

مقال بحثي

Using Deep Learning Techniques to Predict the level of E-learning Students by Analyzing Their Behavior

استخدام تقنيات التعلم العميق للتنبؤ بمستوى طلاب التعليم الإلكتروني عبر تحليل سلوكهم

SJSI

المؤلفون:

محمد فائق نواف سعود ID

علي ذياب ID

الجهات: الجامعة الافتراضية السورية

التواصل: Mohamed faek 125891@svuonline.org

تاريخ التقديم: ٥ شباط ٢٠٢٤

تاريخ القبول: ٧ آذار ٢٠٢٤



ABSTRACT

Educational institutions in our current era are moving towards using artificial intelligence techniques, because of the important services they can provide in the field of education in general and in the field of e-learning in particular, as they help in evaluating the performance of the institution and determining the needs and requirements of students, which reflects positively on the performance of the educational institution and its various cadres. Therefore, educational facilities are competing to build systems with high accuracy to predict students' needs in order to address them and avoid their academic failure. In this research, we propose ensemble classifier to predict students' results based on their classroom behavior and demographic information, composed of several deep learning models capable of predicting accurately and reliably. The proposed system consists of a stacking classifier consisting of three sub classifiers, which are the extra decision tree classifiers and the logistic regression classifier. The study was able to reach a prediction rate of 87.5% for students' level.

Keywords: Online Learning, Deep Learning, Ensemble Classifier, Extra trees Classifier, Logistic Regression Classifier, Stacking Classifier.

الملخص

تتجه المؤسسات التعليمية في عصرنا الحالي نحو استخدام تقنيات الذكاء الاصطناعي، لما يمكن أن تقدمه من خدمات مهمة في مجال التعليم عامة وفي مجال التعليم الإلكتروني خاصة؛ إذ تساعد في تقييم أداء المؤسسة وتحديد احتياجات الطلاب ومتطلباتهم، مما ينعكس إيجاباً على أداء المؤسسة التعليمية وكوادرها المختلفة، لذلك تتنافس المنشآت التعليمية لبناء أنظمة ذات دقة عالية للتنبؤ باحتياجات الطلاب من أجل تلبيةها تجنباً لفشلهم الدراسي. نقترح في هذا البحث مصنفاً تجميعياً للتنبؤ بنتيجة الطلاب من خلال سلوكهم الصفي ومعلوماتهم الديموغرافية، مكوناً من نماذج عدة للتعلم العميق وقادراً على التنبؤ بدقة وموثوقية. يتألف النظام المقترح من مصنف تكديس مكون من ثلاثة مصنفات فرعية هي مصنف أشجار القرار الإضافية ومصنف الانحدار اللوجستي، وقد تم الوصول إلى دقة ٨٧.٥٪ في التنبؤ بمستوى الطلاب وذلك باستخدام النظام المقترح.

الكلمات المفتاحية: التعليم الإلكتروني، التعلم العميق، مصنفات التجميع، مصنف أشجار القرار الإضافية، مصنف الانحدار اللوجستي، مصنف التكديس.

المقدمة:

بغية الإشراف عليهم في الوقت الحقيقي، وضمان تغذية راجعة أثناء العملية التدريسية بوجه مبكر، كما سعت هذه المؤسسات من خلال تحليل سلوك الطلاب إلى تعزيز مهارات الاتصال بين الطلاب والمعلمين، ما يساهم في تحقيق أفضل النتائج الأكاديمية، وتوفير موارد تعليمية عالية الجودة للمتعلمين، ومساعدتهم على بناء فهمهم العلمي الخاص من خلال خدمات تعليمية مختلفة (٦). وفي هذا البحث سوف نقترح مصنفاً تجميعياً هجيناً قادراً على التنبؤ بمستوى الطلاب من خلال تحليل سلوكهم الصفي ومعلوماتهم الديموغرافية، مكوناً من نماذج عدة للتعلم العميق؛ لمساعدة المؤسسات التعليمية الإلكترونية على التنبؤ بدقة وموثوقية بمستوى طلابها عبر تحليل سلوكهم أثناء الفصل الدراسي، وإعطاء تفسير منطقي لأسباب رسوب الطلاب ومؤشر مهم حول جدبتهم ومستواهم وهل هم في حاجة إلى تدخل ودعم الإدارة والمدرسين لمساعدتهم على زيادة أدائهم وتحصيلهم العلمي.

المواد والطرائق:

استُخدمت في هذا البحث مجموعة من الأدوات البرمجية لتصميم نماذج التعلم العميق وتقييمها ورسم المخططات البيانية وغيرها، وهذه الأدوات هي:

Google Colab: يستخدم Google Colab لتطبيق الأكواد البرمجية بلغة بايثون عبر منصته المجانية، ويقدم مجموعة متنوعة من الأدوات التي تساعد الباحثين على تصميم نماذج الذكاء الاصطناعي وتطبيقات بايثون على نحو فاعل ومريح.

Scikit-Learn toolbox: تقدم هذه الأداة مجموعة متنوعة من الأكواد البرمجية التي تتيح تصميم وتدريب واختبار وتقييم نماذج التعلم الآلي المتنوعة، وتقدم طيفاً واسعاً من برمجيات المعالجة الأولية للبيانات التي يتم تطبيقها على مجموعة البيانات لتصبح مناسبة كمداخل لنموذج التعلم الآلي.

Matlab Plot Library: تتيح هذه المكتبة مجموعة واسعة من مساعدات الرسم البياني ومتعدد الأبعاد، وتعمل بالتكامل مع برمجيات أخرى لعرض وتنظيم الرسوميات.

Seaborn Toolbox: تتيح هذه المكتبة كثيراً من البرمجيات الخاصة بالرسوميات مثل الخريطة الحرارية والمنحنيات

إن إستراتيجية الألفة مع الزبون تقوم على جمع أكبر قدر ممكن من المعلومات عن الزبائن لتلبية احتياجاتهم الخاصة، ولقد انعكست هذه الإستراتيجية على مختلف نواحي الحياة الاقتصادية والإعلامية والتربوية والصحية والتعليمية (١)؛ وفي حالة التعلّم فقد تم تطوير كثير من الأنظمة بغية توفير موارد تعليمية عالية الجودة للمتعلمين، ومساعدتهم على تجاوز مقرراتهم الدراسية بأكثر فائدة علمية من خلال خدمات تعليمية مختلفة، ونجد أن معظم المنشآت التعليمية قد اهتمت بمسألة مهمة جداً وهي معدلات الرسوب لديها كونها مؤشراً مهماً لأداء المنشأة من جهة ومؤشراً حول رضا الطلاب من جهة أخرى، فضلاً عن ذلك فإن المنشآت التعليمية التي تكون فيها معدلات الرسوب مرتفعة تعاني خسارة كبيرة في الرسوم وإمكانية خسارة طلاب موهوبين (٢)، لذلك نجد أن المؤسسات التعليمية العالمية قامت بوضع إستراتيجيات مختلفة تسمح لها بمعرفة الطلاب الأكثر عرضة للرسوب بغية دعمهم وتقديم المساعدة لهم. وإن أغلب هذه المؤسسات قد اعتمدت على علامات الاختبارات والوظائف المنزلية كمؤشر لتحديد مستوى الطلاب لديها بوجه عام، و تحديد الطلاب الأكثر عرضة للرسوب بوجه خاص (٣)، ومع تحول العالم نحو أنظمة التعلم الإلكترونية، التي عززتها جائحة كورونا، ظهرت مزايا أخرى للعملية التدريسية يمكن الاستفادة منها لجعل التنبؤ بهؤلاء الطلاب أكثر دقة، إذ إن التعليم الإلكتروني يتيح أرشفة دقيقة للحياة الجامعية لطلابيه وسهولة في الوصول إليها (٤). ولقد اجتذب تحليل سلوك المتعلم إلكترونياً الباحثين، كون المعلومات التي يقدمها موضوعية وبعيدة عن التحيز ودقيقة أكثر من الاستبيانات، فعمدت مؤسسات تعليمية إلكترونية كثيرة إلى توثيق سلوك طلابها؛ بغية شخصنة التعليم وتحقيق ألفة مع كل طالب من خلال الاهتمام بتفاصيل حياته الدراسية والتواصل معه على نحو فاعل، إذ إن ذلك يسمح للمعلمين ومديري المدارس بفهم احتياجات الطلاب، وتحديد المشكلات المحتملة والمؤثرة في تحصيلهم الدراسي (٥). وانطلاقاً من ذلك، سعت هذه المؤسسات لضمان جودة التعلم الإلكتروني فيها عبر استخدام بيانات سلوك طلابها على نحو مستقل لبناء أدوات قادرة على التنبؤ بمستواهم

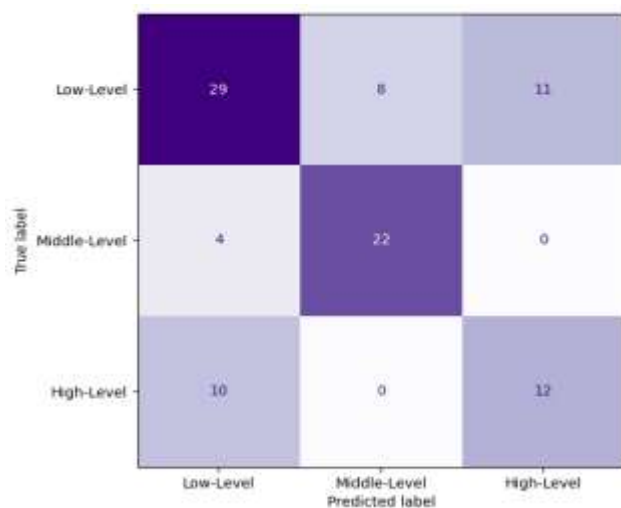
المدرسي؛ إذ صُنِفَ الطلاب إلى فئتين بناءً على أيام غيابهم: ١٩١ طالماً تجاوزت أيام غيابهم ٧ أيام، و ٢٨٩ طالباً لم تتجاوز أيام غيابهم ٧ أيام. كما تضمنت مجموعة البيانات هذه فئة جديدة من الميزات، هذه الميزة هي مشاركة الوالدين في العملية التعليمية. تشتمل ميزة مشاركة أولياء الأمور على ميزتين فرعيتين: استبيان إجابة أولياء الأمور، ورضاً أولياء الأمور عن المدرسة. أجاب ٢٧٠ من أولياء الأمور عن الاستبيان، و ٢١٠ لم يجيبوا عنه؛ وكان ٢٩٢ من أولياء الأمور راضين عن المدرسة، و ١٨٨ غير راضين. وتحتوي مجموعة البيانات على ١٧ عمود بيانات، ١٦ عموداً منها تستخدم كمداخلات أو سمات، والعمود الأخير هو مستوى الطالب الذي سيتم التنبؤ به، وهذه البيانات مرتبة كما يلي:

١. الجنس: جنس الطالب (الاسمي: "ذكر" أو "أنثى")
٢. الجنسية: جنسية الطالب (الاسمية: 'الكويت'، 'لبنان'، 'مصر'، 'المملكة العربية السعودية'، 'الولايات المتحدة الأمريكية'، 'الأردن'، 'فنزويلا'، 'إيران'، 'تونس'، 'المغرب'، 'سورية'، 'فلسطين'، 'العراق'، 'ليبيا')
٣. مكان الميلاد: مكان ميلاد الطالب (الاسمية: 'الكويت'، 'لبنان'، 'مصر'، 'المملكة العربية السعودية'، 'الولايات المتحدة الأمريكية'، 'الأردن'، 'فنزويلا'، 'إيران'، 'تونس'، 'المغرب'، 'سورية'، 'فلسطين'، 'العراق'، 'ليبيا')
٤. المراحل التعليمية: المستوى التعليمي الذي ينتمي إليه الطالب (الاسمي: 'المستوى الابتدائي'، 'المدرسة المتوسطة'، 'المدرسة الثانوية')
٥. مستويات الصف: الصف الذي ينتمي إليه الطالب (الاسمية: 'G-01'، 'G-02'، 'G-03'، 'G-04'، 'G-05'، 'G-06'، 'G-07'، 'G-08'، 'G-09'، 'G-10'، 'G-11'، 'G-12')
٦. معرف القسم: ينتمي الطالب إلى الفصل الدراسي (الاسم: "أ"، "ب"، "ج")
٧. الموضوع: موضوع الدورة (الاسمي: 'الإنكليزية'، 'الإسبانية'، 'الفرنسية'، 'العربية'، 'تكنولوجيا المعلومات'، 'الرياضيات'، 'الكيمياء'، 'علم الأحياء'، 'العلوم'، 'التاريخ'، 'القرآن الكريم'، 'جيولوجيا')

والمخططات البيانية وغيرها من التقنيات التي تساعد في استعراض البيانات والنتائج على نحو سهل وواضح.

البيانات المستخدمة: اعتمدت في هذا البحث مجموعة بيانات (xAPI-Edu-Data) (٧) تم جمعها من نظام إدارة التعلم (LMS) learning management system المسمى Kalboard 360. Kalboard 360 هو نظام إدارة التعلم متعدد الوكلاء، والذي تم تصميمه لتسهيل التعلم من خلال استخدام التكنولوجيا المتطورة. يوفر هذا النظام للمستخدمين إمكانية الوصول المتزامن إلى الموارد التعليمية من أي جهاز متصل بالإنترنت. كما يتم جمع البيانات باستخدام أداة تعقب نشاط المتعلم، والتي تسمى واجهة برمجة تطبيقات الخبرة Experience Application Programming Interface Total (xAPI). تعد xAPI أحد مكونات بنية التدريب والتعلم (TLA) Learning Architecture التي تمكن من مراقبة تقدم التعلم وإجراءات المتعلم مثل قراءة مقال أو مشاهدة فيديو تدريبي. تساعد واجهة برمجة تطبيقات الخبرة على تحديد سلوك المتعلم ونشاطه والأشياء التي تصف تجربته التعليمية. تتكون مجموعة البيانات من ٣٠٥ ذكراً و ١٧٥ أنثى. وهي تعبر عن ٤٨٠ سجلاً للطلاب و ١٦ سمة مختلفة. تُصنّف السمات إلى ثلاث فئات رئيسية: السمات الديموغرافية مثل الجنس والجنسية، سمات الخلفية الأكاديمية مثل المرحلة التعليمية ومستوى الصف والقسم، السمات السلوكية مثل رفع اليد في الفصل، وفتح المراجع، والإجابة عن استبيانات أولياء الأمور، والرضا المدرسي. كما أن الطلاب الذين تمت دراستهم يلجون إلى النظام التعليمي المدروس من مراكز نفاذ مختلفة؛ إذ يوجد ١٧٩ طالباً من الكويت، و ١٧٢ طالباً من الأردن، و ٢٨ طالباً من فلسطين، و ٢٢ طالباً من العراق، و ١٧ طالباً من لبنان، و ١٢ طالباً من تونس، و ١١ طالباً من المملكة العربية السعودية، و ٩ طلاب من تونس ومصر، و ٧ طلاب من سورية، و ٦ طلاب من الولايات المتحدة الأمريكية وإيران وليبيا، و ٤ طلاب من المغرب، وطالب واحد من فنزويلا. جُمعت مجموعة البيانات من خلال فصلين دراسيين: جُمع ٢٤٥ سجل طالب خلال الفصل الدراسي الأول و جُمع ٢٣٥ سجل طالب خلال الفصل الدراسي الثاني. تضمنت مجموعة البيانات أيضاً ميزة الحضور

وهذه المصنفات هي (Support Vector Machines) مصنف آلة متجه الدعم (K-nearest neighbours), SVM مصنف الجار الأقرب (Logistic Regression), KNN مصنف الانحدار اللوجستي LR، مصنف XGBOOST مصنف تعزيز التدرج (extreme Gradient Boosting) ومصنف أشجار القرار الإضافية (ET)(Extra Tree). بعد تدريب واختبار مصنف SVM (آلة متجه الدعم) على مجموعة البيانات المستخدمة حصلنا على النتائج المبينة في الشكل (١)؛ إذ يبين الشكل (١) مصفوفة الارتباك الناتجة عن اختبار مصنف SVM.



الشكل (١) مصفوفة الارتباك لمصنف آلة متجه الدعم

يلاحظ من مصفوفة الارتباك أن مصنف آلة متجه الدعم أخطأ في تصنيف ٣٣ طالباً من أصل ٩٦. بناء على مصفوفة الارتباك المبينة في الشكل (١) نحصل على



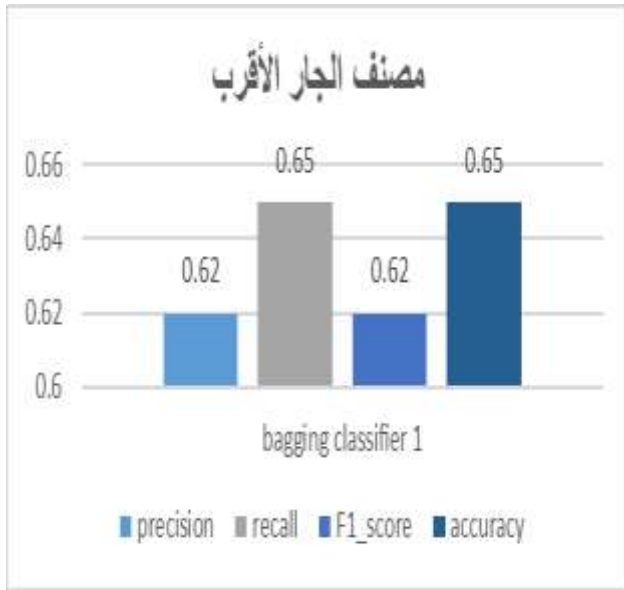
الشكل (٢) نتائج التعرف باستخدام مصنف آلة متجه الدعم

٨. الفصل الدراسي: فصل دراسي (الاسمي: "الأول"، "الثاني")
 ٩. ولي الأمر المسؤول عن الطالب (الاسم: "أمي"، "أبي")
 ١٠. اليد المرفوعة: عدد المرات التي يرفع فيها الطالب يده في الفصل (رقم: ٠-١٠٠)
 ١١. المصادر التي تمت زيارتها - عدد مرات زيارة الطالب لمحتوى المقرر (رقم: ٠-١٠٠)
 ١٢. عرض الإعلانات: كم مرة يقوم الطالب بتدقيق الإعلانات الجديدة (رقم: ٠-١٠٠)
 ١٣. مجموعات المناقشة: عدد مرات مشاركة الطالب في مجموعات المناقشة (رقم: ٠-١٠٠)
 ١٤. استبيان إجابة ولي الأمر: أجاب ولي الأمر عن الاستبيانات المقدمة من المدرسة أم لا (الاسم: "نعم"، "لا")
 ١٥. رضا أولياء الأمور عن المدرسة: درجة رضا أولياء الأمور عن المدرسة (الاسمية: "نعم"، "لا")
 ١٦. يوم غياب الطالب: عدد أيام الغياب لكل طالب (الاسمية: فوق ٧، تحت ٧)
 ١٧. يُصنّف الطلاب إلى ثلاثة مستويات مختلفة بناءً على مجموع درجاتهم/علاماتهم:

المستوى المنخفض: يتضمن القيم من ٠ إلى ٦٩،
 المستوى المتوسط: يشمل القيم من ٧٠ إلى ٨٩،
 المستوى العالي: يتضمن القيم من ٩٠ إلى ١٠٠.


النتائج:

جرى العمل في هذا البحث وفق سيناريوهين مختلفين بالاعتماد على مصنفات هجينة، جرى في السيناريو الأول بناء مصنفات تغليف عدة، مع تغيير معاملات المصنف من أجل الوصول إلى أفضل أداء؛ أما في السيناريو الثاني فقد استُفيد من نتائج السيناريو الأول لبناء مصنف تكديس ذي أداء أعلى. قبل تصميم المصنفات المقترحة، جُربت مجموعة متنوعة من المصنفات المنفردة المعروفة بأدائها العالي من أجل تحديد المصنف الأفضل لاستخدامه كمصنف قاعدة في مصنفات التغليف والتكديس المقترحة،



الشكل (٤) نتائج التعرف باستخدام مصنف الجار الأقرب


يلاحظ من الشكل (٤) أن أداء مصنف الجار الأقرب ضعيف نسبياً ولم يحسن الأداء، بل كان مصنف آلة متجه الدعم أفضل من حيث جميع معايير التقييم المستخدمة. بعد تدريب واختبار مصنف LR (الانحدار اللوجستي) على مجموعة البيانات المستخدمة حصلنا على النتائج المبينة في الشكل (٥)؛ إذ يبين الشكل (٥) مصفوفة الارتباك الناتجة عن اختبار مصنف LR.



الشكل (٥) مصفوفة الارتباك لمصنف الانحدار اللوجستي

يلاحظ من الشكل (٥) أن مصنف الانحدار اللوجستي أخطأ في تصنيف ٢٦ طالباً فقط من أصل ٩٦، متفوقاً على مصنفي SVM و KNN بفارق من ٦ إلى ٩ طلاب.


معايير تقييم الأداء لمصنف آلة متجه الدعم المبين في الشكل (٢). يلاحظ من الشكل (٢) أن أداء آلة متجه الدعم على مجموعة البيانات المستخدمة ضعيف نسبياً من حيث جميع معايير تقييم الأداء؛ لذلك عمدنا إلى تجريب مصنف الجار الأقرب. بعد تدريب واختبار مصنف KNN (الجار الأقرب) على مجموعة البيانات المستخدمة حصلنا على النتائج المبينة في الشكل (٣)؛ إذ يبين الشكل (٣) مصفوفة الارتباك الناتجة عن اختبار مصنف KNN.



الشكل (٣) مصفوفة الارتباك لمصنف الجار الأقرب

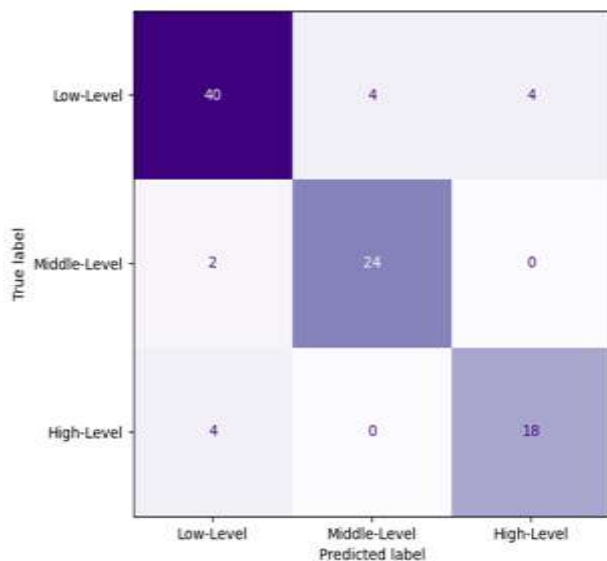
يلاحظ من الشكل (٣) أن مصنف الجار الأقرب أخطأ في تصنيف ٣٥ طالباً من أصل ٩٦، ومن ثم فإن أداء آلة متجه الدعم أفضل وفق شروط التجربة. بناء على مصفوفة الارتباك المبينة في الشكل (٣) نحصل على معايير تقييم الأداء لمصنف الجار الأقرب المبين في الشكل (٤).

يلاحظ من الشكل (٧) أن مصنف XGBOOST أخطأ في تصنيف ١٩ طالباً فقط من أصل ٩٦، متفوقاً على مصنف الانحدار اللوجستي بفارق ٧ طلاب. بناء على مصفوفة الارتباك المبينة في الشكل (٧) نحصل على معايير تقييم الأداء لمصنف XGBOOST المبين في الشكل (٨).



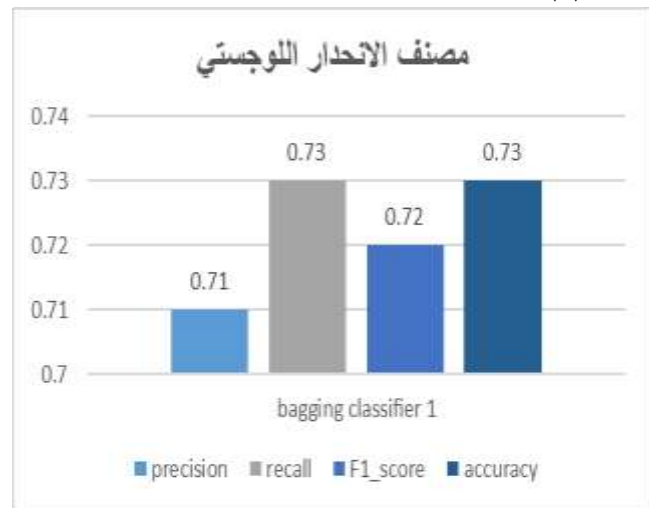
الشكل (٨) نتائج التعرف باستخدام مصنف XGBOOST

يلاحظ من الشكل (٨) أن أداء مصنف XGBOOST أفضل من مصنف الانحدار اللوجستي بنسبة ٧٪ من حيث الدقة ولكن لا تزال غير كافية؛ لذلك عمدنا إلى تجريب مصنف أشجار القرار الإضافية. بعد تدريب واختبار مصنف أشجار القرار الإضافية ET على مجموعة البيانات المستخدمة حصلنا على النتائج المبينة في الشكل (٩)؛ إذ يبين الشكل (٩) مصفوفة الارتباك الناتجة عن اختبار مصنف ET.




الشكل (٩) مصفوفة الارتباك لمصنف أشجار القرار الإضافية

بناء على مصفوفة الارتباك المبينة في الشكل (٥) نحصل على معايير تقييم الأداء لمصنف الانحدار اللوجستي المبين في الشكل (٦).



الشكل (٦) نتائج التعرف باستخدام مصنف الانحدار اللوجستي

يلاحظ من الشكل (٦) أن أداء مصنف الانحدار اللوجستي أفضل من مصنفي KNN و SVM بنسبة تتراوح من ٩٪ مقارنة مع KNN وحتى 7٪ مقارنة مع SVM من حيث الدقة. بعد تدريب واختبار مصنف XGBOOST على مجموعة البيانات المستخدمة حصلنا على النتائج المبينة في الشكل (٧)؛ إذ يبين الشكل (٧) مصفوفة الارتباك الناتجة عن اختبار مصنف XGBOOST.



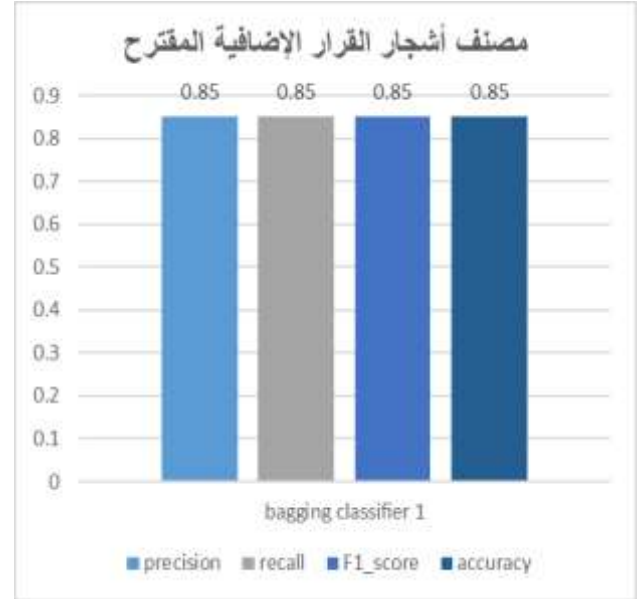
الشكل (٧) مصفوفة الارتباك لمصنف XGBOOST

الإضافية يلاحظ من الشكل (١٠) أن أداء مصنف أشجار القرار الإضافية أفضل من مصنف XGBOOST من حيث الدقة بنسبة ٤.٥٪، ومن ثم فهو يتفوق على جميع المصنفات الفرعية بنسبة كبيرة لذلك يتم استخدامه كحجر أساس في بناء المصنفات المقترحة في السيناريوهين التاليين.

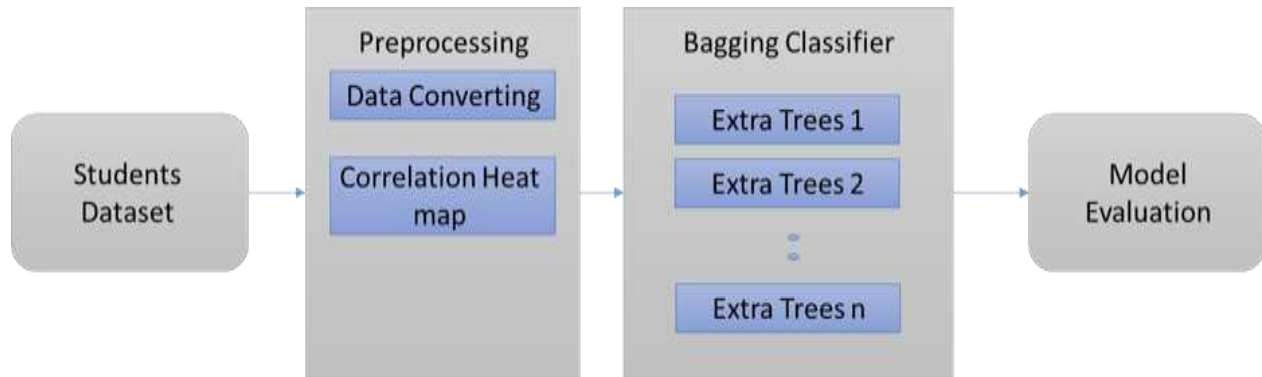
السيناريو الأول:

في هذا السيناريو، تُقسّم مجموعة البيانات إلى 80% كمجموعة تدريب، و 20% كمجموعة اختبار. يبين الشكل (١١) إطار العمل للنظام المقترح فق السيناريو الأول، إذ تُجرى عشر تجارب، في التجربة الأولى نستخدم مصنف أشجار قرار إضافية وحيد كمصنف قاعدة ضمن مصنف التغليف، وفي الثانية نستخدم مصنفي أشجار قرار إضافية ضمن مصنف التغليف، وهكذا حتى نصل لعدد مصنفات فرعية يبلغ عشرة ضمن مصنف التغليف.

يلاحظ من الشكل (٩) أن مصنف ET أخطأ في تصنيف ١٤ طالباً فقط من أصل ٩٦، متفوقاً على مصنف XGBOOST بفارق ٥ طلاب. بناء على مصفوفة الارتباك المبينة في الشكل (٩) نحصل على معايير تقييم الأداء لمصنف أشجار القرار الإضافية المبين في الشكل (١٠).




الشكل (١٠) نتائج التعرف باستخدام مصنف أشجار القرار



الشكل (١١) المخطط الخوارزمي للنظام المقترح

السمات ذات التأثير الضئيل من مجموعة البيانات لتقليل الكلفة الزمنية والحسابية. يبين الشكل (١٢) الخريطة الحرارية التي تعبر عن الارتباط الذاتي لمجموعة البيانات.

ولكن كون الكلفة الزمنية والحسابية كبيرة للمصنفات الهجينة لذلك يجري أولاً تحليل الارتباط الذاتي لمجموعة البيانات لتحديد السمات الأكثر أهمية والتي تؤثر في مستوى الطلاب ثم حذف

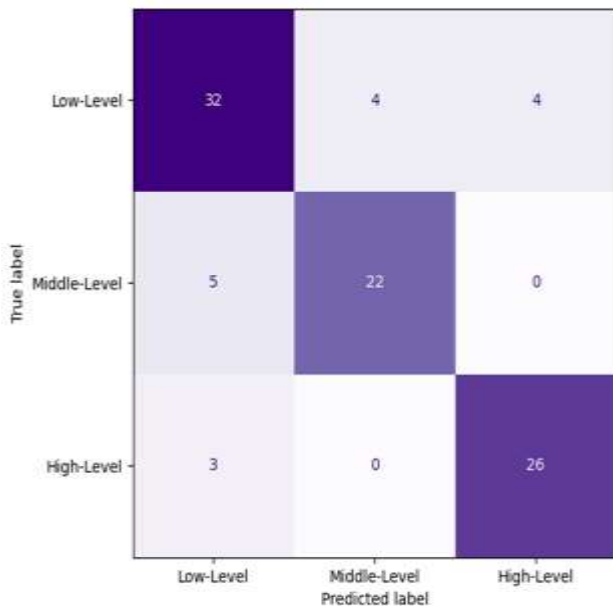


الشكل (١٢) الخريطة الحرارية للارتباط الذاتي في مجموعة البيانات المستخدمة بناء على الشكل (١٢) يمكن ترتيب السمات لمجموعة البيانات تنازلياً حسب الأهمية كما يبين الجدول (١):

نسبة التأثير	اسم السمة	رقم السمة
٠,٢٧	Relation	١
٠,٢٣	Raised hand	٢
٠,٢٠	Student absence days	٣
٠,١٦	Visited resource	٤
٠,١٥	Parent school satisfaction	٥
٠,١٤	Announcement view	٦
٠,١٢	Discussion-Parent answering survey- Gender	٧
0.08	Place of birth	٨
0.065	Nationality	٩

٠,٠٤٤	Grade id	١٠
٠,٠٤٣	Semester	١١
٠,٠٤٠	Topic	١٢
٠,٠١٨	Section	١٣
٠,٠١٢	Stage id	١٤


معايير تقييم الأداء المستخدمة. جرى تجريب مصنف التغليف بعدد مصنفات فرعية مختلف وكان أفضل دقة أعطاهها مصنف التغليف المقترح هي عند تصميم مصنف تغليف مبني على ثمانية مصنفات أشجار قرار إضافية، وحصلنا على مصفوفة الارتباك المبينة في الشكل (١٥).



الشكل (١٥) مصفوفة الارتباك المبينة على ثمانية مصنفات أشجار قرار إضافية ضمن مصنف التغليف

يلاحظ من مصفوفة الارتباك المبينة في الشكل (١٥) أن مصنف Bagging المقترح في هذه التجربة أخطأ في تصنيف ١٦ طالباً من أصل ٩٦، متراجعاً عن مصنف ET بفارق طالبين اثنين. بناءً على مصفوفة الارتباك نستطيع حساب معايير تقييم الأداء المبينة في الشكل (١٦).


يلاحظ من الجدول (١) أن السمات الست الأخيرة ذات ارتباط ضعيف مع تصنيف الطلاب (CLASS) ولذلك فإن حذفها من مجموعة البيانات سيوفر في الكلفة الزمنية والحسابية دون تأثير ملحوظ في نسبة التعرف. اختبر مصنف أشجار القرار الإضافية بعد حذف السمات الأقل أهمية وحصلنا على مصفوفة الارتباك المبينة في الشكل (١٣). يلاحظ من مصفوفة الارتباك المبينة في الشكل (١٣) أن المصنف أخطأ في تصنيف ١٣ طالباً من أصل ٩٦ طالباً، ومن ثم كان لحذف السمات أثر إيجابي في دقة المصنف، إضافة إلى التوفير في الكلفة. ويبين الشكل (١٤) معايير تقييم الأداء بناءً على مصفوفة الارتباك السابقة.



الشكل (١٤) نتائج التعرف باستخدام مصنف أشجار القرار الإضافية بعد حذف السمات الأقل أهمية

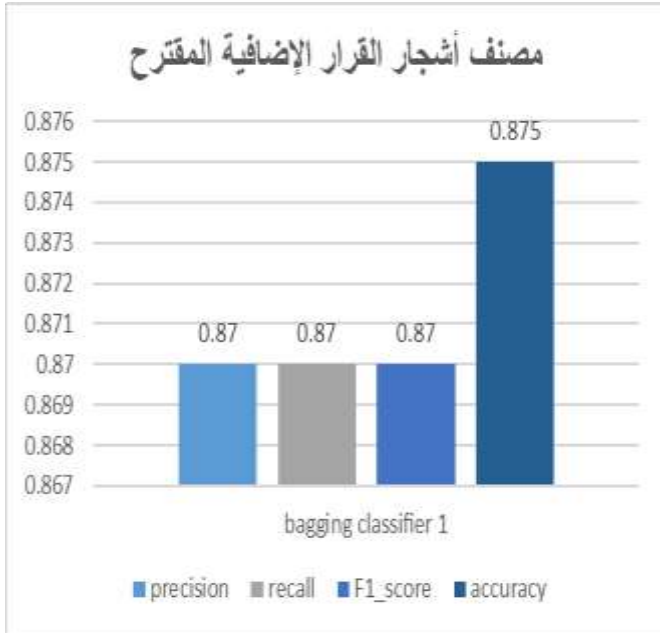
يلاحظ من الشكل (١٤) أن عملية الحذف أدت إلى تحسن أداء مصنف أشجار القرار الإضافية بنسبة ١٪ من حيث جميع

بعد تدريب واختبار مصنف التكديس المقترح حصلنا على مصفوفة الارتباك المبينة في الشكل (١٨).

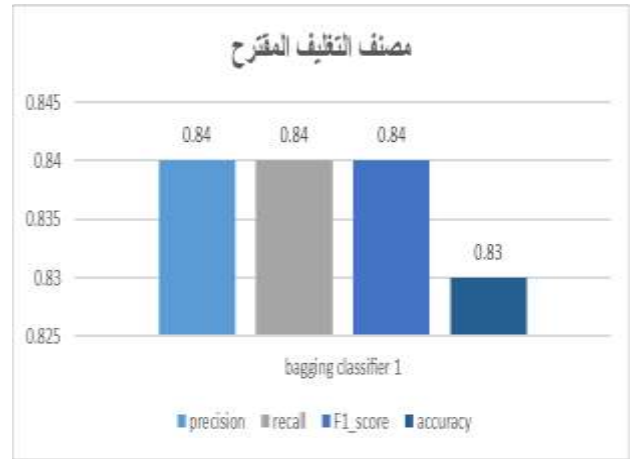


الشكل (١٨) مصفوفة الارتباك لمصنف التكديس المقترح

يلاحظ من الشكل (١٨) أن مصنف التكديس المقترح أخطأ في تصنيف ١٢ طالباً فقط من أصل ٩٦ طالباً، متفوقاً على مصنف أشجار القرار الإضافية بطالب واحد. إن مصنف التكديس قد أدى إلى تحسين الأداء، ويظهر هذا التحسن جلياً كلما ازداد حجم مجموعة البيانات. ويبين الشكل (١٩) المخطط البياني لمعايير تقييم الأداء لمصنف التكديس المقترح.



الشكل (١٩) نتائج التعرف باستخدام مصنف التكديس المقترح

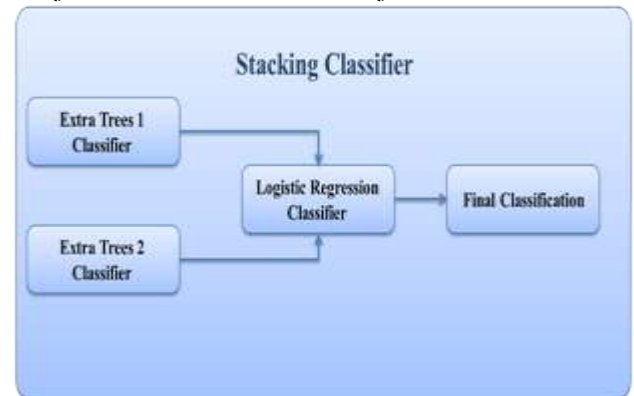


الشكل (١٦) معايير تقييم الأداء باستخدام مصنف التكليف المقترح

يلاحظ من الشكل (١٦) أن أداء مصنف التكليف المقترح في هذه التجربة كان أقل دقة من مصنف ET بنسبة ١.٥٪. ومن ثم فإن مصنف ET أفضل منه أداءً. من خلال ما سبق نجد أن استخدام أشجار القرار الإضافية منفردة أفضل من استخدام مصنف التكليف على مجموعة البيانات المستخدمة، كما يلاحظ أن الانحراف المعياري لمعايير تقييم الأداء مرتفع ويصل في بعض الأحيان إلى ١٢٪، في حين أنه لا يتجاوز ٤٪ عند استخدام مصنف أشجار القرار الإضافية منفرداً، ومن ثم لا جدوى من استخدامه، وبناء على هذه النتيجة نقترح في السيناريو الثاني استخدام مصنف تكديس.

السيناريو الثاني:

بناءً على النتائج السابقة صُمم مصنف التكديس المبين في الشكل (١٧)، والمكون من مصنفي ET التي أعطت أفضل أداء، يليهما مصنف نهائي وهو مصنف الانحدار اللوجستي.



الشكل (١٧) مصنف التكديس المقترح

المناقشة:

في ضوء النتائج السابقة نستطيع القول إن استخدام مصنف التكديس المقترح استطاع تحسين معايير تقييم الأداء على مجموعة البيانات المدروسة بنسبة تتراوح بين ١.٥% و ٤.٥% مقارنة بمصنف أشجار القرار الإضافية ومصنف التغليف وهذه النسبة قابلة للزيادة عند اختبارها على مجموعات بيانات ، كما تم تقليل الكلفة الزمنية والحسابية الناتجة عن استخدام مصنف هجين من خلال تحليل الارتباط الذاتي للسماوات المستخدمة، وعند مقارنة هذه الدراسة مع دراسة Ferrari (٨)، التي استخدمت مجموعة البيانات نفسها (xAPI-Edu-Data) للتنبؤ بسلوك الطلاب، نجد أنه استطاع تقديم نموذج للتنبؤ قائم على تحليل سلوك الطلاب ولقد اعتمد على مصنف منفرد وهو الجار الأقرب ($k=4$) ولكن لم يستطع الوصول سوى إلى دقة ٦٥% في عملية التنبؤ ويعود السبب في ذلك إلى أنه لم يتم طيف واسع من المصنفات المنفردة كما أنه لم يعالج البيانات على النحو الأمثل قبل البدء بعملية التصنيف، ونجد أيضاً أن كثيراً من الباحثين قد اعتمدوا على مؤشرات ميول الطالب لتطوير نماذج التنبؤ، وكان من أهم هذه الدراسات دراسة Fan وآخرون (٩) فلقد استطاعت هذه الدراسة التنبؤ بوجه مبكر بالطلاب الأكثر عرضة للرسوب في المقرر أو الفصل الدراسي. واستطاعت الدراسة الوصول إلى نماذج تنبؤ ذات أداء جيد، إلا أنها تجاهلت دور السجلات التي تصف سلوك الطالب ونشاطاته الصفية والمنزلية واعتمدت على تحليل ميوله فقط. إضافة إلى ذلك، ثمة مشكلة تتعلق بالخصوصية فيما يتعلق بمؤشرات الميول، إذ لا يمكن مشاركة البيانات الشخصية التي جمعتها المؤسسات التعليمية علناً، الأمر الذي يحد من إمكانية الوصول إلى البيانات. كما نجد أن أغلب الدراسات الأخرى، التي كان منها Romero وآخرون (١٠)، اعتمدت على مستوى الطالب في السنوات الدراسية السابقة للتنبؤ بمستواه الحالي بوجه مبكر واستفادت أيضاً من البيانات الديموغرافية التي لا علاقة لها بسلوك المتعلم. وعلى الرغم من أن هذه الدراسات يمكنها التنبؤ بأداء التعلم على نحو جيد، إلا أن هذه الطريقة قد تجاهلت أن معظم المؤشرات التي اعتمدت عليها لم تكن تحت سيطرة الطالب، كما جرى تجاهل تغيرات سلوك الطالب في منهجه

الدراسي الحالي. كما نجد أن بعض الدراسات كدراسة Nawang وآخرون (١١) حاولت استخدام مزيج من ميول المتعلم وسلوكه وبياناته الديموغرافية لإكمال التنبؤ بالمستوى ولكنها واجهت مشكلات تتعلق بزيادة الكلفة الحسابية. وفي المقابل نجد أن نظرية مدخلات التعلم التي قام بها Yao (١٢) تشرح العلاقة بين سلوك الطالب ومستواه التعليمي وتتص على أن سلوك التعلم هو عامل رئيس يؤثر في أداء الطالب ومؤشر مهم للتنبؤ بالأداء، وحثت هذه الدراسة على ضرورة زيادة البيانات التعليمية التي تصف السلوك وذلك لإرساء الأساس لأبحاث جديدة تُعنى بتحليل سلوك طلاب التعليم الإلكتروني. وفي الوقت نفسه، استخدم قريشي وآخرون (١٣) طريقة الاستبيان، ليجدوا أن سمة التعاون كسلوك بين الطلاب يلعب الدور الرئيس في التنبؤ بمستواهم الدراسي، في حين أشارت دراسة Shen وآخرون (١٤) إلى أن نسبة إكمال الواجبات المنزلية للمتعلمين ومعدل إكمال الفيديو في التعلم الإلكتروني يؤثران في مستوى الطالب. لذلك، وبناءً على ما سبق، نجد أن الدراسات المتعلقة بالتنبؤ بأداء الطالب بالاعتماد على سلوكه، غالباً ما اعتمدت على مؤشر مستقل فقط لتقييم مستوى الطلاب. إذ استخدمت أحد سلوكيات الطالب كمؤشر أساسي للتنبؤ، أما في هذه الدراسة فقد دمج أكثر من مؤشر يصف سلوكيات الطالب من أجل تصنيف مستواه واستخدام مصنف هجين قادر على الوصول إلى أفضل أداء ممكن في عملية التنبؤ.

الاستنتاجات:

إن مصنفات أشجار القرار الإضافية تعطي أداءً جيداً في التنبؤ بمستوى الطلاب الدراسي بناءً على سلوكهم ومعلوماتهم الديموغرافية. يؤثر عدد المصنفات الفرعية ضمن مصنف التغليف في أداء المصنف من حيث جميع معايير تقييم الأداء، ولكن تعاني هذه المصنفات نسبة خطأ عالية ولا تؤدي إلى زيادة نسب التعرف إلى مجموعة البيانات المستخدمة بل تؤدي إلى تراجع الأداء. دراسة الارتباط الذاتي لمجموعة البيانات وحذف السماوات الأقل أهمية يؤدي إلى زيادة الدقة وتقليل الكلفة الزمنية والحسابية للنظام المقترح. استخدام مصنفات أشجار القرار

student performance using advanced learning analytics .Proceedings of the 26th International Conference on World Wide Web Companion, 2007.Pages 415–421.<https://doi.org/10.1145/3041021.3054164>

2. . Brown,M. Seeing students at scale: how faculty in large lecture courses act upon learning analytics dashboard data, Teaching in Higher Education. 2020 25:4, 384-400, DOI: [10.1080/13562517.2019.1698540](https://doi.org/10.1080/13562517.2019.1698540)
3. Pallathadka, H . Wenda, A. Ramirez-Asís ,S. Asís-López,M. Albornoz,J. Phasinam,K. Classification and prediction of student performance data using various machine learning algorithms. Materials Today: Proceedings. 2023, Volume 80, Part 3, Pages 3782-3785.
4. Batool,S. Rashid,R. Nisar,W. Kim,J. Yoon Kwon.H & Hussain,A. Educational data mining to predict students' academic performance: A survey study. Springer. 2023. Volume 28, pages 905–971.
5. Zhang,J. ,Qiu,F . Wu ,W. Wang,J. Li,R.Guan,M. and Huang,J.E-Learning Behavior Categories and Influencing Factors of STEM Courses: A Case Study of the Open University LearningAnalysisDataset(OULAD).Sustainability.2023, 15(10),8235; <https://doi.org/10.3390/su15108235>.
6. Irfan, M., Murray, L., & Ali, S. Insights into Student Perceptions: Investigating Artificial Intelligence (AI) Tool Usability in Irish Higher Education at the University of Limerick. Global Digital & Print Media Review.2023 VI(II), 48-63. [https://doi.org/10.31703/gdpmr.2023\(VI-II\).05](https://doi.org/10.31703/gdpmr.2023(VI-II).05).
7. <https://www.kaggle.com/aljarah/xAPI-Edu-Data>.
8. Ferrari ,M. Analyzing Student's Behavior and Model suggestion for classification levels. Data analysis - Student's Behavior.2019. <https://www.kaggle.com/code/marlonferrari/data-analysis-student-s-behavior>
9. Fan, Y. & Wang, Q. Prediction of academic performance and risk: A review of literature on predicative indicators in learning analytics. Dist. Educ. China. 2018.<https://doi.org/10.13541/j.cnki.chinade.2018.01.001>.

الإضافية كمصنفات فرعية ضمن مصنف تكديس يؤديان إلى تحسن الأداء على نحو ملحوظ عند التنبؤ بمستوى الطلاب بالاعتماد على سمات سلوكية للطلاب.

التوصيات:

من التوصيات المهمة التي يمكن أن نوصي بها الباحثين في هذا المجال: إعادة كل تجربة عدد كاف من المرات من أجل تقييم الأداء بدقة وموثوقية. يجب الأخذ في الحسبان أن طريقة تقسيم البيانات إلى مجموعات تدريب واختبار يؤثر تأثيراً كبيراً في الأداء إضافة إلى أن بعض التعليمات البرمجية تقوم بتقسيم مجموعة البيانات على نحو عشوائي، فمثلاً عند تقسيم مجموعة البيانات إلى ٢٠٪ للاختبار و ٨٠٪ للتدريب يتم اختيار العينات عشوائياً ما يؤثر في نتائج تقييم الأداء. عند اختيار مجموعة البيانات يجب الأخذ في الحسبان توازن الأصناف بحيث تكون موزعة على نحو منطقي، فعلى سبيل المثال اختيار مجموعة بيانات لطلاب لديهم جميعاً نسبة مشاركة عالية في الأنشطة الصفية يلغي تأثير هذه السمة في التنبؤ. زيادة عدد السمات التي توصف سلوك الطلاب يساهم في تحسين تقييم مستوى الطلاب.

المقترحات المستقبلية:

من المقترحات المستقبلية التي يمكن أن تؤدي إلى زيادة الأداء: استخدام التسلسل الزمني للنشاط الطلابي مع مصنف LSTM قد يؤدي إلى تحسن الأداء. استخدام قالب محدد لتسجيل معلومات الطلاب الديموغرافية والسلوكية وموحد في جميع الجامعات السورية، ما يؤدي إلى توافر بيانات كافية من أجل تحسين جودة التعليم. تخزين بيانات الطلاب على شكل بيانات وصفية في الجامعة الافتراضية السورية بغية الاستفادة منها لاحقاً.

المراجع

1. A., Aljohani, N.R., Abbasi, R.A., Lytras, M.D., Abbas, F. and Alowibdi, J.S. Daud ..Predicting

10. Romero, C., Cerezo, R., Bogarín, A. & Sánchez-Santillán, M. Educational process mining: A tutorial and case study using moodle data sets
11. Data Min. Learn. Anal. Appl. Educ. 2016 Res. 2, 1–28.
12. Nawang, H., Makhtar, M. & Shamsudin, S. Classification model and analysis on students' performance. J. Fundam. Appl. Sci. 2017. 9, 869–885.
<https://doi.org/10.4314/jfas.v9i6s.65>.
13. Yao, Z. A review of the student engagement theory. J. Shunde Polytechnic . 201816, 44–52.
14. Shen, X., Liu, M., Wu, J. & Dong, X. Towards a model for evaluating students' online learning behaviors and learning performance. Dist. Educ. China2020.
<https://doi.org/10.13541/j.cnki.chinade.2020.10.001>.

التمويل: لا يوجد

مساهمات المؤلفين: شارك المؤلفان في إعداد المخطوط بالتساوي.

تضارب المصالح: يعلن المؤلفون أنه ليس لديهم أي مصالح متضاربة.

توافر البيانات والمواد: جميع البيانات متوفرة في النص الرئيس.