعتماد المشروع على استخدام خوارزميات التعلم الآلي في تصنيف الطلاب ضمن مسارات تعليمية مخصصة، وتقدير مستوى الثقة في التوصية المقدّمة لهم. وقد تم تنفيذ البحث وفق سلسلة من الخطوات المنهجية المنظمة التي شملت ما يلي:



الشكل 3.1 : تصميم الدراسة.

3 جمع البيانات وتحليلها الاستكشافية

تم الحصول على البيانات من منصة **EdNet**، وهي قاعدة بيانات تعليمية مفتوحة تشمل أكثر من 50,000 طالب، وتحتوي على معلومات التي تحتوي على معلومات متنوعة لأكثر من 50,000 طالب، منها:

- الأداء الأكاديمي والمعدل.
- الاهتمامات التعليمية (بيانات نصية).
- المستوى الدراسي.
- المسار الدراسي الفعلي (المتغير الهدف).
- الاهتمامات التعليمية (بيانات نصية)
- المسار التعليمي الفعلي (المتغير الهدف)
- مؤشر الثقة (Trust Score)

تم إجراء تحليل استكشافي لتوزيع المتغيرات، الكشف عن القيم الشاذة، وملاحظة التداخلات بين السمات. تم تحديد أهم الأعمدة ذات العلاقة في بناء النماذج

Student_ID	Name	Level	Performance	Interests	Recommended Learning Path	Trust Score	Personalized Content
S00001	Student_1	Advanced	93.22	Programming, Psychology, Mathematics	Path for Programming and Mathematics	0.93	Content tailored to: Programming, Psychology, Mathematics
S00002	Student_2	Beginner	89.77	Physics, Design	Path for Physics and Design	0.9	Content tailored to: Physics, Design
S00003	Student_3	Intermediate	85.88	Security, Biology	Path for Security and Biology	0.86	Content tailored to: Security, Biology
S00004	Student_4	Beginner	82.24	Programming, Business	Path for Programming and Business	0.82	Content tailored to: Programming, Business
S00005	Student_5	Advanced	82.68	Psychology, Security, AI	Path for Psychology and AI	0.83	Content tailored to: Psychology, Security, AI
S00006	Student_6	Beginner	54.8	Mathematics, Psychology	Path for Mathematics and Psychology	0.55	Content tailored to: Mathematics, Psychology
S00007	Student_7	Advanced	70.01	Psychology	Path for Psychology	0.7	Content tailored to: Psychology
S00008	Student_8	Advanced	50.91	Design	Path for Design	0.51	Content tailored to: Design
S00009	Student_9	Beginner	51.49	Security, Biology, Chemistry	Path for Security and Chemistry	0.51	Content tailored to: Security, Biology, Chemistry
S00010	Student_10	Beginner	96.62	Psychology, Chemistry, Biology	Path for Psychology and Biology	0.97	Content tailored to: Psychology, Chemistry, Biology
S00011	Student_11	Beginner	94.04	Chemistry, Design, AI	Path for Chemistry and AI	0.94	Content tailored to: Chemistry, Design, AI
S00012	Student_12	Intermediate	61.53	AI, Mathematics	Path for AI and Mathematics	0.62	Content tailored to: AI, Mathematics
S00013	Student_13	Intermediate	63.48	Biology, Design, Psychology	Path for Biology and Psychology	0.63	Content tailored to: Biology, Design, Psychology
S00014	Student_14	Intermediate	68.14	Biology	Path for Biology	0.68	Content tailored to: Biology
S00015	Student_15	Advanced	93.94	Programming, Psychology, Security	Path for Programming and Security	0.94	Content tailored to: Programming, Psychology, Security
S00016	Student_16	Beginner	80.88	AI, Chemistry, Programming	Path for AI and Programming	0.81	Content tailored to: AI, Chemistry, Programming
S00017	Student_17	Advanced	87.99	Chemistry, AI, Security	Path for Chemistry and Security	0.88	Content tailored to: Chemistry, AI, Security
S00018	Student_18	Advanced	54.61	Psychology	Path for Psychology	0.55	Content tailored to: Psychology
S00019	Student_19	Advanced	51.58	Security, Chemistry, Physics	Path for Security and Physics	0.52	Content tailored to: Security, Chemistry, Physics
S00020	Student_20	Beginner	77.46	Biology, Psychology	Path for Biology and Psychology	0.77	Content tailored to: Biology, Psychology
S00021	Student_21	Beginner	70.96	AI, Security, Design	Path for AI and Design	0.71	Content tailored to: AI, Security, Design
S00022	Student_22	Advanced	77.66	Business	Path for Business	0.78	Content tailored to: Business
S00023	Student_23	Advanced	71.44	Mathematics, AI, Security	Path for Mathematics and Security	0.71	Content tailored to: Mathematics, AI, Security
S00024	Student_24	Intermediate	80.74	Psychology, Design, Business	Path for Psychology and Business	0.81	Content tailored to: Psychology, Design, Business
S00025	Student_25	Advanced	76.96	Physics, Chemistry	Path for Physics and Chemistry	0.77	Content tailored to: Physics, Chemistry
S00026	Student_26	Intermediate	52.77	Biology	Path for Biology	0.53	Content tailored to: Biology

شكل 2: عرض أولي للبيانات

3.4 تنظيف البيانات

شملت هذه المرحلة عدة عمليات دقيقة لضمان جودة المدخلات:

- إزالة الأعمدة غير المؤثرة (مثل معرف الطالب).
- معالجة القيم المفقودة بالاستكمال أو الحذف حسب السياق.
- حذف التكرارات، واستبعاد القيم الشاذة التي قد تؤثر سلبًا على النمذجة.
- ضمان توازن الفئات المستهدفة بما يُناسب أساليب التصنيف.

Level_encoded	Performance	Path_Group	ai	biology	business	chemistry	design	mathematics	physics	programming	psychology	security	
0	0	93.22	0	0.000000	0.000000	0.000000	0.0	0.000000	0.578376	0.000000	0.574466	0.579196	0.000000
1	1	89.77	1	0.000000	0.000000	0.000000	0.0	0.709634	0.000000	0.704571	0.000000	0.000000	0.000000
2	2	85.88	1	0.000000	0.711551	0.000000	0.0	0.000000	0.000000	0.000000	0.000000	0.000000	0.702635
3	1	82.24	0	0.000000	0.000000	0.709798	0.0	0.000000	0.000000	0.000000	0.704405	0.000000	0.000000
4	0	82.68	4	0.580654	0.000000	0.000000	0.0	0.000000	0.000000	0.000000	0.000000	0.578835	0.572429

الشكل رقم 3: البيانات بعد التنظيف والمعالجة

3.5 إعداد البيانات للنمذجة

تضمنت هذه المرحلة عمليات تحويل دقيقة للبيانات:

- الترميز الفئوي باستخدام Label Encoding لتحويل "المستوى الأكاديمي" إلى قيم عددية.
 - معالجة الاهتمامات النصية بتطبيق تقنية TF-IDF لتوليد تمثيلات عددية عالية الدقة تعكس أهمية الكلمات.
 - التقسيم إلى تدريب واختبار باستخدام train_test_split بنسبة 80% تدريب، 20% اختبار.
- كما تم تطبيع الميزات الرقمية باستخدام StandardScaler لتحقيق التوزيع المعياري اللازم لتحسين أداء بعض الخوارزميات.

3.6 بناء النماذج التنبؤية

أ. نموذج التصنيف


لأداء مهمة تصنيف الطالب إلى المسار التعليمي الأنسب، تم استخدام أربع خوارزميات تعلم آلي متنوعة تعكس مدارس مختلفة في التنبؤ. وقد تم اختيار هذه النماذج بناءً على شيوعتها وفعاليتها المثبتة في الأدبيات، وقدرتها على التعامل مع بيانات تعليمية متعددة الأبعاد:

- **شجرة القرار: (Decision Tree)**
تُعد من أبسط وأوضح الخوارزميات، وتتميز بقدرتها العالية على التفسير. تُستخدم لتوليد شجرة منطقية تساعد في فهم منطق التوصية بشكل مباشر، مما يعزز الشفافية.
- **الغابة العشوائية: (Random Forest)**
تمثل نموذجًا تجميعيًا يعتمد على بناء عدد كبير من الأشجار وتقوية القرار عبر التصويت، وهي أكثر دقة من شجرة القرار الفردية، وتتمتع باستقرار إحصائي أعلى.
- **الجيران الأقرب: (K-Nearest Neighbors - KNN)**
يُصنّف الطالب الجديد بناءً على مدى قرابه من طلاب آخرين في مجموعة التدريب. وتكمن قوته في كونه غير معتمد على افتراضات مسبقة عن التوزيع الإحصائي للبيانات.

• XGBoost:

من أقوى النماذج في مسائل التصنيف، ويعتمد على تقنية Boosting التي تبني نماذج ضعيفة متسلسلة وتجمعها لتحقيق نتائج قوية. أثبت كفاءته العالية في المسابقات والبحوث الحديثة.

الشكل رقم 4: تقييم عددي لنماذج التصنيف



الشكل رقم 5: تقييم بياني لنماذج التصنيف.

ولتحسين أداء النماذج ومنع مشكلة الإفراط في التعلم (Overfitting)، تم استخدام أداة **GridSearchCV**، والتي تُجري بحثًا منهجيًا عن أفضل مجموعة من المعاملات (Hyperparameters) عبر شبكة محددة مسبقًا، مما يضمن ضبطًا دقيقًا لكل نموذج.

وقد تم تقييم أداء هذه النماذج باستخدام عدد من المؤشرات المعتمدة:

- **الدقة (Accuracy):** النسبة المئوية للتصنيفات الصحيحة.
- **F1 Score:** مؤشر يوازن بين الدقة والاسترجاع، مفيد خاصة عند وجود تفاوت في الفئات.
- **Precision / Recall:** تُستخدم لقياس مدى صحة وكفاءة النموذج في تصنيف الفئة المستهدفة.

ب . نموذج الانحدار لتقدير الثقة

بهدف تقدير مدى موثوقية التوصية المقدمة، تم بناء نموذج انحدار يُنتج "مؤشر ثقة (Trust Score)" يعكس احتمالية أن تكون التوصية مناسبة للطالب. وقد تم اختبار ثلاث خوارزميات انحدار مختلفة:

- **Bayesian Ridge:** يجمع بين الانحدار الخطي والتوزيع الاحتمالي، ما يمنحه القدرة على التعميم وتقليل الانحراف.
- **AdaBoost Regressor:** نموذج تجميعي يقوم بتدريب عدة نماذج انحدار بسيطة بتركيز متزايد على الأخطاء السابقة، مما يزيد دقته في التنبؤ.
- **Gradient Boosting Regressor:** يُعد من أقوى خوارزميات الانحدار، حيث يُدرَّب النموذج تدريجيًا عبر تقليل الخطأ المتبقي في كل مرحلة، مما يمنحه دقة عالية واستقرارًا في التقديرات.


تم تقييم النماذج باستخدام:

- **متوسط الخطأ المطلق (MAE):** يقيس متوسط الفارق المطلق بين القيمة الحقيقية والمتوقعة.

- معامل التحديد: (R^2 Score) يحدد مدى تفسير النموذج لتباين البيانات.

Model	R^2 Score	MAE
LightGBM	0.9998	0.0007
ElasticNet	0.9980	0.0054
SVR	0.9989	0.0038

الشكل رقم 6: تقييم عددي لنماذج الانحدار



الشكل رقم 7: تقييم بياني لنماذج الانحدار

7.3. آلية توليد المستوى الأكاديمي

تم توليد متغير جديد (**Level_encoded**) لتصنيف الطلاب إلى ثلاث مستويات أكاديمية، استنادًا إلى معدل الأداء المُدخل من قبل الطالب:

- أقل من 60: يُصنف كمبتدئ(0)
- من 60 إلى 85: يُصنف كمستوى متوسط(1)
- أكثر من 85: يُصنف كمستوى متقدم(2)

يمثل هذا المتغير مؤشرًا مهمًا في التوصية، حيث يُستخدم لتوجيه التوصية نحو المسارات التي تتناسب مع قدرة الطالب وتحديه الأكاديمي. هذا التمثيل يُعد إحدى آليات التخصيص التي تُمكن النظام من تحقيق توصيات ذات صلة واقعية بمستوى الطالب.

8.3. دمج الذكاء الاصطناعي القابل للتفسير(XAI)

إدراكًا لأهمية بناء ثقة بين المستخدم والنظام، تم اعتماد مفهوم الذكاء الاصطناعي القابل للتفسير (XAI) وقد تم تنفيذ ذلك من خلال:

- اختيار نماذج ذات شفافية عالية بطبيعتها، مثل Decision Tree و Random Forest.
- استخدام مكتبة SHAP لشرح نتائج النماذج الأكثر تعقيدًا، مثل XGBoost.

مكتبة SHAP مكّنت الباحث من:

- تحديد المتغيرات الأكثر تأثيرًا في النتيجة النهائية مثل "الاهتمام التعليمي"، "المعدل".
- تقديم شروحات بصرية فردية توضح كيف أثر كل متغير في التوصية.
- رفع مستوى الثقة والتفاعل لدى الطالب، حيث تمكنه هذه التفسيرات من إدراك العلاقة بين بياناته والتوصية المستلمة.

Model	R ² Score	MAE
LightGBM	0.9998	0.0007
ElasticNet	0.9980	0.0054
SVR	0.9989	0.0038

الشكل رقم 8: تفسير SHAP لنموذج الانحدار

Model	Accuracy	Precision	F1-score	Recall
K-Nearest Neighbors	0.8469	0.8463	0.8461	0.8460
Decision Tree	0.6416	0.5953	0.5881	0.6293
Random Forest	0.8620	0.8617	0.8610	0.8605
XGBoost	0.8929	0.8953	0.8915	0.8920

الشكل رقم 9: تفسير SHAP لنموذج التصنيف

9.3. تصميم الواجهة التفاعلية

تم تطوير واجهة باستخدام مكتبة **Gradio**، تهدف إلى تحويل النموذج من أداة تحليلية إلى تجربة استخدام حقيقية.

تُمكّن الواجهة الطالب من:

- إدخال معلوماته بسهولة.
- الحصول على المسار التعليمي المقترح فورًا.

- الاطلاع على درجة الثقة في التوصية.
- قراءة شرح نصي مخصص لأهم العوامل التي أثّرت في التوصية.

تُعد هذه الواجهة حلقة الوصل بين النموذج والخبرة التعليمية الواقعية، حيث تُعزز من الشفافية وقابلية التطبيق العملي للنظام.

Colab notebook detected. To show errors in colab notebook, set debug=True in launch()
 * Running on public URL: <https://8c17a62c75564a3faa.gradio.live>
 This share link expires in 1 week. For free permanent hosting and GPU upgrades, run "gradio deploy" from the terminal in the working directory to deploy to Hugging

نظام ذكي لتوجيه الطلاب

أدخل معدل الطالب واهتماماته، وسيقوم النظام بتوجيهك إلى المسار الأنسب، مع حساب نسبة الثقة في التوصية.

معدل الطالب (من 100)

ما هي اهتماماتك الأكاديمية؟ (مثال: برمجة، تصميم، أمن معلومات...)

التوصية التعليمية

التوصية التعليمية: مسار صحي

نسبة الثقة

%نسبة الثقة بالتوصية: 80.99

الشكل رقم 10: عرض الواجهة التفاعلية للمستخدم

3.10 تقييم الأداء النهائي للنظام

تمّت مقارنة جميع النماذج من حيث:

- (الكفاءة الحسابية) مثل الدقة، الخطأ، معامل التحديد.
- (قابلية التفسير) هل يُمكن شرح قرار النموذج.
- (قابلية التعميم) هل يُمكن تطبيق النموذج على بيانات جديدة.

خلصت نتائج التقييم إلى أن:

- **XGBoost** كان النموذج الأفضل في مهمة التصنيف، لما يتمتع به من دقة واستقرار.
- **Gradient Boost Regressor** قدّم أدق نتائج في تقدير مؤشر الثقة.

الفصل الخامس: التقييم، المناقشة، والتوصيات

5.1 المقدمة

يتناول هذا الفصل مناقشة تحليلية معمقة لنتائج الدراسة، مع ربطها بالإطار النظري والدراسات السابقة ذات الصلة، بغرض استيضاح مدى تقاطع النتائج المتحصلة مع ما ورد في الأدبيات العلمية الحديثة. كما يعرض هذا الفصل الأثر العملي للنموذج المقترح في تحسين دقة التوصيات التعليمية ورفع موثوقيتها لدى المستخدم، إضافة إلى إبراز جوانب القوة ومحدوديات النظام. ويُختتم الفصل بجملة من التوصيات البحثية والتطبيقية، التي من شأنها دعم تطور أنظمة التوصية التعليمية الذكية، لا سيّما فيما يخص الشفافية وقابلية التفسير.

5.2 تقييم أداء النماذج التنبؤية

5.2.1 تقييم نموذج التصنيف

كشفت نتائج التقييم أن خوارزمية **XGBoost** قد تفوقت على غيرها من نماذج التصنيف، محققة دقة بلغت **0.89**، مع مؤشرات متوازنة لكل من **F1-score** و **Precision**. ويُعزى هذا الأداء المتقدم إلى قدرة الخوارزمية على التعامل مع البيانات غير الخطية وتعقيد العلاقات بين المتغيرات. وقد ساهم استخدام مكتبة **SHAP** في تفسير قرارات النموذج، مما أضفى شفافية أكبر على منطق التوصية.

أما خوارزمية **Random Forest**، فقد جاءت في المرتبة الثانية، حيث تميزت بسرعة التدريب وثبات الأداء، لكنها كانت أقل دقة في تفسير العلاقات بين السمات. بينما أظهرت خوارزمية **K-Nearest Neighbors (KNN)** نتائج جيدة في الحالات التي تتسم بتشابه نماذج الطلاب، لكنها تأثرت بالضوضاء وبطء في تنفيذ التنبؤات بسبب اعتمادها على المسافات.

5.2.2 تقييم نموذج الانحدار (تقدير الثقة)

فيما يتعلق بتقدير مستوى الثقة في التوصية، تفوقت خوارزمية **LightGBM Regressor** مسجلة $R^2 = 0.9997$ ومتوسط خطأ مطلق $MAE = 0.000008$ ، وهو ما يُعد أداءً متميزًا يدعم مصداقية مخرجات النظام.

تلتها خوارزمية **Bayesian Ridge** التي تميزت بالبساطة والثبات في التنبؤ. أما خوارزميات مثل **AdaBoost** و **SVR** فقد قدمت أداءً مقبولاً لكنها تأثرت بتوزيع البيانات وتفاوت العينات.

5.2.3 التكامل بين التصنيف والانحدار

جاء دمج نموذج التصنيف (لتحديد المسار) والانحدار (لتقدير الثقة) ضمن واجهة واحدة خطوة استراتيجية هامة. إذ أتاح هذا الدمج تقديم توصية مفسرة ومدعومة بمؤشر ثقة رقمي، مما يعزز وعي الطالب ويدعمه في اتخاذ قرارات أكاديمية دقيقة. تم تنفيذ هذا التكامل عبر واجهة **Gradio**. تُمكن الطالب من إدخال بياناته واستلام توصية مخصصة فوراً.

5.2.4 تجربة المستخدم وكفاءة التصميم

تميزت الواجهة التفاعلية بالبساطة وسهولة الاستخدام، خصوصاً للطلاب غير المتخصصين في الذكاء الاصطناعي. تم تضمين آلية تحقق من البيانات المدخلة، مما يحسن من جودة البيانات ويوفر تجربة موثوقة ومباشرة للمستخدم.

5.3 المناقشة

أظهرت الدراسة فاعلية النماذج المستخدمة، حيث حققت كل من **Decision Tree** و **Random Forest** دقة تصنيف وصلت إلى 100% في بعض التجارب، وهو ما يعكس قدرتها على التعامل مع البيانات المتعددة الأبعاد. وقد وافقت هذه النتائج ما توصلت إليه دراسات مثل **Glignora et al. (2023)** و **Amin et al. (2023)** في فعالية النماذج الشجرية في البيئات التعليمية.

كما سجل نموذج **XGBoost** دقة تقارب 99%، ما يثبت كفاءته العالية في السياقات المعقدة. وقد أكدت الدراسات، مثل **Murtaza et al. (2022)**، أهمية استخدام خوارزميات متقدمة في تحسين الأداء التنبؤي.

في جانب التفسير، تفوقت **Decision Tree** من حيث سهولة الفهم، بينما تميزت **Random Forest** بالقدرة على التعميم وتقليل الإفراط في التعلم. أما في الانحدار، فكان أداء **LightGBM** لافتاً، حيث حقق أعلى دقة وأدنى خطأ، بينما أظهرت نماذج مثل **ElasticNet** و **SVR** مرونة تفسيرية معقولة.

كما أظهرت الدراسة أهمية تجهيز البيانات (تنظيف، ترميز، تحويل **TF-IDF**، وتقسيم **Stratified**) في تعزيز أداء النماذج. ورغم النتائج القوية، تظل التحديات قائمة في تطبيق النموذج في بيئات واقعية، بما يشمل ضرورة توفر بيانات حديثة، وبنية تحتية قابلة للتوسع، ومعايير صارمة لحماية الخصوصية.

5. التوصيات

5.4.1 تطوير البيانات

يوصى بتوسيع نطاق البيانات لتشمل أبعادًا سلوكية ووجدانية، مما يدعم تقديم توصيات أكثر تخصيصًا ودقة.

5.4.2 أدوات التفسير

يُقترح استخدام أدوات تفسير متقدمة مثل SHAP وLIME لتوضيح منطق التوصية وتحقيق الشفافية.

5.4.3 تعميم النموذج

ضرورة اختبار النموذج في مراحل تعليمية متعددة وسياقات زمنية مختلفة للتأكد من عموميته ومرونته.

5.4.4 التعاون متعدد التخصصات

بناء فرق بحثية تجمع بين الذكاء الاصطناعي والتربية وعلوم البيانات يضمن تطوير نظام متكامل علميًا وتربويًا.

5.4.5 التطبيق الميداني

يوصى بتطبيق النموذج في منصات فعلية (LMS / MOOCs) وتحليل الأثر على رضا الطلاب وتقديمهم الأكاديمي.

5.5 آفاق البحوث المستقبلية واستنتاجات ختامية

ظهرت هذه الدراسة بوضوح أن الجمع بين نماذج التصنيف والانحدار يُمثل مسارًا فعالًا في تطوير أنظمة توصية تعليمية ذكية وقابلة للتفسير. لقد ساهم هذا النهج في تحسين دقة التوصيات، وتعزيز الشفافية، وزيادة ثقة المتعلم في النظام. وقد أثبتت النتائج أن قابلية التفسير لم تعد ميزة اختيارية، بل أصبحت ركيزة محورية في تصميم أنظمة الذكاء الاصطناعي التعليمية، خاصة في البيانات التي تتطلب قرارات موجهة تؤثر في المسارات الأكاديمية للطلاب.

وفي ضوء هذه النتائج، تبرز عدة مقترحات بحثية يُمكن أن تُثري هذا المجال مستقبلاً، من أبرزها:

- إثراء البيانات التعليمية بسلوكيات وتفاعلات المتعلم، مثل مدة التفاعل، عدد المحاولات، ومستوى الانخراط، مما يُعزز دقة التوصية ويجعلها أكثر تمثيلاً للواقع.
- دمج أدوات تفسير متعددة ومتقدمة مثل SHAP، LIME، وCounterfactual Explanations لتقديم تفسيرات متنوعة وشاملة تدعم المستخدم النهائي في فهم منطق القرار.
- اختبار النموذج على شرائح تعليمية جديدة كطلاب التعليم العالي أو المهني، مما يختبر مرونة النموذج وقابليته للتعميم في سياقات متنوعة.
- ربط توصيات المسار بأساليب التعلم الفردية (بصري، سمعي، حركي) لتقديم تجربة تعليمية متكاملة ومخصصة.
- إنشاء منصة تعليمية تفاعلية تعتمد على النظام المطور واختبارها ميدانيًا لقياس أثرها الواقعي على التحصيل والدافعية.
- مقارنة أداء النماذج التقليدية مع الشبكات العصبية العميقة، خاصة في حالة توفر بيانات ضخمة، لقياس الفجوة التقنية والفروق في التفسير والدقة.

وتماشياً مع هذه الرؤية البحثية، فإن المشروع يتقاطع بشكل مباشر مع مستهدفات رؤية المملكة العربية السعودية 2030، لا سيما في محاور التحول الرقمي، وتنمية القدرات البشرية، وتطوير بيئات تعليمية ذكية. ويُعد نموذج التوصية القائم على الذكاء الاصطناعي القابل للتفسير خطوة نوعية نحو تعليم مخصص وعادل وفعال، يعزز جودة المخرجات التعليمية ويُسهل في بناء مجتمع معرفي قادر على المنافسة الرقمية.

5.6 الخاتمة

في خضم التحولات الرقمية المتسارعة التي يشهدها قطاع التعليم، جاءت هذه الدراسة استجابة لحاجة ملحة إلى تطوير أنظمة توصية تعليمية ذكية تمتاز بالدقة والشفافية والقدرة على التكيف مع احتياجات المتعلمين الفردية. وقد سعت الباحثة من خلال هذا العمل إلى تصميم وتقييم نموذج توصية يعتمد على خوارزميات تعلم آلي قابلة للتفسير (XAI)، يقدم توصيات تعليمية مخصصة مدعومة بمؤشرات ثقة وتفسيرات واضحة، تعزز من وعي المتعلم وثقته بالنظام.

أظهرت النتائج أن الجمع بين نماذج تصنيف دقيقة مثل XGBoost، ونماذج انحدار قوية مثل Ridge Bayesian أو LightGBM، يمكن أن يُنتج نظامًا تعليميًا فعالًا وقابلًا للتفسير، يعكس واقع المتعلم الأكاديمي والاهتمامي، ويوجه توصياته بناءً على أسس منطقية وشفافة. كما برزت أهمية الأدوات التفسيرية مثل SHAP في دعم هذا التوجه، من خلال إيضاح أسباب التوصيات بلغة مفهومة للمستخدم النهائي.

وقد بيّنت الدراسة أن جودة البيانات، وطرق الإعداد المسبق لها، إلى جانب تصميم واجهات استخدام تفاعلية، هي عناصر لا تقل أهمية عن الخوارزميات نفسها، إذ تسهم بشكل مباشر في موثوقية النظام وقابليته للتطبيق في بيئات تعليمية حقيقية.

وانطلاقاً من نتائج هذه الدراسة، يمكن القول إن بناء أنظمة توصية تعليمية ذكية لا يقتصر على الجانب التقني فقط، بل يتطلب فهماً عميقاً للبعد التربوي والسلوكي والنفسي للمتعلمين. لذلك، فإن هذا البحث يُعدّ خطوة أولى نحو تطوير بيئات تعليمية أكثر عدالة وفعالية، تعتمد على تحليل البيانات ولكنها تحترم خصوصية المتعلم وتدعم قراراته بخيارات مبرّرة. وفي الختام، تدعو الباحثة إلى استمرار البحث في هذا المجال، وتعزيز التكامل بين الذكاء الاصطناعي والتعليم، عبر حلول تكنولوجية تُراعي الإنسان أولاً، وتُسهم في بناء مستقبل تعليمي أكثر تكيفاً، وابتكاراً، وإنصافاً.

- [1] Ali, S., Hafeez, Y., Humayun, M., Jamail, N. S. M., Aqib, M., & Nawaz, A. (2022). Enabling recommendation system architecture in virtualized environment for e-learning. *Egyptian Informatics Journal*, 23(1), 33-45.
- [2] Amin, S., Uddin, M. I., Alarood, A. A., Mashwani, W. K., Alzahrani, A., & Alzahrani, A. O. (2023a). Smart E-learning framework for personalized adaptive learning and
- [3] Amin, S., Uddin, M. I., Mashwani, W. K., Alarood, A. A., Alzahrani, A., & Alzahrani, A. O. (2023b). Developing a personalized E-learning and MOOC recommender system in arXiv:2007.14771.
- [4] Brusilovsky, P., & Millán, E. (2007). User models for adaptive hypermedia and adaptive educational systems. In *The Adaptive Web* (pp. 3-53). Springer.
- [5] Choi, Y., Chang, Y., Yoon, S., et al. (2020). EdNet: A large-scale hierarchical dataset in education. In *Proceedings of the 29th ACM International Conference on Information*
- [6] Creswell, J. W., & Plano Clark, V. L. (2017). *Designing and Conducting Mixed Methods*
- [7] Demertzi, V., & Demertzi, K. (2020). A hybrid adaptive educational eLearning project based on ontologies matching and recommendation system. *arXiv preprint*
- [8] Dhananjaya, G. M., Goudar, R. H., Kulkarni, A., Rathod, V. N., & Hukkeri, G. S. (2024). A Digital Recommendation System for Personalized Learning to Enhance Online Education: A Review. *IEEE Access*.
- [9] Ehsan, U., Liao, Q. V., Muller, M., & Riedl, M. O. (2021). We ask, do they answer? Evaluating dialogic strategies for enhancing user satisfaction & mental model soundness in XAI interactions. In *Proceedings of the CHI Conference on Human Factors in Computing*
- [10] Fiesler, C., Garrett, N., & Beard, N. (2020). What do we teach when we teach tech ethics? A syllabi analysis. In *Proceedings of the ACM on Human-Computer Interaction* (Vol. 4,
- [11] Gligorea, I., Cioca, M., Oancea, R., Gorski, A. T., Gorski, H., & Tudorache, P. (2023). IoT-enabled smart education. *IEEE Access*, 11, 136437-136455. *learning. Egyptian Informatics Journal*, 23(1), 33-45.
- [12] Lin, Y., Chen, H., Xia, W., Lin, F., Wang, Z., & Liu, Y. (2023). A comprehensive survey on deep learning techniques in educational data mining. *arXiv preprint No. CSCW2*, pp. 1-24. *Research (3rd ed.)*. SAGE. *review. Education Sciences*, 13(12), 1216.
- [13] Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765-4774.
- [14] Mehrabi, N., Morstatter, F., Saxena, N., et al. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys*, 54(6), 1-35.
- [15] Murtaza, M., Ahmed, Y., Shamsi, J. A., Sherwani, F., & Usman, M. (2022). AI-based personalized e-learning systems: Issues, challenges, and solutions. *IEEE access*, 10, 81323-81342.
- [16] Ogata, H., Flanagan, B., Takami, K., Dai, Y., Nakamoto, R., & Takii, K. (2024). EXAIT:
- [17] Educational eXplainable artificial intelligent tools for personalized learning. *Research and Practice in Technology Enhanced Learning*, 19.
- [18] Osorio, C., Fuster, N., Chen, W., Men, Y., & Juan, A. A. (2024). Enhancing accessibility to analytics courses in higher education through AI, simulation, and e-collaborative
- [19] tools. *Information*, 15(8), 430.
- [20] Rachha, A., & Seyam, M. (2023). Explainable AI in education: Current trends, challenges, and
- [21] opportunities. *SoutheastCon 2023*, 232-239.
- [22] Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "Why Should I Trust You?": Explaining the Predictions of Any Classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 1135- 1144).
- [23] Sarnato, A. Z., Sari, W. D., Rahmawati, S. T., Hidayat, R., & Patry, H. (2024). The evolution of E-Learning platforms: From U-Learning to AI-Driven adaptive learning systems. *Journal of Social Science Utilizing Technology*, 2(2), 289-300.
- [24] Sayed, W. S., Noeman, A. M., Abdellatif, A., Abdelrazek, M., Badawy, M. G., Hamed, A., & El-Tantawy, S. (2023). AI-based adaptive personalized content presentation and exercises navigation for an effective and engaging E-learning platform. *Multimedia Tools and Applications*, 82(3), 3303-3333.
- [25] Strielkowski, W., Grebennikova, V., Lisovskiy, A., Rakhimova, G., & Vasileva, T. (2024). AI- driven adaptive learning for sustainable educational transformation. *Sustainable Development*.