

## توظيف الذكاء الاصطناعي في تنقيب البيانات التعليمية للتنبؤ بالأداء الأكاديمي للطلاب الجامعي

ذكرى علي علي حمود نعيم<sup>1</sup>، وردمان محمد سعيد<sup>2</sup>

1. أستاذ مساعد، قسم الرياضيات، كلية التربية - جامعة صنعاء

2. أستاذ تربويات الرياضيات، كلية التربية - جامعة صنعاء

### ملخص البحث:

وقد أُستخدمت في البحث خمس تقنيات؛ لاختيار الميزات؛ لتحديد الميزات الأكثر صلة بالميزات التي تم جمعها في مجموعة البيانات. وبعد ذلك تم تحديد أفضل مصنف لمجموعة البيانات. ووضح البحث أن التنبؤ بالأداء الأكاديمي يُمكن كلاً من الأكاديميين والطلبة من الاكتشاف المبكر للطلبة الذين يحتاجون إلى اهتمام خاص في إجراء التدخل المناسب. إضافة إلى أنه يُمكن أعضاء هيئة التدريس من معرفة قدرة كل طالب، وتخصيص مهام التدريس بناءً على احتياجات الطلبة. وأوصى البحث هيئة التدريس استخدام EDM في التنبؤ بالأداء الأكاديمي للطلبة، والاستفادة من ذلك في تخصيص خبرات تعلم الطلبة بناءً على احتياجاتهم المختلفة. الكلمات المفتاحية: تنقيب البيانات التعليمية، التنبؤ بالأداء الأكاديمي، الذكاء الاصطناعي، خوارزميات تعلم الآلة WEKA.

يُعدّ توفير تعليم عالي الجودة للطلبة أحد الأهداف الرئيسية لمؤسسات التعليم العالي. ويمكن أن يتحقق ذلك عن طريق التنبؤ بالأداء الأكاديمي للطلاب الجامعي باستخدام التنقيب في البيانات التعليمية (EDM). حيث هدف البحث إلى التنبؤ بالأداء الأكاديمي للطلبة، وتطوير أدائهم في مرحلة مبكرة. وتم جمع البيانات المستخدمة في هذا البحث من سجلات الطلبة في قسم الرياضيات بكلية التربية - جامعة صنعاء للأعوام (2008-2016م)، واعتمد البحث منهجية CRISP-DM للتنقيب عن البيانات. واستخدمت النمذجة كأداة للبحث لتعلم الآلي (WEKA). كما استخدم ستة خوارزميات تصنيف في تنقيب البيانات؛ لتحديد الخوارزمية الأفضل في نمذجة البيانات، وخمسة مقاييس للتقييم وفي نهاية عملية النمذجة وجد أن خوارزمية الانحدار اللوجستي LR هو أفضل مصنف لمجموعة البيانات.



## Applying Artificial Intelligent in Educational Data Mining for Predicting Academic Performance for University Student's

Thikra Ali Ali Humood Nae'em<sup>1</sup> & Radman Mohamed Saeed<sup>2</sup>

1. Associated professor, Mathematics Department, Faculty of Education - Sana'a University

2. Prof. of Mathematical Education, Faculty of Education - Sana'a University

### Abstract:

Providing high-quality education to students is one of the main goals of higher education institutions. Predicting a university student's academic performance, can be achieved using educational data mining (EDM). The research aimed to predict academic performance of students and develop their performance at an early stage. The data used in this research were collected from the students' records in-Mathematics Department in the faculty of Education at Sana'a University for the years (2008-2016). The research adopted the CRISP-DM methodology for data mining. Modeling was used as a machine learning research tool by WEKA. And Six classification algorithms were used in the data mining to select the algorithm that produces the best model for the data. And five metrics of evaluation, At the end of the modelling process, the research found the logistic regression as the best classifier for the dataset.

In this research five feature selection techniques were used; to select the most relevant features out of the features gathered in the dataset, Having identified the best classifier for the dataset.

The research showed that prediction of academic performance enables both academics and students to detect early students who need special attention in order to conduct appropriate intervention. Moreover, instructors can be aware of each student's capability and customize the teaching tasks based on students' needs. The research would recommend instructors to consider using EDM in predicting students' academic performance and benefit from that in customizing students' learning experience based on their different needs.

**Keywords:** Educational Data Mining, Prediction of academic performance, Artificial Intelligence, WEKA Machine Learning Algorithms.

## القسم (1): الإطار العام للبحث

### 1. مقدمة:

يُعدّ الهدف الأساسي والرئيس للجامعات هو تحسين جودة التعليم، ورفع مستوى الأداء الأكاديمي للطلبة، لذلك لا يمكن القول إن التعلم قد حدث إلا إذا تم تقييم المتعلمين بشكل صحيح؛ لأنه يعدّ تطويراً لحالة الطالب الأكاديمية، وجانباً حاسماً ومهماً في كل مؤسسة تعليمية (Solomon et al., 2018).

وبالتالي، فإن تنقيب البيانات التعليمية (EDM) يعد مجالاً بحثياً متنامياً يساعد المؤسسات الأكاديمية على تحسين أداء طلابها. وغالباً ما يتم التقييم من المؤسسات الأكاديمية حسب الدرجات التي حققتها الطلبة في الامتحانات، لكن تنقيب البيانات التعليمية (EDM) يقدم ممارسات مختلفة للتنبؤ بالأداء الأكاديمي للطلبة (Zaffar et al., 2018).

ولتحقيق الهدف الرئيس في الجامعات يجب أن يتم التركيز على أداء الطالب طيلة السنوات الدراسية، وقد سهلت تكنولوجيا المعلومات تخزين كميات كبيرة من البيانات في أشكال مختلفة، مما أدى إلى زيادة حجم قاعدة البيانات التعليمية. ومع وجود الكثير من البيانات الموجودة المخزنة في ما يسمى بقواعد البيانات، حيث شكك العديد من الباحثين في استخدام تخزين البيانات، وأصبح من

الضروري العثور على التقنيات والأساليب والوسائل المناسبة لتنقيب المعلومات، والإثارة والمعرفة من مثل هذه البيانات المكسدة واستغلالها في حل المشكلات واتخاذ القرار، باستخدام تطبيقات الحاسوب الحديثة وهي تقنية حديثة ذكية تجعل الحاسوب يفكر كما يفكر ويفعل الإنسان، وهو ما يعرف بالذكاء الاصطناعي، وفكرة الكشف والتنقيب في البيانات بطرق ذكية للمساعدة في حل المشكلات واتخاذ القرار، وتنقيب البيانات هو عمليات عالمية تمزج بين الذكاء الاصطناعي والإحصاءات وتعليم الآلة وقواعد البيانات، وهي خطوة لاستكشاف المعرفة الخفية من قواعد البيانات (Ali, 2019).

في ضوء ذلك، يتناول البحث الحالي ظاهرة الأداء الأكاديمي المنخفض من خلال النظر في سمات الطلبة ذوي الأداء المنخفض في جامعة صنعاء. وهنا لا توجد على حد علمنا أبحاث ودراسات سابقة تشير إلى أن هذه الكلية لديها نظام، أو نموذج إدارة المعلومات لتحديد الأداء المنخفض، أو لتحسين أداء الطلبة. ومن ثم، فإن هذا البحث قد يكون بمثابة أساس يمكن للباحثين مستقبلاً البناء عليه في إنشاء نظام أكثر كفاءة وفاعلية لتحديد الطلبة المعرضين لخطر الفشل أو التسرب في وقت مبكر.

## 2. مشكلة البحث وأهدافه:

• تحديد العوامل المؤثرة في التنبؤ بالأداء الأكاديمي للطلبة المعرضين للخطر ذوي التدخل لكل من مجموعة بيانات برنامج الإعداد باستخدام خوارزميات الذكاء الاصطناعي للتعقيب عن البيانات التعليمية.

• تحديد أفضل نموذج مصنف من بين المصنفات الستة المشتركة التي تم اختيارها من مجموعة بيانات برنامج الإعداد باستخدام خوارزميات الذكاء الاصطناعي للتعقيب عن البيانات التعليمية من خلال:

✓ مقارنة أداء التنبؤ لنماذج المصنفات المختارة على مجموعة البيانات من حيث أعداد الطلبة المصنفين بشكل صحيح والذين تم تصنيفهم بشكل غير صحيح.

✓ مقارنة أداء التنبؤ لنماذج المصنفات المختارة باستخدام مقاييس التقييم الخمسة المختارة.

• تحديد المجموعة الفرعية المثلى للميزات من العدد الإجمالي للميزات لمجموعة بيانات برنامج الإعداد باستخدام خوارزميات الذكاء الاصطناعي للتعقيب عن البيانات التعليمية من خلال:

✓ تحديد أكثر الميزات تنبؤية من القوائم الخمس المختارة التي تم تصنيفها باستخدام خوارزميات الترتيب والأفضلية.

تتمثل مشكلة البحث في الصعوبات التي تواجه تقييم الأداء الأكاديمي حالياً بمؤسسات التعليم العالي والبحث العلمي في الجمهورية اليمنية، حيث نجد أن الطرق الإحصائية التقليدية المستخدمة في تقييم البيانات الضخمة تتصف بعدم الدقة، ولا يمكن الاعتماد عليها لعدم تمكنها من تحليل بيانات مؤسسة تعليمية لديها كم هائل من البيانات. وهذا الكم الهائل من البيانات رغم ثرائه بالمعرفة لم يتم استغلاله حتى الآن بشكل فعال في معرفة عوامل نجاح وفشل الطالب في أدائه وتحصيله، ومعرفة التنبؤ بالأداء الأكاديمي للطلاب الجامعي بالطريقة الشاملة التي تحسن من أداء المؤسسة التعليمية. وإضافة إلى ذلك، فإن السياسات المصممة لتحسين أداء الطلبة لا تعمل في البلد بشكل يحد من التسرب، وتحتاج المؤسسات التعليمية اليمنية إلى الاستفادة من تطوير النماذج باستخدام تقنيات التعلم الآلي للتدخل وتحسين أداء الطلبة. لذا يُعدّ التنبؤ بالأداء الأكاديمي للطلاب الجامعي عاملاً رئيساً بالنسبة للمؤسسة التعليمية، ويهدف البحث الحالي إلى:

• معرفة إمكانية التنبؤ بالأداء الأكاديمي للطلاب الجامعي في مرحلة مبكرة من برنامج الإعداد.

البيانات الناقصة للطلبة التي تكون فعالة في استنتاج العديد من الأنماط والعلاقات بين العوامل المؤثرة على التحصيل الأكاديمي.

• قد تسهم نتائج تنقيب البيانات التعليمية (EDM) في اكتشاف أنماط جديدة غير متوقعة، ومعرفة عملية تعلم الطلبة، بحيث يمكن للمرء التحقق من صحة وتقييم بعض جوانب النظام التعليمي بهدف تحسين نوعية التعليم.

• قد تساعد نتائج البحث في ملء الفراغ العملي في التعليم لدعم تطوير نماذج تنبؤية أكثر تطوراً. سيكون ذلك قابلاً للاستخدام من قبل الباحثين كنهج لضمان عمل أنظمة التحسين للإنذار المبكر Early Warning Systems (EWS) في المستقبل على النحو الأمثل. كما أنها أيضاً فرصة للممارسين للاستفادة من المعرفة الجديدة عن الطلبة المعرضين للخطر، واختبار التدخلات على العديد من المستويات في محاولة لتحسين نتائج التخرج.

#### 4. حدود البحث:

ينحصر إجراء هذا البحث ضمن الحدود الآتية:

■ **الحدود الموضوعية:** توظيف الذكاء الاصطناعي وخوارزمياته (التصنيف، التنبؤ والوصف) باستخدام التعلم الآلي (Weka) والتنقيب في البيانات التعليمية الأكاديمية المخزنة في قاعدة البيانات دون البيانات المالية والديمغرافية لعدم توافرها في القاعدة.

✓ تحديد الميزات المثلى التي تحقق أعلى أداء تنبؤي لنماذج التصنيف المختارة في مجموعة البيانات.

• تقديم نموذج تنبؤي يسهل عملية التنقيب في البيانات التعليمية، حيث يتم التنبؤ بالأداء الأكاديمي للطلبة ذوي التدخل العالي في المؤسسة التعليمية كلية التربية - جامعة صنعاء.

### 3. أهمية البحث:

وتتمثل أهمية البحث في الآتي:

• قد تسهم نتائج البحث في بناء قاعدة معرفية لصناع القرار في قسم الرياضيات والكلية بشكل عام في إعطاء مؤشرات لإعداد وتأهيل أعضاء هيئة التدريس حسب ما يقتضيه العصر، وإعادة النظر في تطوير المقررات الدراسية من حيث مخرجاتها وأهدافها التعليمية وأساليب التقويم للأداء الأكاديمي، واستخدام إستراتيجيات وطرق حديثة في تعليم وتعلم الرياضيات.

• قد تسهم نتائج تنقيب البيانات التعليمية (EDM) في قواعد بيانات النظم التعليمية في فهم كيفية تعليم وتعلم الطلبة، ومعرفة أساليب تعلمهم بشكل أكثر شمولية في محاولة لتصميم سياسات تعليمية من شأنها أن تحسن من أدائهم الأكاديمي، وتقلل من معدلات الفشل في نهاية كل عام دراسي، وتحديث البيانات، واستكمال

كالتفكير، والتعلم والابتكار، والتخاطب من خلال مجموعة من الخوارزميات المعيّنة، ولديه القدرة على التعلم الآلي، وتمثيل وفهم المعرفة، والقدرة على تحليل اللغة وغيرها، ومن خلال ما تتميز به هذه البرامج من قدرات القيام على استنتاج النتائج المعرفية المختلفة، والتعلم من الأخطاء من خلال التدريب المسبق في البيانات، مما يجعلها تؤدي مهامها بسرعة ومهارة ودقة فائقة (محمد ومحمد، 2020م).

#### • التنقيب في البيانات التعليمية ( Educational Data Mining)

ويعرف التنقيب في البيانات (Data Mining) بأنه أداة متقدمة لتحليل البيانات تركز على النمذجة واكتشاف المعرفة لأغراض تنبؤية، يستخدم تقنيات حسابية من الإحصائيات والتعلم الآلي، والتعرف على الأنماط لتحليل مجموعات البيانات الكبيرة أو قواعد البيانات (Ayenew, 2018).

ويعرّف التنقيب في البيانات التعليمية (EDM): بأنه نظام حديث المنشأ، يهتم بتطوير طرق لاستكشاف الأنواع الفريدة من البيانات التي تأتي من البيئة التعليمية، واستخدام هذه الأساليب في فهم الطلبة بشكل أفضل، وهي تمثل عملية تحليل البيانات من منظورات مختلفة، واستخلاص علاقات بينها وتلخيصها إلى معلومات مفيدة، ويمكن أن تحول إلى معرفة حول الأنماط المؤثرة أو التوقعات والتنبؤات المستقبلية في حدوث ظاهرة معينة، وتساعد

■ **الحدود المكانية:** كلية التربية جامعة صنعاء قسم مناهج الرياضيات وطرائق تدريسها.

■ **الحدود البشرية:** طلبة البكالوريوس قسم مناهج الرياضيات وطرائق تدريسها، كلية التربية-جامعة صنعاء، خلال الأعوام 2008-2016م؛ لتوافرها إلى حدّ ما، ولصعوبة التنبؤ بعد هذه الأعوام نتيجة الظروف الراهنة التي أثرت على مستوى الأداء التدريسي، ومن ثم الأداء الأكاديمي لدى الطلبة.

#### 5. مجتمع البحث وعينه:

يتكون مجتمع البحث من جميع بيانات الطلبة الأكاديمية والبيانات السابقة (معدل الثانوية العامة) في كلية التربية-جامعة صنعاء المخزنة في قاعدة البيانات، وعينة البحث هي جميع بيانات الطلبة الأكاديمية والسابقة (معدل الثانوية العامة) التي يتراوح عمرها من 2008-2016م لجميع مستويات طلبة البكالوريوس قسم مناهج الرياضيات وطرائق تدريسها في كلية التربية-جامعة صنعاء، وعددهم 741 طالباً وطالبة. وتم تفصيل ذلك في منهجية البحث وإجراءاتها.

#### 6. مصطلحات البحث:

سيتم توضيح المصطلحات الآتية:

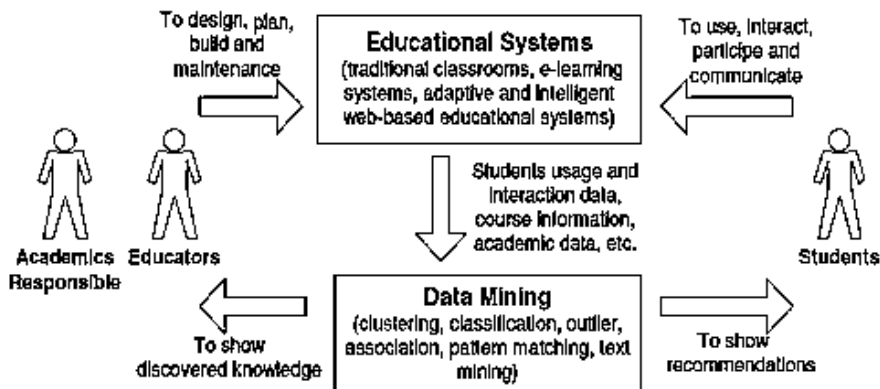
#### • **الذكاء الاصطناعي (Artificial Intelligence)**

يُعرّف الذكاء الاصطناعي على أنه ذلك العلم الذي يجعل الآلة تتصرف بطريقة محاكاة العقل البشري، وهو عبارة عن برامج حاسوبية طوّرت لكي تعمل عمل وظائف الإنسان،

مفيدة غير معروفة سابقاً من قاعدة البيانات التعليمية لفهم وتحسين أداء التعليم بشكل أفضل، وتقييم عملية تعلم الطلبة ( Ayenew, 2018). وعرفت الجمعية الدولية لتنقيب البيانات التعليمية أن "EDM هو تخصص ناشئ، يهتم بتطوير طرق لاستكشاف الأنواع الفريدة من البيانات التي تأتي من الإعدادات التعليمية، واستخدام هذه الأساليب لفهم الطلبة بشكل أفضل، والإعدادات التي يتعلمون فيها" (Siemens & Baker, 2012, P. 12).

#### • دورة التنقيب في البيانات التعليمية (EDM)

إن تطبيق تقنيات التنقيب في البيانات في النظم التعليمية هو سلسلة تكرارية لبناء الفرضيات والاختبار والتحسين. ويوضح الرسم البياني في الشكل (1) تكرارات تطبيق التنقيب في البيانات في الأنظمة التعليمية (دورة EDM) التي يجب أن تساعد المعرفة المكتسبة من عملية التنقيب في اتخاذ القرار من خلال العودة إلى دورة نظام التحسين (Romero & Ventura, 2007).



الشكل (1): دورة التنقيب في البيانات التعليمية مقتبس من (Romero & Ventura, 2007).

المعرفة في اتخاذ القرار المناسب ( Mohamada & Tasir, 2013).

#### • التنبؤ بالأداء الأكاديمي ( Academic Performance Prediction)

##### Performance Prediction

ويعرّف التنبؤ بأنه يُعدّ من الأدوات التي تجذب الانتباه، لأنها تتمكن من إعطاء مغزى التوقع الناجح في سياق العمل، لذا فإنه يمكن النظر إلى العديد من تطبيقات تنقيب بيانات العالم الحقيقي كأنها تنبؤ بحالة بيانات مستقبلية معتمدة على بيانات سابقة وحالية (الحسين، 2017م).

ويعرّف الأداء الأكاديمي: بأنه نشاط يُمكن الدارسين والدارسات من إنجاز المهام أو الأهداف والمخرجات المقصودة بنجاح، وبالأستخدام الأمثل والمعقول للإمكانات والموارد البشرية والمعنوية (قمر وآخرون، 2017م).

#### القسم (2): الخلفية النظرية والدراسات

##### ذات الصلة

#### 1. تنقيب البيانات التعليمية ( Educational Data Mining) (EDM)

يعد التنقيب في البيانات التعليمية (EDM) مجالاً بحثياً مثيراً للاهتمام يستخلص أنماطاً

لمراجعة إستراتيجياتهم من أجل أداء أفضل في الفصول اللاحقة.

لذلك فإن التنبؤ بأداء الطلبة يُعدّ أمرًا بالغ الأهمية لأي مؤسسة تعليمية تهدف إلى تحسين أداء الطلبة وعملية التعلم الخاصة بهم، وبناءً على مخرجات التنبؤ، يمكن للمؤسسة التعليمية دعم أولئك الذين تم تحديدهم على أنهم طلبة ذوو أداء منخفض. وعلى الرغم من أن التنبؤ بأداء الطلبة تتم دراسته على نطاق واسع، فإنه لا يزال يمثل تحديًا وعملية معقدة؛ لأن أداء الطلبة يتأثر بسمات وعوامل وخصائص مختلفة مثل الخصائص الديموغرافية، والاجتماعية، والأكاديمية، والاقتصادية، والصحية، والنفسية وغيرها من السمات البيئية (Yassein et al., 2017). والبحث الحالي يُسهم في التعرف على هذه السمات أو الميزات ومعرفة تأثيرها على أداء الطلبة، وملاحظة الطلبة المعرضين للخطر في وقت مبكر من العملية التعليمية لتفادي الهدر التعليمي والأكاديمي للموارد البشرية والمادية لدى المؤسسة التعليمية.

وعملت الدراسات (Asif et al., 2015; Asif

Jimenez et al., 2017; (b) et al., 2020) حول

التنبؤ بأداء الطلبة في نهاية الدراسة الجامعية في

مرحلة مبكرة من برنامج الحصول على الشهادة

الأكاديمية، من أجل مساعدة الجامعات ليس فقط

من خلال الشكل أعلاه وضح Ekubo

دورة (2020) EDM) للمعلمين والأكاديميين

المسؤولين عن تصميم، وتخطيط، وبناء،

وصيانة الأنظمة التعليمية أثناء تفاعل الطلبة

مع النظام، وباستخدام تقنيات تنقيب البيانات،

مثل التصنيف والتجميع والتنقيب عن قواعد

الارتباط مع جميع المعلومات الموجودة حول

الطلبة، والمقررات الدراسية، والتفاعلات داخل

النظام، ومن الممكن اكتشاف معلومات قيمة

يمكن أن تحسن الأنظمة التعليمية، وتساعد

الطلبة على الأداء بشكل أفضل. ويمكن أن

تساعد المعرفة من هذه العملية الطلبة من

خلال تحسين إمكانية الوصول إلى أنظمة

التوصية، وبالتالي، يمكن للأكاديميين مراقبة

تعلم الطلبة بشكل فعال، وتقييم هيكل دراسة

المقررات، ويمكن للمسؤولين تحسين فعالية

الأنظمة التعليمية وجعلها مرنة للمستخدمين.

## 2. التنبؤ بالأداء الأكاديمي للطلبة (Predicting

### Students' Academic Performance)

الأداء الأكاديمي للطلبة Students'

Academic Performance (SAP) يُعدّ

مقياسًا مهمًا في تحديد حالة الطلبة في أي

مؤسسة تعليمية، ويسمح لأساتذة ومسؤولي

التعليم الآخرين بالحصول على تقييم دقيق

للطلبة في مقررات دراسية مختلفة في فصل

دراسي معين، كما أنه بمثابة مؤشر للطلبة



أشكال الذكاء، وهو سلوك وخصائص معينة تتسم بها البرامج الحاسوبية وتجعلها تحاكي القدرات الذهنية البشرية، وأنماط عملها وتعلمها، ومن أهم هذه الخصائص القدرة على التعلم، والاستنتاج، والتقييم، ورد الفعل على أوضاع لم تبرمج من قبل آلة التعلم. وينتمي الذكاء الاصطناعي إلى الجيل الحديث من أجيال الحاسب الآلي (موسى وبلال، 2019م).

ومن المجالات والجوانب الرئيسة اللازمة لإتقان التنقيب في البيانات، أدوات وآلات تتفرع من الذكاء الاصطناعي منها التعلم الآلي وهذا ما تم استخدامه في البحث الحالي:

التعلم الآلي هو فرع من فروع الذكاء الاصطناعي الذي يشير إلى منح الآلات القدرة على التعلم واتخاذ القرار بالاعتماد على نفسها دون الحاجة إلى برمجتها من قبل الإنسان، بحيث يمكنها التعلم من الإجراءات السابقة، وتخزين البيانات للاستفادة منها والتحسين من أدائها في أي عمل مستقبلي (مجدي، 2020م). ومن طرق التعلم الآلي: التعلم الخاضع للإشراف، والتعلم غير الخاضع للإشراف، والتعلم شبه الإشرافي، والتعلم المعزز. وسنأخذ في الاعتبار النوعين الرئيسيين في هذا البحث وهما التعلم الخاضع للإشراف، وغير الخاضع للإشراف:

في التركيز بشكل أكبر على الطلبة الأذكياء ولكن أيضاً لتحديد الطلبة ذوي الإنجاز الأكاديمي المنخفض في البداية وإيجاد طرق لدعمهم، وأظهرت النتائج أنه من الممكن التنبؤ بأداء التخرج في السنة الرابعة من الجامعة باستخدام فقط درجات مقررات السنتين الأولى والثانية ودرجات ما قبل الجامعة، بدون استخدام عوامل أو ميزات اجتماعية أو اقتصادية أو ديموغرافية، بدقة معقولة. وإضافة إلى ذلك، تم تحديد الدورات التي تعد مؤشرات للأداء الجيد أو الضعيف بشكل خاص، مما يشير إلى أن الملاءمة الرئيسة للبيانات الاجتماعية والاقتصادية والديموغرافية تكمن في التنبؤ بنتائج مقررات السنة الأولى والثانية.

ومع ذلك، يبدو أن دراسة (Machado & Curado, 2006) تتناقض مع أعمال (Asif (b) (et al., 2015 & 2017) من خلال إظهار العلاقة بين الوضع الاقتصادي والثقافي للطلبة ونجاحهم الأكاديمي، والذي يبدو أنه أصبح أقوى مع تقدم مساهمهم الأكاديمي.

### 3. الذكاء الاصطناعي وخوارزميات التنقيب في البيانات التعليمية

#### • الذكاء الاصطناعي (AI) Artificial Intelligence

يعني الذكاء الاصطناعي أشياء مختلفة لأناس مختلفين وليس فقط مرادفاً لشكل من

## • خوارزميات التصنيف والتنبؤ (Classification)

### (and Prediction Algorithms)

يُعدّ أسلوب التصنيف نهجاً منظماً لبناء نماذج التصنيف من خلال قاعدة بيانات المدخلات. ومن الأمثلة المستخدمة في البحث الحالي من الخوارزميات:

## ■ تصنيف خوارزمية شجرة القرار (J48) (J48)

### (Decision Tree Classification)

خوارزمية شجرة القرار J48 هي تطبيق الجافا لخوارزمية C4.5 في أداة النمذجة WEKA، وهذه الخوارزمية كانت امتداداً وخلفاً لـ ID3، C4.0 التي طورته Quinlan Ross (Ali, 2019). ويؤكد الهدف أن J48 دقيقة وسريعة في بناء النماذج، ويتم تقديم النتائج بطريقة سهلة الفهم (Bhullar & Kaur, 2012). وتحسب الخوارزمية نسبة الكسب (Gain Ratio) لكل ميزة وبعد ذلك تنشئ شجرة قرارات (Yadav & Pal, 2012)، ويتم إنشاء الشجرة باستخدام الميزة مع نسبة الكسب القصوى كعقدة الجذر، ويستخدم التقليم لإزالة الفروع غير الضرورية. ونسبة الكسب هي مقياس يعتمد على (Claude Shannon) نظرية المعلومات، ويتم استخدامه في كل عقدة اختبار لتحديد الميزة التي تقدم أفضل نتائج تقسيم. ولشرح كيفية حساب نسبة الكسب، نبدأ بإيجاد قيمة مقياس النقاء يسمى المعلومات، ويُعرف

## ■ التعلم الخاضع للإشراف: إن التعلم بالإشراف

يكتسب التعلم باستخدام حقيقة، أي لدينا معرفة مسبقة بمخرجات عيناتنا، والغرض هو تعلم الدالة، وأفضل تقدير للعلاقة بين مدخلات ومخرجات لظاهرة في البيانات، ومن الخوارزميات المهمة المستخدمة هي خوارزميات التصنيف والتنبؤ.

## ■ التعلم غير الخاضع للإشراف: إن التعلم

بدون الإشراف لا توجد فيه مخرجات معنونة. وبالتالي، فإن الهدف هو استنتاج البنية الطبيعية لمجموعة من نقاط البيانات، واكتشاف الأنماط دون أي توجيه، ومن الخوارزميات المهمة المستخدمة فيه خوارزميات الوصف، وهي العنقدة، وقواعد الارتباط (وزان (ب)، 2022م).

## • مهام التنقيب في البيانات (Data Mining)


### (Tasks)

ويلبي التنقيب في البيانات هدفه الرئيس من خلال وصف الارتباطات والأنماط المفيدة التي يمكن فهمها بسهولة في البيانات المتاحة، ويمكن تحقيق هذا الهدف من التنقيب في البيانات عن طريق النمذجة إما التنبؤية ويشار إلى هذا النوع من النماذج أحياناً باسم التعلم الخاضع للإشراف أو المهام الوصفية ويشار إلى النماذج الوصفية أيضاً بالتعلم غير الخاضع للإشراف (Umer, 2019).

المعدل التراكمي للطلاب خلال الفصول الأربعة الأولى، وعدد الدورات الفاشلة خلال الفصول الأربعة الأولى، ودرجات ثلاثة مقررات أساسية. وكان أداء مصنف Naïve Bayes أفضل من النماذج المستندة إلى الشجرة في توقع التحصيل الدراسي للطلبة بشكل عام.

### ■ تصنيف خوارزمية الانحدار اللوجستي (Logistic Regression Classification):

نموذج خوارزمية الانحدار اللوجستي (LR) هو احتمالية وقوع حدث كمجموعة من المتغيرات التنبؤية، وهو الأفضل للمهام ذات القيم الفئوية للفئة الثنائية (Mgala, 2016). ويتمثل الاختلاف الرئيسي بين الانحدار الخطي الشائع والانحدار اللوجستي في أن نموذج الانحدار الخطي ينتج مخرجاته كقيمة مستمرة ممثلة كخط مستقيم على الرسم البياني، بينما يلائم نموذج الانحدار اللوجستي كمنحنى على الرسم البياني كما في الشكل (2)، ويعطي نتيجته قيمة ثنائية التفرع (Han et al., 2011).



الشكل (2): مخطط للدالة اللوجستية (السينية)  $\sigma(z)$ .

أيضاً باسم الإنترنت، ويتم قياسه بالبيئات (Han et al., 2011).

في دراسة (Hoque et al., 2020) استخدمت ثلاث خوارزميات تصنيف من أشجار القرار (J48؛ Hoeffding Tree؛ REPT Tree)، ووجد أن شجرة القرار J48 حققت أعلى دقة تنبؤية بنسبة (85.65%) من الخوارزميات الأخرى، وذلك لتطوير نظام تحليل نتائج الطلبة الجامعيين والتنبؤ عن طريق خوارزمية شجرة القرار.

### ■ تصنيف البايزي البسيط (Naïve Bayesian Simple Classification)


يستخدم المصنف Naïve Bayesian قاعدة Bayes لحساب احتمالية كل قيمة محتملة لميزة الهدف، مثل معرض للخطر، غير معرض للخطر (Tan et al., 2019). في دراسة (Alturki & Alturki, 2021) تمثلت أحد الأهداف الرئيسية لمؤسسات التعليم العالي في توفير تعليم عالي الجودة لطلابها وتقليل معدلات التسرب، ويمكن تحقيق ذلك من خلال توقع التحصيل الدراسي للطلبة مبكراً باستخدام التنقيب في البيانات التعليمية (EDM). وهدفت هذه الدراسة إلى توقع الدرجات النهائية للطلبة، وتحديد الطلبة المتفوقين في مرحلة مبكرة، وأظهرت النتائج أن الميزات الرئيسية التي يمكن أن تتنبأ بالتحصيل الأكاديمي للطلبة هي

بيانات متوازنة تضم أكثر من 32500 طالب مع الانحدار اللوجستي يوفر أقوى تنبؤ.

### ■ تصنيف خوارزمية الإدراك المتعدد الطبقات

#### (Multi-layer Perceptron) MLP

تقوم الشبكة العصبية متعددة الطبقات بتعميم المفهوم الأساسي للمدرك الحسي إلى بنى أكثر تعقيداً للعقد القادرة على تعلم حدود القرار غير الخطي. وتظهر بنية عامة لشبكة عصبية متعددة الطبقات في الشكل (3) حيث يتم ترتيب العقد في مجموعات تسمى الطبقات (Tan et al., 2019).



الشكل (3): تخطيط لمعلمات نموذج MLP مع (L-1) من الطبقات المخفية.

الشخصية، وخصائص ما قبل الجامعة، والأداء الجامعي، وتتضمن مجموعة البيانات المستخدمة في الدراسة بيانات حول الطلاب المقبولين في الجامعة في ثلاث سنوات متتالية. ويتم تطبيق العديد من خوارزميات تصنيف التنقيب في البيانات المعروفة، بما في ذلك استقراء القواعد (OneR Rule Learner)،

في دراسة (Aulck et al., 2016) قام بنمذجة الطلبة المتسربين باستخدام البيانات التي تم جمعها من قواعد بيانات المسجل في جامعة واشنطن في الولايات المتحدة الأمريكية، وتحتوي مجموعة البيانات على 32538 من بيانات الطلبة، وتطبيق خوارزميات الانحدار اللوجستي، والجار الأقرب-K، والغابة العشوائية للتنبؤ بالتسرب الثنائي في الميزات، مثل العرق، والنوع، وحالة المقيمين، والمعدل التراكمي، وما إلى ذلك بإجمالي 784 ميزة إضافية. وتشير نتائجهم إلى أن التنبؤ بتناقص الطلبة في نهاية المطاف من مجموعة

وفي دراسة (Kabakchieva, 2012) الهدف الرئيس الكشف عن الإمكانيات العالية لتطبيقات التنقيب في البيانات لإدارة الجامعة والمساهمة في حملات تسجيل جامعية أكثر كفاءة واستقطاب الطلبة الأكثر رواجاً. وتركز الدراسة على تطوير نماذج التنقيب في البيانات للتنبؤ بأداء الطلبة، بناءً على خصائصهم

وفي دراسة (Ayenew, 2018) أظهرت البيانات الإحصائية أن هناك فجوة كبيرة وتحديات في جودة التعليم من حيث المساهمة المهنية في التنمية، والكفاءة الفردية، وبشكل أكثر تحديداً في أداء الطلبة. وكان هدف الدراسة تحديد العوامل المحددة لجودة التعليم، وأخذ المجال 8520 بيانات تقييم أداء المدارس الابتدائية والثانوية بمنطقة أمهرة للأعوام 2006-2008م، وتم تطبيق شجرة قرار J48، وخوارزمية استقراء القاعدة JRip باستخدام أداة تنقيب البيانات WEKA لبناء نماذج مختلفة تحدد العوامل الأكثر تحديداً لجودة التعليم. وبعد المعالجة المسبقة، وبعد إزالة بعض السجلات تم استخدام إجمالي 8514 سجلاً لبناء النماذج وإجراء التجارب للتوصل إلى مخرجات ذات معنى. وتم تحديد العوامل الرئيسية للتعليم الجيد وإنشاء القواعد باستخدام أشجار قرار J48، وخوارزمية الاستقراء لقاعدة JRip بدقة 84.67% و 84.80% على التوالي. وأظهرت مقارنة النماذج باستخدام أداة النمذجة WEKA أن خوارزمية JRip تتفوق على خوارزمية J48. وشملت العوامل الأكثر تحديداً لجودة التعليم التي حددتها خوارزمية JRip ما يلي: مرافق التعلم التعليمية، والكفاءة المالية للتحسين، والمشاركة الطلابية، وأداء تقديم التعليم


ومصنف شجرة القرار (DT)، والشبكة العصبية (NN)، ومصنف الجار الأقرب (NN-K)، على مجموعة البيانات. وتم تحليل ومقارنة أداء هذه الخوارزميات لنماذج التصنيف، وكشفت النتائج أن دقة التصنيف بين 67.46%-73.59%. وتم تحقيق أعلى دقة لنموذج الشبكة العصبية (73.59%)، ويتنبأ نموذج الشبكة العصبية بدرجة عالية من الدقة بفئة "الممتاز"، بينما تؤدي النماذج الثلاثة الأخرى أداءً أفضل للفئة "الضعيفة". وتعد ميزات البيانات المتعلقة بدرجة قبول الطلبة بالجامعة، وعدد حالات الفشل في امتحانات السنة الأولى بالجامعة من بين العوامل التي تؤثر على معظم عمليات التصنيف.

#### ■ تصنيف خوارزمية JRip من استقراء

#### القاعدة ( Classification of the JRi ) (algorithm from base induction)

تعدّ هذه الخوارزمية واحدة من الخوارزميات الأساسية والأكثر شهرة، ويتم استخدام مجموعة من القواعد في زيادة الحجم لفحص الفئات، ويتم إنشاء مجموعة أولية من القواعد لكل فئة باستخدام JRip (RIPPER) مع تقليل الأخطاء تدريجياً عن طريق التعامل مع جميع سجلات قرار خاص في بيانات التدريب كفئات، حيث يتم تقييمها بترتيب تصاعدي (Aubaid & Mishra, 2020).

SVM من بين أفضل خوارزميات التعلم الخاضعة للإشراف، ويعتقد الكثيرون أنها الأفضل بالفعل، ويستخدم لمهام التصنيف، عبر البحث عن المستوى الفائق الذي يحقق أقصى استفادة من الهامش الموجود في الفئتين كما هو موضح في الشكل (4)، وهذه الخوارزمية مخصصة لمهام التصنيف حيث تكون الفئة المستهدفة ثنائية التفرع وهذا ما يتناسب مع بيانات البحث الحالي (Ng, 2012; Ekubo, 2020).



الشكل (4): بنية تصنيف آلة متجه الدعم SVM.

دروس الرياضيات واللغة البرتغالية. وتطبق الخوارزمية المقترحة في المقام الأول تحويل الدرجات إلى الدرجات الطبيعية، وتحويل درجة z الطبيعية في مرحلة ما قبل المعالجة لحل مشكلة التوزيع غير المتوازن للفئة. وبعد ذلك، تم تنفيذ عمليات اختيار الميزة باستخدام الخوارزمية الجينية. وتم تقدير نجاح الطلبة في دروس الرياضيات واللغة البرتغالية من خلال

للمعلمين، واتجاهات وميول الطلبة ودافعيتهم نحو التعلم، والمسؤولية والسلوك.

#### ■ تصنيفات آلة متجه الدعم (Support Vector Machines Classifiers)

آلة متجه الدعم (SVM) هي نموذج تصنيف تمييزي يتعلم حدود القرارات الخطية أو غير الخطية في مساحة السمة لفصل الفئات. بصرف النظر عن تعظيم إمكانية الفصل بين الفئتين، يوفر SVM إمكانات تنظيم قوية، أي أنه قادر على التحكم في تعقيد النموذج لضمان أداء التعميم الجيد، وتعد

ودراسة (Begum & Padmanavar, 2022) ذكرت أن التنقيب في البيانات التعليمية هو الجانب الرئيس لتحسين أداء الطلبة في التعليم، ويمكن التنبؤ بالأداء الأكاديمي للطلبة أو المدرسين باستخدام التقنيات والخوارزميات في تنقيب البيانات التعليمية وتنقيب البيانات. واقترحت هذه الدراسة منهج التعلم الآلي للتنبؤ بالأداء الأكاديمي لطلبة المدارس الثانوية في

(Huang, 2015). وهناك إمكانية لوجود عدة مجموعات فرعية محددة بأحجام مختلفة، والمبدأ العام هو تحديد مجموعة فرعية مع عدد أقل من الميزات.

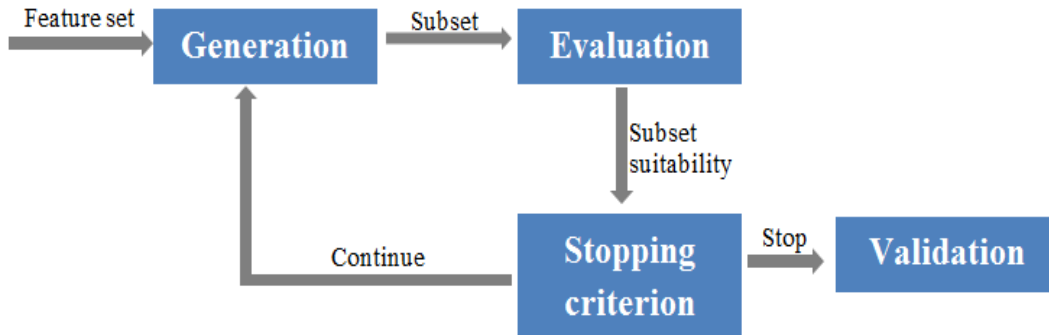
وتتضمن الأساليب الشائعة التي تم استخدامها لاختيار مجموعة الميزات الفرعية التصفية (filters)، والأغلفة (wrappers) (Acharya & Sinha, 2014; Saeys et al., 2007)، وتتبع جميع التقنيات خطوات مماثلة لتحقيق عملية اختيار الميزات، وهناك أربع خطوات في تقييم أفضل الميزات في مجموعة البيانات والتحقق من صحتها، وهذه الخطوات موضحة في الشكل (5).

تصنيفات الجار الأقرب K (KNN) والتحليل التمييزي الخطي (LDA)، وتصنيفات آلة المتجه الداعمة (SVM). وتوصلت النتائج بعد مقارنة مقاييس التقييم بين الخوارزميات إلى أن طريقة SVM هي الطريقة الأكثر ملاءمة لمشكلة التوزيع غير المتوازن للفئة. وتقدم آلة المتجه الداعمة تنبؤاً بنسبة 90.6%، وهو أعلى نسبياً من الخوارزميات الأخرى.

#### 4. اختيار الميزات الفرعية الأمثل (Optimal Feature Subset Selection)

##### ■ تقنية اختيار الميزات (Feature Selection Techniques)

تهدف تقنيات اختيار الميزة إلى تحديد مجموعة فرعية مثالية من الميزات؛ حيث تساهم جميع الميزات في التنبؤ بالفئة المستهدفة



الشكل (5): عملية اختيار الميزات الفرعية المثلى (Harb & Moustafa, 2012).

مجموعة فرعية سابقة، ويتم اعتماد المجموعة الفرعية الجديدة إذا كانت متفوقة على المجموعة السابقة؛ (3) معايير الإيقاف: تنظم النقطة التي قد تنتهي عندها عملية البحث عن أفضل مجموعة فرعية من السمات؛ (4) التحقق من صحة النتائج: يتحقق من خلال ملاحظة

يوضح الشكل (5) خطوات اختيار مجموعة الميزات الأربع المقترحة، وهي: (1) توليد مجموعة فرعية: هي سلسلة من الخطوات التي تولد المجموعات الفرعية التي سيتم تقييمها وفقاً للإجراء المحدد؛ (2) التقييم: يتم تقييم كل مجموعة فرعية ومقارنتها بأفضل

والامتحان النهائي، والوصول إلى التقييم. والمجموعة الفرعية Wrapper-IBK ميزة واحدة فقط هي علامة التخصيص كأهم ميزة.

#### ■ اختيار الميزات الفرعية المثلى ( Optimal Feature Subset Selection)

وفي نهاية مرحلة المعالجة المسبقة، تم تقييم الميزات باستخدام طرق اختيار الميزة، ونتيجة لذلك تم إنشاء مجموعة ميزات تمت تصفيتها لكل مجموعة بيانات، حيث يُعدّ Harb (Harb & Moustafa, 2012) واختيار الميزة أحد الأساليب المهمة المستخدمة بشكل متكرر في المعالجة المسبقة للبيانات لتنقيب البيانات. ومن مهامه أنه يقلل من عدد الميزات، ويزيل البيانات غير ذات الصلة أو الزائدة عن المطلوب أو الصاخبة، وبالتالي يحسن من سمات أداء التنقيب، مثل الدقة التنبؤية، وإمكانية فهم النتائج. حيث تنقسم خوارزميات اختيار الميزات المصممة بمعايير تقييم مختلفة إلى ثلاث فئات هي: نموذج المرشح ( The Filter model)، ونموذج الغلاف ( The Wrapper mode)، والنموذج الهجين ( The Hbrid model). وقد استخدم الباحثان في البحث الحالي أربع طرق تصفية في أداة النمذجة WEKA وهي: مجموعة فرعية تعتمد على الارتباط (CfsSubset)، ونسبة الكسب (GainRatio)، وكسب المعلومات (InfoGain)،

الاختلاف في الأداء الفريد مع المجموعات الفرعية للميزات المختلفة (Harb & Moustafa, 2012; Mgala, 2016; Ekubo, 2020).

وفي دراسة (Alhassan et al., 2020) طبقت ست طرق مختلفة للتصفية والأغلفة على مجموعة بيانات الطالب، وتم تطبيق ثلاث طرق للتصفية تشمل خوارزمية الارتباط (Correlation)، وخوارزمية اكتساب المعلومات (InfoGain)، وخوارزمية مجموعة (CfsSubset) الفرعية المستندة على الارتباط. إضافة إلى ثلاث خوارزميات شائعة للتعلم الآلي في طريقة الأغلفة، وتتضمن Decision Tree (J48) و Naive Bayes (NB) و K-Nearest Neighbor (IBK) والتي تُستخدم لتنفيذ طريقة التجميع. وأظهرت نتائج خوارزميات اختيار الميزات الست هذه أن درجات التقييم هي أهم الميزات التي تؤثر على الأداء الأكاديمي للطلاب. وأعطت خوارزميات مجموعة (CfsSubset) واكتساب المعلومات الترتيب العالي نفسه لست ميزات من 19 ميزة. وأوضحت المجموعات الفرعية التي تم إنتاجها بواسطة طرق التجميع أن خوارزمية Wrapper-J48 تحدد ميزتين هما: علامة المهام، والاختبار النهائي، بينما تتضمن المجموعة الفرعية Wrapper - NB أربع ميزات هي علامة المهام، وأول اختبار نصفي،



الجوهريّة المعروفة أيضاً باسم معلومات التقسيم، والمعلومات التي يتم إنشاؤها عن طريق تقسيم بيانات التدريب إلى عدد محدد من الأقسام التي تتوافق مع عدد نتائج الاختبار على الميزة. والميزة ذات أعلى نسبة كسب تؤخذ كميزة تقسيم، وتعدّ العقدة غير الورقية لشجرة القرار التي تم إنشاؤها من الميزات ذات الصلة (Karegowda et al., 2010).

❖ **التصفية (ReliefF):** Relief هي خوارزمية اختيار الميزة الأصلية، و ReliefF هو تحسين لخوارزمية Relief. وعلى الرغم من أن خوارزمية Relief الأصلية قادرة على تحديد السمات الأكثر ملاءمة، فإنها محدودة عند التعامل مع البيانات غير الكاملة، وقد لا تعمل حيث توجد أكثر من فئتين، نظراً لأن ReliefF هو امتداد لـ Relief، والشكل (6) توضيح لخوارزمية ReliefF.

```

1. set all weights W[A] := 0.0;
2. for i := 1 to m do begin
3.   randomly select an instance R;
4.   find nearest hit H and nearest miss M;
5.   for A := 1 to #all_attributes do
6.     W[A] := W[A] - diff(A,R,H)/m + diff(A,R,M)/m;
7. end;

```

الشكل (6): خوارزمية ReliefF الأساسية.

والهدف من التصفية ReliefF هو اكتشاف تلك السمات التي تختلف قيمها بين الأمثلة القريبة من بعضها البعض، لذلك تجد التصفية لأقرب جوارين: من فئة مماثلة "Nearest hit" ومن فئة أخرى "Nearest

والتصفية (ReliefF) لاختيار أفضل الميزات من مجموعة بيانات الميزات المستخدمة في البحث الحالي وهي:

❖ **كسب المعلومات (IG):** هو مقياس للتغيير في الإنتروبيا بسبب وجود أو عدم وجود سمة (Greven et al., 2014)، وتعدّ طريقة تصنيف شائعة؛ لأنها سريعة وفعالة وبسيطة للغاية، ويقاس التبعية الموجودة بين الميزات والفئات، وتحقيق ذلك عن طريق حساب كسب المعلومات بين الميزة  $A_i$ ,  $i^{th}$  ودرجة الفئة.

ويعكس المقدار الذي ينخفض به إنتروبيا فئة المعلومات الإضافية حول الفئة التي توفرها الميزة ويسمى كسب المعلومات. عبر تعيين درجة لكل ميزة  $A_i$  بناءً على اكتساب المعلومات بينها وبين الفئة (Mgala, 2016). وتعد الميزة ذات صلة إذا كانت لها قيمة عالية في اكتساب المعلومات، وأقل صلة إذا نسبة الكسب (GR): وهي إعادة اكتساب المعلومات، فهي تقلل من انحياز كسب المعلومات نحو السمات متعددة القيم؛ ويؤخذ في الاعتبار عدد وحجم فروع الشجرة أثناء اختيار الصفات، وتستخدم نسبة كسب شجرة القرار C4.5 المعروفة أيضاً باسم خوارزمية J48 في بيئة WEKA (Jantawan & Tsai, 2014). وتُعرف نسبة الكسب للميزة A على أنها كسب المعلومات لـ A مقسوماً على المعلومات

جودة المجموعات الفرعية من الميزات  
بالعلاقة (Anuradha & Velmurugan, 2016):

$$metiS = \frac{K_{Rcf}}{\sqrt{k + (k - 1)rff}} \dots (2.1)$$

واعتمد البحث الحالي نهجاً لتحديد مجموعة الميزات المثلى الفرعية، حيث يتم البحث عن الميزات المثلى من خلال النمذجة المتتالية من مجموعة فرعية محددة إلى الحد الأقصى لعدد من الميزات، حيث استخدمت مجموعة البيانات الكاملة من 569 سَجلاً لبيانات طلبة برنامج النظام (2008-2016م) مع جميع الميزات الـ 15 ميزة للسنة الأولى، و 28 ميزة للسنة الثانية. وتم تحقيق ذلك باستخدام 4 خوارزميات تصفية: خوارزمية (ReliefF) ((RF)، واكتساب المعلومات (IG)، ونسبة الكسب (GR). وخوارزمية واحدة تغليف المجموعة الفرعية IBK - Wrapper في أداة النمذجة WEKA. وذلك لأجل التنبؤ بالأداء الأكاديمي للطلبة.

## 5. التقييم (Evaluation)

التقييم يعد عملية مهمة في بناء نماذج جيدة واختيار أفضل الميزات، وتتضمن طرق تقييم النماذج في التعلم الآلي تقسيم البيانات واختبار التحقق من الصحة K من المرات (K-fold). ويتضمن تقسيم البيانات تقسيم مجموعة البيانات إلى قسمين، الجزء الأول (عينة

miss". تحسب الدالة diff (السمة، والسجل 1، والسجل 2) الفرق بين قيم السمة للحالات، كما تحسب المسافة بين السجلين لتحديد أقرب جوار. وتحدد الأوزان  $W[A]$  جودة السمات، كما هو معروض في الخوارزمية، ويتم تحديث الأوزان للإشارة إلى نفس القيمة للحالات من الفئة نفسها (ب طرح (diff (A; R; H)، ويجب أن تفرق بين المثيلات من الفئات المختلفة (إضافة الفرق (diff (A; R; M). واستخدم البحث الحالي ReliefF بسبب التحسينات المذكورة أعلاه؛ وأيضاً لأنها متاحة بسهولة في بيئة تعلم الآلة (WEK) (Mgala, 2016).

## ❖ مجموعة فرعية تستند على الارتباط

(CfsSubset): يحدد هذا الأسلوب القدرة التنبؤية لكل ميزة. ومع ذلك، يلعب عامل التكرار أيضاً دوراً حاسماً في هذا النهج، وتستخدم خوارزمية CFS ميزة متجانسة في عملية الاختيار جنباً إلى جنب مع خطوات المعالجة المسبقة التقديرية (Zaffar et al., 2018).

وطريقة التصفية المعتمدة على الارتباط CFS تعطي درجات عالية للمجموعات الفرعية التي تتضمن ميزات ترتبط ارتباطاً وثيقاً بسمة الفئة ولكن لها ارتباط منخفض ببعضها البعض، وليكن S مجموعة سمة لها سمات k، و RCf ارتباط السمات بسمة الفئة، و rff الارتباط البيني بين السمات، ويمكن حساب

يتم الاحتفاظ بمجموعة واحدة كمجموعة اختبار، وتستخدم المجموعات الفرعية التسع المتبقية كمجموعة تدريب، تتكرر العملية بعد ذلك لمدة 10 مرات، مع استخدام كل مجموعة من المجموعات الفرعية العشر مرة واحدة بالضبط كمجموعة اختبار، وأخيراً، يتم حساب متوسط النتائج العشر لإنتاج تقدير واحد. ويمثل الشكل (7) كامل عملية التحقق المتقاطع بمقدار 10 أضعاف. (2) تقسيم النسبة المئوية (%) حيث إن 66% بيانات تدريب، و34% بيانات اختبار.

التدريب) ويستخدم لتدريب الخوارزمية، والجزء الثاني (اختبار أو عينة التحقق من الصحة)، ويستخدم لتقييم أداء الخوارزمية (Ekubo, 2020). وطرق التقييم الشائعة الاستخدام في التعلم الآلي التحقق من الصحة k-fold فإننا في البحث الحالي، استخدمنا تقنيتين في تقييم التعلم الآلي وهما: (1) التحقق من الصحة ذات 10 أضعاف لتقييم النموذج التنبؤي حيث يتم تقسيم مجموعة البيانات الفعلية بشكل عشوائي إلى 10 مجموعات فرعية، من بين المجموعات الفرعية العشر،



الشكل (7): عملية التحقق المتقاطع بمقدار 10 أضعاف (Rifat et al., 2019).

منطقة خصائص تشغيل جهاز الاستقبال. واستخدمت دراسة (Pardos et al., 2012) مقياس الخطأ التربيعي لمتوسط الخطأ (RMSE). واستخدم (Romero and Ventura, 2010) مقياس كوبا Cohen's Kappa. واستخدمت دراسات (Sadiq & Ahmed, 2019; Altaye, 2019) المقاييس الثلاثة:

حيث استخدمت دراسة (Awaji, 2018) مقياسي الحساسية (Sensitivity)، والنوعية (Specificity). واستخدمت دراسة (Shaikh et al., 2015) المقاييس الأربعة: الحساسية (Sensitivity)، والنوعية (Specificity)، والدقة (Precision)، ومقياس F. واستخدمت دراسة (Sarlis & Christopoulos, 2014) المقياس

مقياس F-، والاستدعاء (Recall)، والدقة المرشحة (Precision). واستخدمت دراسات (Ekubo, 2020؛ Mgala, 2016) المقاييس الخمسة: النوعية (Specificity)، والاستدعاء (Recall)، ومنطقة خصائص تشغيل جهاز الاستقبال (ROC)، ومقياس كوبا Cohen's Kappa، والخطأ التربيعي لمتوسط الخطأ RMSE. واستخدمت دراسة (Remphele, 2018) المقاييس المختلفة الآتية: الدقة التنبؤية (Accuracy)، والدقة المرجحة (Precision)، والاستدعاء (Recall)، والحساسية (Sensitivity)، والمعدل الإيجابي الحقيقي (TPR)، والإيجابي الخاطئ (FPR)، ومعامل ارتباط ماثيو (MCC)، ومنحنى الاستدعاء

الدقيق (PR curve)، واسترجاع الدقة (AUC-PR). واستخدمت دراسة (Alhassan et al., 2020) المقاييس المختلفة الدقة التنبؤية (Accuracy)، والدقة المرجحة (Precision)، والاستدعاء (Recall)، ومقياس F-، والمعدل الإيجابي الحقيقي (TPR)، والمعدل الإيجابي الخاطئ (FPR)، ومقياس كوبا Cohen's Kappa، والجذر التربيعي لمتوسط الخطأ RMSE.

وهنا هذه المقاييس يتم حسابها من مصفوفة الارتباك (التشويش)، ويتم تقييم أداء نموذج التصنيف على أساس حساب حالات التحقق المتقاطع الصحيحة، وتلك التي تم توقعها بشكل غير صحيح بواسطة النموذج (Asif et al., 2014).

الجدول رقم (1): مصفوفة الارتباك (التشويش) (M'arquez-Vera et al., 2013).

التدخل المنخفض (Low Intervention(LI))	التدخل المرتفع (High Intervention(HI))	الفعلية (الواقع) المتنبئ به (التنبؤ)
التدخل المرتفع الكاذب False High (Intervention(FH))	التدخل المرتفع الحقيقي True High (Intervention(TH))	التدخل المرتفع (High Intervention(HI))
التدخل المنخفض الحقيقي True Low (Intervention(TL))	التدخل المنخفض الكاذب False Low (Intervention(FL))	التدخل المنخفض (Low Intervention(LI))

لتحليل أداء التنبؤ كما هو مبين في الجدول (1)، وتعرض الأعمدة لطلبة التدخل المرتفع الفعلي والتدخل المنخفض، بينما تمثل الصفوف ما تم التنبؤ به على أنهم طلبة ذوو تدخل مرتفع وتدخل منخفض، ويظهر الطلبة الذين تم تصنيفهم بشكل صحيح في المربع الحقيقي

ومصفوفة الارتباك هي أداة لتحليل أداء تصنيف الخوارزميات المرشحة في البحث، فهي تجمع النتائج بحيث يمكن استخدامها كأساس لتحليل الدقة (Sen et al., 2012). وفي الأصل، تم نشرها في مجال التعلم الآلي، وتم تكييف مصفوفة الارتباك في البحث الحالي

ومن مقاييس التقييم المختارة والتي تم التركيز عليها في مناقشة نتائج البحث الحالي هي:

❖ **الدقة التنبؤية (Accuracy):** هو المقياس الشائع المستخدم لتقييم أداء التصنيفات المرشحة للاستخدام في البحث الحالي، ويحسب من خلال نسبة الحالات المصنفة بشكل صحيح إلى العدد الإجمالي لجميع السجلات كما في العلاقة (Tan et al., 2019):

$$Accuracy = \frac{TH + TL}{TH + FH + FL + TL} \dots \dots (2.2)$$

❖ **مقياس F-(F-Measure):** تحدد F-Measure فاعلية الفئة في تصنيف طلبة التدخل المرتفع، أو الإيجابيات الحقيقية، من خلال الجمع بين كل من الدقة والاستدعاء للوصول إلى متوسط قيمة متوازنة (Shaikh et al., 2015). ويُفضل لمجموعات البيانات غير المتوازنة؛ لأن الفئات يتم التعامل معها بشكل مستقل، ويتم التعبير عن مقياس F في المعادلة (Thai-Nghe et al., 2009):

$$F - \text{measure} = 2 \times \frac{Recall * Precision}{Recall + Precision} \dots \dots (2.3)$$

❖ **مقياس كوهن كابا (Cohen's Kappa):** يعمل Cohen's Kappa بطريقة مشابهة لمعامل ارتباط المقياس الإحصائي، الذي يعطي قيمة الارتباط بين 0: 1- و 0: 1 (Wood, 2007). وتشير قيمة Kappa البالغة 1 إلى أن التصنيف الذي أجراه ثنائي من المقيمين يتفق تمامًا؛

للتدخل المرتفع، والمربع الحقيقي للتدخل المنخفض. والتدخل المرتفع الكاذب هم الطلبة الذين يمثلون في الواقع حالات تدخل منخفض، وفقًا للدرجات المستخدمة في التدريب، لكن النموذج توقعهم على أنهم ينتمون إلى فئة التدخل المرتفع، وهذا يمثل الخطأ من النوع الأول. وبالمثل، فإن التدخل المنخفض الكاذب هم الطلبة الذين ينتمون بالفعل إلى فئة التدخل المرتفع، ولكن النموذج قد توقعهم في فئة التدخل المنخفض، وهذا يمثل الخطأ من النوع الثاني متجاهلاً الخطر. لذلك، يتم تحديد دقة الفئة من خلال نسبة الطلبة الذين تم تصنيفهم بشكل خاطئ؛ كلما كانت النسبة أصغر، كان التصنيف أكثر دقة. أي أن:

✓ **True High (TH):** هو عدد الطلبة الفعليين ذوي التدخل المرتفع الذين يتم توقعه بشكل صحيح.

✓ **False High (FH):** هو عدد الطلبة الفعليين ذوي التدخل المنخفض المتوقع أن يكونوا طلبة تدخل مرتفع.

✓ **True Low (TL):** هو عدد الطلبة الفعليين ذوي التدخل المنخفض الذي يتم توقعه بشكل صحيح.

✓ **False Low (FL):** هو عدد الطلبة الفعليين ذوي التدخل المرتفع المتوقع أن يكونوا طلبة تدخل منخفض.

$$RMSE = \sqrt{\frac{1}{n} (y_i - \hat{y}_i)^2 \dots \dots} \quad (2.5)$$

حيث  $n$  عدد العينات، و  $(y_i - \hat{y}_i)$  هو الخطأ المحسوب لـ  $i = 1, 2, \dots, n$  الناتج من الفرق بين القيمة الفعلية والقيمة المتوقعة.

#### ❖ منطقة خصائص تشغيل جهاز الاستقبال

(ROC): (Receiver Operating Characteristics)

ROC هو منحنى مترى تم الحصول عليه من خلال رسم الحساسية (المعدل الإيجابي الحقيقي) على المحور السيني مقابل الخصوصية (المعدل الإيجابي الخاطئ) على المحور الصادي، وهو يقيس قدرة إحدى الفئتين على تصنيف الحالات إلى فئات مختلفة، إنه مقياس شائع يستخدم لمقارنة الأداء الفريد (Jimenez-Valverde, 2012).

والشكل أدناه مأخوذ من ( Powers, 2008)، حيث يُستخدم هذا لتوجيه تفسير منحنى ROC، مشيراً إلى أن "المصنف المثالي سوف يسجل في الزاوية اليسرى العليا إذا كان المعدل الإيجابي الكاذب (FPR = 0)، والمعدل الإيجابي الحقيقي (TPR = 1)، وسيسجل مصنف أسوأ حالة في الزاوية اليمنى السفلية، حيث (FPR = 1)، (TPR = 0). ومن المتوقع أن يسجل المصنف العشوائي في مكان ما على طول القطر الموجب (TPR = FPR) وتكون المساحة تحت المنحنى أو (AUC) تساوي

وتشير قيمة 1- إلى أنهما يختلفان تماماً، والقيمة 0 تعني تخميناً من قبل المقيمين (Mchugh, 2012). وهناك إجماع من قبل الباحثين على أن قيمة الاتفاق المقبولة بين أي مقيمين يجب أن تكون 0.60 على الأقل (Wood, 2007)، لذلك تم استخدامه في الدراسات لمقارنة أداء المصنفين (Romero & Ventura, 2010)، واكتسبت كوهن كابا موافقة الباحثين على كونها أقل عرضة للخطأ (Mgala, 2016). ويتم التعبير عنها في المعادلة (Mchugh, 2012):

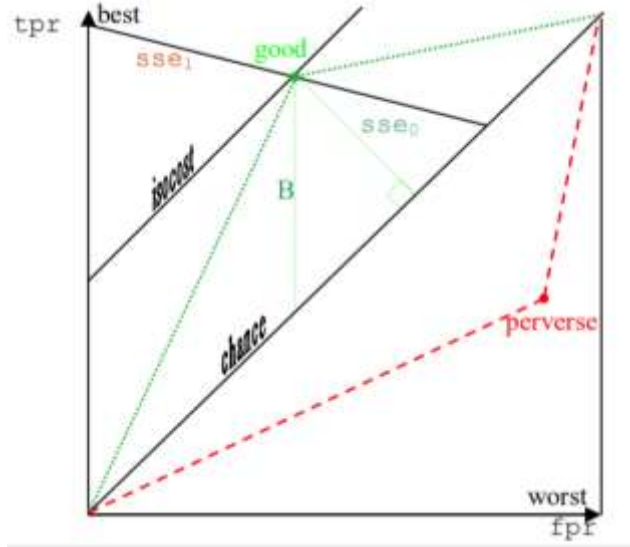
$$K = \frac{P(a) - P(e)}{1 - P(e)} \dots \dots (2.4)$$

حيث  $K$  هي قيمة Cohen's Kappa، و  $P(a)$  هو إجمالي احتمال الاتفاق، و  $P(e)$  هي القيمة الافتراضية لاحتمال الاتفاق بين المقيمين. وسيحقق الاتفاق المثالي بين المقيمين قيمة  $K = 1$ ، بينما هناك حالة يكون فيها اتفاق المقيمين بالصدفة إذا كان  $K \leq 0$ .

#### ❖ الجذر التربيعي لمتوسط الخطأ (RMSE):

تم استخدام RMSE لتقييم أداء التصنيف من حيث حجم الأخطاء التي يرتكبها المصنفون (Pardos et al., 2012)، وتم العثور على RMSE ليكون مقياساً أكثر ملاءمة لأداء النموذج مقارنة بمقياس متوسط الخطأ المطلق الشائع MAE، ويظهر تعبير RMSE في المعادلة (Chai & Draxler, 2014):

الواحد، وكلما كانت قيمة ROC أقرب من الواحد كانت دقة التصنيف أكثر موثوقية، والشكل (8) يبين منحنى ROC (خاصية تشغيل جهاز الاستقبال).



الشكل (8): مخطط توضيحي لتحليل ROC.

بيانات برنامج إعداد معلم رياضيات التعليم الثانوي نظام الماستري (2016-2008) تحتوي على 163 سجل تدخل مرتفعا، و406 سجل تدخل منخفض، وبالتالي فهي غير متوازنة.

### القسم (3): منهجية البحث وإجراءاته

#### 1. عملية تنقيب البيانات التعليمية

##### (Educational Data Mining Process)

المنهجية الشائعة في اكتشاف المعرفة

من تنقيب البيانات هي عملية Cross-Industry

Standard Process-Data mining (CRISP-

DM) وهي عملية معروفة للتنقيب عن البيانات

وتُظهر مسارات واضحة لتحقيق الأهداف

المرجوة من تنفيذ البحث الحالي (Oreski et al., 2017).

وتحتوي عملية (CRISP-DM)

الموضحة في الشكل (9) على ست مراحل من

وتبلغ مساحة النموذج بدقة كاملة 1.0؛

أي أنه كلما كانت المساحة أكبر، كان الأداء

أفضل للنموذج، أو القيم الكبرى لمتغير نتيجة

الاختبار تشير إلى الدليل الأقوى للحالة الفعلية

الإيجابية (1.00). وكلما اقترب منحنى ROC

للمنموذج من الخط القطري، كانت دقة النموذج

أقرب إلى منطقة 0.5، والجدول (2) يبين

مقياس أداء منحنى ROC (Altaye, 2019).


#### الجدول رقم (2): مقياس أداء منطقة ROC.

ROC Area	Performance
0.9 – 1.0	Excellent (A)
0.8 – 0.9	Good (B)
0.7 – 0.8	Fair (C)
0.6 – 0.7	Poor (D)
0.5 – 0.6	Fail (F)

وكان مقياس منطقة ROC مناسباً في البحث

الحالي؛ لأن مجموعة البيانات المستخدمة من

النسخة التعليمية تمر لاكتشاف المعرفة بنجاح (Ayenew, 2018; Ekubo, 2020).



الشكل (9): مراحل عملية CRISP-DM.

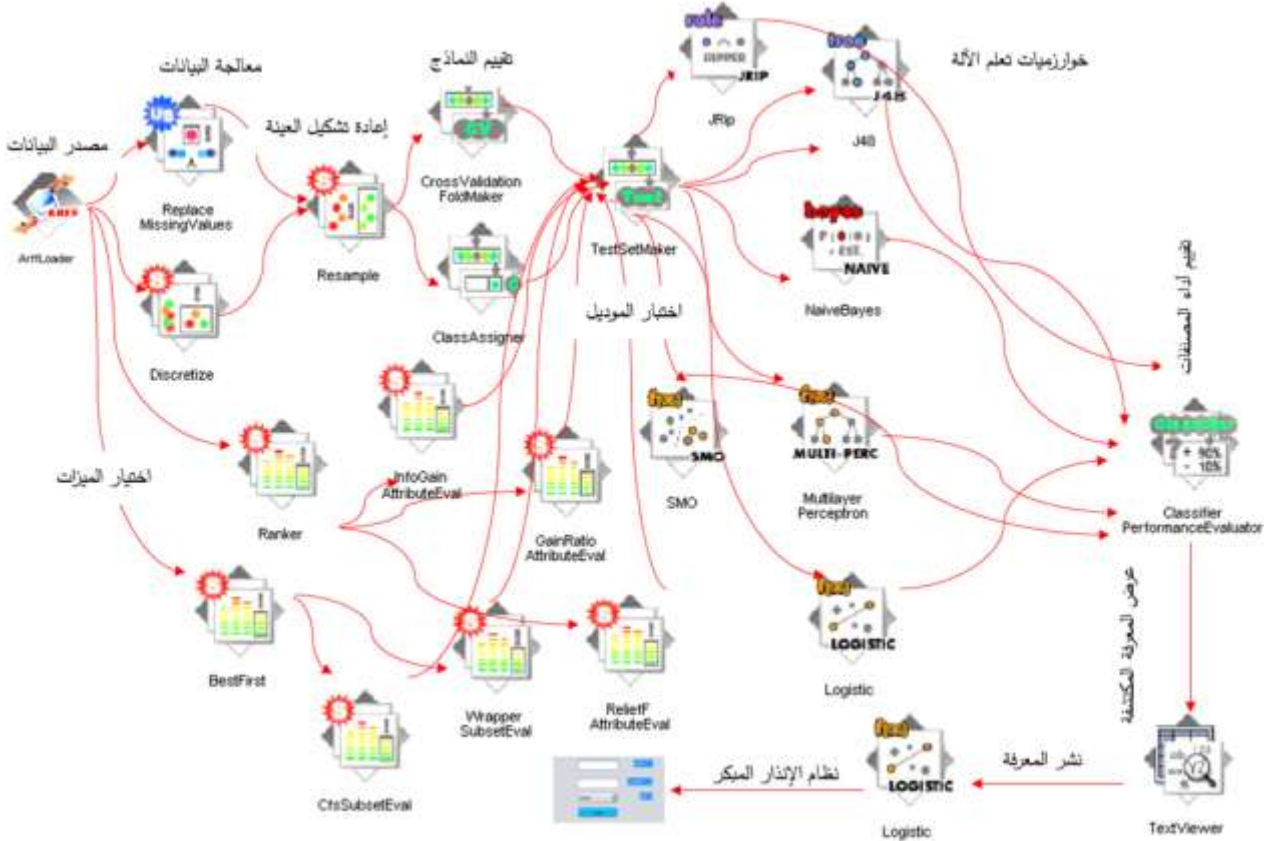
- 1- فهم المجال: تركز هذه المرحلة الأولية على فهم أهداف ومتطلبات البحث من منظور مجال البحث، ثم تحويل هذه المعرفة إلى تعريف مشكلة التنقيب في البيانات.
- 2- فهم البيانات: تبدأ مرحلة فهم البيانات بجمع وفحص البيانات الأولية ذات الصلة.
- 3- معالجة وتحضير البيانات: تغطي هذه المرحلة إعداد البيانات، وتتناول هذه المرحلة تنظيف البيانات (غير المكتملة وغير المفهومة، والزائدة عن الحاجة، والمفقودة، وإزالة القيم الشاذة، والمتطرفة)، وتحويل البيانات التي تم جمعها بتنسيق مناسب، واختيار مجموعة الميزات الفرعية ذات الصلة.
- 4- التنقيب في البيانات (النمذجة): تتضمن هذه المرحلة اختيار خوارزميات النمذجة وتطبيقها على البيانات المعدة لتوليد معرفة جديدة، واستخدام هذا البحث أداة النمذجة WEKA التي تحتوي على العديد من خوارزميات التصنيف والانحدار والتجميع والارتباط لنمذجة البيانات.
- 5- التقييم: في هذه المرحلة من النموذج يتضمن التفسير البحث عن أنماط جديدة ومثيرة للاهتمام تم اكتشافها وفي نهاية هذه المرحلة، ينبغي التوصل إلى قرار بشأن استخدام نتائج التنقيب في البيانات.
- 6- نشر المعرفة المكتشفة: تقدم هذه المرحلة النهائية المعرفة المكتشفة من عملية التنقيب في البيانات إما عن طريق تصميم نظام، أو دمجه في نظام موجود بالفعل، وتوفر مرحلة النشر للمعرفة المكتشفة هذه لأصحاب المؤسسة التعليمية المعرفة التي يحتاجونها لاتخاذ قرارات أفضل للمؤسسة.



جامعة صنعاء-كلية التربية. ويوضح الشكل (10) الإطار المتبع في هذا البحث لتحقيق أهداف البحث ومناقشة الخطوات الآتية:

## 2. الإطار العملي للبحث ( The Practical Framework of the Research )

اعتمد البحث الحالي المراحل الست من عملية CRISP-DM للتحقيق في مشكلة الأداء الأكاديمي المنخفض للطلاب الجامعي في



الشكل (10): الإطار العملي للبحث لتنقيب في البيانات.

من الدراسة وتخرجه، والحصول على الشهادة الأكاديمية. وكان مصدر بيانات درجات الطلبة في جميع المقررات من قسم مناهج الرياضيات وطرائق تدريسها، وكذلك تم جمع بقية مجموعة البيانات من أرشيف الكلية. حيث تم اختيار ما مجموعه 741 طالباً وطالبة في برنامج إعداد معلم رياضيات التعليم الثانوي نظام الماستري

فهم البيانات: أي الأداء الأكاديمي الضعيف لدى الطلبة خريجي بكالوريوس كلية التربية جامعة صنعاء. حيث تم التركيز على الهدف الرئيس للبحث: تطوير نموذج تصنيف على مستوى التدخل المبكر يتنبأ بما إذا كان الطالب سيتطلب تدخلاً مرتفعاً أم منخفضاً لتحقيق درجات النجاح في امتحان المقررات الدراسية وحتى الانتهاء

والشاذة، وغير الصحيحة، والقيم المفقودة غير المقبولة (37791) سجلاً بعد إدخال المعدل التراكمي يدوياً، وبلغ إجمالي عدد سجلات الطلبة الحاصلين على المعدل التراكمي (685) سجلاً، المحذوف منها (116) سجلاً؛ بسبب كثرة عدد القيم المفقودة لدرجات المقررات واعتبار الطلبة فيها منسحبين ومتسربين، و(56) سجلاً لم تحتو على درجات للمقررات الدراسية سوى مقرر واحد، أو اثنين، أو ثلاثة على الأكثر، وبالتالي ليس لها معدل تراكمي فتم حذفها واعتبار الطلبة فيها منسحبين ومتسربين. فأصبح العدد الإجمالي لعينة البحث المتبقي والذي تم الاعتماد عليه في التنقيب (569) سجلاً، منهم (153) سجلاً لطلبة حصلوا على معدل تراكمي بنجاح، و(416) سجلاً تشكل ما مجموع عدد الطلبة الجامعيين ذوي الأداء الضعيف في البحث الحالي.

وتم إضافة متغيرين في ملف Micro-

Excel وهما: المتغير التابع (التعرض للخطر) لبيانات السنتين الأولى والثانية للمقررات الدراسية، حيث يكون الطالب/الطالبة معرضاً للخطر إذا رسب في مقررين فأكثر في الفصل الدراسي الواحد، ويكون الطالب/الطالبة غير معرض للخطر إذا رسب في أقل من مقررين،

للأعوام (2008-2016م) كمجموعة بيانات أولية باستخدام العينات التطبيقية. وكان معدل التسرب والرسوب المرتفع نسبياً هو مصدر إثارة الباحثين لدراسة هذه المشكلة. **جمع البيانات:** تم جمع البيانات الموجودة من المصادر المتاحة والخطوة التالية وكان تجميع جميع البيانات التي تم جمعها في تنسيق وملف واحد (Micro-Excel)، وتنظيف البيانات للتخلص من البيانات غير الدقيقة، أو غير الكاملة، أو المفقودة والشاذة، وتحويلها لتناسب مع أداة النمذجة، وأخيراً مجموعة البيانات للتنقيب، وهي المنتج المشتق من عملية جمع البيانات بأكملها. وكان عدد المقررات في برنامج النظام (2008-2016) 49 مقررًا بعد حذف مقررين اختياريين، وتم أخذ 28 مقررًا للسنوات الدراسية الأولى والثانية في التنبؤ بالأداء الأكاديمي للطلبة من أجل التعرف المبكر على الطلبة المعرضين للخطر.

**تحضير البيانات:** تحتوي البيانات التي تم جمعها على العديد من البيانات المتكررة وغير الكاملة وغير الدقيقة. حيث بلغت بيانات برنامج النظام (2008-2016م) التي تم جمعها من مصادرها بعد تصفية التكرار، وتنظيفها من القيم غير الدقيقة

إلى متغير معدل الثانوية، ومتغير النوع الاجتماعي، ومتغيرات الاستجابة. والجدول (3) يوضح إجمالي عدد الطلبة لكل دفعة دراسية وتوزيع الفئات المعرضة للخطر وغير المعرضة للخطر في السنتين الدراسيتين الأولى والثانية في مجموعة البيانات، وفي الجدول (4) وصف وترميز المقررات الدراسية التي تسمى بالميزات.

وأثناء المعالجة الأولية لمجموعات البيانات، تم فحص نوعية البيانات لكل متغير للتأكد من أنها تمثل بيانات صحيحة وقابلة للتحليل، ومن ثم تصديرها بتنسيق مناسب (ARFF) إلى برنامج التنقيب في البيانات (Weka) لتحليل البيانات الضخمة. وتم إجراء تحليل للقيم المفقودة بعد إزالة القيم المفقودة غير المعقولة من السجلات كما تم ذكره مسبقاً.

واستند الباحثان في تعيين الطلبة في هذه المستويات إلى استشارة رئيس القسم، وعلى حسب لائحة الكلية متى يتم بقاء الطالب في مستوى معين؟

**تحويل البيانات:** حتى تتناسب مع أداة النمذجة، تم تحويل درجات المقررات من بيانات رقمية إلى بيانات نوعية لضرورة استخدامها في بعض الخوارزميات المرشحة. وأيضاً تحويل جميع البيانات إلى درجة موحدة، وتكون الدرجة العظمى من (100) لجميع بيانات البحث حتى تكون نتائج التنقيب ذات ثقة ودقة تنبؤية.

وبعد الانتهاء من مرحلة جمع بيانات الطلبة المستخدمة في البحث الحالي أخذت متغيرات البحث من درجات المقررات التي تم دراستها في الفصول الدراسية الأربعة من السنتين الدراسيتين الأولى والثانية، بالإضافة

الجدول رقم (3): توزيع فئات الطلبة المعرضين للخطر وغير المعرضين للخطر في السنوات الدراسية الأولى والثانية في برنامج النظام (2008-2016م).

إجمالي عدد الطلبة Total	غير المعرضة للخطر No-Risk	المعرضة للخطر At-Risk	السنوات Years	
184	%46.74	86	%53.26	98
105	%50.48	53	%49.52	52
99	%60.61	60	%39.39	39
76	%63.16	48	%36.84	28
116	%53.45	62	%46.55	54
161	%59.63	96	%40.37	65
741	%54.66	405	%45.34	336
الإجمالي (Total)				

الجدول رقم (4): وصف وترميز المقررات الدراسية (الميزات) في بيانات برنامج النظام (2008-2016م).

القيمة المحتملة للميزة	اسم الميزة	رمز الميزة	رقم الميزة	القيمة المحتملة للميزة	اسم الميزة	رمز الميزة	رقم الميزة
Exzellen ≥ 90, V.good ≥ 80, Good ≥ 65, Pass ≥ 50, Fail > 0	إدارة صفوف	40483	31	Exzellen ≥ 90, V.good ≥ 80, Good ≥ 65, Pass ≥ 50, Fail > 0	النوع الاجتماعي	Gender	1
	تاريخ الرياضيات	40539	32		معدل الثانوية العامة	SH average	2
	نظرية الأعداد	40540	33		جبر وحساب المثلثات	40508	3
	معادلات تفاضلية عادية	40541	34		فيزياء عامة (1)	40015	4
	تقنيات التعليم (2)	40542	35		فيزياء عملية (1)	40013	5
	تربية إسلامية	40002	36		لغة إنجليزية (101)	40025	6
	تربية عملية (1)	40006	37		لغة عربية (101)	40026	7
	احتمالات	40069	38		ثقافة إسلامية	40287	8
	أصول تربية	40210	39		مقدمة في الحاسوب	40507	9
	تحليل رياضي (2)	40553	40		تفاضل وتكامل (2)	40017	10
	برمجة حاسوب	40554	41		فيزياء عامة (2)	40016	11
	حل مسألة	40560	42		فيزياء عملية (2)	40014	12
	تربية عملية (2)	40012	43		رياضيات متقطعة	40509	13
	جبر مجرد (1)	40157	44		لغة إنجليزية (102)	40073	14
	تحليل مركب (1)	40233	45		لغة عربية (102)	40109	15
	إحصاء رياضي (1)	40250	46		تفاضل وتكامل (2)	40023	16
	بحث تربوي	40433	47		جبر خطي (1)	40068	17
	تحليل عددي	40232	48		هندسة وقياس (1)	40513	18
	جبر مجرد (2)	40402	49		نظام التعليم في اليمن	40004	19
	قياس وتقويم	40426	50		مناهج وتحليل مناهج	40338+40514	20
	بحث تخرج تربوي	40581	51		علم النفس التربوي	400424	21
	مقررات التخصص	Field.1	52		جبر خطي (2)	40181	22
	مقررات داعمة	Field.2	53		هندسة وقياس (2)	40559	23

القيمة المحتملة للميزة	اسم الميزة	رمز الميزة		القيمة المحتملة للميزة	اسم الميزة	رمز الميزة	
	مقررات عملية	Field.3	54		تفاضل وتكامل (3)	40137	24
	م. متطلبات الجامعة	Field.4	55		مبادئ الإحصاء	40179	25
	م. متطلبات القسم	Field.5	56		طرق تدريس (1)	40140	26
$AtRisk < 2$	منغير الاستجابة (1) لمقررات سنة (1)	Var-Risk1	57		علم نفس النمو	40211	27
	منغير الاستجابة (2) لمقررات سنة (2)	Var-Risk2	58		تقنيات التعليم	40452	28
Pass/Fail	المعدل التراكمي	GPA	59		طرق تدريس (2)	40066	29
					تحليل رياضي	400231	30

رسوب في أكثر من مقررين، لذلك، تم اعتبار من كان لديه مقرر فأكثر فشل فيه فإن سجل الطالب يعد (Fail)، ومن لم يكن لديه أي مقرر فشل فيه فإن سجل الطالب يعتبر (Pass). والسجلات التي وجد فيها عدد من القيم المفقودة الممكن تفاديها تم استبدالها بقيم المتوسط للبيانات في العمود الذي توجد فيه قيم مفقودة كما هو في الدراسات السابقة التي تم ذكرها مسبقاً، وذلك من خلال فلتر الميزات غير الخاضعة للإشراف، وتطبيق ( Replace Missing Values) في أداة النمذجة WEKA. و خلاصة السجلات المحذوفة 23% من عينة البحث. والجدول (5) يبين حجم عينة البحث المختزلة.

وبعد مرحلة تنظيف وتحويل وترميز البيانات لأكواد خاصة تناسب أداة النمذجة WEKA، تأتي مرحلة تنسيق وتحويل البيانات إلى تنسيق مناسب، حيث تم تحويل تنسيق البيانات المجمعة في ملف Micro-Excel إلى الفاصلة المنقوطة (؛) بالفاصلة (،). ثم تحويلها للتنسيق Attribute-Relation File Format (arff) الذي يتناسب مع الأداة WEKA. وكانت ميزة المعدل التراكمي في البحث الحالي أنها تحتمل إحدى القيمتين ( Pass & Fail)؛ وذلك لأنه وجد عدد من سجلات الطلبة معدلاتهم التراكمية أعلى بكثير من درجة متوسط المعدل التراكمي (GPA)، ولكن لديهم

الجدول رقم (5): بيانات عينة البحث النهائية لتنقيب البيانات التعليمية.

إجمالي عدد الطلبة (Total)	عدد الطلبة		السنوات (Years)	
	اناث	ذكور		
بيانات برنامج إعداد معلم رياضيات التعليم الثانوي نظام الماستري (2008-2016م)				
146	106	40	2008	10
80	66	14	2009	11
77	57	20	2010	12
54	38	16	2011	13
90	63	27	2012	14
122	86	36	2013	15
569	416	153	الإجمالي (Total)	

أهمية إلى الأقل أهمية. حيث تم إنشاء مجموعتي بيانات: إحداها مع مجموعة الميزات الكاملة، بينما الأخرى تضمنت فقط الميزات المحددة بواسطة طرق اختيار الميزات؛ لأجل تحديد المجموعات الفرعية المثلى للميزات المستخدمة.

وكذلك بالاعتماد على الجدول (4)، تم اختيار الميزات لبيانات السنتين الأولى والثانية لبيانات برنامج النظام (2008-2016م). وتبين الجداول (6)، (7) مجموعات البيانات وعدد الميزات في مجموعة الميزات الكاملة، ومجموعة الميزات التي تمت تصفيتها، واختيار الأفضل منها، وترتيبها من الأكثر

الجدول رقم (6): عدد المشاهدات والميزات في مجموعة بيانات برنامج نظام (2008-2016م).

عدد Number		مجموعة السمات Features Set	الوصف Description	قاعدة البيانات Dataset
المشاهدات Observations	الميزات Features			
569	15	الميزات (السمات) كاملة	تحتوي مجموعة البيانات هذه فقط على بيانات الطلبة التي كانت متاحة قبل بداية الفصل الدراسي وهي: النوع الاجتماعي، معدل الثانوية العامة، ودرجات مقررات الفصل الدراسي الأول والثاني، وسمة الاستجابة (1) AT_RISK	السنة الدراسية الأولى First Study Year
	7	الميزات الفرعية المثلى		
	28	الميزات (السمات) كاملة	تحتوي مجموعة البيانات هذه فقط على بيانات الطلبة التي كانت متاحة قبل بداية الفصل الدراسي وهي: النوع الاجتماعي، معدل الثانوية العامة، ودرجات مقررات الفصل الدراسي الأول والثاني والثالث والرابع، وسمة الاستجابة (2) AT_RISK	السنة الدراسية الثانية Second Study Year
	15	الميزات الفرعية المثلى		

الجدول رقم (7): عدد الميزات التي تم تصنيفها حسب الأفضلية وترتيبها من الأكثر أهمية إلى الأقل أهمية لبيانات السنة الدراسية الأولى من بيانات برنامج نظام (2008-2016م).

رتب السمات Attributes Rank	اختيار الميزات الأفضل Selected best attributes	طرق البحث Search Method	تقييم الميزات Attributes Evaluator	اختيار الميزات Feature selection
----	3,4,7,9,10,11,13,1 5,5,14,6	BestFirst	CfsSubsetEval	
13,3,10,11,14,7,6, 4,9,5,15,8,12,1,2	----	Ranker	GainRatioAttributeEval	
3,10,13,9,14,11,5, 15,7,6,4,8,12,1,2	----	Ranker	InfoGainAttributeEval	
13,10,3,4,15,11,7, 2,6,14,12,9,5,1,8	----	Ranker	ReliefFAttributeEval	
----	3,13,15,11,4,10,6, 5,7,2,9,14,1,8	BestFirst	WrapperSubsetEval With IBK	

و Relief. وهذا يعني أن هذه الميزات المشتركة الأعلى أهمية قد تدل على الفئة المستهدفة المعرضة للخطر. لذلك يُقترح أن تكون الثلاث الميزات الأولى: 13 (رياضيات متقطعة)، والميزة 3 (جبر وحساب المثلثات)، والميزة 10 (تفاضل وتكامل (1)) هي الميزات الأساسية.

والجدول (8) يبين مجموعة الميزات التي تمت تصنيفها واختيار الأفضل منها، وترتيبها من الأكثر أهمية إلى الأقل أهمية بواسطة طرق اختيار الميزات لأجل تحديد المجموعات الفرعية المثلى للميزات المستخدمة لبيانات السنة الدراسية الثانية من بيانات برنامج نظام (2008-2016م).

كما لوحظ في المجموعات الثلاث من الميزات المرتبة في حالة البيانات الأصلية، أن الميزة 13 (رياضيات متقطعة)، والميزة 3 (جبر وحساب المثلثات)، والميزة 10 (تفاضل وتكامل (1)) هي أهم الميزات لأنها تظهر الأهمية الأولى في جميع المجموعات الفرعية الثلاث رغم اختلاف ترتيب أماكنها ولكنها تشترك في الأهمية. حيث تم مشاركتها من خلال خوارزمية ترتيب نسبة الكسب واكتساب المعلومات وخوارزميات التصفية في حالة البيانات الأصلية. ويمكن أيضاً ملاحظة أن الميزات: 8 (ثقافة إسلامية)، 12 (فيزياء عامة (2))، 1 (النوع الاجتماعي)، 2 (معدل الثانية العامة) يتم مشاركتها بين أقل 4 ميزات بواسطة Gain Ratio و Information Gain

الجدول رقم (8): عدد الميزات التي تم تصفيتها حسب الأفضلية وترتيبها من الأكثر أهمية إلى الأقل أهمية لبيانات السنة الدراسية الثانية من بيانات برنامج نظام (2008-2016م).

رتب السمات Attributes Rank	اختيار أفضل الميزات Selected attributes	طرق البحث Search Method	تقييم الميزات Attributes Evaluator	اختيار الميزات Feature selection
----	3,4,10,11,13,15,16,1 8,22,23,24,28,5,7,8, 9,14,27,19,25,26,6	BestFirst	CfsSubsetEval	
3,23,10,11,24,13,2 2,14,7,17,28,16,9,1 8,8,26,5,15,25,19,2 7,6,21,4,12,20,2,1		Ranker	GainRatioAttributeEval	
10,3,24,13,22,11,1 6,14,9,17,28,23,8,2 6,15,7,5,19,18,27,2 1,4,6,20,25,12,2,1		Ranker	InfoGainAttributeEval	
3,10,16,23,22,13,1 8,24,25,4,15,17,19, 28,11,7,21,9,12,2,2 7,14,6,5,26,20,8,1		Ranker	ReliefFAttributeEval	
----	3,11,22,25,10,13,16, 4,15,23,9,17,24,14,2 0,28,5,8,18,26,27,1, 6,7,12,19,21	BestFirst	WrapperSubsetEval With:IBK	

ولتحقيق الهدف الرئيس للبحث، يتبع طريقة اختيار الميزات الرئيسة للأداء الأكاديمي المنخفض في كلية التربية-قسم مناهج الرياضيات وطرائق تدريسها، ومقارنة أداء ست خوارزميات مختلفة للتعلم الآلي، واختيار أفضل الميزات من الميزات الكاملة التي تم جمعها، واختيار أفضل نموذج مصنف، وتطوير البرمجيات التنبؤية باستخدام أفضل نموذج مصنف تم تحديده. ويوفر هذا البرنامج المقترح للكلية معلومات دقيقة، وفي الوقت المناسب لتحديد أصحاب الأداء المنخفض، ومساعدة الكلية والقسم المختص على التدخل في وقت مبكر بما فيه الكفاية.

مما سبق يلاحظ أنه في المجموعات الثلاث من الميزات المرتبة في بيانات السنة الثانية لبيانات طلبة برنامج نظام (2008-2016م)، أن الميزتين كانت في: جبر وحساب المتلثات (40508)، وتفاضل وتكامل (2)، كانت هي الأهم؛ لأنها تظهر في الموضع الأول في جميع المجموعات الفرعية الثلاث، ويتم مشاركتها من خلال الترتيب في خوارزميات نسبة الكسب، وكسب المعلومات، وخوارزميات التصفية. وقد تعني هذه الميزات المشتركة أنها تدل على الفئة المستهدفة، لذلك يُقترح أن تكون الميزتان الأولى هي الميزات الأساسية.



## القسم (4): تحليل نتائج البحث

### ومناقشتها وتفسيرها

يقدم هذا القسم تحليل البيانات التفصيلي الذي تم إجراؤه في اختيار تقنية النمذجة لتوظيف خوارزميات الذكاء الاصطناعي للتنقيب في البيانات التعليمية من أجل التنبؤ بالأداء الأكاديمي لدى الطالب الجامعي، ومن ثم تنفيذ التقنية المختارة باستخدام خوارزميات المناسبة، وتقييم النماذج لاختيار أفضلها وتحديد العوامل المؤثرة على أداء الطلبة:

### الخطوات الرئيسية في تنفيذ تقنيات التنقيب في البيانات التعليمية

وتتمثل الخطوات الرئيسية لتنفيذ تقنية التنقيب في البيانات التعليمية في الآتي:

#### 1- بناء النموذج

يتضمن بناء النموذج المهام الآتية: اختيار تقنية النمذجة، والإعداد التجريبي، وبناء وتقييم النموذج، وذلك باستخدام تقنيات مختلفة لمشاكل التنقيب في البيانات.

#### 2- اختيار تقنية النمذجة

لتحقيق أهداف هذه الدراسة والإجابة عن أسئلتها، تم اختيار ست تقنيات تصنيف لبناء النموذج. وتم إجراء التحليل باستخدام بيئة الـ WEKA من بين خوارزميات التصنيف المختلفة المتاحة في WEKA، وهي خوارزمية J48 من شجرة القرار، وخوارزمية JRip من

استقراء القاعدة، وخوارزمية البايزي البسيط Naïve Bayes من البايزي Bayesian، وخوارزمية الانحدار اللوجستي Logistic Regression من Regression، وخوارزمية التحسين الأدنى المتسلسل Sequential Minimal Optimization (SMO) من متجهات آلة الدعم Support Vector Machines، وخوارزمية الإدراك المتعدد الطبقات Multilayer Perception من خوارزمية الشبكة العصبية Neural Network. وقد تم اختيارها؛ لتدريب واختبار البيانات في الإعداد التجريبي، حيث تم استخدام الحجم الإجمالي للسجلات والسمات كما تم ذكرها في نظام التعليم الماستري للتدريب والاختبار.

#### 3- موازنة مجموعة البيانات

يحدث التوزيع غير المتوازن للفئة في نموذج التصنيف عندما يكون عدد السجلات (المثيلات) في فئة واحدة أقل بكثير من عدد الحالات في الفئة الأخرى، والفئة التي بها عدد قليل من الأمثلة تسمى فئة الأقلية، بينما تُعرف الفئة التي تحتوي على عدد كبير من الأمثلة بفئة الأغلبية، ويكون أداء خوارزميات التعلم الآلي أفضل عندما تكون الفئات متوازنة تقريباً في مجموعة البيانات، ومن ثم فإنه عند تطبيق خوارزميات التعلم الآلي على مجموعة بيانات غير متوازنة يؤدي ذلك إلى تحيز النتيجة لفئة

الافتراضية لـ (التحيز إلى التصنيف الموحد (0.0) إلى (1.0)). كما هو مبين في الشكل (11) كنموذج لحل مشاكل عدم التوازن بعد أن تقدمت بطلب لإعادة أخذ العينات، حيث تصبح الفئات التابعة الثنائية متساوية مع نجاح قيمة كل فئة، فئة معرضة للخطر وفئة غير معرضة للخطر.

الأغلبية (Whitlock, 2018; Zabriskie, et al., 2019; Alhassan, et al., 2020)، حيث تكون فئة الأقلية هي الطبقة ذات الاهتمام الأكبر، وتكلفة الخطأ أكبر من وجهة نظر التعلم الآلي (Altaye, 2019).

ولحل مشكلة عدم توازن الفئات، طَبَّق الباحثان تقنية إعادة التشكيل (Resample) تحت الإشراف عن طريق تغيير القيم



الشكل (11): الجانب الأيسر فئة البيانات الأصلية، والجانب الأيمن فئة البيانات المتوازنة.

النماذج باستخدام اختبار التحقق المتقاطع 10 أضعاف، والنقسيم بالنسبة المئوية لجميع التجارب. وتم تصميم تجربة لبناء، واختبار النموذج للتنبؤ بأداء الطلبة:

**التجربة 1:** خوارزميات التعلم الآلي الست المذكورة آنفاً باستخدام اختبار التحقق من الصحة 10 أضعاف.

**التجربة 2:** خوارزميات التعلم الآلي الست المذكورة آنفاً باستخدام إعادة التشكيل، واختبار التحقق من الصحة 10 أضعاف.

1. الإعداد التجريبي لبيانات السنوات الدراسية الأولى والثانية لمجموعة السمات الكاملة من بيانات برنامج إعداد معلم رياضيات التعليم الثانوي نظام الماستري (2008-2016م).

أجريت أربع تجارب باستخدام السمات الكاملة، ثم على السمات التي تم تصنيفها لأفضل الميزات وترتيبها، وتحديد مجموعات فرعية مثلى للميزات المعروضة لدينا في البحث الحالي، وهنا تم استخدام البيانات الأصلية، وإعادة تشكيل البيانات، وتقييم

وهي: شجرة القرار (J48)، وخوارزمية (JRip) من استقراء القاعدة، وخوارزمية Naïve Bayes (NB)، وخوارزمية (LR) Sequential Minimal (Logistic)، وخوارزمية (SMO) Optimization (MLP)، وخوارزمية Multilayer Perception. وتم مقارنة خلاصة النتائج التي تم الحصول عليها لكل خوارزمية، ثم تم اختيار أفضل نموذج في الجدول (9) أدناه.

**التجربة 3:** خوارزميات التعلم الآلي الست المذكورة آنفاً باستخدام اختبار تقسيم النسبة المئوية (%).

**التجربة 4:** خوارزميات التعلم الآلي الست المذكورة آنفاً باستخدام إعادة التشكيل، واختبار التقسيم بالنسبة المئوية (%).

وكان اختيار أفضل أسلوب تصنيف لبناء نموذج يحقق أفضل تنبؤ للأداء الأكاديمي للطلاب الجامعي هو أحد أهداف هذه الدراسة. لهذا السبب؛ تم تطبيق ست تقنيات تصنيف

الجدول رقم (9): أداء نماذج التصنيف المختارة للسمات الكاملة.

ملخص خصائص تشغيل المُستقبل (ROC)	مقياس (F-) Measure	قيمة كوهن كابا Cohen's Kappa Value	الجزء التربيعي لمتوسط الخطأ (RMSE)	الدقة التنبؤية (Accuracy) (Prediction)	السنة الدراسية	نموذج الاختبار	نوع الخوارزمية
0.980	0.966	0.9374	0.1707	96.8912 %	السنة الأولى	استخدام إعادة التشكيل واختبار التقسيم بالنسبة المئوية (%).	J48
0.937	0.928	0.8556	0.2640	92.7817 %	السنة الثانية	استخدام إعادة التشكيل والتحقق المتقاطع 10 أضعاف	
0.974	0.953	0.9049	0.2102	95.2465 %	السنة الأولى	استخدام إعادة التشكيل والتحقق المتقاطع 10 أضعاف	JRip
0.930	0.928	0.8556	0.2620	92.7817 %	السنة الثانية	استخدام إعادة التشكيل والتحقق المتقاطع 10 أضعاف	


نوع الخوارزمية	نموذج الاختبار	السنة الدراسية	الدقة التنبؤية (Accuracy) (Prediction)	الجذر التربيعي لمتوسط الخطأ (RMSE)	قيمة كوهن كابا Cohen's Kappa Value	مقياس (F-) Measure	منحنى تشغيل تشغيل المستقبل (ROC)
NB	استخدام إعادة التشكيل واختبار التقسيم بالنسبة المئوية (%)	السنة الأولى	% 88.6010	0.3089	0.7722	0.879	0.969
	استخدام إعادة التشكيل والتقسيم بالنسبة المئوية (%)	السنة الثانية	% 91.7098	0.2685	0.8343	0.912	0.976
LR	استخدام اختبار التقسيم بالنسبة المئوية (%)	السنة الأولى	% 93.2642	0.2340	0.7708	0.812	0.960
	استخدام إعادة التشكيل واختبار التقسيم بالنسبة المئوية (%)	السنة الثانية	% 93.7824	0.2181	0.8739	0.929	0.981
SMO	استخدام إعادة التشكيل واختبار التقسيم بالنسبة المئوية (%)	السنة الأولى	% 94.8187	0.2276	0.8178	0.848	0.875
	استخدام إعادة التشكيل والتقسيم بالنسبة المئوية (%)	السنة الثانية	% 93.7824	0.2494	0.8742	0.930	0.938
MLP	استخدام إعادة التشكيل والتقسيم بالنسبة المئوية (%)	السنة الأولى	% 94.1901	0.2304	0.8838	0.943	0.963
	استخدام إعادة التشكيل واختبار التقسيم بالنسبة المئوية (%)	السنة الثانية	% 94.8187	0.2124	0.8941	0.939	0.989

اختبار التقسيم بالنسبة المئوية (%) من بيانات برنامج نظام (2008-2016م) السنة الأولى: أعلى دقة تنبؤية بلغت 96.8912%، وأقل قيمة

كما هو مبين في الجدول (9) أعلاه، من بين الخوارزميات الست حققت شجرة القرار (J48) باستخدام تقنية استخدام إعادة التشكيل،

كنموذج نهائي للتعرف المبكر للطلبة المعرضين للخطر، والشكل (12) يلخص تقييم أداء النماذج للست الخوارزميات في بيانات السنة الأولى من بيانات برنامج نظام (2008-2016م)، ويوضح أن أداء خوارزمية شجرة القرار (J48) باستخدام إعادة التشكيل واختبار التقسيم النسبة المئوية (%) هي الأفضل في جميع المقاييس.

للجذر التربيعي لمتوسط الخطأ (RMSE)، وكانت (0.1707)، وأعلى قيمة كوهن كابا (Cohen's Kappa Value)، وهي (0.9374)، وأعلى قيمة لمقياس F (F-Measure)، كانت (0.966)، وأعلى قيمة منحني خصائص تشغيل المُستقبل (ROC) وهي (0.980). ونتيجة ما سبق ذكره، تم اختيار خوارزمية شجرة القرار (J48) باستخدام تقسيم النسبة المئوية (%) وتقنية إعادة التشكيل



الشكل (12): تقييم أداء النماذج للست الخوارزميات في بيانات السنة الأولى من برنامج نظام (2008-2016م).

تظهر مصفوفة الارتباك للنموذج النهائي للتعرف المبكر على الطلبة المعرضين للخطر في الجدول (10) أعلاه. وفقاً لذلك، يُظهر أنه من بين 193 حالة، تم تصنيف 102 حالات بشكل صحيح على أنها فئة غير معرضة للخطر، وتم تصنيف 85 حالة بشكل صحيح على أنها فئة معرضة للخطر. وصنف هذا المصنف بشكل غير صحيح 6 حالات على أنها فئة معرضة للخطر، بينما هي في الحقيقة


حيث إن مصفوفة الارتباك للنموذج المحدد خوارزمية شجرة القرار (J48) باستخدام تقنية إعادة العينة موضحة في الجدول (10) أدناه.

الجدول رقم (10): مصفوفة الارتباك لخوارزمية شجرة القرار (J48) باستخدام إعادة التشكيل واختبار التقسيم بالنسبة المئوية (%).

A	B	
102	6	A=No-Risk (غير معرض للخطر)
0	85	B=At-Risk (معرض للخطر)

ونتيجة ما سبق ذكره، تم اختيار خوارزمية الشبكة العصبية (MLP) Multilayer Perception باستخدام اختبار التقسيم بالنسبة المئوية (%)، وإعادة تشكيل البيانات كنموذج نهائي للتعرف المبكر على الطلبة المعرضين للخطر. والشكل (13) يلخص تقييم أداء النماذج لست الخوارزميات في بيانات السنة الثانية المميزة باللون الأزرق من بيانات برنامج نظام (2016-2008م)، ويوضح أن أداء خوارزمية الشبكة العصبية Multilayer Perception (MLP) باستخدام تقنية إعادة التشكيل، واختبار التشكيل واختبار التقسيم بالنسبة المئوية (%) هي الأفضل في جميع المقاييس.

تنتمي إلى الفئة غير المعرضة للخطر. وتم تصنيف 0 حالة بشكل غير صحيح على أنها فئة غير معرضة للخطر، بينما في الواقع هي تنتمي إلى الفئة المعرضة للخطر. وكذلك حققت خوارزمية الشبكة العصبية Multilayer Perception (MLP) باستخدام تقنية إعادة التشكيل واختبار التقسيم بالنسبة المئوية (%) من بيانات برنامج نظام (2016-2008م) السنة الثانية: أعلى دقة تنبؤية بلغت 94.8187%، وأقل قيمة للجذر التربيعي لمتوسط الخطأ (RMSE) وكانت (0.2124)، وأعلى قيمة كوهن كابا (Cohen's Kappa Value) وهي (0.8941)، وأعلى قيمة لمقياس F (F-Measure) كانت (0.939)، وأعلى قيمة منحني خصائص تشغيل المُستقبل (ROC) وهي (0.989).



الشكل (13): تقييم أداء النماذج لست الخوارزميات في بيانات السنة الثانية من برنامج نظام (2016-2008م).

الجدول رقم (11): مصفوفة الارتباك لخوارزمية Multilayer Perception (MLP) باستخدام إعادة التشكيل والتحقق المتقاطع 10 أضعاف.

A	B	
264	20	A=No-Risk (غير معرض للخطر)
14	270	B=At-Risk (معرض للخطر)

حيث إن مصفوفة الارتباك للنموذج المحدد خوارزمية شجرة القرار (J48) باستخدام تقنية إعادة العينة موضحة في الجدول (11) أدناه.

الباحثان مقاييس منحى خصائص تشغيل المُستقبل، والجذر التربيعي لمتوسط الخطأ (RMSE)، من بين عدد من مقاييس التقييم التي نوقشت سابقاً نظراً لقدرتها على العمل بشكل جيد مع مجموعات البيانات غير المتوازنة (Mgalak, 2016)، كما هو الحال مع مجموعة البيانات المستخدمة في البحث الحالي.

حيث تعرض نتائج النماذج المبنية بدءاً من الميزات الثلاث الأولى (3، 10، 13) لبيانات السمة الأولى، ونتائج النماذج المبنية بدءاً من الميزتين الأولى (3، 10) لبيانات السنة الثانية، ثم تتم إضافة الميزات على التوالي حتى آخر رتبة مصنفة للميزات، ثم نلاحظ أفضل أداء لكل مصنف والذي يحدث إذا كانت قيمة منحى المميز لأداء المستقبل (ROC) لمجموعة فرعية معينة من الميزات أعلى من المجموعة الفرعية الأخرى، وأيضاً الحصول على أقل قيمة تعطى للجذر التربيعي لمتوسط الخطأ (RMSE) الذي تم اختصاره بـ (RE).

حيث تقرر في هذا الجزء من البحث أن تكون مساحة المجموعات الفرعية للميزات هي السمات الـ 7 الأولى في كل رتبة لبيانات السنة الدراسيتين الأولى، والميزات الـ 15 الأولى لبيانات السنة الدراسية الثانية؛ وذلك لأن إضافة ميزة بعد الميزات الـ 7 الأولى أو بعد الميزات الـ 15 الأولى لم يكن له تأثير

تظهر مصفوفة الارتباك للنموذج النهائي للتعرف المبكر على الطلبة المعرضين للخطر في الجدول (11) أعلاه. وفقاً لذلك، يُظهر أنه من بين 568 حالة، تم تصنيف 264 حالة بشكل صحيح على أنها فئة غير معرضة للخطر، وتم تصنيف 270 حالة بشكل صحيح على أنها فئة معرضة للخطر، وصنف هذا المصنف بشكل غير صحيح 20 حالة على أنها فئة معرضة للخطر، بينما هي في الحقيقة تنتمي إلى الفئة غير المعرضة للخطر، وتم تصنيف 14 حالة بشكل غير صحيح على أنها فئة غير معرضة للخطر، بينما هي في الواقع تنتمي إلى الفئة المعرضة للخطر.

2. تحديد مجموعة الميزات المثلى باستخدام النمذجة المتتالية لبيانات السنة الدراسية الأولى والثانية في برنامج إعداد معلم رياضيات التعليم الثانوي نظام الماستري (2008-2016م).

يتم عرض نتائج تحديد المجموعة الفرعية المثلى. حيث تم اتباع نفس منهجية (Harb & Moustafa, 2012; Mgalak, 2016; Remplhele, 2018; ALhassan, et al., 2020; Ekubo, 2020) لكن في دراستهم، والبعض منهم استخدم مقاييس الدقة التنبؤية، والمدة الزمنية لتنفيذ الخوارزمية. والأغلب استخدم مقياس منحى خصائص تشغيل المُستقبل، أو ما يسمى المنحى المميز لأداء المستقبل (ROC)، ومقياس الجذر التربيعي لمتوسط الخطأ (RMSE). وفي البحث الحالي اختار

كبير على قيمة منحني المميز لأداء المستقبل (ROC)، أو قيمة الجذر التربيعي لمتوسط الخطأ (RMSE). وفيما يلي تتم مناقشة نتائج كل مجموعة من نماذج اختيار أفضل خوارزمية، والنتائج النماذج المبنية على التكرار المبني للأمام بدءاً من الثلاث الميزات الأولى الأساسية حتى يتم استخدام جميع الميزات الـ 15 و 28 ميزة لبيانات السنة الأولى والثانية من بيانات برنامج إعداد معلم رياضيات التعليم الثانوي نظام الماستري (2008-2016م).

يناقش هذا الجزء ملخص أداء خوارزميات اختيار الميزة المستخدمة للحصول على أفضل الميزات لهذه الدراسة. والخوارزميات المستخدمة في هذا البحث هي نسبة الكسب (GR)، وكسب المعلومات (IG)، وتصفية الميزات (ReliefFAttributeEval)، وخوارزمتي (CfsSubsetEval)، ومجموعة الأغلفة من خلال خوارزمية الجار الأقرب

تم الحصول على هذه القيم من النمذجة المتتالية للميزات المرتبة لكل خوارزمية بدءاً من أهم الميزتين الأوليين حيث تم تصميم جميع الميزات الـ 15 لبيانات السنة الأولى، وجميع الميزات الـ 28 لبيانات السنة الثانية. وكان أداء خوارزمية تصفية الميزات أفضل مع الحد الأدنى من الميزات التي تحقق أعلى قيمة لـ (ROC) (0.969)، وأقل قيمة لـ (RMSE) (0.238) لبيانات السنة الأولى، وبالمثل كان أداء خوارزمية تصفية الميزات أفضل مع الحد الأدنى من الميزات التي تحقق أعلى قيمة لـ (ROC) تساوي (0.957)، وأقل قيمة لـ (RMSE) تساوي (0.283) لبيانات السنة الثانية.

الجدول رقم (12): ملخص أداء خوارزميات اختيار الميزة المستخدمة لاختيار أفضل الميزات لبيانات السنتين الدراسيتين الأولى والثانية من بيانات نظام (2008-2016م).

مدى أفضل الميزات	أقل قيمة للجذر التربيعي لمتوسط الخطأ (RMSE)	أعلى قيمة لمنحني المميز لأداء المستقبل (ROC)	الخوارزمية Algorithm
11 ميزة	0.963	0.239	CfsSubsetEval
22 ميزة	0.956	0.289	
14 - 3	0.963	0.233	GainRatioAttributeEval
25 - 2	0.953	0.287	



مدى أفضل الميزات	أقل قيمة للجذر التربيعي لمتوسط الخطأ (RMSE)	أعلى قيمة لمنحنى المميز لأداء المستقبل (ROC)	الخوارزمية Algorithm	
14-3	0.963	0.233	السنة الأولى	InfoGainAttributeEval
23-2	0.954	0.291	السنة الثانية	
7-3	0.969	0.238	السنة الأولى	ReliefFAttributeEval
15-2	0.957	0.283	السنة الثانية	
13 ميزة	0.949	0.289	السنة الأولى	WrapperSubsetEval With:IBK
27 ميزة	0.949	0.289	السنة الثانية	

بالتالي فإن العوامل المؤثرة على التنبؤ بالأداء الأكاديمي، والتعرض للخطر لدى طلبة السنة الأولى يكمن في المقررات الدراسية الآتية على الترتيب حسب الأهمية التي تم الحصول عليها: رياضيات متقطعة، وتفاضل وتكامل (1)، وجبر وحساب مثلثات، وفيزياء عامة (1)، ولغة عربية (102)، ولغة عربية (101)، وفيزياء عامة (2).

وكذلك نموذج التصنيف ذو الأداء الأفضل الذي يستخدم خوارزمية تصفية الميزات (ReliefFAttributeEval) هو تصنيف خوارزمية Logistic (LR) لبيانات السنة الثانية وأداؤه مع الحد الأدنى من الميزات بين نطاقات 2-15 ميزة له أعلى قيمة لـ (ROC)، وتساوي (0.954)، وأدنى قيمة لـ (RE) تساوي (0.283) مقارنة بالميزات الكاملة، حيث كانت قيمة (ROC) تساوي (0.947)، وقيمة (RE) تساوي (0.291). وهذا يدل على أن الحد الأدنى من الميزات يعمل بشكل أفضل من

يوضح ملخص أداء خوارزميات اختيار الميزة أن الحد الأدنى من الميزات يمكن أن يؤدي بشكل أفضل من الميزات الكاملة؛ لأن النتائج في جميع الخوارزميات تظهر مستوى أعلى من الأداء مع ميزات أقل من الميزات الكاملة. حيث إن نموذج التصنيف ذا الأداء الأفضل الذي يستخدم خوارزمية تصفية الميزات (ReliefFAttributeEval) هو تصنيف خوارزمية Logistic (LR) لبيانات السنة الأولى، وأداؤه مع الحد الأدنى من الميزات بين نطاقات 3-7 ميزة له أعلى قيمة لـ (ROC) مقدارها (0.963) وأدنى قيمة لـ (RE) وتساوي (0.238) مقارنة بالميزات الكاملة، حيث كانت قيمة (ROC) تساوي (0.961) وقيمة (RE) تساوي (0.245). وهذا يدل على أن الحد الأدنى من الميزات يعمل بشكل أفضل من الميزات الكاملة. لذلك، يتجاهل البحث الحالي 8 ميزات مرتبة، وتنفذ أفضل 7 ميزات مرتبة باستخدام خوارزمية تصفية الميزات في التنبؤ،

تظهر النتائج من خلاصة خوارزميات اختيار الميزة في الجزء السابق (2) أن خوارزمية تصفية الميزات باستخدام خوارزمية Logistic Regression (LR) قد حققت أفضل أداء مع الحد الأدنى من السمات لأعلى 7 سمات مرتبة. ويبنى هذا الجزء نموذجًا جديدًا للبحث مع 7 سمات محددة، وخوارزمية تصنيف Logistic Regression (LR)، يحقق أفضل القيم من عملية النمذجة المتتالية. وتبدأ عملية النمذجة باستخراج السمات المحددة في WEKA من برنامج التعلم الآلي، ثم الاستفادة من خوارزمية تصنيف الانحدار اللوجستي Logistic Regression (LR) لبناء النموذج. حيث يعرض الجدول (13) ملخص نتائج مجموعة بيانات السنة الأولى للنموذج الذي تم إنشاؤه باستخدام مصنف (LR) وأفضل الميزات.

الميزات الكاملة. لذلك يتجاهل البحث الحالي 13 ميزة مرتبة، وتنفذ أفضل 15 ميزة مرتبة باستخدام خوارزمية تصفية الميزات في التنبؤ، والميزات الـ 8 المختارة للتنبؤ، أو العوامل المؤثرة على التنبؤ بالأداء الأكاديمي، والتعرض للخطر لدى طلبة السنة الثانية يكمن في المقررات الدراسية الآتية على الترتيب حسب الأهمية التي تم الحصول عليها: جبر وحساب مثلثات، وتفاضل وتكامل (1)، وتفاضل وتكامل (2)، وهندسة وقياس (2)، وجبر خطي (2)، ورياضيات متقطعة، وهندسة وقياس (1)، وتفاضل وتكامل (3)، ومبادئ الإحصاء، وفيزياء عامة (1)، ولغة عربية (102)، وجبر خطي (1)، ونظام التعليم في اليمن، وتقنيات التعليم (1)، وفيزياء عامة (2).

### 3. أداء خوارزمية التصنيف Logistic Regression باستخدام أفضل الميزات المحددة لبيانات السنة الأولى:

الجدول رقم (13): ملخص لنتائج أداء خوارزمية تصنيف Logistic Regression (LR) باستخدام مجموعة بيانات أفضل الميزات مع مجموعة بيانات السنة الأولى من بيانات برنامج نظام (2008-2016م) باستخدام التحقق من الصحة 10 أضعاف واختبار النسبة المئوية (%).

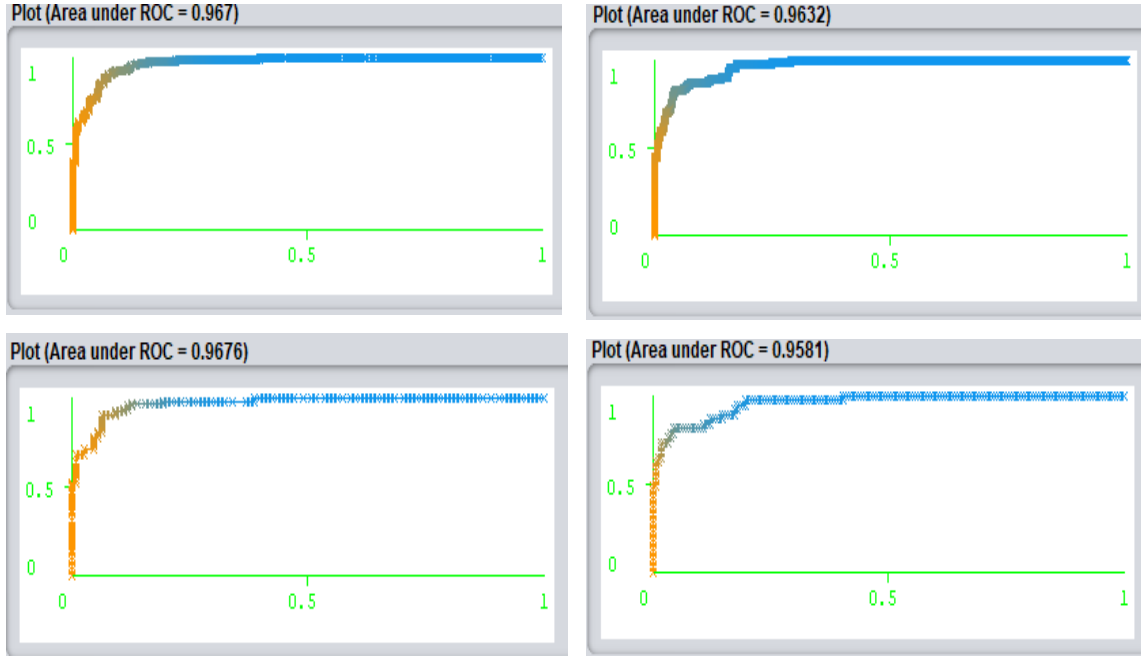
النموذج (Model)				التجربة
(LR) Logistic باستخدام إعادة التشكيل واختبار النسبة المئوية (%)	(LR) Logistic باستخدام اختبار النسبة المئوية (%)	(LR) Logistic باستخدام إعادة التشكيل واختبار التحقق من الصحة 10 أضعاف	(LR) Logistic باستخدام التحقق من الصحة 10 أضعاف	
% 91.1917	% 92.7461	% 91.1972	% 91.9156	الدقة التنبؤية (Prediction Accuracy)

النموذج (Model)				التجربة
(LR) Logistic باستخدام إعادة التشكيل واختبار النسبة المئوية (%)	(LR) Logistic باستخدام اختبار النسبة المئوية (%)	(LR) Logistic باستخدام إعادة التشكيل واختبار التحقق من الصحة 10 أضعاف	(LR) Logistic باستخدام التحقق من الصحة 10 أضعاف	
0.2655	0.2394	0.2637	0.2375	الجذر التربيعي لمتوسط الخطأ (RMSE)
0.8233	0.7505	0.8239	0.7144	قيمة كوهن كابا (Cohen's Kappa Value)
0.953	0.730	0.923	0.718	المعدل الإيجابي الحقيقي (TP Rate) أو الاسترجاع (Recall) أو الحساسية (Sensitivity)
0.120	0.026	0.099	0.036	المعدل الإيجابي الكاذب (FP Rate)
0.862	0.871	0.903	0.813	الدقة (Precision)
0.905	0.794	0.913	0.763	مقياس F- (F-Measure)
0.968	0.958	0.967	0.963	ROC Area
0.800	0.974	0.901	0.964	النوعية (Specificity)

أفضل نسبة دقة تنبؤية، وأقل نسبة خطأ (RMSE)، وأعلى قيمة لكوهن كابا (Cohen's Kappa Value)، وأعلى قيمة لمنحنى خصائص تشغيل المستقبل (ROC)، وأعلى قيمة لمقياس-F (F-Measure) وكانت: 92.7461%، 0.2394، 0.7505، 0.958، 0.794 على الترتيب من التجارب الأخرى.

والشكل (14) يبين رسم منحنى (ROC) لخوارزمية Logistic (LR) في حالتي البيانات الأصلية، وإعادة تشكيل البيانات باستخدام اختبار التحقق من الصحة 10 أضعاف يميناً، والنسبة المئوية (%) يساراً.

وبناءً على التجارب الأربعة المذكورة في الجدول أعلاه، نجد أن خوارزمية (LR) Logistic باستخدام اختبار النسبة المئوية (%) للبيانات الأصلية في السنة الأولى: سجلت



الشكل (14): منحني (ROC) للبيانات الأصلية، وإعادة التشكيل باستخدام اختبار التحقق من الصحة 10 أضعاف، والنسبة المئوية (%) لخوارزمية Logistic (LR).

السمات المحددة في WEKA من برنامج التعلم الآلي، ثم الاستفادة من خوارزمية (LR) Logistic في بناء النموذج. حيث يعرض الجدول (14) ملخص نتائج مجموعة بيانات السنة الثانية للنموذج الذي تم إنشاؤه باستخدام مصنف وأفضل الميزات.

4. أداء خوارزمية التصنيف Logistic (LR) Regression باستخدام أفضل الميزات المحددة لبيانات السنة الثانية:

وبالمثل يبني هذا الجزء نموذجًا جديدًا للبحث مع 15 سمة محددة وخوارزمية (LR) Logistic، يحقق أفضل القيم من عملية النمذجة المتتالية. وتبدأ عملية النمذجة باستخراج

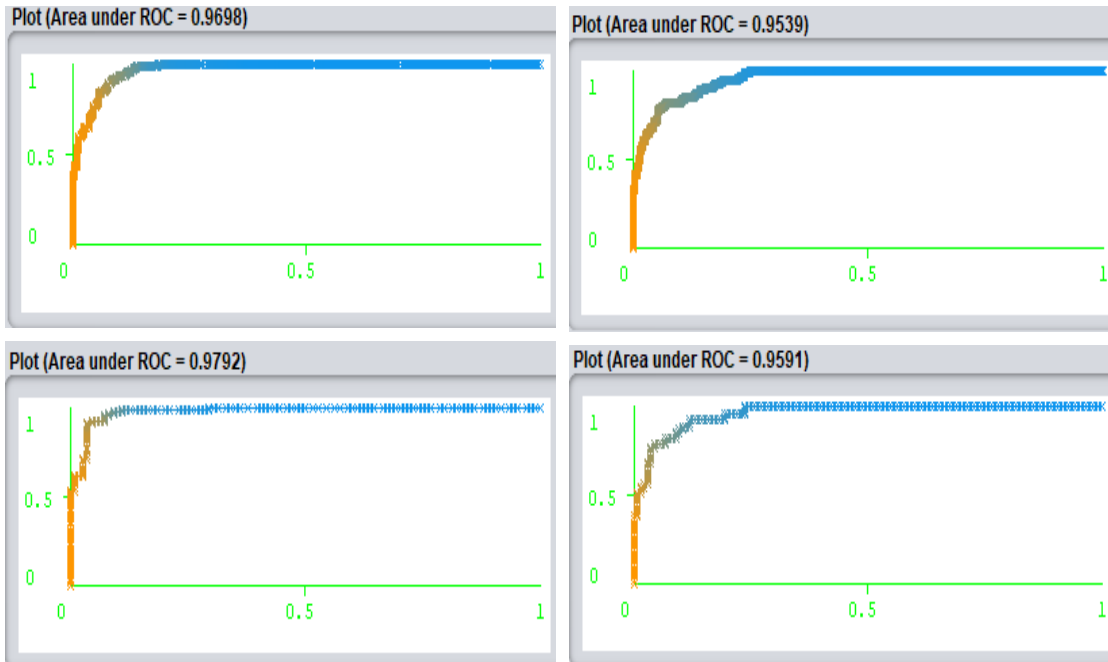
الجدول (14): ملخص لنتائج أداء خوارزمية Logistic (LR) باستخدام مجموعة بيانات أفضل الميزات مع مجموعة بيانات السنة الثانية من بيانات برنامج نظام (2016-2008م) باستخدام التحقق من الصحة 10 أضعاف واختبار النسبة المئوية (%).

النموذج (Model)				التجربة
(LR) Logistic باستخدام إعادة التشكيل واختبار النسبة المئوية (%)	(LR) Logistic باستخدام اختبار النسبة المئوية (%)	(LR) Logistic باستخدام إعادة التشكيل واختبار التحقق من الصحة 10 أضعاف	(LR) Logistic باستخدام التحقق من الصحة 10 أضعاف	
92.228%	90.1554%	91.3732%	89.6309%	الدقة التنبؤية (Prediction Accuracy)
0.2277	0.2773	0.2538	0.2835	الجذر التربيعي لمتوسط الخطأ (RMSE)

النموذج (Model)				التجربة
(LR) Logistic باستخدام إعادة التشكيل واختبار النسبة المئوية (%)	(LR) Logistic باستخدام اختبار النسبة المئوية (%)	(LR) Logistic باستخدام إعادة التشكيل واختبار التحقق من الصحة 10 أضعاف	(LR) Logistic باستخدام التحقق من الصحة 10 أضعاف	
0.8425	0.7601	0.8275	0.7421	قيمة كوهن كابا (Cohen's Kappa) (Value)
0.918	0.780	0.926	0.791	المعدل الإيجابي الحقيقي (TP Rate) أو الاسترجاع (Recall) أو الحساسية (Sensitivity)
0.074	0.045	0.099	0.062	المعدل الإيجابي الكاذب (FP Rate)
0.907	0.885	0.904	0.838	الدقة (Precision)
0.912	0.829	0.915	0.814	مقياس F- (F-Measure)
0.979	0.959	0.970	0.954	ROC Area
0.926	0.955	0.901	0.938	النوعية (Specificity)

التحقق من الصحة 10 أضعاف يميناً،  
وإعادة التشكيل باستخدام اختبار النسبة المئوية (%) يساراً.

والشكل (15) يبين رسم منحنى (ROC) لخوارزمية Logistic (LR) في حالتها الأصلية، وإعادة تشكيل البيانات باستخدام



الشكل (15): منحنى (ROC) للبيانات الأصلية، وإعادة التشكيل وباستخدام اختبار التحقق من الصحة 10 أضعاف، والنسبة المئوية (%) لخوارزمية Logistic (LR).

الجامعيين في قسم مناهج الرياضيات وطرائق تدريسها، وذلك من خلال مراجعة الأدبيات على نطاق واسع، واستعرض البحث أسباب ضعف الأداء الأكاديمي وكان من هذه الأسباب: مقررات التخصص والمقررات الداعمة للتخصص وقد تم تحديد هذه الأسباب من خلال المراجعة، وتحديد السمات ذات الصلة أثناء عملية جمع البيانات والمعالجة المسبقة.

• **السؤال البحثي الثاني في البحث الحالي هو:**

"ما أفضل نموذج مصنف من بين المصنفات الستة المشتركة التي تم اختيارها من مجموعة بيانات برنامج الإعداد باستخدام خوارزميات الذكاء الاصطناعي للتعقيب عن البيانات التعليمية؟".

وتمت الإجابة عن هذا السؤال من خلال

الأسئلة الفرعية التي تمَّ الإجابة عليها وهي:

لمقارنة أداء التنبؤ لنماذج المصنفات المختارة على مجموعة بيانات البحث من حيث أعداد الطلبة المصنفين بشكل صحيح الذين تم تصنيفهم بشكل غير صحيح، وضح الجزء (1) أن خوارزمية شجرة القرار (J48) لبيانات السنة الأولى، وخوارزمية الإدراك متعدد الطبقات (MLP) لبيانات السنة الثانية من برنامج نظام (208-2016م) باستخدام إعادة التشكيل واختبار التقسيم بالنسبة المئوية هي

وبناءً على التجارب الأربعة المذكورة في الجدول أعلاه، نجد أن خوارزمية (LR) Logistic باستخدام إعادة التشكيل، واختبار النسبة المئوية (%) في السنة الثانية: سجلت أفضل نسبة دقة تنبؤية، وأقل نسبة خطأ (RMSE)، وأعلى قيمة لكوهن كايا (Cohen's Kappa Value)، وأعلى قيمة لمنحنى خصائص تشغيل المُستقبل (ROC)، وأعلى قيمة لمقياس F-(F-Measure)، وكانت: 92.228%، 0.2277، 0.8425، 0.979، 0.912 على الترتيب من التجارب الأخرى.

**القسم (5): خلاصة استنتاجات البحث**

**والتوصيات والمقترحات**

توضح الخلاصة الإجابة على أسئلة البحث، حل مشكلة تحديد الطالب الجامعي ذي (المخاطر المرتفعة-المخاطر المنخفضة) في كلية التربية جامعة صنعاء.

• **السؤال البحثي الأول في البحث الحالي هو:**

"ما العوامل المؤثرة في التنبؤ بالأداء الأكاديمي للطلبة المعرضين للخطر ذوي التدخل لكل من مجموعة بيانات برنامج الإعداد باستخدام خوارزميات الذكاء الاصطناعي للتعقيب عن البيانات التعليمية؟". للإجابة عن هذا السؤال، سعى البحث إلى تحقيق الهدف: لفحص ووصف العوامل التي تؤثر على ضعف أداء الطلبة

ثلاثة خوارزميات ترتيب وهي: (نسبة الكسب GainRatio، كسب المعلومات InfoGain، التصفية ReliefF)، وخوارزميتان؛ لتحديد أفضل الميزات وهي (القائمة على الارتباط SfcSubsetEval، ومجموعة الأغلفة من خلال الجار الأقرب WrapperSubsetEval)، وكانت أفضل الخوارزميات في تحديد أكثر الميزات تنبؤاً خوارزمية التصفية ReliefF لبيانات السنتين الأولى والثانية.

ولتحديد العدد الأمثل للميزات التي تحقق أعلى أداء تنبؤي لنماذج التصنيف المختارة في مجموعة البيانات. فقد تم توضيح العدد الأمثل للميزات في الجدول (12) لبيانات السنتين الأولى والثانية.

#### • السؤال البحثي الرابع في البحث الحالي هو:

"ما أفضل تقنيات الذكاء الاصطناعي وأفضل الميزات الفرعية المثلى لتقديم نظام أداء تنبؤي للتنبؤ بالأداء الأكاديمي في تصنيف الطلبة فئة التدخل المرتفع؟".

أفضل تقنيات الذكاء الاصطناعي، وأفضل الميزات الفرعية المثلى في تنفيذ نظام الإنذار المبكر للتنبؤ بالأداء الأكاديمي في تصنيف الطلبة فئة التدخل المرتفع في برنامج نظام (2016-2008م) المنفذ حالياً في قسم مناهج الرياضيات بكلية التربية جامعة صنعاء حتى وقت تنفيذ البحث الحالي هي خوارزمية

أفضل النماذج من خلال التصنيف الصحيح الأكبر لعدد من السجلات، حيث كان عدد الطلبة المصنفين بشكل غير صحيح كان قليل.

ولمقارنة أداء التنبؤ لنماذج المصنفات باستخدام المقاييس الخمسة المختارة تم إجراء مقارنة بين أداء نماذج التصنيف باستخدام عدد من المقاييس، ركزت الدراسة على خمسة مقاييس هي: أعلى قيمة للدقة التنبؤية (PA) في تصنيف فئة التدخل المرتفع، وأقل قيمة للجذر التربيعي لمتوسط الخطأ (RE)، وأكبر قيمة لـ كوهن كابا (Cohen's Kappa Value)، وأكبر قيمة لـ مقياس F (F-Measure)، وأعلى قيمة لمنحنى خصائص تشغيل المُستقبل (ROC) كانت النماذج المختارة أفضل نماذج تصنيف، والقيم مبينة في الجدول (9) لبيانات برنامج الإعداد نظام (2016-2008م).

#### • السؤال البحثي الثالث في البحث الحالي هو:

"ما المجموعة الفرعية المثلى للميزات من العدد الإجمالي للميزات لمجموعة بيانات برنامج الإعداد باستخدام خوارزميات الذكاء الاصطناعي للتنقيب عن البيانات التعليمية؟".

وتمت الإجابة عن هذا السؤال من خلال الأسئلة الفرعية التي تمَّ الإجابة عليها وهي:

لتحديد أكثر الميزات التنبؤية من القوائم الخمس المختارة التي تم تصنيفها باستخدام خوارزميات الترتيب والأفضلية. تم استخدام

أدائهم والتقليل من الخطر، والهدر الأكاديمي ومعرفة المشكلات التي تواجههم أثناء دراستهم، وتقديم النصائح والإرشادات التعليمية لهم بشكل جيد، ومراقبة سلوك تعلمهم بشكل مستمر.

• إعادة النظر في العوامل المؤثرة في الأداء الأكاديمي التي أدت إلى مستوى أداء أكاديمي منخفض، وخصوصاً المقررات الخاصة بالتخصص من خلال التغيير في تقديم المقرر الدراسي والأنشطة وأساليب التقييم، والاستفادة من التوجهات الحديثة القائمة على مهارات القرن الحادي والعشرين، والمنحى التكاملية Steam، والمشروعات،... الخ.

**المقترحات:** يقترح الباحثان إجراء الآتي:

- إيجاد فرصة للباحثين لتطوير أساليب ونماذج تراقب سلوكيات تعلم الطلبة، ونتائج التعلم في الجامعات اليمنية عامة، وجامعة صنعاء كلية التربية-قسم مناهج الرياضيات وطرائق تدريسها خاصة في مختلف الأقسام.
- تطبيق خوارزميات الذكاء الاصطناعي المختلفة الأخرى الفردية، واختيار أفضل خوارزمية في التنبؤ بالأداء الأكاديمي في وقت مبكر من العملية التعليمية مع تحديد الميزات المثلى الفرعية، ومقارنتها مع خوارزميات التنقيب المجمع.

تصنيف الانحدار اللوجستي (LR Logistic Regression) لبيانات السنتين الأولى والثانية.

**التوصيات:** في ضوء النتائج التي توصل إليها هذا

البحث يمكن أن نقدم عدداً من التوصيات، هي:

• الأخذ بعين الاعتبار في استخدام تنقيب البيانات التعليمية EDM، وتقنياتها في التنبؤ بالأداء الأكاديمي للطلبة، والاستفادة من ذلك في تخصيص خبرات تعلم الطلبة بناءً على احتياجاتهم وخصائصهم المختلفة.

• توفير البيانات المخزنة من مصادرها المختلفة للباحثين، واستكمالها، وإضافة بيانات ما قبل الجامعة، وبيانات ديموغرافية لجميع طلبة الكليات والجامعات من قبل المختصين، والتحقق من رصد جميع بيانات الطلبة الفعلية في سجلات قاعدة البيانات.

• إعطاء الفكرة العامة لنظام التنبؤ المصمم في البحث الحالي لهيئة التدريس في قسم مناهج الرياضيات وطرائق تدريسها، والجهة المسؤولة عن العملية التعليمية في تقديم مقترحات للتدخلات الأكاديمية والتربوية المناسبة في الوقت المناسب للطلبة ذوي التدخل المرتفع قبل تعرضهم لخطر الفشل والتسرب.

• إعطاء الطلبة فكرة عامة عن مستوى أدائهم الأكاديمي من السنة الأولى، والثانية التي تم التنبؤ بها مما يساعدهم على تحسين



- إجراء دراسات حول معرفة مدى تقدم أداء الطلبة خلال السنوات الدراسية باستخدام تنقيب البيانات وخوارزميات الذكاء الاصطناعي الخاضعة للإشراف وغير الخاضعة للإشراف.
- محاولة عمل تحسين النظام التنبؤي (نظام إنذار مبكر) المصمم عن طريق خوارزميات التعلم الخاضع للإشراف المستخدمة في هذا البحث، والتعلم غير الخاضع للإشراف من خلال قواعد الارتباط، والعنقدة؛ لدعم مجموعة البيانات غير المسماة، وجعل البيانات جاهزة لخوارزميات التعلم الخاضع وغير الخاضع للإشراف.
- إجراء دراسة مقارنة بين مجموعات من الطلبة اتبع معها أنظمة الإنذار المبكر وقدمت لهم التدخلات المناسبة في وقت مبكر، ومجموعات من الطلبة لم يطبق عليها أنظمة الإنذار المبكر.

### المراجع العربية:

- الحسين، مديحة مهدي محمد. (2017م). استكشاف معرفة مؤثرات التحصيل الأكاديمي لنتيجة طلاب مرحلة الأساسي باستخدام تقنيات تنقيب في البيانات: دراسة حالة (شهادة التعليم الأساسي ولاية القضارييف من العام 2005م وحتى العام 2016م)، رسالة ماجستير، جامعة

- النيلين، كلية علوم الحاسوب وتقانة المعلومات، السودان.
- قمر، مجذوب أحمد محمد أحمد؛ أحمد، محجوب الصديق محمد؛ أبكر، موسى مكي حامد؛ داؤود، محمد عبد الله. (2017م). الأداء الأكاديمي لأعضاء هيئة التدريس بكليتي التربية جامعتي دنقلا والقضارف كما يدركها الطلبة، المجلة العربية لضمان جودة التعليم الجامعي، مج (10)، ع (29)، ص 3-18.
- مجدي، نرمين. (2020م). الذكاء الاصطناعي وتعلم الآلة، صندوق النقد الدولي، سلسلة كتيبات تعريفية، العدد (3)، أبو ظبي، الإمارات العربية المتحدة.
- محمد، أسماء السيد؛ محمد، كريمة محمود. (2020م). تطبيقات الذكاء الاصطناعي ومستقبل تكنولوجيا التعليم، ط1، المجموعة العربية للتدريب والنشر، القاهرة، مصر.
- موسى، عبد الله؛ بلال، أحمد حبيب. (2019م). الذكاء الاصطناعي ثورة في تقنيات العصر، ط1، المجموعة العربية للتدريب والنشر، القاهرة، مصر.
- وزان (ب)، ميلاد. (2022م). التعلم العميق - من الأساسيات حتى بناء شبكة عصبية عميقة بلغة الباثيون، (ترجمة علاء طعيمة)، كلية علوم الحاسوب وتكنولوجيا المعلومات، جامعة القادسية، العراق.

## Foreign References:

- Acharya, A. and Sinha, D. (2014). Application of feature selection methods in educational data mining. *International Journal of Computer Applications*, vol. 10, no.32, pp. 34-38.
- Alhassan. A.; Bassam, Z.; Mueen, A. (2020). Predict Students' Academic Performance based on their Assessment Grades and Online Activity Data. (IJACSA) International Journal of Advanced Computer Science and Applications, Vol. 11, No. 4, pp. 185-194.
- Ali, I. F.H. (2019). Mining Students' Data to Predict and Evaluate Their Academic Performance (Case study: Faculty of Science, University of Nyala). Master thesis, Sudan University of Science and Technology, College of Graduate Studies.
- Altaye, S. S. (2019). Use of Data Mining for Determining Higher Education Students' Performance. The Faculty of Informatics of St. Mary 's University. Master thesis of Science in Computer Science.
- Alturki, S. & Alturki, N. (2021). Using educational data mining to predict students' academic performance for applying early interventions. *Journal of Information Technology Education: Innovations in Practice*, Vol. 20, pp. 121-137. <https://doi.org/10.28945/4835>.
- Anuradha, C. & Velmurugan, T. (2016). "Feature Selection Techniques to Analyse Student Academic Performance using Naïve Bayes Classifier", in The 3rd International Conference on Small & Medium Business, pp. 345-350.
- Asif, R.; Hina, S.; Haque, S. I. (2017 (b)). Predicting Student Academic Performance using Data Mining Methods, IJCSNS International Journal of Computer Science and Network Security, vol.17, no.5, pp. 187-191.
- Asif, R.; Merceron, A.; Pathan, M. K. (2015). Predicting Student Academic Performance at Degree Level: A Case Study. *IJ. Intelligent Systems and Applications*, Vol 01, pp. 49-61.
- Asif, R.; Merceron, A.; Pathan, M. K. (2014). Predicting Student Academic Performance at Degree Level: A Case Study. *International Journal of Intelligent Systems and Applications*, vol. 7, no. 1, pp. 49-61.
- Aubaid, A. M & Mishra, Alok. (2020), A Rule-Based Approach to Embedding Techniques for Text Document Classification, *Appl. Sci.* 2020, 10, 4009; doi:10.3390/app10114009
- Aulck, L.; Velagapudi, N.; Blumenstock, J.; West, J. (2016). Predicting Student Dropout in Higher Education. *International Conference on Machine Learning (ICML)*, pp. 16–20. <https://doi.org/10.1002/prot.24187>.
- Awaji, M. (2018). Evaluation of Machine Learning Techniques for Early Identification of At-Risk Students. College of Engineering and Computing Nova Southeastern University. PhD thesis of Information Technology.
- Ayenew, E. B. (2018). Factor Identification for Quality Education Performance Using Data Mining Technique. Master thesis, Bahir Dar University Bahir Dar Institute of Technology School Of Research And Postgraduate Studies Faculty Of Computing.
- Begum, S. & Padmannavar, S. S. (2022). Prediction of Student Performance using Genetically Optimized Feature Selection with Multiclass Classification, *International Journal of Engineering Trends and Technology*, Vol. 70 , no. 4, pp. 223-235, ISSN: 2231 – 5381 / <https://doi.org/10.14445/22315381/IJET-T-V70I4P219>.

- Bhullar, M. S. & Kaur, A. (2012). Use of data mining in education sector. In Proceedings of the World Congress on Engineering and Computer Science, vol. 1, PP. 24–26.
- Chai, T. & Draxler, R. R. (2014). Root mean square error (rmse) or mean absolute error (mae)?-arguments against avoiding rmse in the literature. *Geoscientific Model Development*, 7(3), pp. 1247-1250.
- Ekubo, E. A. (2020). Predictive system for characterizing low performance of Undergraduate students using machine learning techniques. *Computer Science and Information Systems at the North-West University, Doctoral Dissertations of Philosophy in Computer and Information Sciences*.
- Greven, A., Keller, G., and Warnecke, G. (2014). *Entropy*. Princeton university press.
- Han, J., Kamber, M. & Pei, J. (2011). *Data Mining Concepts and Techniques*, third Edition, Morgan Kaufmann Publishers is an imprint of Elsevier.
- Harb, H. M. & Moustafa, M. A. (2012). Selecting Optimal Subset of Features for Student Performance Model. *IJCSI International Journal of Computer Science Issues*, Vol. 9, Issue 5, No. 1, ISSN (Online): 1694-0814.
- Hoque, M. I.; Azad, A. k.; Tuhin, M. A. H.; Salehin, Z. U. (2020). University Students Result Analysis and Prediction System by Decision Tree Algorithm, *Advances in Science, Technology and Engineering Systems Journal*, Vol. 5, No. 3, pp. 115-122.
- Huang, S. H. (2015). Supervised feature selection: A tutorial. *Artificial Intelligence Research*, vol. 4, no. 2, pp. 22-37.
- Jantawan, B. & Tsai, C. F. (2014). A comparison of filter and wrapper approaches with data mining techniques for categorical variables selection. *International Journal of Innovative Research in Computer and Communication Engineering*, vol. 2, no. 6, pp. 4501-4508.
- Jim´enez-Valverde, A. (2012). Insights into the area under the receiver operating characteristic curve (auc) as a discrimination measure in species distribution modelling. *Global Ecology and Biogeography*, vol. 21, no. 4, pp. 498-507.
- Jimenez, V. H.; Jimenez, A.; Ortiz-Rojas, M.; Marn, J.; Moreno-Marcos, P. M.; Mu~noz-Merino, P. J.; Kloos, C. D. (2020), An early warning dropout model in higher education degree programs: A case study in Ecuador, for this paper by its authors. Use permitted under Creative Commons License Attribution 4.0 International (CC BY 4.0).
- Kabakchieva, D. (2012). Student Performance Prediction by Using Data Mining Classification Algorithms. *International Journal of Computer Science and Management Research*, vol. 1, no. 4, pp. 686– 690.
- Karegowda, A. G.; Manjunath, A.; Jayaram, M. (2010). Comparative study of attribute selection using gain ratio and correlation based feature selection. *International Journal of Information Technology and Knowledge Management*, vol. 2, no. 2, pp. 271-277.
- M´arquez-Vera, C.; Cano, A.; Romero, C.; Ventura, S. (2013). Predicting student failure at school using genetic programming and different data mining approaches with high dimensional and imbalanced data. *Applied intelligence*, 38 (3), pp. 315-330.
- Machado, J. & Curado, A. P. (2006). Percursos escolares dos estudantes da universidade de lisboa: à entrada: um retrato sociográfico dos estudantes inscritos no 1 ano. <http://hdl.handle.net/10451/2991>.

- Mchugh, M. L. (2012). Interrater reliability: the kappa statistic. *Biochemia medica*, vol. 22, no. 3, pp. 276-282.
- Mgala, M. (2016). Investigating Prediction Modelling of Academic Performance for Students in Rural Schools in Kenya. Faculty of Science University of Cape Town. PhD thesis of Philosophy in Computer Science.
- Mohamada, S. K. & Tasir, Z. (2013). Educational data mining: A review, The 9th International Conference on Cognitive Science, *Procedia-Social and Behavioral Sciences* 97, PP. 320 – 324.
- Ng, A. (2012). Cs 229 lecture notes: Support vector machines. [online] cs229.stanford.edu/notes.
- Oreski, D.; Pihir, I.; Konecki, M. (2017). CRISP-DM Process Model in Educational Setting. *Economic and Social Development: Book of Proceedings*, pp.19-28.
- Pardos, Z. A.; Wang, Q. Y.; Trivedi, S. (2012). The real world significance of performance prediction. *International Educational Data Mining Society*.
- Powers, D. (2008). Evaluation: From Precision, Recall and F-measure to ROC, Informedness, Markedness & Correlation, *Journal of Machine Learning Technologies*, vol. 2, no. 1, pp. 37-63.
- Remphele, F. (2018). Predicting grade progression within the Limpopo Education System, Faculty of Science at the University of Cape Town, Department Of Compute Science, Master thesis of Philosophy Information Technology.
- Rifat, Md R. I.; Al Imran, A.; Badrudduza, A. S. M. (2019). Educational Performance Analytics of Undergraduate Business Students, *IJ. Modern Education and Computer Science*, 7, pp. 44-53 ,Online in MECS (<http://www.mecs-press.org/>).
- Romero, C. & Ventura, S. (2010). Educational data mining: a review of the state of the art. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 40, no. 6, pp.601-618.
- Romero, C. & Ventura, S., (2007). Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications*, 33 (1), pp.135-146.
- Sadiq, M. H. & Ahmed, N. S. (2019). Classifying and Predicting Students' Performance using Improved Decision Tree C4.5 in Higher Education Institutes. *Journal of Computer Science*, 15(9), pp. 1291-1306 DOI: 10.3844/jcssp.2019.1291.1306.
- Saeys, Y.; Inza, I.; Larrañaga, P. (2007). A review of feature selection techniques in bioinformatics. *Bioinformatics*, vol. 23, no. 19, pp. 2507-2517.
- Sarlis, N. V. and Christopoulos, S. R. G. (2014). Visualization of the significance of Receiver Operating Characteristics based on confidence ellipses. *Computer Physics Communications*, vol. 185, no. 3, pp. 1172-1176.
- Sen, B. U.; car, E.; Delen, D. (2012). Predicting and analyzing secondary education placement-test scores: A data mining approach. *Expert Systems with Applications*, vol. 39, no. 10, pp. 9468-9476.
- Shaikh, A.; Mahoto, N.; Khuhawar, F.; Memon, M. (2015). Performance evaluation of classification methods for heart disease dataset. *Sindh University Re-search Journal-SURJ (Science Series)*, 47 (3).
- Siemens, G. & Baker, R. S. (2012). Learning analytics and educational data mining: towards communication and collaboration. In *Proceedings of the 2nd international conference on learning analytics and knowledge*, pp. 252-254. ACM.
- Solomon, D.; Patil, P. s.; Agrawal, P. p. (2018). Predicting Performance and Potential Difficulties of University

- Student using Classification: Survey Paper. International Journal of Pure and Applied Mathematics, 118(18), PP. 2703–2707.
- Tan, P.N.; Steinbach, M.; Karpatne, A.; Kumar, V. (2019). Introduction to Data Mining. Pearson Education Limited, Second Edition.
  - Thai-Nghe, N.; Busche, A.; Schmidt-Thieme, L. (2009). Improving academic performance prediction by dealing with class imbalance. In Intelligent Systems Design and Applications, 2009. ISDA'09. Ninth International Conference on, pp. 878-883. IEEE.
  - Umer, M. U. (2019). A Data Mining Approach on Occupational Competency Assessment: The Case of Addis Ababa, Master thesis in Information Systems Engineering, Adama Science and Technology University, Ethiopia.
  - Wood, J. M. (2007). Understanding and computing cohen's kappa: A tutorial. WebPsychEmpiricist. Web Journal at <http://wpe.info/>.
  - Yadav, S. K. & Pal, S. (2012). Data mining: A prediction for performance improvement of engineering students using classification. World of Computer Science and Information Technology Journal (WCSIT), 2 (2), pp. 51–56.
  - Yassein, N. A.; Gaffer, R.; Helali, M.; Mohomad, S. B. (2017). Citation: Predicting student academic performance in KSA using data mining techniques. Journal of Information Technology and Software Engineering, vol. 7, no. (5), pp. 213.
  - Zaffar, M.; Savita, K.S.; Hashmani, M. A.; Rizvi, S.S. H. (2018). A Study of Feature Selection Algorithms for Predicting Students Academic Performance, (IJACSA) International Journal of Advanced Computer Science and Applications, vol. 9, no. 5, pp. 541-549.