

استخدام تقنيات التّقيب في البيانات الضخمة لاكتشاف الأنماط
التعليمية بالمقررات الإلكترونية عبر نظام إدارة التعلم والتّنبؤ
بالتحصيل الدراسي لطلاب الجامعة

إعداد

د/ عادل إبراهيم محمد قحمش

أستاذ تقنيات التعليم المساعد
كلية التربية - جامعة الملك خالد

أ.د/ أحمد صادق عبد المجيد

أستاذ تقنيات التعليم
كلية التربية - جامعة الملك خالد

استخدام تقنيات التنبؤ في البيانات الضخمة لاكتشاف الأنماط التعليمية بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

أ.د/ أحمد صادق عبد المجيد ود/ عادل إبراهيم محمد قحمش *

المستخلص:

هدف البحث اكتشاف الأنماط التعليمية في المقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لدى طلبة الجامعة من خلال تقنيات التنبؤ في البيانات الضخمة؛ ولتحقيق هذا الهدف تم اختيار مجموعة من المقررات الإلكترونية التي يتم تقديمها لطلبة جامعة الملك خالد عبر نظام إدارة التعلم (Blackboard). ولمعرفة الأنماط السائدة في المقررات الإلكترونية تم استخدام خوارزمية التجميع "K-Means" لاكتشاف الأنماط، وخوارزميات "Linear Regression, Random Forest, KNN, Tree, SVM" للتنبؤ بالتحصيل الدراسي للطلبة. وقد أشارت النتائج إلى أن خوارزمية التجميع "K-Means" قد جمعت درجات الطلبة في ثلاث طبقات رئيسية: الأعلى في الدرجات الطبقة الأولى والثانية وأقلها الطبقة الثالثة، وبالنسبة للتنبؤ بالتحصيل الدراسي، فقد أشارت النتائج إلى أنه يمكن التنبؤ بالتحصيل الدراسي للطلبة في هذا المقرر من خلال الاختبارات الفصلية فقط، وأن الأنشطة الفصلية لا تسهم في التنبؤ بأداء الطلبة الأكاديمي. وأن خوارزمية Linear Regression أكثر الخوارزميات إسهاماً في التنبؤ بالتحصيل الدراسي للطلبة، وأن خوارزمية SVM أقلها وأنه يوجد ارتباط قوى بين الأنماط التعليمية في المقررات الإلكترونية المصممة على أنظمة إدارة التعلم الإلكتروني (Blackboard) ومستوى تحصيل الطلاب.

الكلمات المفتاحية: التنبؤ في البيانات، البيانات الضخمة، الأنماط التعليمية، التنبؤ، الخوارزميات.

* أ.د/ أحمد صادق عبد المجيد: أستاذ تقنيات التعليم -كلية التربية - جامعة الملك خالد.

د/ عادل إبراهيم محمد قحمش: أستاذ تقنيات التعليم المساعد -كلية التربية - جامعة الملك خالد.

Using Big Data Mining Techniques to Discover Educational Patterns in Electronic Courses Through the Learning Management System and Predict the Academic Achievement of University Students

Ahmed Sadek Abdelmagid

Department of educational technology
College of Education - King Khalid
University
Abha - Kingdom of Saudi Arabia

Adel Ibrahim Qahmash

Department of educational technology
College of Education - King Khalid
University
Abha - Kingdom of Saudi Arabia

Abstract:

The aim of the research is to discover educational patterns in electronic courses through the learning management system and to predict academic achievement among university students through big data mining techniques. To achieve this goal, a group of electronic courses were selected that are offered to King Khalid University students via the learning management system (Blackboard). To identify the prevailing patterns in electronic courses, the “K-Means” clustering algorithm was used to discover patterns, and the “Linear Regression, Random Forest, KNN, Tree, SVM” algorithms were used to predict students’ academic achievement. The results indicated that the “K-Means” clustering algorithm grouped students’ grades into three main classes: the highest grades were the first and second classes and the lowest was the third class. As for predicting academic achievement, the results indicated that it is possible to predict students’ academic achievement through activities and tests. For all courses except the course (111 Ladder), the results indicated that the academic achievement of students in this course can be predicted through semester tests only, and that semester activities do not contribute to predicting students’ academic performance. The Linear Regression algorithm is the most contributing algorithm in predicting students’ academic achievement, while the SVM algorithm is the least, and that there is a strong correlation between educational patterns in electronic courses designed on e-learning management systems (Blackboard) and the level of student achievement.

Keywords: Data mining, big data, learning patterns, prediction, algorithms.

المقدمة:

لقد ساعد التطوير في العلم والاقتصاد وتكنولوجيا المعلومات والاتصالات بدور كبير في زيادة كمية البيانات الرقمية في السنوات الأخيرة؛ بحيث لم تعد تقنيات التحليل التقليدية والإحصائية قادرة على التعامل مع الكميات الهائلة المطروحة من البيانات، وقد ظهر التفتيش عن البيانات Data Mining بوصفه أحد الحلول الناجحة لتحليل محتوى البيانات الرقمية، وذلك بتحويلها من مجرد بيانات Data متراكمة وغير مفهومة إلى معلومات Information تمتلك قيمة معرفية يمكن استغلالها والاستفادة منها من قبل مُتخذي القرار وبصورة ابتكارية (أحمد، عبد الله، ٢٠١٨).

إن التفتيش عن البيانات هي اكتشاف المعرفة من البيانات، أو هي عملية تحليل البيانات من منظورات مختلفة، واستخلاص علاقات بينها وتلخيصها إلى معلومات مفيدة مثل: معلومات يمكن أن تسهم في زيادة الربح، أو تخفيض التكاليف، أو كليهما معاً، أو الكشف عن معلومات والعثور على معلومات ذات فائدة من خلال استخدام مجموعة من الأدوات الإحصائية المُعدّة أو تطبيقات الذكاء الاصطناعي (سيد، ٢٠١٦).

وتوجد البيانات في صورة بيانات مُهيكلّة "Structured" وبيانات غير مُهيكلّة "Unstructured"، أما البيانات المُهيكلّة فهي البيانات المُخزّنة في حقول بيانات، يميّزها إمكانية البحث فيها وتحليلها وإدارتها في حين أن البيانات غير المُهيكلّة هي كل ما لا يمكن تصنيفه بسهولة مثل: الصور، والرسوم البيانية ومقاطع الفيديو، وصفحات الويب، ووثائق الويكي، والتّغريدات، ومنشورات الفيسبوك، ورسائل الدردشة وغيرها. وبالرغم من أنّ هذه الأنواع من المُلفّات لها هيكل داخلي يخصّها، لكنّها تُعدّ "غير مُنظمة" لأنّ بياناتها لا تتسق تماماً بوصفها قاعدة بيانات. وبين النوعين السابقين بيانات تسمى بيانات "شبه مُهيكلّة" Semi-structured. وهي خليط بين الإثنين، لكنّها تفتقر إلى بيئة مُنظمة مثل: برامج معالجة النصوص (Hilbert, 2015). ويتمّ التفتيش عن البيانات من كل الفئات السابقة بواسطة المؤسسات بهدف استخدامها في: التحليلات التنبؤية، أو تعلّم الآلة، أو لمجرد الاحتفاظ بمستودع كبير من البيانات. وتعرف البيانات التي يتمّ التفتيش عنها أيّاً كانت صورتها أو فئتها باسم البيانات الضخمة "Big Data" (عبد الله، ٢٠٢١).

ينمّ اتخاذ قرارات في علوم البيانات بناءً على المعلومات المتوافرة من البيانات، والهدف هنا ليس إنتاج نظرية أو قانون بقدر ما هو قرار أو إجراء يتّسق مع البيانات المتوافرة؛ فمثلاً: تستخدم شركة أمازون البيانات الضخمة التي تجمعها من خلال العمليات التي يقوم بها الزبائن لتتخذ قراراتٍ تتعلّق بعملية تسويق منتجاتها، وتقديم اقتراحات بناءً على تحليل البيانات، ومن ثمّ

فإن شركة "أمازون Amazon" ليست مهتمة بالوصول إلى نظرية عن السلوك البشري، بقدر ما هي مشغولة بالبحث عن أعلى دقة ممكنة للتنبؤ بسلوك المستهلكين وتوجيه هذا السلوك (المطيري، ٢٠١٧)؛ لذا اهتمت دراسة قيراطي (٢٠١٧) بتحليل موقع "جوجل" وموقع "الفيسبوك" وخلصت إلى أن "الفيسبوك" تستخدم بيانات المستخدمين في تطوير خدماتها وتحسينها، وذلك من خلال جمع بيانات عن المستخدمين من حيث استخداماتهم وتفاعلهم مع الخدمات المقدمة من موقع "الفيسبوك" والأشخاص والأشياء التي يتفاعلون معها، وكل هذا من أجل إضفاء طابع شخصي على المحتوى، أي بتوفير خدمات تتوافق مع ميول المستخدم. وقد توصلت دراسة (Rostami, et al., 2011) إلى أن التقيب في البيانات يُستخدم لحل أربع قضايا هي: اكتشاف العلاقات، وتحليل الروابط، وصنع الخيارات؛ حيث يتم تقييم البيانات اللازمة لاتخاذ القرار، وتحديد سبل التفضيل، واقتراح أفضل طريقة، وقضية التنبؤ مثل: التنبؤ باحتياجات السوق وطلبات العملاء في المستقبل، وأخيرًا تحديد أفضل الإجراءات لتنفيذ العمل؛ ومن ثم توجد أربع قضايا أساسية للتقيب في البيانات وهي: التنبؤ Prediction، والتصنيف Classification، وتحليل التجميع Clustering Analysis، واكتشاف قواعد الارتباط Association Rules Discovery. وقد خلصت دراسة (Koksal et al., 2011) إلى أن أكثر الاستراتيجيات استخدامًا في الأبحاث الأكاديمية في التقيب في البيانات هي استراتيجية التنبؤ.

ومن تجارب الجامعات العربية في تحليل البيانات، تجربة جامعة الملك سعود وذلك باستحداثها نظام "إتقان ITQAN" لتحليل البيانات، وهدف هذا النظام تحقيق أعلى معايير الجودة للجامعة والوصول بكل تطبيقاتها لتكون تطبيقات مؤسسية معيارية، كما أن هدف هذا النظام تحقيق قيمة مضافة للجامعة ومساعدة المسؤولين في الجامعة على اتخاذ القرار المناسب (الأكلبي، ٢٠١٨).

وفي البيئات التعليمية تم استخدام التحليلات منذ ما يقرب من عشرين عامًا لتطوير النماذج التنبؤية للوظائف الإدارية مثل: إدارة التسجيل، فعند النظر في الطلبات المقدمة للقبول تقوم بعض المؤسسات التعليمية بتقدير احتمالية حصول المتقدمين على نتائج تعليمية ناجحة مثل: الاستمرار في التخرج بناءً على النماذج التي تم تطويرها من تقديرات احتمال حصول طلابهم السابقين على نتائج ناجحة، وقد استمدت هذه التقديرات من بيانات الإعداد الديموغرافي، والأكاديمي قبل التقديم المرتبطة بالنتائج (السيد، ٢٠٢١).

إن التقيب في البيانات في النظم التعليمية يكشف بقوة عن معلومات مفيدة يمكن استخدامها في التقويم البنائي لمساعدة المعلمين في وضع أساس علمي للقرارات التي يتخذونها

بشأن تصميم البيانات التعليمية أو تعديلها. وتطبيق التقييم في البيانات في النظم التعليمية هو عملية دائرية تتكون من: صياغة الفروض، واختبارها، وتنقيحها من أجل تخطيط النظم التعليمية وتصميمها، وتطويرها، وصيانتها، ويقوم المعلمون بالتفاعل مع هذه النظم. ويبدأ تطبيق أساليب التقييم عن البيانات من كل المعلومات المتاحة عن المقررات، والطلاب، والاستخدام والتفاعل، لاكتشاف معلومات مفيدة تساعد المعلمين والمسؤولين على تحسين عملية التعلم الإلكتروني (خميس، ٢٠٢٠).

ويشير كل من موالومبوى ومتيبى (Mwalumbwe & Mtebe, 2017) إلى أن أنظمة إدارة التعلم الإلكتروني مثل: البلاكورد Blackboard توفر البيانات، ولكنها لا تشرح أهمية هذه البيانات؛ حيث إن السجلات تسجل بيانات كثيرة عن سلوك المتعلمين في نظام إدارة التعلم، كما أنها لا تشرح لماذا تكون بعض هذه البيانات مهمة وبعضها غير مهم؛ لذا يجب إجراء مزيد من البحوث والدراسات لتحديد سبب أهمية البيانات غير المعروف أهميتها، فقد أشارت نتائج هذه الدراسة أن الوقت الذي يقضيه الطلاب في نظام إدارة التعلم Moodle وعدد التنزيلات التي يقومون بتنزيلها، وتكرار تسجيل الدخول على النظام ليس له تأثير كبير على تعلم الطلبة. إن مراحل تصميم المقررات الإلكترونية تبدأ بتحليل البيانات المرتبطة بهذه المقررات، وبيئة التعلم المحيطة بها مثل: أنظمة إدارة التعلم الإلكترونية التي تقدم من خلالها المقررات، وشبكات التواصل الاجتماعي التعليمية، والمنتديات الإلكترونية وغيرها، فكل هذه البيانات ينتج عنها كم ضخم من البيانات لها علاقة بالتعلم سواء أكانت بيانات مهيكلة مخزنة في قواعد بيانات أو غير مهيكلة مثل: النصوص والرسومات، والأصوات وغيرها، نتيجة تفاعل المتعلم مع ما يقدم له من مقررات إلكترونية (محمد، ٢٠١٨).

ويستطيع المتعلم أن يسجل ويشكل مستمر تفاعلات عديدة مع المقرر الإلكتروني مثل: إعجاب أو تحميل مصدر تعلم، أو تقديم تعليق، أو إضافة محتوى أو غيرها، ويتم ذلك في أوقات مختلفة، ويسجل الدخول على النظام في أوقات تناسب ظروفه، كل ذلك يتم رصده في شكل بيانات عددية، تُعرض على لوحة المعلومات داخل أنظمة إدارة التعلم الإلكتروني، التي يتم من خلالها تقديم المقررات الإلكترونية لذلك فإن هذا الكم الهائل من البيانات الضخمة له أهمية جوهرية لإثراء أهداف التعلم عند تحليلها، وقد تكون هذه البيانات متعلقة بالمحتوى، والمتعلمين، وأساليب أو أنماط التعلم الخاصة بهم، واتجاهاتهم نحو التعلم الإلكتروني أو غيرها (محمد، ٢٠١٨).

إن استخدام تقنيات التقييم عن البيانات في مجال التعليم يوفر القدرة على الاستكشاف والتركيز على أهم المعلومات في قواعد البيانات، كما تركّز تقنيات التقييم على البيانات كذلك

استخدام تقنيات التنبؤ في البيانات الضخمة لاكتشاف الأنماط التعليمية بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

على بناء التنبؤات المستقبلية، واستكشاف السلوك والاتجاهات؛ مما يسمح باتخاذ القرارات الصحيحة، واتخاذها في الوقت المناسب (أحمد، عبد الله، ٢٠١٨). كما أن التحليلات التنبؤية Predictive Analytics هي الغاية الأهم بالنسبة للبيانات الضخمة، وهي فرع من فروع التنبؤ في البيانات المعنية باحتمالات التنبؤ. وتستخدم التقنية المتغيرات التي يمكن قياسها للتنبؤ بالسلوكيات المستقبلية للفرد أو المؤسسة؛ حيث يتم الجمع بين تنبؤات متعددة في نموذج تنبؤي واحد (سايمون، ٢٠٢٠).

تعد عملية إدارة مؤسسات التعليم العالي من الصعوبات التي تواجه القائمين عليها؛ وذلك لكبر حجمها؛ وتعدد مصادر بياناتها؛ حيث تتضمن أية مؤسسة تعليمية عديداً من المستخدمين الذين بدورهم يستخدمون المعرفة المكتشفة من التنبؤ في البيانات التعليمية Educational Data Mining (EDM) تبعاً لحاجاتهم وأهدافهم في المؤسسة التعليمية؛ لذا يمكن القول أن الهدف الأساسي من التنبؤ في البيانات التعليمية هو استخدام هذا الكم الهائل من البيانات التعليمية في سبيل الفهم الأفضل لتطويرها، وتأمين معلومات أوسع حولها (ناصر، ٢٠١٩).

ولتحقيق أهداف التنمية المستدامة والقدرة التنافسية في مؤسسات التعليم يجب على هذه المؤسسات أن تتبني ثورة البيانات الضخمة، والقدرة على تحليلها واستغلالها، فتحليل البيانات الضخمة لأنظمة إدارة التعلم الإلكتروني في الجامعات مثل: نظام الـ Blackboard وغيره من أنظمة إدارة التعلم الإلكتروني يساعد على إضفاء قيمة للبحوث التجريبية ومعنى لها في العلوم الإنسانية؛ إذ تفتقد معظم الدراسات إلى التراكم، أي تُبنى نتائج بعضها على بعض من أجل مساعدة الطلاب الذين يدرسون من خلال هذه الأنظمة؛ ولذا يجد الباحثون أنفسهم في معظم الأحيان أمام كم كبير من الدراسات الخاصة بالتعلم الإلكتروني التي لا تجمعها نتيجة أو نتائج عامة مما يقلل من الاستفادة التعليمية منها (الجهني، ٢٠١٧)، (مقناني، شبيلة، ٢٠١٩).

وفي هذا الجانب خلصت نتائج دراسة (Horst, 2020) إلى أن استخدام التنبؤ في البيانات في مؤسسات التعليم العالي لا يزال في بدايته، بالرغم من أهميته وتطور أساليبه وفوائده المختلفة، التي يمكن أن تزودنا بنتائج الارتباطات بين الأنماط المختلفة التي تُظهر جوانب الضعف والقوة لصانعي القرار التطويري ليقوم بما يفيد في تقويم الأداء داخل المؤسسة التعليمية من أجل جودة المخرجات والنواتج التعليمية.

مشكلة البحث:

تخرج الجامعات سنويا أعدادا كبيرة من الطلاب والطالبات في تخصصات مختلفة، وبذلك تتوفر كميات كبيرة من البيانات لم يتم وضعها وتنسيقها في قاعدة بيانات، وفي كثير من الكليات لكي يتم استغلالها واستثمارها بشكل أمثل، والاستفادة منها في معرفة سلوك الطالب في

أثناء مدة دراسته، والعوامل والأسباب التي تؤدي إلى تأخره في الدراسة، وبالتالي لم يتم حصر خصائص الطالب، وتحليل الأسباب التي تؤدي إلى تأخره، أو عدم تأخره في الدراسة، وكذلك لم تتم دراسة مؤشرات أداء الطالب في النجاح في المواد الدراسية لمساعدة متخذي القرار في وضع سياسات كفيلاً بتطوير العملية التعليمية، والحد من ظاهرة الرسوب والتأخر في الدراسة (يوسف، ٢٠١٦).

ويشير كل من موسى، بلال (٢٠١٩) إلى أن الجامعات العربية تمتلك كميات كبيرة من البيانات ومع ذلك لا تزال مشكلة معالجة هذه البيانات من حيث: الحجم، والتنسيق، والتنوع مستمرة؛ حيث تركز البيانات الضخمة على البعد التقني، في حين تهتم البيانات الذكية Smart Data أكثر بالبعد التحليلي وقيمة البيانات وتكاملها في عمليات صنع القرار، والتنبؤ الأكاديمي في المؤسسات التعليمية المختلفة.

ويشير كل من بيتلر، هبل، كوهن (٢٠١٨) إلى أن الجامعات العربية تهتم بإنشاء مجتمعات تعلم عبر شبكة الإنترنت، يستطيع الطلاب والطالبات من خلالها مثل: نظام البلاكبورْد Blackboard تبادل المصادر بصورة آمنة، وكذلك إدارة النقاشات، وتبادل الأفكار مع الطلاب، وكذلك يتواصل الطلبة مع بعضهم البعض ومع المعلم، وبالرغم من اهتمام الجامعات العربية بتوفير هذه النظم، فإن هذه الجامعات لا تهتم بتحليل البيانات الضخمة للمقررات الإلكترونية التي تقدم للطلاب من خلال هذه الأنظمة، ونتيجة لذلك فإن كثيراً من الطلاب ينسبون نجاحهم أو فشلهم إلى عوامل خارجية وليست داخلية.

ولذلك تتعرض مؤسسات التعليم العالي، الجامعات والكليات والمعاهد العليا، للوم من فئات المجتمع كافة، لتقصيرها في تأهيل خريجها، وتزويدهم بالمهارات اللازمة للنجاح في الحياة وفي العمل. هذا العتب الاجتماعي مستمر، ولم يتوقف يوماً؛ غير أنه يزداد قسوة في هذا العصر، لسببين اثنين هما: الوتيرة السريعة للتغير، والنطاق الواسع له، وربما تضفي حركة "خاصية بطء حركة التعليم العالي التقليدية المزمدة في الاستجابة للتحوّلات التقنية والاجتماعية والاقتصادية قدراً أكبر من الضغوط عليها. فالتقنيات الحديثة أصبحت تتطور بوتيرة متسارعة جعل رصدها أمراً غير ممكن. ووصل تأثيرها في شتى مجالات الحياة، وأساليب العمل والإنتاج، وغدّت التنبؤات التي كانت توصف أنها خيالية، حقيقة معاشة، ليس في الدول المتقدمة فحسب، بل حتى في الدول النامية أيضاً (النويصر، ٢٠٢١).

ويشير ناصر (٢٠١٩) إلى أن هناك كثيراً من الأبحاث التي اهتمت بدراسة استخدام التقيب في مجال التجارة، ودراسة أثرها في عملية تطوير هذه الأنظمة، لكن استخدامها في مجال التعليم ما زال في بداياته. والأبحاث التعليمية عادة تستخدم الطرق التقليدية مثل:

استخدام تقنيات التقيب في البيانات الضخمة لاكتشاف الأنماط التعليمية بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

المقابلات، ونشاطات المتعلمين في المرحلة الدراسية، وبرنامج SPSS, Excel وذلك لجمع البيانات المرتبطة بالتجربة التعليمية الخاصة بهم وتعدُّ هذه الطرق محدودة الجدوى وذلك لأنها مستهلكة للوقت وللجهد، ودائمًا تقف عند حدٍ معينٍ قصير المدى والفائدة، وبخاصة فيما يتعلَّق باتخاذ القرار المناسب في العملية التعليمية.

ويشير فلوريد (٢٠١٧) إلى أنَّ الإشكالية الحقيقية في البيانات الضخمة تتمثلُ في القدرة على تحليل هذه البيانات وفهماها؛ من أجل استغلال نتائج هذا التحليل في تحسين جودة حياة البشر، وتطوير المعرفة، وقد وجدتُ البيانات الضخمة لتتطور، والطريقة الوحيدة للتعامل معها هي أن نكون على علمٍ ودرايةٍ بكيفية تحليل هذه البيانات، وكيفية الاستفادة منها بصورة جيدة. ويؤكد كيتس (٢٠١٨) على أنَّ الاهتمام بتحليل البيانات الضخمة في الجامعات ما زال ضعيفاً في الواقع العملي؛ حيث توجد كتاباتٌ نظرية كثيرة حول البيانات الضخمة وتحليلها، لكنَّ قدرة المؤسسات التعليمية على تحليل هذه البيانات ما زالت ضعيفةً للغاية.

ويشير كل من أحمد، عبد الله (٢٠١٨) إلى أنَّ جامعة الملك خالد تتوفر لديها قاعدة بيانات ضخمة عن الطلاب والبرامج والمقررات الدراسية وأعضاء هيئة التدريس والموظفين والمخرجات والنتائج التعليمية وغيرها منذ التأسيس وحتى الآن. وهذا الكمُّ الهائل من البيانات لم يتم استغلاله والاستفادة منه بشكلٍ فعَّالٍ في معرفة مؤشرات النجاح والفشل، ولم تتم كذلك معرفة الأنماط السائدة المؤثرة على أداء الطلاب والأقسام الأكاديمية الذي يعدُّ من أهم عناصر تقويم العملية التعليمية.

ويمثَّل تحليلُ البيانات الضخمة للمقررات الإلكترونية التي تُدرِّس للطلاب عبر أنظمة إدارة التعلُّم الإلكتروني (Blackboard) في جامعة الملك خالد صعوبةً للمؤسسة التعليمية وبخاصة البيانات غير المنظمة منها مثل: الصور، والتغريدات، وتعليقات الطلاب على الفيسبوك، والتدوين الإلكتروني وغيرها لذا لا بدُّ من الاهتمام بتحليل بيانات هذه المقررات؛ من أجل فهم سلوك الطلاب، والتنبؤ بتحصيلهم ومهاراتهم التي يحتاجها سوق العمل، كذلك التوصل إلى معرفة مبنية على أسسٍ علمية تساعدُ متَّخذي القرار على بناء بيئة تعليمية إلكترونية ذات جودة عالية.

مما سبق تحدَّدت مشكلةُ البحث الحالي في ضعف الاهتمام بتحليل نتائج طلبة الجامعة في المقررات التي يدرسونها بصورة إلكترونية كاملة لاكتشاف الأنماط التعليمية السائدة لدى طلبة الجامعة في مقررات (١١١س، ١١٢س، ١١٣س، ٢٠٢عرب)، وكذلك ضعف الاهتمام بالتنبؤ بتحصيل الطلاب ومهارات المستقبلية؛ لذا يحاول البحث الحالي علاج هذا الضعف من

خلال استخدام تقنيات التقيب في البيانات التعليمية باستخدام تقنية "Orange" باستخدام خوارزميات خاصة بالأنماط التعليمية والتنبؤ بالتحصيل الدراسي لطلبة الجامعة.
أسئلة البحث:

تمثلت أسئلة البحث في الإجابة على السؤال الرئيس التالي:
كيف يمكن استخدام تقنيات التقيب في البيانات الضخمة لاكتشاف الأنماط التعليمية بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة؟
ويتفرع من هذا السؤال الأسئلة الفرعية الآتية:

١- ما الأنماط التعليمية السائدة في المقررات الإلكترونية (١١١ اسلم، ١١٢ اسلم، ١١٣ اسلم، ٢٠٢ عرب) وفقاً لاستخدام خوارزميات التقيب في البيانات من خلال تقنية "Orange"؟
٢- ما أفضل الخوارزميات التي يمكن استخدامها للتنبؤ بالتحصيل الدراسي لدى طلاب جامعة الملك خالد في مقررات (١١١ اسلم، ١١٢ اسلم، ١١٣ اسلم، ٢٠٢ عرب) من خلال تقنية "Orange"؟

٣- ما العلاقة الارتباطية بين الأنماط التعليمية السائدة في المقررات الإلكترونية (١١١ اسلم، ١١٢ اسلم، ١١٣ اسلم، ٢٠٢ عرب) ومستوى تحصيل طلبة جامعة الملك خالد؟
أهداف البحث:

هدف البحث الحالي إلى:

١- تحليل البيانات التعليمية الضخمة لطلبة جامعة الملك خالد في المقررات الإلكترونية التي يدرسونها كاملاً عبر نظام إدارة التعلم الإلكتروني Blackboard في الجامعة.
٢- اكتشاف الأنماط السائدة في المقررات الإلكترونية التعليمية للطلاب الذين يدرسون المقررات إلكترونياً عبر نظام إدارة التعلم الإلكتروني Blackboard في الجامعة.
٣- مساعدة متخذي القرار في اتخاذ القرارات التطويرية المناسبة والخاصة بالتنبؤ بالتحصيل الدراسي للطلاب الذين يدرسون المقررات كاملة عبر نظام إدارة التعلم الإلكتروني Blackboard. هذه أهمية

٤- تقديم بعض الخوارزميات Linear Regression, Random Forest, KNN, Tree, SVM, K-Means المستخدمة في التقيب في البيانات من خلال تقنية Orange من أجل مساعدة المعلمين ومتخذي القرار على تطوير المقررات الإلكترونية التي يتم تقديمها من خلال إدارة التعلم الإلكتروني Blackboard بصورة كاملة.
أهمية البحث:

قد تسهم نتائج البحث في:

استخدام تقنيات التنقيب في البيانات الضخمة لاكتشاف الأنماط التعليمية بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

- ١- توجيه نظر المسؤولين بالتعليم الجامعي بضرورة الاهتمام بعمليات التنقيب في البيانات في منظومة التعليم الجامعي.
- ٢- توجيه نظر القائمين على التدريس الإلكتروني بفهم أنماط تعلم الطلبة وتقديم المحتوى التعليمي المناسب لهم من أجل تحسين المحتوى التعليمي وتطوير بيئة التعلم الإلكتروني Blackboard.
- ٣- توجيه نظر المسؤولين بالتعليم الجامعي بضرورة الاهتمام بتوظيف تقنيات التنقيب في البيانات من أجل التنبؤ المستقبلي بالتحصيل الدراسي للطلبة.
- ٤- تقديم عدة خوارزميات يمكن أن تساعد المسؤولين في التعليم الجامعي على تقييم وتقويم المنظومة التعليمية، واتخاذ القرارات التطويرية المناسبة.

منهجية البحث:

استخدم البحث الحالي المنهج الوصفي من خلال استخدام أساليب التنقيب في البيانات، والتعلم الآلي؛ لاكتشاف المعرفة من نتائج الطلاب والطالبات بجامعة الملك خالد؛ بغرض تحليل بيانات الطلاب، وتحديد الأنماط السائدة والتنبؤ بالتغيرات التي تحدث في المستقبل، وتطوير المقررات الإلكترونية على نظام إدارة التعلم "Blackboard" وذلك من خلال استخدام عدة خوارزميات من خلال تقنية وبرنامج Orange مفتوح المصدر.

محددات البحث:

اقتصر البحث الحالي على المحددات الآتية:

- ١- طلاب جامعة الملك خالد.
- ٢- مقررات ١١١اسلم، ١١٢اسلم، ١١٣اسلم، ٢٠٢عرب. هذه المقررات تُقدم بصورة إلكترونية كاملة عبر نظام إدارة التعلم الإلكتروني Blackboard.
- ٣- خوارزميات: Linear Regression, Random Forest, KNN, Tree, SVM, K-Means.

تحديد مصطلحات البحث:

١- التنقيب في البيانات Data Mining:

تعرف إجرائياً بأنها عملية يتم من خلالها تحويل البيانات الخام في مقررات (١١١اسلم، ١١٢اسلم، ١١٣اسلم، ٢٠٢عرب) إلى معلومات ومعارف مفيدة من خلال استخدام تقنية "Orange" للتعرف إلى الأنماط التعليمية السائدة في تعلم طلبة جامعة الملك خالد، والتنبؤ بأدائهم الأكاديمي، وتطوير بيئات التعلم الإلكترونية الخاصة بهم من خلال استخدام

خوارزميات Linear Regression, Random Forest, KNN, Tree, SVM, K-Means.

٢-برنامج أورانج Orange:

يعرف إجرائيًا على أنه تطبيق ذكي مفتوح المصدر للتقريب في البيانات التعليمية يعتمد على لغة بايثون Python، ويتم فيه تحليل المعرفة واستخراجها من بيانات طلبة جامعة الملك خالد في مقررات (١١ اسلم، ١٢ اسلم، ١٣ اسلم، ٢٠٢٢ عرب) بصورة بصرية من خلال مجموعة من الأدوات الذكية والخوارزميات المتنوعة التي تساعد على فهم بيانات طلبة جامعة الملك خالد والتنبؤ بأدائهم الأكاديمي بصورة علمية.

٣-الأنماط التعليمية Learning Styles:

يعرف إجرائيًا بأنه الشكل العام لدرجات طلبة جامعة الملك خالد في مقررات (١١ اسلم، ١٢ اسلم، ١٣ اسلم، ٢٠٢٢ عرب) نتيجة أدائهم في الأنشطة والاختبارات الفصلية والنهائية، ويمكن التعرف إليها من خلال استخدام خوارزمية K-Means عبر تقنية وتطبيق "Orange".

٤-التنبؤ الأكاديمي Academic prediction:

يعرف إجرائيًا على أنه تقدير أو توقع درجات طلبة جامعة الملك خالد النهائية اعتمادًا على تحليل درجاتهم في الأنشطة والاختبارات الفصلية في مقررات (١١ اسلم، ١٢ اسلم، ١٣ اسلم، ٢٠٢٢ عرب) من خلال خوارزميات Linear Regression, Random Forest, KNN, Tree, SVM عبر تقنية "Orange".

أدبيات البحث

أولاً- التقريب في البيانات Data Mining:

ظهر مصطلح التقريب في البيانات في منتصف التسعينيات في الولايات المتحدة الأمريكية بإسهام عدة تخصصات من بينها: الإحصاء، وقواعد البيانات، والدكاء الاصطناعي، والتعلم الآلي، فقد بدأ الاهتمام بالتقريب في البيانات عام (١٩٨٩م) في أثناء انعقاد ورشة عمل حول اكتشاف المعرفة في قواعد البيانات، ومن ذلك الحين تم عقد هذه الورشة بصفة مستمرة سنويًا حتى عام (١٩٩٤م)، أمّا في عام (١٩٩٥م) أصبح المؤتمر الدولي لاكتشاف المعرفة والتقريب في البيانات من أهم الأحداث السنوية (سيد، ٢٠١٧).

ومنذ ذلك الوقت أثبت التقريب في البيانات نجاحًا منقطع النظير بوصفه أحد الحلول الفاعلة لتحليل كميات ضخمة من البيانات، وذلك بتحويلها من مجرد معلومات متراكمة غير مفهومة "بيانات" إلى معلومات قيمة يمكن استثمارها والاستفادة منها بصورة كبيرة. وهي عملية

دمج الطرق التقليدية لتحليل البيانات مع خوارزميات Algorithms مُعدّة من أجل استخلاص معلومات مفيدة ودقيقة، من بين كم هائل من البيانات غير المُستخدمة، ليتم استخدامها لاحقاً في التّوقُّع بحدّث ما في المستقبل (الكعبي، ٢٠١٨).

ويعتمدُ التّنبُّؤ في البيانات على ركيزتين: الأولى: استراتيجيات التّنبُّؤ في البيانات مثل: التّصنيف والتّنبُّؤ واكتشاف العلاقات، والثانية: هي أساليب علمية للتّنبُّؤ في البيانات، والكشف عن الأنماط والعلاقات الجديدة مثل: تحليل الانحدار، وشجرة القرار، والشبكات العصبية، وبايزن، والمنطق غير الواضح، والخوارزميات، والنظم الخبيرة (Sharma & Panigrahi, 2012).

ويشير كل من مليك، صباح (٢٠١٧) إلى أن التّنبُّؤ في البيانات يهدف إلى استخلاص المعلومات المُخبّأة فيها، فاستخدامها يوفّر للمؤسّسات في جميع المجالات الاستكشاف والتّركيز على أهم المعلومات في قواعد البيانات؛ لذا أصبح من الضروري إيجاد تقنيات وطرق لاستخلاص المعلومات والمعرفة من البيانات المُكدّسة، واستغلالها في حل المشكلات واتخاذ القرارات، باستخدام تطبيقات وبرامج الحاسب الآلي الحديثة الذكية؛ ولهذا ظهرت فكرة الكشف والتّنبُّؤ في البيانات بطريقة ذكية للمساعدة في حل المشكلات واتخاذ القرارات، وتعدّ بذلك خطوة من خطوات اكتشاف المعرفة من البيانات.

ولخصّ كل من الزعبي (٢٠١٨)، وهلال (٢٠٢١)، (Sinha & Singh, 2019)، (Tarmizi, et.al. 2019) أنواع التّنبُّؤ في البيانات في الآتي:

١- التّنبُّؤ الوصفي Descriptive:

يعتمدُ على إعادة تنظيم البيانات والتّنبُّؤ في أعماقها؛ لاستنباط النماذج الموجودة فيها، كتشابه درجات التّحصيل لمجموعة من الطُّلاب، ويقدمُ إجابةً عن الأسئلة من النمط "ماذا حصل في الماضي؟"، "كم كانت نسبة المبيعات من خدمة معيّنة في الربع الأول من العام الماضي؟" ويتمّ ذلك في صورة أشكال ورسومات يسهل فهمها ومن ثم اتّخاذ القرار المناسب.

٢- التّنبُّؤ التشخيصي Diagnostic:

يقدمُ هذا النوع إجابةً عن الأسئلة من النمط "لماذا حصل هذا الشيء؟ ما سبب انتقال الطالب من شعبة إلى شعبة أخرى؟ أو ما سبب انتقال الزبون إلى المنافس؟

٣- التّنبُّؤ التنبؤي Predictive:

يعتمدُ على استخدام المعلومات القديمة لتوقُّع ما سيحدث في المستقبل، فيحاول إيجاد أفضل التنبؤات اعتماداً على المعطيات مثل: معرفة التخصّص الأفضل لطالب معيّن، وقد

يتم ذلك من خلال دمج البيانات التاريخية، مع القواعد والخوارزميات والبيانات الخارجية كمدخلات، ومن ثم تحديد العلاقة بينهم، ومن ثم تحديد النتيجة المستقبلية للحدث.

٤- التَّقْيِبُ الكيفي Prescriptive:

هو أداة قوية تتجاوز التنبؤ بالنتائج المستقبلية، وهذا النوع من التحليلات لا يهتم بما سيحدث أو متى سيحدث فحسب، بل أيضاً سبب حدوثه، وتُقدِّمُ بدائل للقرار ترتبط بكيفية الاستفادة من الفرص المستقبلية، أو التخفيف من مخاطرها. ويستخدم هذا النوع البيانات المنظمة وغير المنظمة مما يساعد المسؤولين على اتخاذ القرار بناءً على الفهم الصحيح للنتائج المتوقعة.

ويوضح الكعبي (٢٠١٨) أن اكتشاف المعرفة في قواعد البيانات ليس بالعملية السهلة كما يعتقد البعض، وخصوصاً أنها تتعدى عملية تجميع البيانات وإدارتها، إلى التحليل والتوقع والتنبؤ بما سيحدث مستقبلاً. والتقيب في البيانات يشكّل جزءاً من اكتشاف المعرفة، وهذه العملية هي الأكثر شمولاً وتتضمن عملية اكتشاف المعرفة عدة خطوات كما هو واضح في شكل (١)، تبدأ باكتشاف البيانات وهي مرحلة تشمل: تحديد البيانات المتاحة، ثم مرحلة تصنيف البيانات، وفي هذه المرحلة تتم إزالة البيانات التي ليس لها أهمية، ثم مرحلة تكامل البيانات وتجميع البيانات المتشابهة، ثم مرحلة انتقاء البيانات وتحديد البيانات الملائمة منها، ثم مرحلة تحويل البيانات إلى نماذج ملائمة لإجراء البحث والاسترجاع، ثم مرحلة التقيب في البيانات، أي استخدام طرق ذكية لاستخلاص أنماط البيانات ونماذج مفيدة، ثم مرحلة تقييم البيانات، وفي هذه المرحلة يتم تحديد الأنماط المهمة حقاً التي تمثل قاعدة المعرفة، ثم المرحلة الأخيرة وهي مرحلة تمثيل المعرفة وتقديمها، وهذه المرحلة هي التي يراها المستفيد بصورة مرئية من أجل فهم نتائج استخراج البيانات وتفسيرها.



شكل (١) خطوات اكتشاف المعرفة في قواعد البيانات

وقد أشار كل من نايف، أيوب (٢٠١٦) إلى أن عملية التقيب في البيانات تستخدم تقنيات وأساليب مختلفة، يمكن استخدامها أحد هذه الأساليب أو أكثر وهي كما يلي:

١- التصنيف Classification:

يتم في التصنيف تحليل مجموعة من البيانات لتكوين مجموعات حسب خصائص معينة، وللتصنيف أدوات عديدة أبرزها: شجرة القرار، المجاور الأقرب، الانحدار.

٢- الاقتران Association:

وهي القاعدة التي تتضمن علاقات اقتران ثابتة بين مجموعة من الأشياء في قاعدة البيانات. أي الاقتران بين حدوث حدث ما وحدث حدث آخر.

٣- التحليل المتسلسل Sequential Analysis:

وهو يشبه الاقتران ويوضع تحت مسمى: تحليل الربط لكونه مرتبطاً بالزمن، فيبحث عن نماذج تحدث بالتتابع، أي يتعامل مع البيانات التي تحدث في حالات منفصلة.

٤- العقدة أو التجميع والتصنيف Clustering:

وهي تقنية تجمع الكيانات المتشابهة معاً، وتفصلها عن البيانات غير المتشابهة في مجموعات مختلفة. ويختلف التجميع عن التصنيف بأنه في الأول لا نعرف ما ستكون عليه التجمعات عند البدء، أو بأية صفة ستتجمع البيانات، ويستخدم أدوات مثل: متوسط K-means، الشبكات العصبية Neural Networks.

من جانب آخر ركز عبد الله (٢٠٢١) على توضيح علاقة البيانات عامةً والبيانات النظيفة خاصةً بمجال الذكاء الاصطناعي، فالبيانات النظيفة لا تقل أهمية عن مجال الذكاء الاصطناعي، بل إن البيانات مهمة لدرجة أن جودة الذكاء الاصطناعي تعتمد بشكل رئيسي على جودة البيانات المستخدمة لإنتاجها ونظافتها، فإذا كانت البيانات غير جيدة، فالمقابل سوف يتم الحصول على نتائج فوضوية. وفي هذا الجانب خلصت دراسة زهير (٢٠١٩) إلى أن التقيب عن تكامل البيانات النظيفة مع أنظمة الذكاء الاصطناعي أسهم بدرجة كبيرة في التنبؤ بالجريمة ومنع حدوثها، وضمان سلامة الأفراد، وذلك من خلال استخدام مجموعة غنية من البيانات النظيفة والمتكاملة من تطبيقات الذكاء الاصطناعي.

تحليل البيانات الضخمة للمقررات الإلكترونية التعليمية:

منذ أن انطلقت ثورة التكنولوجيا في العالم المعاصر، والمجالات الحياتية تشهد تغييرات مذهلة مهمة في جميع مجالات الحياة، وقد استأثر مجال التعليم بالنصيب الأكبر من هذه التغييرات الإيجابية فقد أصبح يستخدم أنماطاً جديدة تعلبت على الطرق الاعتيادية التي تعتمد على التحفيز والتلقين التي باتت بعيدة كل البعد عن تطورات العالم الرقمي والتكنولوجي، وتطبيقات الذكاء الاصطناعي الذي أخرج تطبيقات وأجهزة تدعم آفاقاً جديدة، تحمل في طياتها مفهوم التعلم الذاتي، وتدعم التعلم القائم على الإبداع والابتكار والريادة لإثراء رحلة الطلبة

التَّعليميَّة نحو مستقبلٍ رقمي، لا مكان فيه للمُتعلِّم التَّقليدي والمُعلِّم المُلقَّن (Kandlhofer, Steinbauer, 2018).

والمقرَّر الإلكتروني هو استجابة للثورة التكنولوجيَّة المعاصرة التي تدعو إلى ضرورة إدخال المقرَّرات التَّعليميَّة على الإنترنت، والدراسة من خلال منصات التَّعلُّم، والتَّوجُّه إلى التَّعلُّم الذاتي، والفصول الافتراضية، وذلك من أجل الاستفادة من الخدمات التي تقدِّمها الإنترنت وبخاصة المقرَّرات الإلكترونيَّة التي تُعرَّف أنَّها "مجموعة من الدروس والوحدات الدراسيَّة الإلكترونيَّة، التي يتمُّ نشرها عبر الإنترنت ويتفاعل من خلالها الطلبة مع بعضهم البعض، ومع المُعلِّم باستخدام نظام يطبَّق عليه نظام إدارة التَّعلُّم (LMS) Learning Management System؛ حيث يستطيع الطُّلاب من خلال هذا النظام دراسة المقرَّرات في أي وقتٍ خلال اليوم، وفي أي مكان بصورة تتناسب مع احتياجاتهم وقدراتهم" (عطار، كنساره، ٢٠١٥).

ويعدُّ نظام إدارة التَّعلُّم الإلكتروني أداةً تسمح بنقل المادة التَّعليميَّة للمتعلِّمين ضمن التَّعلُّم الإلكتروني، وكذلك بمتابعة نشاطاتهم على النظام، وتوفير عديدٍ من الأدوات لبيئة التَّعلُّم مثل: المحادثة والمنتديات، والتَّواصل، وإجراء الاختبارات وغيرها من الأنشطة الأخرى. ومن الأمثلة على نظم إدارة التَّعلُّم نظام (Moodle) ونظام (Blackboard) الذي يُستخدَم حاليًا في جامعة الملك خالد (الشرمان، ٢٠١٩).

وتعدُّ البيانات التي يتمُّ الحصولُ عليها من نظام إدارة التَّعلُّم (Blackboard) بيانات قليلة الفائدة إلا إذا أمكن استخلاصُ معنى وقيمة لها، أي أنَّ ما يمكن فعله والحصولُ عليه من البيانات أهم من مجرد عملية إنتاجها؛ لذا تركَّز جميعُ العلوم على تحقيق معنى وقيمة من البيانات، وأصبح الاهتمامُ باستخلاص المعلومات من بيانات ضخمة متَّصلة بعضها ببعض، يشغلُ حيزًا واهتمامًا كبيرًا في الوقت الحالي من أجل الحصولِ على معلومات ذات فائدة للمجتمع (كيتشن، ٢٠١٨).

ويمكنُ الاستفادة من تحليل البيانات الضخمة داخل بيئات التَّعلُّم الإلكتروني، لتوفير مجموعة متنوِّعة من الخيارات بهدف تحسين تعلم الطُّلاب من خلال التَّعلُّم التكيفي أو التَّعلُّم القائم على الكفاءة ممَّا ينتجُ عنه تعلمٌ أفضل نتيجةً لتشخيصٍ أسرع وأكثر تعمقًا لاحتياجات المتعلِّم، أو الصعوبات التي تواجهه في أثناء عملية التَّعلُّم، بما في ذلك من تقييم المهارات مثل: التفكير الناقد، وحل المشكلات في سياق عميق، والتَّعاون والتَّشارك الإلكتروني، بالإضافة لتحديد التَّدخلات المستهدفة لتحسين نجاح الطُّلاب وكذلك استخدام البيانات الضخمة في صنع القرارات وتحديد السياسات، وتصميم بيئات تعلم تُصمَّم خصيصًا وفق احتياجات مُحدَّدة للطلاب (البار، ٢٠١٨).

استخدامُ تقنيات التَّقيب في البيانات الضخمة لاكتشاف الأنماط التعليمية بالمقررات الإلكترونية عبر نظام إدارة التعلم والتَّنبؤ بالتحصيل الدراسي لطلاب الجامعة

ويساعدُ تحليلُ البيانات الضخمة لأنظمة إدارة التَّعلم الإلكتروني مثل نظام "البلاكبورد Blackboard" المُطبَّق في غالبية الجامعات السعودية ومنها جامعة الملك خالد على مراقبة تقدُّم الطُّلاب في أثناء دراستهم للمقرَّرات الإلكترونية، كما يساعدُ على فهم سلوكياتِ الطُّلاب والمشكلات التي تواجههم في أثناء دراستهم للمقرَّرات الإلكترونية والعمل على حلها، كما تساعدُ على تقديم الدعم للطُّلاب المتفوقين، وتقديم الإثرائيات المناسبة لهم، كما تساعدُ القائمين بالتدريس على إعادة تصميم مقرَّراتهم الإلكترونية، وتحسينها من خلال تعرُّف المحتوى ذي الأداء الضعيف من قبل الطُّلاب، ومن ثمَّ يمكنُ القولُ أنَّ تحليل البيانات الضخمة عبر نظام إدارة التَّعلم الإلكتروني "البلاكبورد" يعملُ على تحسين بيئة التَّعلم بعناصرها كافة وتطويرها إلى الأفضل.

وقد أشار كلُّ من عثمان (٢٠١٧)، والأكلبي (٢٠١٨) إلى أنَّه في ظل الظروف التي أدَّت إلى تضخُّم البيانات، وسرعة تواردها معتمده على ما أسهمت به مستجدات التقنية وأدواتها وبيئات العمل الرقمية، ووسائل التواصل الاجتماعي، أصبحت الحاجة ملحةً لبناء نظام يضمن سرعةً فائقةً في تحليل البيانات الضخمة في الوقت المتزامن، وهذا ما أدَّى إلى ظهورٍ عديدٍ من النظم التي اختصت بتحليل البيانات الضخمة ومن أهمها الآتي:

١- نظام هادوب Hadoop:

وهذا النظام متاح على الرابط (<https://hadoop.apache.org>) وهو برنامج مفتوح المصدر ويتميز بإطارٍ يسمحُ بتخزينٍ موزَّعٍ لمجموعاتٍ كبيرة من البيانات في تجمُّعات؛ ممَّا يعطيه خاصية التوسُّعية والاعتمادية والعمل دون خوف من فشل الأجهزة، ولديه المقدرة على تخزين بياناتٍ كبيرة مختلفة الأنواع، مع القدرة الهائلة على التَّعامل مع وظائف متزامنة لا حدود لها تقريبًا.

٢- نظام ساب SAP:

هذا النظام متاح على الرابط (<https://www.sap.com/mena-ar/products/hana.html>) ويساعدُ هذا النظامُ على القيام بعمليات التَّحليل المتزامن للبيانات الضخمة التي تردُّ إلى منصَّة النظام، وتساعدُ هذه المنصَّة المؤسسات التي تمتلكه على إنجاز العمليات بشكلٍ أسرع من خلال ما توفَّره لها من بيانات معالجة؛ تساعد المسؤولين على اتِّخاذ القرار والقيام بعمليات التَّخطيط والتنفيذ بكفاءةٍ عالية.

٣- تقنية Orange:

هي حزمة برمجية مفتوحة المصدر متاحة على الرابط (<https://orangedatamining.com>) وهي مجموعة أدوات لتصوير البيانات والتَّعلم الآلي وتحليلها، وهي قائمة على لغة بايثون Python وتحتوي على واجهة مرئية

للاستكشاف، كما أنها تحتوي على عديداً من الأقسام والخوارزميات التي يمكن المقارنة بينها بصورة مرئية، واختيار الأفضل لفحص البيانات واستخراجها (Mohi, 2020). ومن الدراسات التي اهتمت بتحليل البيانات الضخمة لنظام إدارة التعلّم الإلكتروني (البلابورد) دراسة واليس (Walsh, 2015) وقد خلصت إلى أنّ تحليل البيانات وإعداد التقارير الخاصة بالطلّاب تُعدُّ بمثابة أدوات ومؤشّرات جيدة للمعلّمين لتعرّف الأداء الأكاديمي للطلّاب ومستوى مشاركتهم الإيجابية في هذه البيئة. كذلك اهتمت دراسة إبراهيم (٢٠١٧) بالتحليلات التعلّميّة في بيئة التعلّم الإلكتروني وخلصت إلى أنّ التغذية الراجعة التفصيلية لها أثر كبير لدى الطّلاب من التغذية الراجعة الموجزة في تنمية المهارات الخاصة بإنتاج المواقع التعلّميّة، وقد أوصت الدراسة بضرورة الاهتمام بالتحليلات التعلّميّة ببيئات التعلّم الإلكتروني من أجل تطوير المفرّزات الإلكترونيّة، وتحسين بيئة التعلّم لدى الطّلاب. ولكن جاءت نتائج دراسة ليرش، كايل (Lerche, Kiel, 2018) بنتيجة مغايرة عن نتائج الدراسات السابقة، وخلصت إلى أنه يصعب التنبؤ بتحصيل الطّلاب من خلال تحليل بيانات الطّلاب على نظام إدارة التعلّم الإلكتروني (Moodle).

الطريقة والإجراءات

استخدمَ البحثُ الحالي المنهج الوصفي القائم على أساليب التّقيب في البيانات Data mining لاكتشاف المعرفة من خلال نتائج الطلبة في مُقرّرات الإعداد العام التي يدرسونها بصورة إلكترونيّة كاملة عبر نظام إدارة التعلّم Blackboard. وذلك بغرض معرفة أنماط تعلّمهم التي تؤثر على تحصيلهم الأكاديمي، وكذلك التنبؤ بالتحصيل الدراسي للطلبة مستقبلاً، وذلك من خلال استخدام خوارزميات Linear Regression, Random Forest, KNN, Tree, SVM, K-Means المتوقّرة عبر تقنية أو تطبيق Orange.

إجراءات البحث:

لتعرّف فاعلية استخدام تقنيات التّقيب في البيانات التعلّميّة "تقنية Orange" لاكتشاف الأنماط التي تؤثر على تحصيل الطّلاب الأكاديمي بجامعة الملك خالد، والتنبؤ بأدائهم الأكاديمي، تمّ إجراء ما يلي:

أولاً- عينة البحث:

تمّ اختيار عينة البحث من طلبة جامعة الملك خالد الذين يدرسون مواد الإعداد العام بصورة إلكترونية كاملة خلال الفصل الدراسي الأول لعام (٢٠٢٢/٢١م) عبر نظام إدارة التعلّم Blackboard وهذه المواد وعددها كما هو بجدول (١).

استخدام تقنيات التنقيب في البيانات الضخمة لاكتشاف الأنماط التعليمية
بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

جدول (١) مقررات الإعداد العام والتي تدرس إلكترونياً لطلبة الجامعة

م	اسم المقرر	عدد المقررات	عدد المقررات المختارة	عدد الطلبة
١	١١١ سلم	٣٧	٤	٧١٧
٢	١١٢ سلم	١١	٤	٧٣٠
٣	١١٣ سلم	٢٦	٤	٧٦٠
٤	٢٠٢ عرب	٢٥	٤	٧٥٠
	الإجمالي	٩٩	١٦	٢٩٥٧

يوضح جدول (١) أنّ عدد المقررات (٩٩) مقرراً يتم تقديمها كاملةً عبر نظام إدارة التعلم الإلكتروني Blackboard المعتمد في جامعة الملك خالد. وقد تمّ اختيار (١٦) مقرراً بصورة عشوائية من هذه المقررات، وقد بلغ عدد الطلبة في هذه المقررات (٢٩٥٧) طالباً وطالبة. وقد تمّ الحصول على هذه البيانات من وحدة تحليلات بيانات التعلم بعد موافقة عمادة التعلم الإلكتروني بالجامعة.

ثانياً - مرحلة المعالجة الأولية للبيانات:

إن قاعدة البيانات التي تمّ استخدامها والتنقيب في بياناتها هي درجات طلبة جامعة الملك خالد لمواد الإعداد العام، والتي تُدرّس بصورة إلكترونية كاملة عبر نظام إدارة التعلم الإلكتروني (Blackboard). وقد تمّ استبعاد بعض الحقول غير المهمة في البحث وهي (اسم الطالب أو الطالبة) والنوع (طالب أو طالبة ذكر/ أنثى)، وكذلك اسم المستخدم، والطلبة الذين لم يقدموا أنشطة، أو قيد التقدم لإداء الاختبارات الفصلية، أو النهائية. وقد تمّ التركيز في البيانات على درجات الأنشطة الطلابية، والاختبارات الفصلية والنهائية لهم كما يوضّح جدول (٢).

جدول (٢)

درجات الأنشطة والاختبارات الفصلية والنهائية لمقررات الإعداد العام

م	اسم المقرر	درجات الأنشطة	درجات الاختبار الفصلي	درجات الاختبار النهائي
١	١١١ سلم	٥٠	٢٠	٣٠
٢	١١٢ سلم	٥٠	٢٠	٣٠
٣	١١٣ سلم	٥٠	٢٠	٣٠
٤	٢٠٢ عرب	٦٠	٢٠	٢٠

ثالثاً - تحويل البيانات إلى صيغة (Comma Separated Value .CSV):

يسمّح برنامج (Orange) بالتعامل مع الملفات ذات الإمداد (.CSV) وقد تم تحويل شكل البيانات المتوفرة في برنامج (Excel) إلى ملفات ذات امتداد (.CSV) كما بشكل (٢).

Final	Midterms	Total1	AC5	AC4	AC3	AC2	AC1	Total
30	20	47	10	10	10	10	7	97
30	20	50	10	10	10	10	10	100
30	19	50	10	10	10	10	10	99
30	20	50	10	10	10	10	10	100
30	20	40	9	10	5	7	9	90
29	20	49	10	9	10	10	10	98
30	20	50	10	10	10	10	10	100
30	20	50	10	10	10	10	10	100
30	20	48	10	10	10	10	8	98
30	20	50	10	10	10	10	10	100
28	20	49	9	10	10	10	10	97
30	20	50	10	10	10	10	10	100
30	20	47	10	10	8	10	9	97
30	20	50	10	10	10	10	10	100
30	20	50	10	10	10	10	10	100
30	20	50	10	10	10	10	10	100
30	20	49	9	10	10	10	10	99
30	20	50	10	10	10	10	10	100
30	20	50	10	10	10	10	10	100
30	20	50	10	10	10	10	10	100
30	20	45	8	9	10	10	8	95
30	20	50	10	10	10	10	10	100

شكل (٢) بيانات الطلبة بعد التعديل والتحويل إلى ملف (CSV).

خامساً- وصف بيانات الطلبة (Meta Data):

تتضمن قاعدة بيانات طلبة جامعة الملك خالد عدّة حقول تتّضح هذه الحقول كما في

جدول (٣).

جدول (٣) حقول قاعدة بيانات مُقرّرات الإعداد العام

م	اسم الحقل	نوع البيانات	م	اسم الحقل	نوع البيانات
١	Family name	Nominal	٧	AC3	Numeric
٢	First name	Nominal	٨	AC4	Numeric
٣	User	Numeric	٩	AC5	Numeric
٤	Total	Numeric	١٠	Total1	Numeric
٥	AC1	Numeric	١١	Midterms	Numeric
٦	AC2	Numeric	١٢	Final	Numeric

يتّضح من جدول (٣) أنّ حقل (Family name)، وحقل (First name) نوع البيانات

فيهما (Nominal)، أما بقية الحقول فنوع البيانات فيها هو (Numeric).

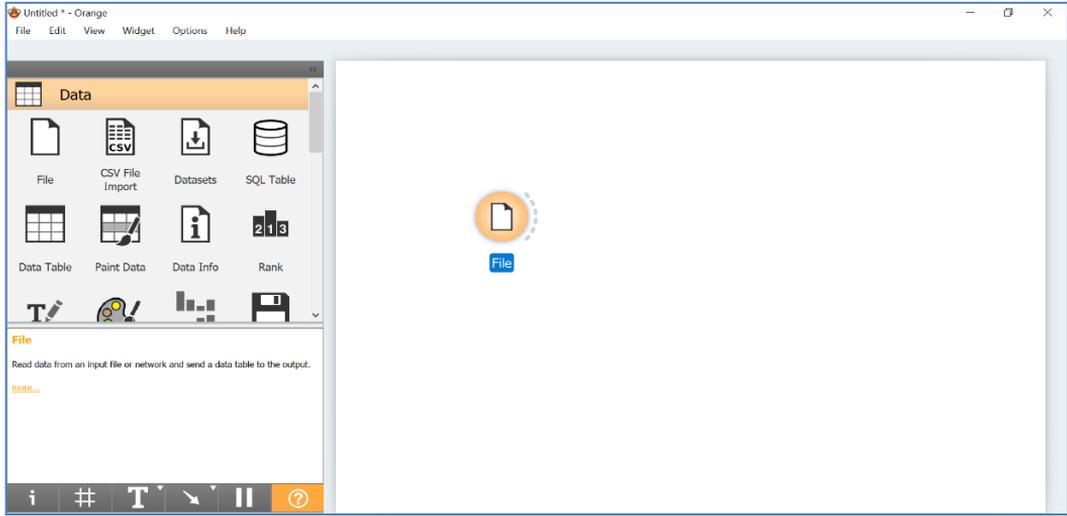
سادساً- برنامج Orange والتّقيب عن البيانات:

يعدّ برنامج أو تقنية (Orange) من البرامج مفتوحة المصدر لأساليب التّقيب وعندة

البيانات المعقّدة، والتّحليل المتقدّم للبيانات، وإنشاء الرسوم البيانية، ويتميز بواجهة رسومية سهلة

الاستخدام، مُزوّد بمكتبة لغة البايثون Python، وموقع (<https://orangedatamining.com>)

ويظهر ذلك في شكل (٣) (خميس، ٢٠٢٠). وقد تمّ استخدام هذا البرنامج في هذا البحث.



شكل (٣) برنامج Orange للتنقيب في البيانات

سابعاً - التقنيات والخوارزميات المستخدمة في البحث (Algorithm):

تم استخدام تقنية التصنيف (Classification)، وتقنية العناقيد (Clustering)، وتقنية التنبؤ (Predictions)، وخوارزميات Linear Regression, Random Forest, KNN, Tree, SVM, K-Means. هذه الخوارزميات تعمل على اكتشاف المعرفة في قواعد البيانات المحملة على برنامج Orange.

نتائج البحث ومناقشتها

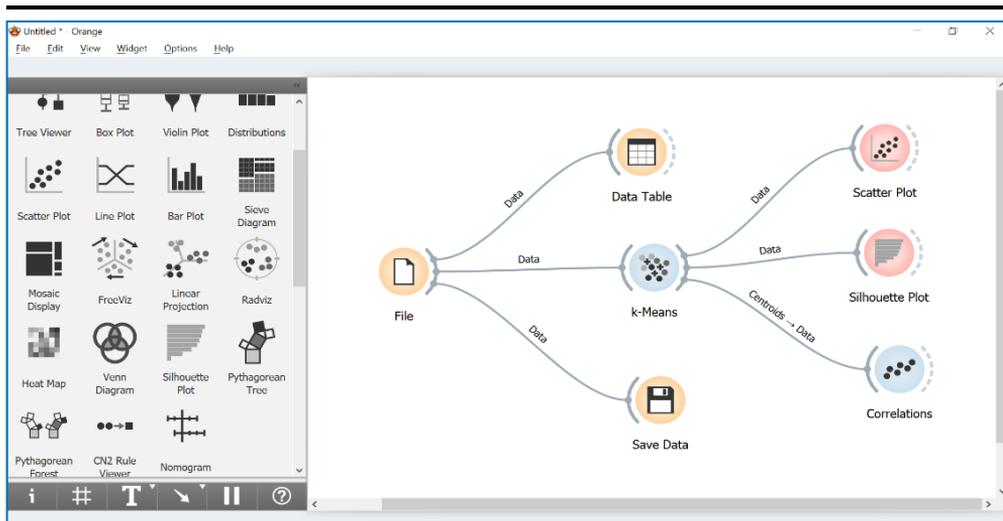
بعد تنظيف البيانات وتحميلها على تقنية "Orange"، تمت الإجابة عن أسئلة البحث على النحو

الآتي:

١ - إجابة السؤال الأول الذي نصَّ على:

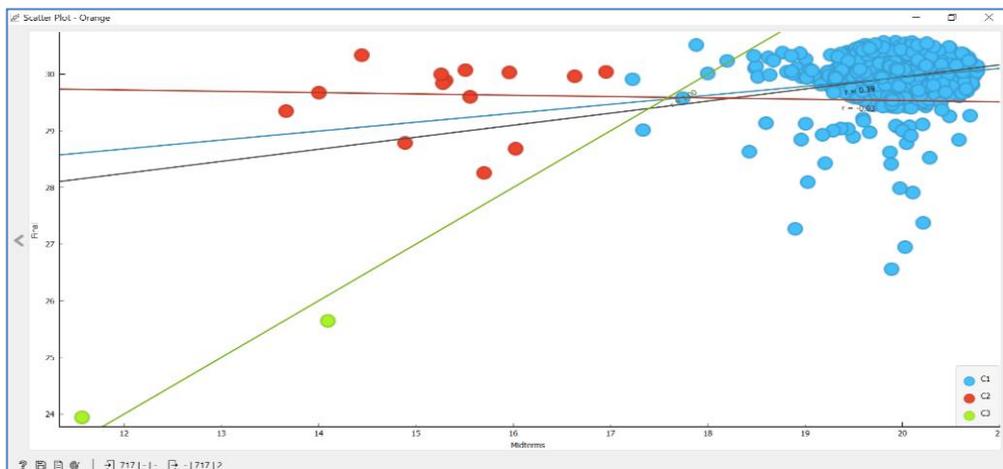
ما الأنماط التعليمية السائدة في مقررات (١١ اسلم، ١٢ اسلم، ١٣ اسلم، ٢٠٢ عرب) التي تؤثر على تحصيل طلبة جامعة الملك خالد، ويمكن اكتشافها باستخدام خوارزميات التنقيب في البيانات من خلال تقنية أو برنامج "Orange"؟

وللإجابة عن هذا السؤال، تمت مراجعة الأدبيات والدراسات والبحوث المرتبطة التي اهتمت بتصنيف البيانات التعليمية مثل دراسة نايف، وأيوب (٢٠١٦)، ودراسة أحمد، وعبد الله (٢٠١٨). وقد تم استخدام خوارزمية K-Means عبر برنامج (Orange) كما بالشكل الآتي:



بعد معالجة البيانات وتحميلها على برنامج "Orange"، تمت الإجابة عن أسئلة البحث على النحو الآتي:

١- بالنسبة لمقرر (١١١ سلم) كانت النتائج بالشكل الآتي:

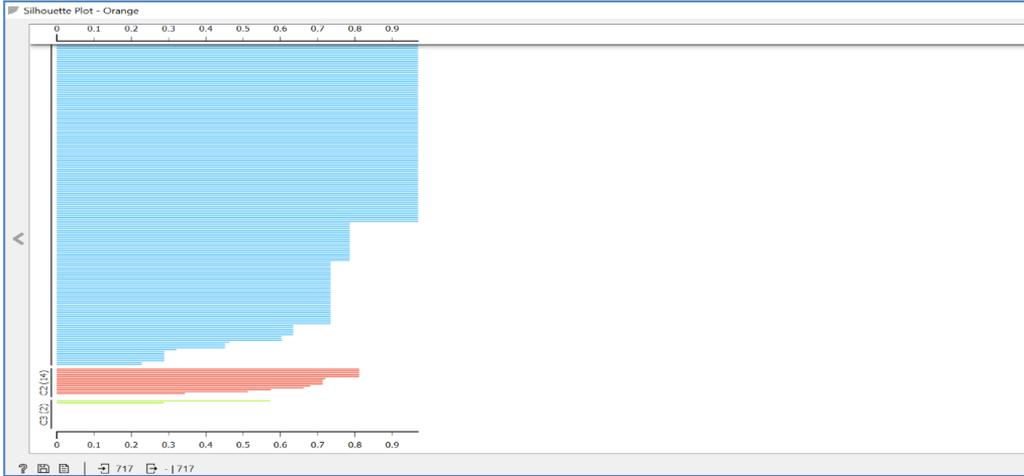


يتضح من الشكل السابق الخاص بمقرر (١١١ سلم) أنّ برنامج (Orange) قد قام بتقسيم درجات الطلبة في هذا المقرر إلى ثلاث طبقات رئيسية:

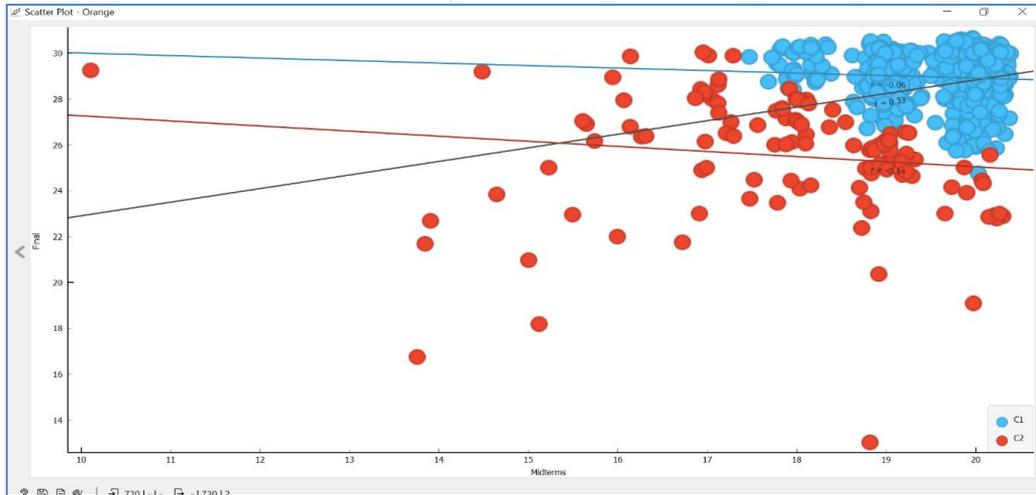
١- الطبقة الأولى وهي الأكثرية في درجات الطّلاب وتتحصّر درجاتهم في المدى من (١٨ إلى ٢٠) في درجات الاختبار الفصلي، وينظرها درجات (٢٨-٣٠) في الاختبار النهائي.

استخدام تقنيات التّقيب في البيانات الضخمة لاكتشاف الأنماط التعليمية
بالمقررات الإلكترونية عبر نظام إدارة التعلم والتّنبؤ بالتحصيل الدراسي لطلاب الجامعة

- ٢- أما الطبقة الثانية فتتّحصر درجات الطّلاب في المدى (١٤-١٧) وبنظرها في الاختبار النهائي (٢٨-٣٠)
- ٣- أما الطبقة الثالثة وهي القليلة في عدد درجات الطّلاب فتتّحصر في المدى (١٢-١٤) في الاختبار الفصلي، وبنظرها في الاختبار النهائي (٢٤-٢٦) وهي تمثّل عددًا قليلًا للغاية من الطّلاب. ويبيّض شكل هذه الطبقات الثلاثة في الشكل الآتي:



- ٢- بالنسبة لمقرر (١٢ اسلم) كانت النّتائج بالشكل الآتي:

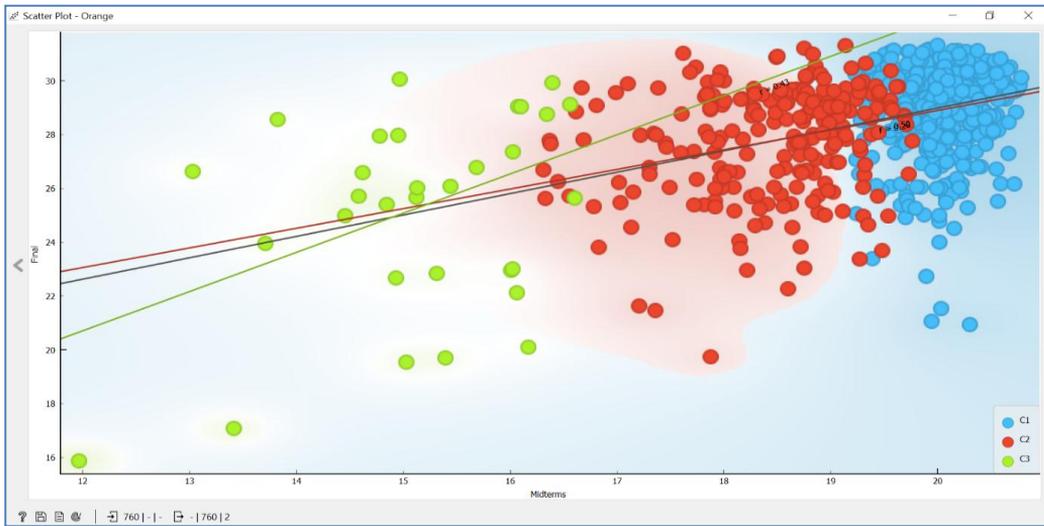


- يبيّض من الشكل السابق الخاص بمقرر (١٢ اسلم) أنّ برنامج (Orange) قد قام بتقسيم درجات الطلبة في هذه المادة إلى ثلاث طبقات متداخلة:

- ١- الطبقة الأولى تتحصرُ درجاتهم في المدى من (١٩ إلى ٢٠) في درجات الاختبار الفصلي ويناظرها درجات (٢٨-٣٠) في الاختبار النهائي.
- ٢- أما الطبقة الثانية فتتصرُ درجات الطُّلاب في المدى (١٨-٢٠) ويناظرها في الاختبار النهائي (٢٤-٢٨) وهي طبقة متداخلة مع الطبقة الأولى.
- ٣- أما الطبقة الثالثة وهي طبقة متداخلة مع الطبقة الأولى والثانية ولكن بدرجة قليلة، فدرجات الطلبة تتحصر في المدى (١٤-١٨) في الاختبار الفصلي ويناظرها في الاختبار النهائي (١٧-٣٠). ويتضح شكلُ هذه الطبقات الثلاثة في الشكل الآتي:



- ٣- بالنسبة لمقرر (١٣ اسلم) كانت النتائج بالشكل الآتي:



استخدام تقنيات التقيب في البيانات الضخمة لاكتشاف الأنماط التعليمية
بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

يُتضح من الشكل السابق الخاص بمقرر (١٣س) أنّ تقنية (Orange) قد قامت بتقسيم درجات الطلبة في هذه المادة إلى ثلاث طبقات متداخلة:

١- الطبقة الأولى تتحصّر درجاتها في المدى من (١٩ إلى ٢٠) في درجات الاختبار الفصلي ويناظرها درجات (٢٧-٣٠) في الاختبار النهائي.

٢- أمّا الطبقة الثانية فتتحصّر درجاتها في المدى (١٧-٢٠) ويناظرها في الاختبار النهائي (٢٧-٣٠) وهي طبقة متداخلة مع الطبقة الأولى.

٣- أمّا الطبقة الثالثة فهي طبقة متداخلة مع الطبقة الأولى والثانية ولكن بدرجة أقل فإنّ درجات الطلبة تتحصّر في المدى (١٢-١٦) في الاختبار الفصلي، ويناظرها في الاختبار النهائي (١٦-٢٩). ويُتضح شكل هذه الطبقات الثلاثة في الشكل الآتي:



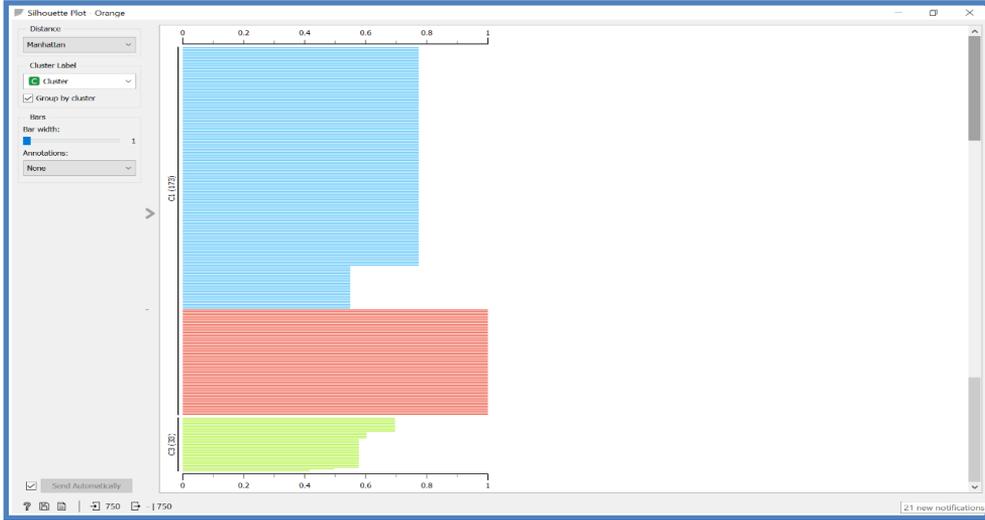
٤- بالنسبة لمقرر (٢٠٢عرب) كانت النتائج بالشكل الآتي:

يُتضح من الشكل السابق الخاص بمقرر (٢٠٢عرب) أنّ برنامج (Orange) قد قام بتقسيم درجات الطلبة في هذه المادة إلى ثلاث طبقات متداخلة:

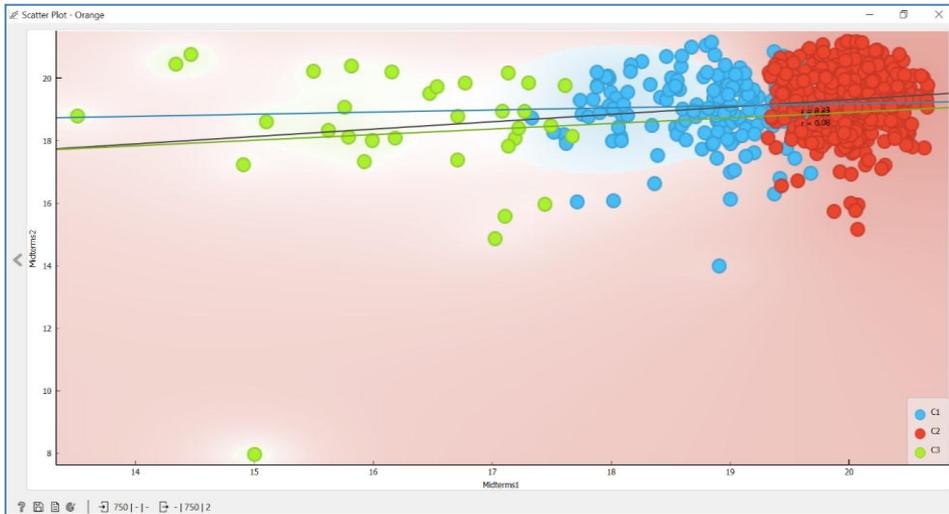
١- الطبقة الأولى تتحصّر درجاتها في المدى من (١٩ إلى ٢٠) في درجات الاختبار الفصلي ويناظرها درجات (١٧-٢٠) في الاختبار النهائي والتي درجته النهائية (٢٠).

٢- أمّا الطبقة الثانية وأكثر درجات الطلبة يتمركز في هذه الطبقة، وتتحصّر درجات الطلبة في هذه الطبقة في المدى (١٨-١٩) ويناظرها في الاختبار النهائي (١٦-٢٠) وهي طبقة متداخلة بدرجة قليلة مع الطبقة الأولى.

٣- أما الطبقة الثالثة فهي طبقة متداخلة مع الطبقة الثانية ولكن بدرجة أقل، حيث إن درجات الطلبة تنحصر في المدى (١٣-١٧) في الاختبار الفصلي وبنظرها في الاختبار النهائي (١٩-٢٠). ويتضح شكل هذه الطبقات الثلاثة في الشكل الآتي:



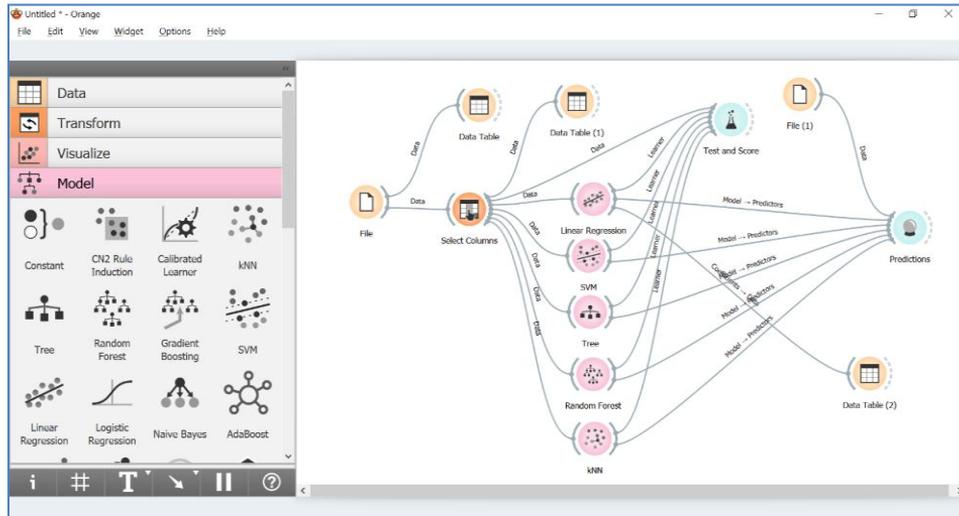
٢- إجابة السؤال الثاني الذي نصّ على:



استخدام تقنيات التنقيب في البيانات الضخمة لاكتشاف الأنماط التعليمية بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

ما أفضل الخوارزميات التي يمكن استخدامها للتنبؤ بالتحصيل الأكاديمي لطلبة جامعة الملك خالد في مقررات (١١١ اسلم، ١١٢ اسلم، ١١٣ اسلم، ٢٠٢ عرب) من خلال تقنية "Orange"؟

وللإجابة عن هذا السؤال، تم مراجعة الأدبيات والدراسات والبحوث المرتبطة التي اهتمت بالتنقيب في البيانات التعليمية والتنبؤ مثل: دراسة أبو قرون، حجازي (٢٠١٨)، ودراسة عبد الله (٢٠٢٠). وقد تم استخدام خوارزميات Linear Regression, Random Forest, KNN, Tree, SVM عبر تقنية (Orange) بالشكل الآتي:



بعد تحليل البيانات واستخدام Linear Regression, Random Forest, KNN, Tree, SVM عبر تقنية "Orange"، تمت الإجابة عن أسئلة البحث على النحو الآتي:

١- بالنسبة لمقرر (١١١ اسلم) كانت النتائج بالشكل الآتي:

تم استخدام خوارزميات Linear Regression, SVM, Tree, Random Forest, KNN. وذلك للتنبؤ ببيانات الطلبة وكانت النتائج وفق جدول (٤).

جدول (٤) نتائج خوارزميات الطلاب في مقرر (١١١ اسلم).

R ²	MAE	RMSE	MSE	Model	N
0.160	0.145	0.375	0.141	Random Forest	1
0.152	0.145	0.377	0.142	Tree	2
0.125	0.146	0.383	0.146	Linear Regression	3
0.028	.160	0.403	0.163	KNN	4
0.009	0.172	0.407	0.166	SVM	5

يَبْضُحُ من جدول (٤) أنَّ خوارزمية Random Forest هي الأفضل لتصنيف درجات الطُّلاب تليها خوارزمية Tree، ثمَّ خوارزمية Linear Regression ثمَّ خوارزمية KNN، ثمَّ خوارزمية SVM. وقد كانت درجات التنبُّو الأكاديمي وفق هذه الخوارزميات كما بالشكل التالي:

	Linear Regression	SVM	Tree	Random Forest	KNN	Total Act	Midterms	Final
1	28	29	27	26	28	47	12	?
2	29	29	27	28	29	50	14	?
3	29	29	27	28	29	50	14	?
4	29	29	27	28	29	50	14	?
5	29	30	30	29	30	40	15	?
6	29	30	30	30	30	49	15	?
7	29	30	30	30	29	50	15	?
8	29	30	30	30	29	50	15	?
9	29	30	30	30	29	48	15	?
10	29	30	30	30	29	50	15	?
11	29	30	30	30	30	49	16	?
12	29	30	30	30	30	50	16	?
13	29	29	28	28	30	47	16	?
14	29	30	30	30	30	50	16	?
15	29	30	30	30	30	50	16	?
16	29	30	30	30	30	50	17	?
17	30	30	30	30	30	49	18	?
18	30	30	30	30	30	50	18	?
19	30	30	30	30	30	50	18	?

وقد أمكن التَّوصُّلُ إلى معادلة التنبُّو بالتحصيل الدراسي بالصورة الآتية:
درجة الطالب النهائية (Final) =

درجة الطالب في الاختبار الفصلي (Midterms) $\times 0.213 + 20,378$

مما سبق يَبْضُحُ أنَّ درجات الطلبة في الأنشطة الفصلية، لا تؤخذ في الاعتبار عند التنبُّو بدرجاتهم النهائية في مقرر (١١ اسلم)، بل إنَّ درجات الطلبة الفصلية فقط هي التي تؤخذ في الاعتبار للتنبُّو بدرجاتهم النهائية.

٢- بالنسبة لمقرر (١٢ اسلم) كانت النتائج بالشكل الآتي:

تمَّ استخدام خوارزميات Linear Regression، SVM، Tree، Random Forest، KNN. وذلك للتنبُّو بالتحصيل الدراسي لطلبة جامعة الملك خالد وكانت النتائج وفق جدول (٥).

جدول (٥) نتائج خوارزميات الطُّلاب في مقرر (١٢ اسلم)

R ²	MAE	RMSE	MSE	Model	N
0.149	1.224	1.735	3.012	Linear Regression	1
0.095	1.224	1.790	3.204	Random Forest	2
0.050	1.288	1.834	3.362	KNN	3
0.028	1.264	1.855	3.440	Tree	4
-5.943	4.585	4.956	24.565	SVM	5

استخدام تقنيات التنبؤ في البيانات الضخمة لاكتشاف الأنماط التعليمية
بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

يتضح من جدول (٥) أنّ خوارزمية Linear Regression هي الأفضل لتصنيف درجات الطلبة تليها خوارزمية Random Forest، ثمّ خوارزمية KNN ثمّ خوارزمية Tree، ثمّ خوارزمية SVM. وقد كانت درجات التنبؤ وفق هذه الخوارزميات كما بالشكل الآتي:

	Linear Regression	SVM	Tree	Random Forest	kNN	Total AC	Midterms	Final
1	28.96140	23.38...	28.88...	28.90869	28.80...	50	20.00	?
2	28.42301	23.37...	28.72...	28.62488	28.20...	49	19.00	?
3	27.88461	23.34...	28.50...	28.26575	28.40...	48	18.00	?
4	27.60376	22.67...	26.90...	26.40723	26.10...	44	19.00	?
5	28.96140	23.38...	28.88...	28.90869	28.80...	50	20.00	?
6	28.79755	23.22...	28.82...	28.75578	26.40...	49	20.00	?
7	28.63370	23.03...	28.19...	28.26572	27.60...	48	20.00	?
8	27.46321	23.61...	29.00...	27.56833	28.80...	50	16.00	?
9	28.21231	23.56...	29.03...	29.01913	28.80...	50	18.00	?
10	28.63370	23.03...	28.19...	28.26572	27.60...	48	20.00	?
11	28.96140	23.38...	28.88...	28.90869	28.80...	50	20.00	?
12	28.63370	23.03...	28.19...	28.26572	27.60...	48	20.00	?
13	24.63094	23.61...	26.08...	24.26310	26.00...	35	15.00	?
14	28.96140	23.38...	28.88...	28.90869	28.80...	50	20.00	?
15	28.79755	23.22...	28.82...	28.75578	26.40...	49	20.00	?
16	28.96140	23.38...	28.88...	28.90869	28.80...	50	20.00	?
17	28.96140	23.38...	28.88...	28.90869	28.80...	50	20.00	?
18	26.08228	23.67...	27.00...	27.36664	27.10...	37	18.00	?
19	28.79755	23.22...	28.82...	28.75578	26.40...	49	20.00	?

وقد أمكن التوصل إلى معادلة التنبؤ بالصورة الآتية:

$$\text{درجة الطالب النهائية (Final)} = \text{درجة الطالب في الأنشطة الفصلية (ACTI)} \times 0,164 + \text{درجة الطالب في الاختبار الفصلي (Midterms)} \times 0,375 + 13,278$$

مما سبق يتضح أنّ كلاً من درجات الطلبة في الأنشطة الفصلية، والاختبار الفصلي

تؤخذ في الاعتبار عند التنبؤ بدرجات الطلبة النهائية، وإن كانت مساهمة درجات الاختبار الفصلي أكبر من درجات الأنشطة في التنبؤ بدرجاتهم النهائية.

٣- بالنسبة لمقرّر (١٣ اسلم) كانت النتائج بالشكل الآتي:

تمّ استخدام خوارزميات Linear Regression، SVM، Tree، Random Forest،

KNN. وذلك للتنبؤ ببيانات الطلاب وكانت النتائج وفق جدول (٦).

جدول (٦) نتائج خوارزميات الطلاب في مقرّر (١٣ اسلم)

R ²	MAE	RMSE	MSE	Model	N
0.254	1.151	1.589	2.526	Linear Regression	1
0.201	1.187	1.645	2.705	Random Forest	2
0.192	1.196	1.655	2.738	Tree	3
0.129	1.242	1.718	2.951	KNN	4
-3.735	3.702	4.005	16.037	SVM	5

من جدول (٦) أنّ خوارزمية Linear Regression هي الأفضل لتصنيف درجات الطلبة تليها خوارزمية Random Forest، ثمّ خوارزمية Tree ثمّ خوارزمية KNN، ثمّ خوارزمية SVM. وقد كانت درجات التنبؤ بالتحصيل الدراسي لطلبة جامعة الملك خالد وفق هذه الخوارزميات كما بالشكل التالي:

	Linear Regression	SVM	Tree	Random Forest	kNN	Total AC	Midterms	Final	
1	28	23	28		28	29	50	19	?
2	27	23	27		27	27	49	17	?
3	29	23	29		29	29	50	20	?
4	29	23	29		29	29	50	20	?
5	29	23	29		29	29	50	20	?
6	29	23	29		29	29	50	20	?
7	29	23	29		29	29	50	20	?
8	28	23	28		28	29	50	19	?
9	27	23	28		28	28	50	18	?
10	29	23	28		27	28	49	20	?
11	29	23	29		29	29	50	20	?
12	29	23	29		29	29	50	20	?
13	29	23	29		29	29	50	20	?
14	29	23	29		29	29	50	20	?
15	29	23	29		29	29	50	20	?
16	29	23	29		29	29	50	20	?
17	29	23	29		29	29	50	20	?
18	29	23	29		29	29	50	20	?
19	29	23	29		29	29	50	20	?

وقد أمكن التوصل إلى معادلة التنبؤ بالصورة الآتية:

$$\text{درجة الطالب النهائية (Final)} = \text{درجة الطالب في الأنشطة الفصلية (ACTI)} \times 0,113 + \text{درجة الطالب في الاختبار الفصلي (Midterms)} \times 0,761 + 8,137$$

مما سبق يتضح أنّ كلاً من درجات الطلبة في الأنشطة الفصلية، والاختبار الفصلي تؤخذ في الاعتبار عند التنبؤ بدرجاتهم النهائية، وإن كانت مساهمة درجات الاختبار الفصلي أكبر من درجات الأنشطة في التنبؤ بدرجات الطلاب النهائية.

٤- بالنسبة لمقرّر (٢٠٢٢عرب) كانت النتائج بالشكل الآتي:

تمّ استخدام خوارزميات Linear Regression، SVM، Tree، Random Forest، KNN. وذلك للتنبؤ ببيانات الطلاب وكانت النتائج وفق جدول (٧).

جدول (٧) نتائج خوارزميات الطلاب في مقرّر (٢٠٢٢عرب)

R ²	MAE	RMSE	MSE	Model	N
0.146	0.668	0.878	0.771	Linear Regression	1
0.003	0.703	0.949	0.900	KNN	4
-0.0006	0.701	0.953	0.908	Tree	3
-0.007	0.706	0.953	0.909	Random Forest	2
-2.108	1.475	1.675	2.806	SVM	5

استخدامُ تقنيات التنبؤ في البيانات الضخمة لاكتشاف الأنماط التعليمية
بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

يُتضح من جدول (٧) أنّ خوارزمية Linear Regression هي الأفضل لتصنيف درجات الطلبة تليها خوارزمية KNN، ثمّ خوارزمية Tree ثمّ خوارزمية Random Forest، ثمّ خوارزمية SVM. وقد كانت درجات التنبؤ بالتحصيل الدراسي وفق هذه الخوارزميات كما بالشكل الآتي:

	Linear Regression	SVM	Tree	Random Forest	kNN	Total AC	Midterms	Final
1	19	18	19	19	19	59	20	?
2	19	18	19	19	19	60	20	?
3	19	18	19	19	19	59	20	?
4	18	18	19	19	18	55	18	?
5	17	18	18	16	15	42	20	?
6	19	18	19	19	19	59	20	?
7	19	18	19	19	19	59	20	?
8	19	18	19	19	20	58	20	?
9	19	18	19	19	20	60	20	?
10	19	18	19	19	19	59	20	?
11	19	18	19	19	20	60	20	?
12	19	18	19	19	19	59	20	?
13	19	18	19	19	20	60	20	?
14	19	18	19	19	20	60	20	?
15	19	18	19	19	20	60	20	?
16	19	18	19	19	19	57	20	?
17	19	18	19	19	19	56	20	?
18	19	18	19	19	19	59	20	?
19	19	18	19	19	19	59	20	?

وقد أمكن التوصل إلى معادلة التنبؤ بالصورة الآتية:

درجة الطالب النهائية (Final) = درجة الطالب في الأنشطة الفصلية (ACTI) $\times 0,147 +$

درجة الطالب في الاختبار الفصلي (Midterms) $\times 0,186 + 6,897$

مما سبق يتضح أنّ كلاً من درجات الطلبة في الأنشطة الفصلية، والاختبار الفصلي تؤخذ في الاعتبار عند التنبؤ بالتحصيل الدراسي لطلبة جامعة الملك خالد، وأنّ مساهمة درجات الاختبار الفصلي أكبر من درجات الأنشطة في التنبؤ بدرجات الطلبة النهائية.

٣- إجابة السؤال الثالث الذي نصّ على:

ما العلاقة الارتباطية بين الأنماط التعليمية السائدة في المقررات الإلكترونية (١١ اسلم،

١٢ اسلم، ١٣ اسلم، ٢٠٢٠ عرب) ومستوى تحصيل طلبة جامعة الملك خالد؟

وللإجابة عن هذا السؤال، تمّ إيجاد معامل ارتباط بيرسون بين درجات الطلاب في الأنماط التعليمية السائدة في المقررات الإلكترونية (١١ اسلم، ١٢ اسلم، ١٣ اسلم، ٢٠٢٠ عرب) ودرجاتهم في التحصيل الدراسي ووجد أنه يساوي (٠.٨٤) وهو معامل ارتباط قوى، يوضح أنّ تصميم المقررات الإلكترونية في نظام إدارة التعلم في جامعة الملك خالد يراعي الأنماط التعليمية

للطالبة عند تصميم هذه المقررات، ومن ثم أثر ذلك وبصورة إيجابية على تحصيلهم الدراسي وتتفق هذه النتيجة مع دراسة أبو صالح، الطراونة (٢٠٢١).

مناقشة نتائج البحث:

هدف البحث إلى تحليل البيانات التعليمية لطلبة جامعة الملك خالد في المقررات الإلكترونية التي يدرسونها كاملاً عبر نظام إدارة التعلّم Blackboard (مقرر ١١ اسلم، ١٢ اسلم، ١٣ اسلم، ٢٠٢٠ عرب). من أجل اكتشاف الأنماط السائدة في بيانات الطلبة، والتنبؤ بالتحصيل الدراسي لهم، ومساعدة متخذي القرار في اتخاذ القرارات التطويرية الفعّالة.

وكذلك هدف البحث إلى تقديم بعض الخوارزميات Linear Regression, Random Forest, KNN, Tree, SVM, K-Means المستخدمة في التّقيب في البيانات من خلال تقنية Orange من أجل المساعدة في تطوير المقررات الإلكترونية التي يتمّ تقديمها من خلال إدارة التعلّم الإلكتروني Blackboard بصورة كاملة. وقد حاول البحث الإجابة عن الأسئلة الآتية:

أولاً- ما الأنماط التعليمية السائدة في مقررات (١١ اسلم، ١٢ اسلم، ١٣ اسلم، ٢٠٢٠ عرب) التي تؤثر على تحصيل طلبة جامعة الملك خالد ويمكن اكتشافها باستخدام خوارزميات التّقيب في البيانات من خلال برنامج "Orange"؟

١- للإجابة عن هذا السؤال تمّ استخدام تقنية (K-Means) عبر برنامج (Orange) وقد تمّ التّوصل إلى أنّ درجات الطلبة في مقرر (١١ اسلم) تنحصر في ثلاث طبقات رئيسة هي: الطبقة الأولى وهي الأكثرية في درجات الطّلاب وتنحصر درجاتهم في المدى من (١٨ إلى ٢٠) في درجات الاختبار الفصلي يناظرها درجات (٢٨-٣٠) في الاختبار النهائي. أمّا الطبقة الثانية فتتصدر درجات الطلبة في المدى (١٤-١٧) ويناظرها في الاختبار النهائي (٢٨-٣٠) أمّا الطبقة الثالثة وعددها قليل هي القليلة في عدد درجات الطّلاب فتتصدر في المدى (١٢-١٤) في الاختبار الفصلي ويناظرها في الاختبار النهائي (٢٤-٢٦) وهي تمثل عددًا قليلاً للغاية من الطلبة في هذا المقرر.

٢- أما بالنسبة لمقرر (١٢ اسلم) فقد تمّ كذلك استخدام تقنية (K-Means) عبر برنامج (Orange) وقد تمّ التّوصل إلى أنّ درجات الطلبة في هذا المقرّر تنحصر في ثلاث طبقات متداخلة: فالطبقة الأولى في درجات الطلبة تنحصر درجاتهم في المدى من (١٩ إلى ٢٠) في درجات الاختبار الفصلي ويناظرها درجات (٢٨-٣٠) في الاختبار النهائي. وتتداخل مع الطبقة الثانية التي جاءت درجات الطّلاب فيها في المدى (١٨-٢٠) ويناظرها في الاختبار النهائي (٢٤-٢٨)، أمّا الطبقة الثالثة فهي طبقة متداخلة مع الطبقة

- الأولى والثانية ولكن بدرجة قليلة حيث إن درجات الطلبة تنحصر في المدى (١٤-١٨) في الاختبار الفصلي ويناظرها في الاختبار النهائي (١٧-٣٠).
- ٣- بالنسبة لمقرر (١٣ اسلم) فقد تمّ كذلك استخدام تقنية (K-Means) عبر برنامج (Orange) وتم التوصل إلى أن درجات الطلبة في هذه المادة تنحصر في ثلاث طبقات متداخلة: فالطبقة الأولى تنحصر درجاتهم في المدى من (١٩ إلى ٢٠) في درجات الاختبار الفصلي ويناظرها درجات (٢٧-٣٠) في الاختبار النهائي. أمّا الطبقة الثانية فتتصرّ درجاتهم في المدى (١٧-٢٠) ويناظرها في الاختبار النهائي (٢٧-٣٠) وهي طبقة متداخلة مع الطبقة الأولى، أمّا الطبقة الثالثة فهي طبقة متداخلة مع الطبقة الأولى والثانية ولكن بدرجة أقل حيث إن درجات الطلبة تنحصر في المدى (١٢-١٦) في الاختبار الفصلي ويناظرها في الاختبار النهائي (١٦-٢٩).
- ٤- بالنسبة لمقرر (٢٠٢عرب) تمّ استخدام تقنية (K-Means) عبر برنامج (Orange) وقد تمّ التوصل إلى أن درجات الطلبة متداخلة في ثلاث طبقات: الأولى تنحصر درجاتها في المدى من (١٩ إلى ٢٠) في درجات الاختبار الفصلي ويناظرها درجات (١٧-٢٠) في الاختبار النهائي والتي درجته النهائية (٢٠). أمّا الطبقة الثانية وأكثر درجات الطلبة يتمركز في هذه الطبقة وتنحصر درجات هذه الطبقة في المدى (١٨-١٩) ويناظرها في الاختبار النهائي (١٦-٢٠) وهي طبقة متداخلة بدرجة قليلة مع الطبقة الأولى، أمّا الطبقة الثالثة وهي طبقة متداخلة مع الطبقة الثانية ولكن بدرجة أقل فإن درجات الطلبة تنحصر في المدى (١٣-١٧) في الاختبار الفصلي ويناظرها في الاختبار النهائي (١٩-٢٠).
- وقد يرجع ذلك إلى أن طبيعة أنشطة الطلبة في مقررات (١١ اسلم، ١٢ اسلم، ١٣ اسلم، ٢٠٢عرب) ساعدت على انتقال الطلبة من الحالة السلبية إلى الحالة الإيجابية والتعلم النشط التشاركي والتفاعل مع بعضهم البعض، وكذلك ارتباط إنجاز الأنشطة بوقت معين من قبل الطلبة، كما أن تصميم أنشطة هذه المقررات تقوم على مبدأ النظرية البنائية الاجتماعية والتفاعل النشط للطلبة مع المعلم، ومع المحتوى في أي وقت وفي أي مكان. كما أن برنامج "Orange" وتقنية "K-Means" ساعد على تجميع بيانات الطلبة وفقاً لخصائصها، وتتفق هذه النتيجة مع نتائج دراسة نايف، وأيوب (٢٠١٦)، ودراسة المبارك (٢٠١٧).
- ثانياً: ما أفضل الخوارزميات التي يمكن استخدامها للتنبؤ بالتحصيل الأكاديمي لطلبة جامعة الملك خالد في مقررات (١١ اسلم، ١٢ اسلم، ١٣ اسلم، ٢٠٢عرب) من خلال برنامج "Orange"؟

- للإجابة عن هذا السؤال تمّ استخدام خوارزميات Tree، SVM، Linear Regression، KNN، Random Forest عبر برنامج أو تقنية (Orange) وتمّ التّوصّل إلى الآتي:
- ١- بالنسبة لمقرر (١١ اسلم) تمّ التّوصّل إلى أنّ درجات الطلبة في الأنشطة الفصلية، لا تؤثر في التنبؤ بدرجاتهم النهائية في مقرر (١١ اسلم)، بل إنّ درجات الطلبة الفصلية فقط هي التي تؤخذ في الاعتبار للتنبؤ بدرجاتهم النهائية. كما أنّ خوارزمية Random Forest هي الأفضل لتصنيف درجات الطلبة، وأنّ خوارزمية SVM هي الأقل في التنبؤ بدرجات الطلبة. وقد يرجع اعتماداً معادلة التنبؤ على الاختبارات الفصلية فقط، إلى سهولة الأنشطة الفصلية في هذا المقرر، وضعف تصميمها وكذلك فإنّ الاختبار الفصلي اختبار مبنى وفق أسس بناء الاختبارات، ممّا أدى ذلك إلى ظهور هذا الاختبار في معادلة التنبؤ لدرجات الطلبة النهائية.
 - ٢- بالنسبة لمقرر (١٢ اسلم) تمّ التّوصّل إلى أنّ درجات الطلبة في الأنشطة الفصلية، والاختبار الفصلي يمكن من خلالهما التنبؤ بدرجات الطلبة في الاختبارات النهائية، وأنّ مساهمة درجات الاختبار الفصلي أكبر من درجات الأنشطة في التنبؤ. كما أنّ خوارزمية Linear Regression هي الأفضل لتصنيف درجات الطلبة، وأنّ خوارزمية SVM هي الأقل في التنبؤ بالتحصيل الدراسي لطلبة الجامعة.
 - ٣- بالنسبة لمقرر (١٣ اسلم) تمّ التّوصّل إلى أنّ درجات الطلبة في الأنشطة الفصلية، والاختبار الفصلي يمكن من خلالهما التنبؤ بدرجات الطلبة في الاختبارات النهائية، وأنّ مساهمة درجات الاختبار الفصلي أكبر من درجات الأنشطة في التنبؤ. كما أنّ خوارزمية Linear Regression هي الأفضل لتصنيف درجات الطلبة، تليها خوارزمية Random Forest، وأنّ خوارزمية SVM هي الأقل في التنبؤ بدرجات الطلبة.
 - ٤- بالنسبة لمقرر (٢٠٢ عرب) تمّ التّوصّل إلى أنّ درجات الطلبة في الأنشطة الفصلية، والاختبار الفصلي يمكن من خلالهما التنبؤ بدرجات الطلبة في الاختبارات النهائية، وأنّ مساهمة درجات الاختبار الفصلي أكبر من درجات الأنشطة في التنبؤ. كما أنّ خوارزمية Linear Regression هي الأفضل لتصنيف درجات الطلبة، تليها خوارزمية KNN، وأنّ خوارزمية SVM هي الأقل في التنبؤ بدرجات الطلبة.
- وقد يرجع ذلك إلى أنّ خوارزمية Linear Regression لها قدرة كبيرة على استبعاد المتغيرات غير المؤثرة وغير المرغوبة في عملية التنبؤ، وقد يرجع ذلك أيضاً إلى طبيعة البيانات في الأنشطة والاختبارات الفصلية أنّها بيانات ممثلة للمجتمع، كما أنّ تصميم هذه الأنشطة

والاختبارات كان بصورة علمية دقيقة. وتتفق هذه النتيجة مع نتائج دراسة كل (Bum, Iorliam, 2019 & Okube)، ودراسة عبد الله (٢٠٢٠).

ثالثاً: ما العلاقة الارتباطية بين الأنماط التعليمية السائدة في المقررات الإلكترونية (١١١ اسلم، ١١٢ اسلم، ١١٣ اسلم، ٢٠٢٠ عرب) ومستوى تحصيل طلبة جامعة الملك خالد؟ وللإجابة عن هذا السؤال، تم إيجاد معامل ارتباط بيرسون بين درجات الطلاب في الأنماط التعليمية السائدة في المقررات الإلكترونية (١١١ اسلم، ١١٢ اسلم، ١١٣ اسلم، ٢٠٢٠ عرب) ودرجاتهم في التحصيل الدراسي وتم التوصل إلى الآتي:

- ١- يوجد ارتباط قوى بين الأنماط التعليمية في المقررات الإلكترونية المصممة على أنظمة إدارة التعلم الإلكتروني (Blackboard) ومستوى تحصيل الطلاب.
- ٢- وقد يرجع ذلك إلى أن نظام إدارة التعلم Blackboard يتضمن أدوات كثيرة منها الخاص بالنصوص فقط، ومنها الخاص بالوسائط المتعددة التفاعلية، ومنها الخاص بالتسجيلات الصوتية، ومنها الخاص بالرسومات التوضيحية، ومنها الخاص بالتفاعل والتشارك مع الآخرين في أي مكان وفي أي زمان، كذلك منها الخاص بالمعايير العالمية للتعلم الإلكتروني ومن أهمها معايير SCORM, Tin Can.
- ٣- كذلك يتيح نظام إدارة التعلم Blackboard للمتعلمين التعلم في أي مكان وفي أي زمان. فبعض الطلاب يفضل التعلم في الفترة الصباحية والبعض الآخر يفضل الفترة المسائية، وبالتالي ساعد هذا النظام طلاب جامعة الملك خالد على تحصيلهم الدراسي، نظراً لأنه يتيح أنماط كثيرة لتعلم الطلاب.
- ٤- يتيح نظام إدارة التعلم Blackboard حرية للنقاش وتبادل الأفكار والحصول على المعلومات من مصادر إلكترونية متنوعة ومتعددة.
- ٥- كذلك تتبنى جامعة الملك خالد المعايير العالمية لتصميم المقررات وهي معايير Quality Matters (QM) وهي معايير تختص بجودة المقررات الإلكترونية.

توصيات البحث:

١. بناء على نتائج البحث الحالية يمكن التوصية بالآتي:
ضرورة تدريب أعضاء هيئة التدريس على برنامج أو تقنية (Orange) للتقيب في البيانات التعليمية.
٢. ضرورة الاهتمام بتبني خوارزمية K-Means لاكتشاف الأنماط التي تؤثر على التحصيل الأكاديمي للطلبة.

٣. ضرورة الاهتمام بتبني خوارزمية Linear Regression عند التنبؤ بالتحصيل الدراسي لطلبة الجامعة.
٤. ضرورة الاهتمام بتطبيق تقنيات التنقيب في البيانات الضخمة وخوارزمياته على مقررات إلكترونية أو غير إلكترونية أكثر من المقررات الحالية.
٥. ضرورة الاهتمام بدمج تطبيق (Orange) للتنقيب في البيانات التعليمية في أنظمة إدارة التعلم الإلكتروني (LMS) لتوجيه الطلبة في أثناء عملية التعلم والتنبؤ بأدائهم بصورة مستمرة.

بحوثٌ مقترحة:

- في ضوء نتائج البحث، يمكن اقتراح بعض البحوث الآتية:
١. المقارنة بين تقنية (Orange) وتقنية (Weka) لاكتشاف الأنماط التعليمية والتنبؤ بالتحصيل الدراسي لطلبة الجامعة.
 ٢. استخدام تقنية (Orange) للتحليل الدلالي للصور والمشاعر، والتنبؤ بالتحصيل الدراسي لطلبة الجامعة.
 ٣. استخدام تقنية (Orange) للتعامل مع الروك، وخوارزميات تعلم الآلة ROC Analysis and ML algorithms
 ٤. استخدام تقنية (Orange) التنبؤ بالتحصيل الدراسي لطلبة الجامعة من خلال خوارزمية (Logistic regression).
 ٥. استخدام تقنيات الذكاء الاصطناعي لتنمية مهارات أعضاء هيئة التدريس لمعالجة البيانات الضخمة في المقررات الإلكترونية واتخاذ القرار.

المراجع

- إبراهيم، محمود أحمد. (٢٠١٧). نمط التغذية الراجعة القائمة على التحليلات التعليمية بيئة تعلم إلكترونية لتنمية مهارات إنتاج المواقع الإلكترونية والتنظيم الذاتي لدى تلاميذ الحلقة الابتدائية. مجلة تكنولوجيا التربية- دراسات وبحوث، ٣٣ (١)، ٧٥-١.
- أبو صالح، فاديا، والطراونة، ردينة. (٢٠٢١). أنماط التعلم وعلاقتها بالاتجاهات نحو المباحث العلمية لدى طلبة مدارس الملك عبد الله الثاني للتميز. مجلة دراسات. ٤٨ (٤)، ٤٨٠-٤٩٨.
- أبو قرون، مظاهر عبد الرحمن، حجازي، محمد عثمان. (٢٠١٨). مقارنة خوارزميات تتقيب البيانات التعليمية لدعم القرار في مؤسسات التعليم العالي السودانية حالة دراسية - أداء الطلاب بكلية علوم الحاسوب وتقانة المعلومات - جامعة الزعيم الأزهرى [رسالة دكتوراه غير منشورة]، جامعة النيلين.
- أحمد، أحمد عبد المطلب، عبد الله، محمد حسن. (٢٠١٨). تتقيب البيانات التعليمية باستخدام خوارزمية (Apriori) لتقييم أداء الطلاب وتحسين الإنتاج، مجلة النيل الأبيض للدراسات والبحوث، ١ (١١)، ٩-٣٦.
- الأكلبي، على ديب. (٢٠١٨). أهمية تحليل البيانات الضخمة في اتخاذ القرار في جامعة الملك سعود. البيانات الضخمة وآفاق استثمارها: الطريق نحو التكامل المعرفي، المؤتمر الرابع والعشرون، جمعية المكتبات المتخصصة، ١-١٦.
- الأكلبي، على ذيب. (٢٠١٨). البيانات الضخمة واتخاذ القرار في جامعة الملك سعود: دراسة تقييمية لنظام إنقان. كيو ساينس QSCINCE، ١ (٢)، ١-١٢.
- البار، عدنان مصطفى. (٢٠١٨). البيانات الضخمة ومجالات تطبيقاتها. كلية الحاسبات وتقنية المعلومات، جامعة الملك عبد العزيز: كلية الحاسبات وتقنية المعلومات.
- بيتلر، هوارد، هبل، إيزابيث روس، كوهن، مات. (٢٠١٨). توظيف التقنية في التدريس الصفي الناجح (سوس مستو، مترجم). مكتبة العبيكان.
- الجهنى، ليلي سعيد. (٢٠١٧). كفاءة التعليم الإلكتروني في ضوء التحليل البعدي لنتائج الدراسات المنشورة في الدوريات العربية خلال ٢٠٠٥ إلى ٢٠١٥. المجلة الدولية التربوية المتخصصة، ٦ (٧)، ١٧-٣٣.
- حسين، العلوانى. (٢٠١٦). إدارة البيانات في عصر التحول الوطني. شركة علم.
- خميس، محمد عطية. (٢٠٢٠). اتجاهات حديثة في تكنولوجيا التعليم ومجالات البحث فيها. المركز الأكاديمي للنشر والتوزيع.

الزعبي، إبراهيم. (٢٠١٨). التنبؤ بجنس وعمر الزبون في شركات الاتصالات الخليوية ضمن بيئة البيانات الكبيرة [رسالة ماجستير غير منشورة]، المعهد العالي للعلوم التطبيقية والتكنولوجيا.

زهير، عمار ياسر. (٢٠١٦). دور أنظمة الذكاء الاصطناعي في التنبؤ بالجريمة. مجلة الفكر الشرطي، ٢٨ (١١٠)، ٥٩-١٣٣.

سايمون، فيل. (٢٠٢٠). البيانات الضخمة من المنظور التجاري (عاطف محمد العمري، مبروك صالح الرخمي، مترجم). دار جامعة الملك سعود.

سيد، أحمد فايز. (٢٠١٦). أدوات التقيب عن البيانات مفتوحة المصدر - دراسة تحليلية تقييمية. مجلة جامعة طيبة، ١٠ (١)، ٧٩١-٨٦٥.

الشرمان، عاطف أبو حميد. (٢٠١٩). تصميم التعليم للمحتوى الرقمي. دار المسيرة للنشر والتوزيع. عبد الله، أبو بكر محمد مصطفى. (٢٠٢٠). تقيب بيانات طلاب المرحلة الأساسية للتنبؤ بدرجاتهم في مادة الرياضيات [رسالة ماجستير غير منشورة]، جامعة أفريقيا العالمية.

عبد الله، سلوى. (٢٠٢١). الذكاء الاصطناعي. مداد للنشر والتوزيع. عثمان، عبد الرحمن. (٢٠١٧). تعلم هادوب. جامعة أم القرى: كلية الحاسب بـقنفة.

عطار، عبد الله إسحاق، كفساره، إحسان محمد. (٢٠١٥). الكائنات التعليمية وتكنولوجيا النانو. كلية التربية: جامعة أم القرى.

فلوريد، لوتشيانو. (٢٠١٧). ثورة المعلومات الرابعة - كيف يغير الفضاء الإلكتروني واقعنا البشري. مؤسسة محمد راشد آل مكتوم للمعرفة.

قيراطي، هناء. (٢٠١٧). توظيف البيانات الضخمة في الشركات التقنية وخصوصية المستخدم [رسالة ماجستير غير منشورة]، جامعة ٨ ماي.

الكعبي، سليمان. (٢٠١٨). موسوعة استشراف المستقبل. دار قنديل للطباعة والنشر والتوزيع. كيتشن، روب. (٢٠١٨). ثورة البيانات - البيانات الكبيرة والبيانات المفتوحة والبنى التحتية للبيانات (محمد أحمد

غروي، مترجم). معهد الإدارة العامة. المبارك، سعد البدوي المبارك. (٢٠١٧). استخدام تقنيات تقيب البيانات لاكتشاف أنماك

مؤثرات التحصيل الأكاديمي لطلاب المرحلة الثانوية [رسالة ماجستير غير منشورة]. جامعة النيلين.

محمد، مالك خالد. (٢٠١٨). إطار عمل قائم على تحليلات التعلّم للبيانات الضخمة في نظم إدارة التعلّم لتطوير تصميم المقررات التعليمية الإلكترونية وإنتاجها. دراسات تربوية

واجتماعية، ٢٤ (٤)، ٤٢٦-٣٤٣.

استخدام تقنيات التنقيب في البيانات الضخمة لاكتشاف الأنماط التعليمية
بالمقررات الإلكترونية عبر نظام إدارة التعلم والتنبؤ بالتحصيل الدراسي لطلاب الجامعة

- المطيري، عبد الله. (٢٠١٧). البيانات الضخمة وحلم النظرية الكبرى. *مجلة الفيصل العلمية*، السنة ٥٤، ٥٥ (١)، ٣٣-٣٨.
- مقناني، صبرينه، شبيلة، مقدم. (٢٠١٩). دور البيانات الضخمة في دعم التنمية المستدامة بالدول العربية، *مجلة دراسات المعلومات والتكنولوجيا*، ١ (٤)، ١-١٤.
- مليك، محمودي، وصباح، زروخي. (٢٠١٧). تقنية التنقيب في البيانات كأداة مساعدة في اتخاذ القرارات. *الملتقى الدولي حول التحول الرقمي للمؤسسات والنماذج التنبؤية على المعطيات الكبيرة*، ١٢-١٣ نوفمبر، ١-١١.
- موسي، عبد الله، وبلال، أحمد حبيب. (٢٠١٩). *النكاء الاصطناعي ثورة في تقنيات العصر*. المجموعة العربية للتدريب والنشر.
- ناصر، ريم جمال. (٢٠١٩). *استخدام تقنيات التنقيب في البيانات في التعلّم* [رسالة ماجستير غير منشورة]، جامعة البعث.
- نايف، قتيبة نبيل، وأبوب، محي الدين خلف. (٢٠١٦). استخدام خوارزمية (K-Means) للعقدة في تنقيب البيانات (Data Mining) مع واقع تطبيقي. *مجلة العلوم الاقتصادية والإدارية*، ٢٢ (٩١)، ٣٨٩-٤٠٦.
- النويصر، خالد بن رشيد. (٢٠٢١). *مهارات القرن الحادي والعشرين-التعليم وتحديات العصر الرقمي*. دار تكوين للطباعة والنشر.
- هلال، محمد عبد الحكيم. (٢٠٢١). تصور مقترح لدور تنقيب البيانات في صنع القرار المستتير بمؤسسات التعليم العالي في مصر. *مجلة كلية التربية جامعة عين شمس*، ٣ (٤٥)، ٩٠-١٥.
- يوسف، نورس كاظم. (٢٠١٦). هل تؤثر البيانات الديموغرافية على تخرج الطالب؟: دراسة تحليلية باستخدام تنقيب البيانات. *مجلة العلوم الإنسانية والعلمية والاجتماعي*، ١ (١)، ٢٣٨-٢٦٥.
- Adam, k., Bakar, N.A. (2018). Big data and learning Analytics: A Big potential to improve e-learning. *American Scientific Publishers*, 24(10), 7838-7843.
- Bum, S., Iorliam, I.B., & Okube, E.O. (2019). Prediction of students' academic using liner regression. *Nigerian Annals of Pure and Applied Science*. 2(1), 259-264.
- Hilbert, M. (2016). Big data for development: A review of promises and challenges. *Development Policy Review*, 34(1), 135-174.

- Horst, R. M. (2020). Higher Education Executives and Data-Driven Decision Making- A Phenomenological Study [Unpublished PhD thesis], Concordia University.
https://digitalcommons.csp.edu/cgi/viewcontent.cgi?article=1435&context=cup_commons_grad_edd
- Kandlhofer, M., Steinbauer, G. (2018). Evaluating the impact of educational robotics on pupils' technical-and social-skills and science related attitudes. *Journal of Robotics and Autonomous System*. 75(1), 679-685.
<https://doi.org/10.1016/j.robot.2015.09.007>
- Koksal, G., Batmaz, I., & Testik, M. C. (2011). A review of data mining applications for quality improvement in manufacturing industry. *Expert Systems with Applications*, 38(10), 13448-13467.
- Lerche, T., Kiel, E. (2018). Predicting student achievement in learning management systems by log data analysis, *Computers in Human Behavior*, 89(1), 367-372. Available: <https://doi.org/10.1016/j.chb.2018.06.015>.
- Mohi, Z.R. (2020). Orange Data Mining as a tool to compare Classification Algorithms. *Dijlah Journal of Sciences and Engineering*, 3(3). 13-23.
- Mwalumbwe, I. & Mtebe, J., S. (2017). Using Learning Analytics to Predict Students' Performance in Moodle Learning Management System: A Case of Mbeya University of Science and Technology. *The Electronic Journal of Information Systems in Developing Countries*, 79(1), 1-13.
- Rostami, K. H., Samadi, S., Omrani, H., Margavi, A. K., Asadzadeh, H., & Nazari, H. (2011). Data Mining and Application in Accounting and Auditing. *Journal of Education and Vocational Research*, 2(6), 211 - 215.
- Sharma, A. & Panigrahi, P. K. (2012). A review of financial accounting fraud detection based on Data Mining techniques. *International Journal of Computer Applications*, 39(1), 37-47.
- Sinha, S.K. & Singh, H. (2019). Significance of Big Data and Analytics of Student Success in Higher Education, *A Monthly Journal of Computer Science and Information Technology*, 8(11), 7– 12.
- Tarmizi, S. S. A., Mutali, S., Hamid, N. & Rahman, S. (2019): A Review On Student Attrition In Higher Education Using Big Data Analytics And Data Mining Techniques, *Modern Education And Computer Science*, 11(8) 1-14. <https://www.mecs-press.org/ijmecs/ijmecs-v11-n8/IJMECS-V11-N8-1.pdf>
- Walsh, P. (2015). Evaluating the data analytic features of Blackboard Learn 9.1. *Irish Journal of Academic Practice*, 4(1), 1-35.
- Xinpeng, W.C, Yinglai Liu, Y.,Xiao, Y. Chen, B., Liu, H and Zhoy, S. (2020). Analysis of University Students' Behavior Based on a Fusion K-Means Clustering Algorithm. *Applied Sciences International*, 10(18), 2-18.
<https://doi.org/10.3390/app10186566>