المجلة العلمية لجامعة الملك فيصل
The Scientific Journal of King Faisal University
العلوم الإنسانية والإدارية
Humanities and Management Sciences

أساليب التغلب على الهدر البياناتي في التعليم: مراجعة منهجية

أمينه سعد الدوسري[1] ولينا أحمد الفراني [2]
[1] قسم المناهج وطرق التدريس، كلية التربية، جامعة الملك فيصل، الأحساء، المملكة العربية السعودية
[2] قسم تقنيات التعليم، كلية الدراسات العليا التربوية، جامعة الملك عبد العزيز، جدة، المملكة العربية السعودية

Methods of Overcoming Data Waste in Education: A Systematic Review

Aminah S. Aldossary [1] and Leena A. Alfarani [2]
[1] Department of Curriculum and Teaching Methods, College of Education, King Faisal University, Al Ahsa, Saudi Arabia
[2] Department of Educational Technologies, College of Education Graduate Studies, King Abdulaziz University, Jeddah, Saudi Arabia

LINK الرابط	RECEIVED الاستقبال	ACCEPTED القبول	PUBLISHED ONLINE النشر الإلكتروني	ASSIGNED TO AN ISSUE الإحالة لعدد
https://doi.org/10.37575/h/edu/220042	23/11/2022	13/03/2023	13/03/2023	01/06/2023

NO. OF WORDS عدد الكلمات	NO. OF PAGES عدد الصفحات	YEAR سنة العدد	VOLUME رقم المجلد	ISSUE رقم العدد
6604	7	2023	24	2

الملخص

هدفت هذه الدراسة إلى إجراء مراجعة منهجية منظمة للأبحاث العلمية الحديثة، التي تناولت موضوع التنقيب عن البيانات التعليمية، وذلك من خلال تسليط الضوء على الاتجاهات البحثية الحديثة، بالإضافة إلى استعراض أفضل الممارسات التقنية الذكية في هذا المجال. وقد تم حصر الدراسة الحالية على الأبحاث والمؤتمرات العلمية الإنجليزية، والتي تم نشرها من خلال قاعدة بيانات IEEE في الفترة من عام 2020م وحتى تشرين الأول/أكتوبر من عام 2022م، وبعد تطبيق نموذج PRISMA ومراجعة آلية التطبيق وتوثيقها تم تحديد (25) بحثًا انطبقت عليهم معايير التضمين. وقد توصلت نتائج الدراسة الحالية إلى أن اتجاه التنبؤ كان من أكثر الاتجاهات البحثية الحديثة شيوعًا في مجال التنقيب عن البيانات التعليمية. علاوة على ذلك، فقد تنوع هذا الاتجاه بشكل لافت في تغطيته للجوانب العلمية التعليمية. في المقابل فقد أشارت النتائج إلى أن اتجاه التوصية بالمسارات التخصصية الأكثر ملاءمة للمتعلمين كان من أقل الاتجاهات البحثية شيوعًا. وفيما يتعلق في الممارسات التقنية الذكية، فقد كشفت نتائج الدراسة أن أكثر التقنيات الذكية استخدامًا ونضجًا في الأطر العملية والخوارزميات المستخدمة كانت لأغراض التنبؤ على وجه التحديد، وقد أسهم ذلك بشكل ملحوظ في تمكين الباحثين من الوصول إلى نتائج منطقية دقيقة وقابلة للتطبيق في سياقات تعليمية حقيقية.

ABSTRACT

This research aimed to perform a systematic review of recent scientific studies that addressed the topic of educational data mining by highlighting recent research trends and reviewing the best practices of smart technology in this field. The current research was restricted to scientific studies and conferences in English that were published through the IEEE database between 2020 and October 2022. After applying the PRISMA form and reviewing and documenting the method, 25 papers were identified that matched the criteria. The outcomes of the current research concluded that the trend of prediction was one of the most common research trends in the domain of educational data mining. Moreover, this trend varied remarkably in its coverage of educational scientific aspects. On the other hand, the outcomes demonstrated that the trend of recommending the most appropriate specialised tracks for learners was one of the least common research trends. With regard to intelligent technical practices, the outcomes of the research revealed that the most used and mature intelligent technologies in practical frameworks and algorithms were intended for prediction purposes, and these were shown to greatly enhance researchers' ability to reach accurate and logical results that are applicable in real educational contexts.

KEYWORDS
الكلمات المفتاحية
Artificial intelligence, machine learning, algorithms, neural networks, educational data, educational institutions
الذكاء الاصطناعي، التعلم الآلي، الخوارزميات، الشبكات العصبية، البيانات التعليمية، المؤسسات التعليمية

CITATION
الإحالة
Aldossary, A.S. and Alfarani, L.A. (2023). Asalib altaghalub ealaa alhadr albayanatii fi altaelimi: Murajieat manhajia 'Methods of overcoming data waste in education: A systematic review'. *The Scientific Journal of King Faisal University: Humanities and Management Sciences*, **24**(2), 1-7. DOI: 10.37575/h/edu/220042 [in Arabic]
الدوسري، امينه سعد و الفراني، لينا احمد. (2023). أساليب التغلب على الهدر البياناتي في التعليم: مراجعة منهجية. *المجلة العلمية لجامعة الملك فيصل: العلوم الإنسانية والإدارية*، **24**(2)، 1-7.

1. المقدمة

تُولي الحكومات الاهتمام الأكبر لقطاع التعليم وتحرص على توفير كافة السُبل الرامية للنهوض بالعملية التعليمية وتحسين كفاءتها؛ إيمانًا منها بالدور الرائد للمؤسسات التعليمية في توفير معارف نوعية، من شأنها إحداث التنمية الشاملة للفرد والمجتمع. ويأتي على رأس تلك السُبل دمج مستحدثات قطاع تكنولوجيا المعلومات وتقنية الاتصالات في البُنى التحتية للمؤسسات التعليمية والعمل على توطينها. فعلى المستوى العالمي قامت العديد من دول العالم المتقدمة بتنفيذ تجارب رائدة في مجال توطين التقنية وتطبيق أنظمة التعليم الإلكتروني في سياقات ومواقف تعليمية نوعية، فعلى سبيل المثال التجربة اليابانية التي بدأت منذ عام 1994م، وكذلك التجربة الأمريكية التي بدأت في عام 1995م تلها المؤسسات التعليمية الأسترالية والماليزية في عام 1996م (لال والجندي، 2005). وعلى المستوى المحلي ووفقًا للتجربة السعودية فقد تم العمل على إدخال التقنية في العملية التعليمية منذ عام 2003م، وقد كثفت الجهات المعنية مساعيها الهادفة إلى تأصيل هذا الاندماج، من خلال استحداث المركز الوطني للتعليم الإلكتروني، بالإضافة إلى نشر واعتماد قائمة التعليم عن بعد في مؤسسات التعليم العالي في المملكة العربية السعودية (لال والجندي، 2005). وحديثًا وفي إطار التحول الرقمي فقد تم العمل على تنفيذ العديد من المبادرات، والتي من أهمها مبادرة التحول إلى التعليم الرقمي لدعم تقدم المتعلم والمعلم وقد خُصصت لتلك المبادرة 1.600.00 ريال سعودي كتكلفة إجمالية (600.000 دولار أمريكي) (وثيقة التحول الوطني 2020، 2020: 104).

و في سياق متصل، فقد أدى هذا الانفتاح الواسع على الأنظمة التقنية إلى تضخم هائل في حجم و نوعية البيانات المتعلقة بالمؤسسات التعليمية، وقد نتج عن ذلك التضخم عجز الطرق التقنية التقليدية على استيعاب واستثمار هذا الكم المعلوماتي الضخم على الوجه الأمثل؛ فالطرق التقليدية- و التي تعد خليطًا من الأساليب الإحصائية و الأنظمة الحاسوبية المصممة لإدارة قواعد البيانات- أصبحت غير قادرة على التعامل مع أنواع و أحجام تلك البيانات، فضلًا عن ذلك فإن تلك الطرق التقليدية تعتمد- بشكل أساسي- على محلل البيانات في توجيه دفة كافة الأنشطة و العمليات لاستخراج مؤشرات ذات مغزى. ونظرًا لأهمية تلك البيانات والتي تمثل ثروة حقيقية يمكن الاعتماد عليها في رسم السياسات والخطط الإستراتيجية والتنبؤ بأساليب التحسين المستقبلي؛ فقد عملت العديد من الشركات التقنية الرائدة حول العالم وكذلك الباحثين على إيجاد طرق بديلة قائمة على الأدوات والنماذج التقنية والخوارزميات الذكية، والتي تهدف إلى

Corresponding Author: Aminah S. Aldossary 00966542747419 .aldossary@kfu.edu.sa المؤلف المراسل: أمينه سعد الدوسري

ملاحظة وتعميم واستنباط واستنتاج الأنماط الشائعة والعلاقات المحتملة بين البيانات، بهدف الحصول على معنى حقيقي منها (Du *et al.*, 2020b). وتجدر الإشارة إلى أن علم التنقيب عن البيانات (Data mining) يُعد من العلوم التطبيقية التي تركز على البيانات وتهدف إلى توفير أطر عملية عامة تشمل: أدوات، ونماذج، وخوارزميات ذكية قادرة على التعامل مع البيانات بكفاءة وفاعلية؛ للخروج بقيم ومؤشرات حقيقة منها (Du *et al.*, 2020b). يعرف كلٌ من: سيمنز، وبيكر (Siemens and Baker, 2012) التنقيب في البيانات التعليمية (Educational Data mining) على أنه علم يهدف إلى جمع وفحص وقياس بيانات ذات سياقات تعليمية، وذلك بهدف تقديم فهم وتصور يضمن تحقيق الجودة الشاملة في التعليم والبيئات التعليمية.

2. مشكلة الدراسة

يعد علم التنقيب عن البيانات التعليمية من الاتجاهات البحثية التي ظهر الاهتمام بها بشكل متزايد في السنوات القليلة الماضية. ومن الجدير بالملاحظة، أنه عند البحث في العديد من قواعد البيانات العربية: (المنظومة، اسك زاد، المكتبة السعودية الرقمية) لم نجد أي دراسة عربية تناولت مراجعة منهجية منظمة في مجال التنقيب عن البيانات التعليمية حتى شهر تشرين الأول/ أكتوبر من عام 2022م، كذلك فمن الملاحظ ندرة في الأبحاث العربية التي تطرقت إلى التنقيب عن البيانات التعليمية؛ لذا فإن هذه الدراسة تهدف إلى تقديم مراجعة منهجية منظمة Systematic literature Review للأبحاث المنشورة باللغة الإنجليزية بين عامي 2020م و2022م ، والمتعلقة بالتنقيب عن البيانات التعليمية، وذلك بهدف إثراء المجتمع البحثي العربي وتسليط الضوء على أهم الاتجاهات البحثية الحديثة والممارسات التقنية الذكية في مجال التنقيب عن البيانات التعليمية. وفي هذا السياق تظهر أهمية وجود المراجعات المنهجية المنظمة، التي تُسهم في إثراء المجتمع البحثي، من خلال تقديم رؤى ثاقبة حول الوضع الأدبي الراهن للأبحاث المنشورة في مجال ما. علاوة على ذلك، فإنها تُسهم في مساعدة الباحثين والمتخصصين على تحديد أهم الفجوات البحثية في الدراسات المنشورة؛ لتكون ركيزة حقيقية تفتح المجال لوجود أبحاث مستقبلية ذات إسهام علمي (العلوان، 2020).

3. أسئلة الدراسة

تهدف هذه الدراسة إلى الإجابة على الأسئلة الآتية:

السؤال الرئيس الأول: ما الاتجاهات البحثية الحديثة في مجال التنقيب عن البيانات التعليمية؟

ويتفرع من هذا السؤال الرئيس الأسئلة الفرعية التالية:

- ما الاتجاهات البحثية الأكثر شيوعًا؟
- ما الاتجاهات البحثية الأقل شيوعًا؟
- ما دول نطاق البحث ومنافذ النشر؟

السؤال الرئيس الثاني: ما أفضل الممارسات التقنية الذكية في مجال التنقيب عن البيانات التعليمية؟

ويتفرع من هذا السؤال الرئيس الأسئلة الفرعية التالية:

- ما التقنيات الذكية الأكثر استخدامًا؟
- ما نتائج التقنيات الذكية الأكثر استخدامًا؟
- ما نتائج الدقة في التقنيات الذكية المستخدمة؟

4. أهداف الدراسة

- إجراء مراجعة منهجية منظمة للأبحاث العلمية الحديثة التي تناولت موضوع التنقيب عن البيانات التعليمية.
- التعرف على أهم الاتجاهات البحثية الحديثة في مجال التنقيب عن البيانات التعليمية.
- استعراض الاتجاهات البحثية الحديثة في مجال التنقيب عن البيانات التعليمية.
- استعراض أفضل الممارسات التقنية الذكية في مجال التنقيب عن البيانات التعليمية.

5. أهمية الدراسة

تكمن أهمية هذه الدراسة فيما يلي:

- **الأهمية النظرية:** تُسهم هذه الدراسة في إظهار أهمية علم التنقيب عن البيانات كأحد أهم المجالات الحديثة والطرق الذكية في المجال التعليمي، كما تُسهم في إبراز مدى فاعلية المجال التطبيقي لعلم التنقيب عن البيانات في الحد من المشاكل والصعوبات التي تواجه العملية التعليمية.
- **الأهمية البحثية:** تُسهم نتائج هذه الدراسة في لفت أنظار المسؤولين والقائمين على الأنظمة التعليمية إلى أهمية دمج أفضل الممارسات التقنية الذكية في مجال التعليم، والتي لابد من أخذها في عين الاعتبار عند تطوير المناهج الدراسية ورسم الخطط والاتفاقيات والمشاريع التنموية الحديثة. علاوة على ذلك، تُسهم هذه الدراسة في إثراء قواعد البيانات العربية التي تركز على مجالات توظيف أدوات الذكاء الاصطناعي في التعليم.

6. حدود الدراسة

اقتصرت الدراسة الحالية على الأبحاث المنشورة في مجال التنقيب عن البيانات التعليمية في قاعدة بيانات Institute of Electrical and Electronics Engineers (IEEE) خلال الفترة الزمنية من عام 2020م وحتى تشرين الأول/ أكتوبر من عام 2022م. وقد تم الاقتصار على قاعدة بيانات IEEE، للأسباب التالية:

- وفرة في أعداد الأوراق العلمية المنشورة حديثًا، وهذا يتوافق مع توجه الدراسة.
- تنوع اتجاهات الأوراق المنشورة (بمعني أنها لم تقتصر على مجال واحد كالتنبؤ بالتسرب الدراسي)، وهذا يتوافق مع أهداف وأسئلة الدراسة.
- تنوع الممارسات التقنية الذكية بشكل ملحوظ، وهذا يتوافق مع أهداف وأسئلة الدراسة.
- كثرة أعداد الأوراق المنشورة المفتوحة المصدر.
- إمكانية تنزيل البيانات الوصفية للأبحاث كملف إكسل (مما أكسب عملية الفرز الأولى والمراجعة والفرز الثاني دقة عالية).
- إمكانية تنزيل كل بحث بصيغة pdf.
- سهولة إجراء عمليات تضيق نطاق البحث التي تتيحها قاعدة بيانات IEEE.
- يعد هذا الموضوع من أحد تخصصات قاعدة بيانات IEEE.

7. مصطلحات البحث

- التنقيب عن البيانات التعليمية Educational Data Mining (EDM): يُشير مصطلح التنقيب عن البيانات التعليمية إلى مجموعة الأساليب والأدوات الحاسوبية التي تُستخدم للكشف عن أنماط وعلاقات ذات معنى، واستخراجها بشكل فعال من مجموعات ضخمة من البيانات التعليمية وذلك بهدف رفع كفاءة التعليم (Kumar and Sharma, 2017).
- التنقيب عن البيانات التعليمية Educational data mining (EDM) (إجرائيًا): هو العلم الذي يهدف إلى تطوير أساليب لاكتشاف الأنماط والعلاقات من البيانات الناتجة عن البيئات التعليمية، ثم طرحها في شكل منطقي ومفهوم يُسهم في تقديم الحلول الممكنة لتحسين العملية التعليمية.

8. منهجية البحث

لتحقيق الهدف من هذه الدراسة تم استخدام المراجعة المنهجية المنظمة Systematic Literature Review والتي تهدف إلى جمع وفرز الدراسات السابقة في سياق ما، ومن ثم العمل على تحليل نتائج تلك الدارسات، من أجل الوصول إلى خلفية شاملة عن الوضع الأدبي الراهن، ولإجراء هذا النوع من المراجعات تم اتباع الخطوات التي أشار إليها (Siddaway, 2014):

- البحث والاطلاع على العديد من الأبحاث والدراسات السابقة التي تناولت موضوعات التنقيب عن البيانات في البيئات التعليمية.
- تحديد مجال المراجعة المنهجية حيث تم تحديد الأسئلة البحثية الرئيسة ونطاق الفترة الزمنية من عام 2020م إلى 2022م.

- تحديد قاعدة البيانات والكلمات المفتاحية للوصول للدراسات المطلوبة.

جدول (1): يوضح محددات عملية البحث

قاعدة البيانات	الاستعلام	الوصول	اوعية النشر
IEEE	(Data mining in education) OR (Educational Data mining)	الأبحاث مفتوحة المصدر	المجلات المؤتمرات

- تحديد أربعة معايير لاختيار وتضمين الدراسات السابقة، بحيث تحقق الدراسة جميع المعايير أو أحدها:
  - أن تكون الدراسة قد تطرقت إلى إحدى اتجاهات التنقيب عن البيانات في المؤسسات التعليمية، والتي تتمثل في (القضايا، المشاكل، الاتجاهات).
  - أن تكون الدراسة قد عرضت إحدى الحلول التقنية المتمثلة في: (التقنيات، الأدوات، النماذج، الخوارزميات) والمستخدمة للتنقيب عن البيانات التعليمية.
  - أن تكون الدراسة قد أشارت إلى دور الحلول التقنية في تحسين النتائج، الأداء، الكفاءة في المجال التعليمي على وجه التحديد.
  - أن تكون الدراسة قد وضحت نتائج الأداء للحلول التقنية.
- تحديد أربعة معايير لاستبعاد الدراسات السابقة التي لا تتوافق مع أهداف هذه الدراسة وأسئلتها:
  - الدراسات التي تناولت الأطر النظرية والوصفية البحتة لعلم التنقيب عن البيانات التعليمية: (تعريف التنقيب عن البيانات التعليمية، فوائد التنقيب عن البيانات التعليمية، أهمية التنقيب عن البيانات التعليمية، تاريخ التنقيب عن البيانات التعليمية).
  - الدراسات التي لم يكن موضوعها الرئيس التنقيب عن البيانات التعليمية (نظم التوصية، المحاكاة الميكانيكية، الكهربائية الهيدروليكية، تمثيل وتصنيف الصور، إطار عمل إنترنت الأشياء IoT، أطر عمل التقييم الآلي (التصحيح الآلي)، تشخيص الأعطال، معالجة اللغات الطبيعية).
  - استبعاد الدراسات السابقة التي تناولت التنقيب عن البيانات في البيئات غير التعليمية: (مصانع، شركات، سجلات طبية، معامل، أدوية، التهديدات الإلكترونية، مستشفيات).
  - استبعاد الدراسات السابقة التي تناولت التنقيب عن البيانات التعليمية من خلال الأساليب والطرق اليدوية.
- تنقيح الدراسات السابقة، بحيث تم التأكد من استيفاء كل دراسة على حدة لمعايير الاختيار، وذلك من خلال قراءة عنوان وملخص وأسئلة وأهداف كل دراسة.

شكل (1): مخطط تدفق PRISMA2020 للمراجعات المنهجية التي تضمنت عمليات البحث من خلال قواعد البيانات والسجلات فقط

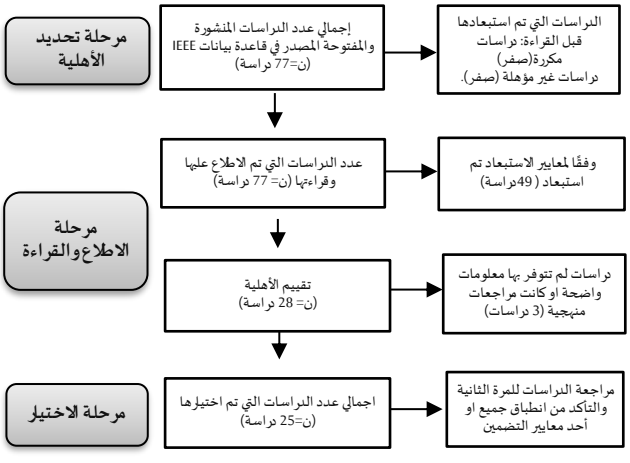

- تسجيل كافة خصائص الدراسات المشمولة في قائمة Eexcel Sheet تضمنت: اسم الباحث، سنة النشر، عنوان البحث، الاتجاهات، المنهجية البحثية، الحلول التقنية، النتائج وترميزها.
- تحليل ومناقشة النتائج وكتابة المراجعة المنهجية.

9. نتائج المراجعة المنهجية

9.1. ما الاتجاهات البحثية الحديثة في مجال التنقيب عن البيانات التعليمية؟

يمكن الإجابة على السؤال الأول من خلال الأسئلة الفرعية التالية:

9.1.1. ما الاتجاهات البحثية الأكثر شيوعًا؟

توصلت نتائج المراجعة المنهجية إلى أن الاتجاهات البحثية الأكثر شيوعًا للتنقيب عن البيانات التعليمية كانت في المجالات التالية: التنبؤ، دعم عملية التدريس، تحليل مشاعر المتعلمين. ومن الجدير بالذكر، أن اتجاه التنبؤ على وجه التحديد قد تنوع - بشكل واضح- في تغطيته لجوانب العملية التعليمية فمن ناحية ركز على التنبؤ بأداء المتعلمين الأكاديمي و سلوكهم في التعلم، ومن ناحية أخرى فقد ركز على التنبؤ بالمتعلمين المعرضين للرسوب أو الضعف الأكاديمي والتسرب الدراسي، بالإضافة إلى التنبؤ بالعوامل المؤثرة على جودة التكاليف الدراسية للمتعلمين كالرسائل الجامعية (Abdelkader *et al.*, 2022; Prabowo *et al.*, 2021; Feng *et al.*, 2022; Nabil *et al.*, 2021; Priyambada *et al.*, 2021; Du *et al.*, 2020a; Ghorbani and Ghousi, 2020; Qu *et al.*, 2022; Zeng *et al.*, 2020; Wen *et al.*, 2020; Li *et al.*, 2020).

وفي المقابل، فإن اتجاه دعم عمليات التدريس ركز على زيادة فرص نجاح عملية التدريس من خلال التنقيب عن مشكلات حقيقية وطرحها في قالب أسئلة للمتعلمين، بالإضافة إلى تكييف التعليم ليناسب طبيعة المتعلمين، وذلك من خلال العمل على تحليل البيانات الديناميكية في الوقت الحقيقي كوقت الإجابة والتعديل، كذلك في تحديد الموضوعات الدراسية المناسبة أو الصعبة للمتعلمين (Rahman *et al.*, 2022; Prada *et al.*, 2020; Shao *et al.*, 2020; Araujo *et al.*, 2020; Chen *et al.*, 2022).

في حين أن اتجاه تحليل مشاعر المتعلمين ركز بشكل لافت على تحليل النصوص text mining كأسلوب لمعرفة آراء المتعلمين ومستوى رضاهم عن العملية التعليمية (Zhai *et al.*, 2020; Qi and Liu, 2021; Gronberg *et al.*, 2021; Buenano-Fernandez *et al.*, 2020).

9.1.2. ما الاتجاهات البحثية الأقل شيوعًا؟

توصلت نتائج المراجعة المنهجية إلى أن الاتجاهات البحثية الأقل شيوعًا للتنقيب عن البيانات التعليمية كانت في المجالات التالية: التوصية، دعم العمليات الإدارية. من الجدير بالملاحظة، أن اتجاه التوصية بالمسارات التخصصية الملائمة للمتعلمين ومصادر تعلمهم المناسبة كان أقل اتجاه تم التركيز عليه (Xiao *et al.*, 2021). بينما حاول اتجاه دعم العمليات الإدارية الاستعانة بتقنيات التنقيب عن البيانات، بهدف تمكين القائمين على العملية التعليمية من اتخاذ القرارات المناسبة والمتعلقة بتكييف البرامج التعليمية لتناسب احتياجات المجتمع، فضلًا عن مساعدة المعلمين وتمكينهم من اتخاذ القرارات المتعلقة بتصميم البرامج الدراسية، بالإضافة إلى تسهيل عمليات إدارة المرافق الجامعية كالمكتبات (Czibula *et al.*, 2022; Mengash, 2020; Iqbal *et al.*, 2020).

9.1.3. ما دول نطاق البحث ومنافذ النشر ؟

أشارت نتائج المراجعة المنهجية إلى وجود إقبال كبير من قِبل الباحثين والأكاديميين من مختلف دول العالم على البحث في مجال التنقيب عن البيانات التعليمية؛ حيث تنوعت أماكن إجراء الأبحاث بشكل لافت بين الصين، إسبانيا، البرتغال، بولندا، رومانيا، أمريكا، الإكوادور، إندونيسيا، تايوان، اليابان، كوريا الجنوبية، المملكة العربية السعودية، مصر، إستونيا، إيطاليا، بنجلادش، إيران، وبولندا. من الجدير بالملاحظة، أنه و رغم تنوع أماكن إجراء الأبحاث إلا أن أغلب أوعية النشر كانت أمريكية، قد يشير ذلك إلى اهتمام قواعد البيانات والمجلات العلمية الأمريكية بهذا المجال، مما أدى إلى توجه خطوط النشر لمجال التنقيب عن البيانات التعليمية

(Abdelkader *et al.*, 2022; Prabowo *et al.*, 2021; Feng *et al.*, 2022; Nabil *et al.*, 2021; Priyambada *et al.*, 2021; Du *et al.*, 2020a; Ghorbani and Ghousi, 2020; Qu *et al.*, 2022; Zeng *et al.*, 2020; Wen *et al.*, 2020; Li *et al.*, 2020; Rahman *et al.*, 2022; Prada *et al.*, 2020; Shao *et al.*, 2020; Araujo *et al.*, 2020; Chen *et al.*, 2022; Zhai *et al.*, 2020; Qi and Liu, 2021; Gronberg *et al.*, 2021; Buenano-Fernandez *et al.*, 2020; Xiao *et al.*, 2021; Czibula *et al.*, 2022; Mengash, 2020; Iqbal *et al.*, 2020).

شكل (2): يوضح أماكن إجراء الأبحاث

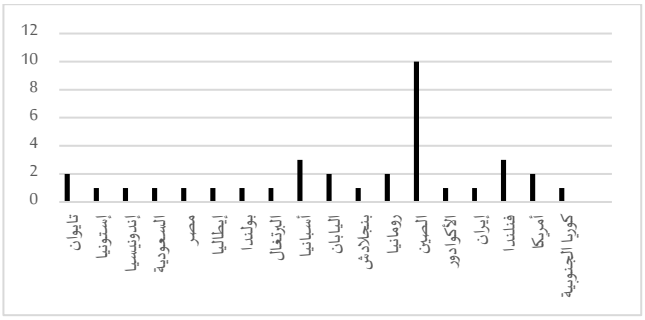

شكل (3): يوضح أماكن النشر

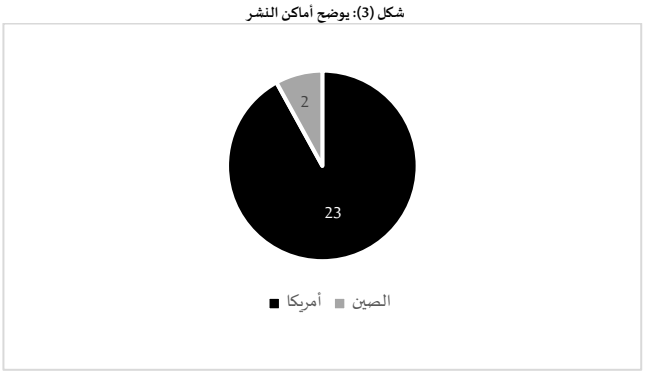

9.2. ما أفضل الممارسات التقنية الذكية في مجال التنقيب عن البيانات التعليمية؟

يمكن الإجابة على السؤال الثاني من خلال الأسئلة الفرعية التالية:

9.2.1. ما التقنيات الذكية الأكثر استخدامًا؟

أشارت نتائج المراجعة المنهجية إلى أن جميع الأبحاث اعتمدت في أطر عملها التطبيقية على استخدام وتطوير عدد من التقنيات المتداخلة؛ حيث إن كل تقنية تؤدي مهمة أو عددًا من المهام في كل مستوى من مستويات البحث. ففي سياق التقنيات الذكية المتعلقة بنماذج التنبؤ، والتي تُعد من أكثر التقنيات الذكية استخدامًا من قِبل الباحثين في مجال التنقيب عن البيانات التعليمية، فمن الملاحظ أن تلك الأطر اعتمدت- بشكل كبير- على تطبيقات التعلم العميق (ANN) و(DNN)، والتي تعد من إحدى فروع الذكاء الاصطناعي المتقدمة و الهادفة إلى إيجاد طرق و أساليب، تستطيع من خلالها الآلات ان تتعلم من تلقاء نفسها و بطريقة تحاكي فيها عمليات العقل البشري في التفكير و التحليل و اتخاذ القرارات، و يتم ذلك بالاعتماد على شبكات عصبية قائمة على دوال رياضية، بالإضافة إلى تدريب تلك التطبيقات بشكل مكثف في ذات السياق للبيانات التعليمية، ويأتي على رأس تلك التقنيات المستخدمة الشبكة العصبية الالتفافية (CNN)، و التي تحدد اختلافًا واحدًا في منظور متعدد المستويات، و يمكن أن تحتوي الشبكة العصبية الالتفافية على أكثر من طبقة التفاف واحدة؛ مما يكسب الشبكة عمقًا مع عدد أقل من المعلمات.

علاوة على ذلك، فقد تم الاعتماد على عدد من الخوارزميات ك الغابة العشوائية واشجار القرار و التي تعد من خوارزميات التعلم الآلي الخاضعة للإشراف و التي تستخدم في مهام التصنيف و الانحدار كما ان آلية عملها تعتمد على مبدأ ensemble بهدف بناء نتائج دقيقة، ومن الخوارزميات الأخرى التي تم الاعتماد عليها في الأطر العملية Naive Bayes و التي تعد من الخوارزميات عالية السرعة في مهام التصنيف اللحظي للبيانات ذات الطابع الرقمي أو الفئوي، في حين أن عددًا من الأطر العملية اعتمدت على خوارزميات Support Vector Machine والتي تعد من خوارزميات التعلم الآلي الخاضعة للإشراف و المستخدمة في أداء المهام المتعلقة بالتصنيف و الانحدار، و تقوم فلسفة عملها على إيجاد أعلى حد يفصل بين المجموعات، سواء اكانت المجموعات ثنائية أم متعددة، بالإضافة إلى ذلك فقد احتوت الأطر العملية على خوارزمية دعم متجه الانحدار اللوجستي، و التي تندرج تحت خوارزميات التعلم الآلي، كما أنها تتميز ببساطتها و وضوح إجراءاتها و تستخدم في مهام التصنيف (Mengash, 2020; Prabowo *et al.*, 2021; Nabil *et al.*, 2021; Wen *et al.*, 2020; Iqbal *et al.*, 2020).

وفي سياق آخر، متعلق بخوارزميات التجميع والتصنيف فإن العديد من الأبحاث أدخلت في أطر عملها تقنيات معالجة اللغات الطبيعية و التي تعد من إحدى فروع الذكاء الاصطناعي التي تمكن الآلات والأجهزة من فهم و معالجة اللغات البشرية و التفاعل معها، أيضًا تم ادخال نموذج (DNN) للتعلم العميق، بهدف التخفيف من التوزيع غير المتماثل للبيانات التعليمية، فضلًا عن خوارزميات K-means لتجميع البيانات وFP-Growth لاستخراج البيانات، بالإضافة إلى خوارزميات K-Nearest-Neural Network وXG-boost و Support Vector Machine Radial Basis Function وأشجار القرار و Logistic Regression و Naïve Bayes والغابة العشوائية. علاوة على ذلك، فقد تم استخدام العديد من الطرق والوسائل للتحقق العشوائي من صحة تلك النماذج المطورة Random Hold Out و Shuffle 5-fold Crossing ، بهدف جعل مستويات أداء النماذج تحقق نتائج تتسم بالدقة والكفاءة

(Rahman *et al.*, 2022; Shao *et al.*, 2020; Chen *et al.*, 2022; Ghorbani and Ghousi, 2020; Du *et al.*, 2020b; Araujo *et al.*, 2020).

9.2.2. ما نتائج التقنيات الذكية الأكثر استخدامًا؟

انحصرت التقنيات الذكية الأكثر استخدامًا على مجال التنبؤ وخوارزميات التصنيف والتجميع، ويوضح الجدول رقم (2) والجدول رقم (3) بالتفصيل الأطر العملية للتقنيات الذكية الأكثر استخدامًا، بالإضافة إلى مجال استخدامها الدقيق والنتائج التي حققتها:

جدول (2): نماذج التنبؤ

المؤلف	الاطر العملية للتقنيات المستخدمة	الاغراض والنتائج
H. A. Mengash (2020)	تم تطوير إطار عمل يشمل التالي: 1. الشبكة العصبية الاصطناعية (ANN). 2. شجرة القرار. 3. دعم آلة المتجهات (SVM). 4. Naive Bayes.	فاعلية إطار العمل المقترح في إدارة مؤسسات التعليم العالي؛ حيث يمكن لمتخذي القرار استخدام هذه النماذج في تخطيط وتحسين المؤسسات التعليمية. وقد أشارت الدراسة إلى تفوق نموذج الشبكة العصبية الاصطناعية (ANN) بنسبة 79.22% من حيث الدقة مقارنة بالنماذج الأخرى.
Prabowo *et al.*, (2021)	تم تطوير نموذج للتعلم العميق، بهدف معالجة السلاسل الزمنية والبيانات المجدولة في وقت واحد.	حقق النموذج المقترح أفضل اداء مقارنة بجميع النماذج المختبرة مع MSE 0.4142 (متوسط الخطأ التربيعي) و MAE 0.418 (متوسط الخطأ المطلق) لـ GPA بمقياس 4.0. كما أن لديها أفضل درجات R 2 وهي 0.4879.
Nabil et al., (2021)	تم تطوير إطار عمل يشمل التالي: 1. الشبكة العصبية الاصطناعية (DNN). 2. شجرة القرار. 3. Random Forest. 4. gradient boosting. 5. الانحدار اللوجستي. 6. مصنف ناقل الدعم. 7. K-nearest neighbor.	فعالية إطار العمل المقترح وعلى وجه التحديد نموذج الشبكة العصبية الاصطناعية (DNN) حيث يمكنه التنبؤ بأداء المتعلمين، بالإضافة إلى تحديد المتعلمين المعرضين للرسوب في مرحلة مبكرة من الفصل الدراسي وبدقة تصل إلى 89٪ ، وهي نسبة أعلى من نماذج الأخرى.
Iqbal et al., (2020)	تم تطوير إطار عمل يشمل التالي: 1. استخدام تقنيات استخراج البيانات لتحليل واستخراج الأنماط الأساسية والمفيدة من بيانات. 2. تم اقتراح نموذج تنبؤ جديد استنادًا إلى الشبكة العصبية الاصطناعية (DNN) و Support Vector Regressor (SVR) و Random Forest (RF) للتنبؤ بالاستخدام المستقبلي.	إطار العمل المقترح فعال في إدارة المرافق التعليمية، كما أن نتائج النموذج DPA-LRBD المقترح أثبتت أن البيانات والتحليلات التنبؤية هي حلول مجدية لإدارة الموارد والمرافق التعليمية بشكل فعال وتحسين جودة الخدمات. علاوة على ذلك، فقد أشارت النتائج إلى أن أداء نموذج DNN دقيق في عملية التنبؤ مقارنة بخوارزميات SVR و RF.
Wen *et al.*, (2020)	تم تطوير إطار عمل يشمل التالي: 1. مصفوفة بسيطة لحفظ المعلومات المتعلقة بالارتباط بسلوكيات التعلم. 2. نموذج شبكة عصبية (CNN) للتنبؤ بالتسرب الدراسي.	نموذج الشبكة العصبية الاصطناعية المقترح CNN حسن من دقة التنبؤ بالتسرب الدراسي. كما يمكن استخدام النموذج المقترح للتنبؤ بالتسرب مؤقتًا وفي وقت مبكر في حال كانت البيانات المجموعة كافية.

جدول (3): خوارزميات التصنيف والتجميع

المؤلف	الاطر العملية للتقنيات المستخدمة	الاغراض والنتائج
Rahman *et al.*, (2022)	تم تطوير إطار عمل يشمل التالي: 1. استخدام خوارزمية التجميع K-mean لتجميع البيانات. 2. خوارزمية النمو المتكرر على كل مجموعة لتحديد أنماط بيانات.	الإطار العملي استخرج بشكل فعال انماط وقواعد مفيدة من البيانات، ومن الملاحظ أن الميزات والأنماط والقواعد المستخرجة حددت نقاط الضعف ومجال التحسينات المحتملة في تعلم مقرر البرمجة والذي يعد الهدف من البحث.
Shao *et al.*, (2020)	تم تطوير إطار عمل يشمل التالي: 1.خوارزمية تنقيب محسنة لتحليل درجة تعلم الطلاب بناءً على بيانات المتعلمين الديناميكية (تحليل النص). 2. استخدام خوارزمية التجميع DBSCAN لتجميع خصائص التعلم الشخصية للمتعلمين وفقًا لمصفوفة درجة التعلم.	فعالية إطار العمل المقترح، فضلًا عن قدرته على التعامل بفاعلية مع البيانات الضخمة بشكل تلقائي.
Chen *et al.*, (2022)	تم تطوير إطار عمل يشمل التالي: 1. استخدام التحليل العنقودي Cluster analysis K-mean لتصنيف الطلاب وفقًا لسلوكهم التعليمي ونتائجهم. 2. تحليل ملف تعريف الكتلة للتركيز على العوامل القابلة للتنفيذ التي يمكن أن تؤثر على درجات المتعلمين النهائية. 3. استخدام نفس العوامل لبناء نموذج تصنيف يمكن من خلاله عمل تنبؤات مبكرة للنتائج النهائية للمتعلمين.	فعالية الإطار المقترح في توفير صورة قيمة عن سلوكيات التعلم لدى المتعلمين في مقررات البرمجة، يمكن استخدام هذا الإطار لتحسين أداء المتعلمين أثناء تعلمهم للمقرر البرمجة.
Ghorbani and Ghousi (2020)	تم تطوير إطار عمل يشمل التالي: 1.مقارنة تقنيات إعادة التشكيل بهدف إعطاء إطار العمل القدرة على التعامل مع المشاكل المتعلقة بالبيانات غير المتجانسة أو غير المتوازنة. 2. استخدام تقنيات تصنيفية للتعلم الآلي الغابة	اشارت النتائج إلى فاعلية إطار العمل المقترح، كما اكدت على أن عددًا أقل من الفئات والسمات الأسمية ستقود النماذج إلى أداء أفضل وأكثر دقة. كما أكدت نتائج اختبار فريدمان وهو اختبار دلالة إحصائية أن SVM-SMOTE

المؤلف	الاطر العملية للتقنيات المستخدمة	الاغراض والنتائج	المؤلف
	العشوائية و-K-Nearestالشبكة العصبية و-XG Support Vector Machine (Radial و boost (Basis Function) واشجار القرار والانحدار اللوجستي وNaïve Bayes. 3. استخدام طريقتين لتحقق العشوائي من صحة النموذج (Random Hold Out) وShuffle 5-fold Crossing.	أكثر فاعلية من طرق إعادة التشكيل الأخرى. علاوة على ذلك، فقد حققت خوارزمية Random Forest أفضل نتيجة مقارنة بجميع النماذج الأخرى أثناء استخدام SVM-SMOTE كطريقة لإعادة التشكيل.	
Du *et al.*, (2020 a)	تم تطوير إطار عمل يشمل التالي: 1. (LVAEPre) المعتمدة على المشفر التلقائي المتغير (LVAE). 2. الشبكة العصبية الاصطناعية (DNN) للتخفيف من التوزيع غير المتوازن لمجموعة البيانات التعليمية وكذلك لتوفير التنبؤ المبكر للمتعلمين المعرضين للرسوب.	قدم إطار العمل المقترح نتائج أفضل وأكثر استقرارًا من الطرق الأخرى من حيث الدقة بدرجة F 1.5.	Du *et al.*, (2020 a)
Araujo *et al.*, (2020)	تم تطوير إطار عمل يشمل التالي: 1.تقنيات معالجة اللغات الطبيعية. 2.نموذج للتعلم العميق يستخرج تلقائيًا الموضوعات الرئيسة التي يتم تناولها في المستندات التعليمية.	إطار العمل المقترح قدم درجة دقة عالية بلغت حوالي 90 %، كما أن هذا الإطار عمل بكفاءة في التطبيقات المتعلقة بتحليلات التعلم.	Araujo *et al.*, (2020)

9.2.3. ما نتائج الدقة في التقنيات الذكية المستخدمة؟

حسب ما جاء في نتائج الدراسات المضمنة في هذه المراجعة المنهجية؛ فقد تبين أن نموذج Multi-AFM التنبؤي تمتع بأداء أفضل وأكثر استقرارًا من الأساليب الحالية القائمة على الانتباه؛ حيث بلغت نسبة دقة هذا النموذج 94 % (Zhai *et al.*, 2020). بينما قدمت الأدوات البرمجية المستندة على الويب والمستخدمة في تحليل أداء المتعلمين الأكاديمي نسبة دقة تجاوزت 90% في العديد من الحالات، حيث تم تطبيقها على بيانات حقيقية لمؤسسات التعليم العالي في الاتحاد الأوربي؛ مما يدل على جاهزيتها للتطبيق في سيناريوهات ذات نطاق أوسع لاستخراج أنماط مبكرة وذات قيمة من البيانات (Prada *et al.*, 2020). وفي سياق آخر فإن اختبار الميزة أظهر ملاءمة عالية الدقة للتنبؤ برضا المتعلمين عن تجربتهم في التعلم عن بعد خلال جائحة (Covid-19)؛ حيث بلغت دقة التصنيف 100% على بيانات الوقت الفعلي (Abdelkader *et al.*, 2022). في حين أن إطار العمل القائم على الدمج بين خوارزمية KNN وSVM أظهر أداءً أكثر دقة في التصنيف من الشبكات العصبية وخوارزميات أشجار القرار (Shao *et al.*, 2020). بينما أظهرت الشبكة العصبية (ANN) عند استخدامها للتنبؤ بالأداء الأكاديمي للمتقدمات لجامعة الأميرة نورة في المملكة العربية السعودية نسبة دقة 79% (Mengash, 2020).

وقد توصلت النتائج إلى أن دقة نموذج DNN المستخدم في التنبؤ بالأداء الأكاديمي للمتعلمين في بداية الفصل الدراسي، وتحديد المتعلمين المعرضين للرسوب بلغت حوالي 89% (Nabil *et al.*, 2021). وعلى صعيد الدمج بين تقنيات معالجة اللغة الطبيعية ونموذج التعلم العميق كإطار عمل موحد يهدف إلى استخراج موضوعات محددة من المستندات و الوثائق التعليمية فإن نسبة الدقة تجاوزت 90% (Araujo *et al.*, 2020).كما دلت نتائج إطار العمل الذي يتكون من (LVAEPre) و المعتمد على المشفر التلقائي المتغير (LVAE) مع إدخال الشبكة العصبية الاصطناعية (DNN)، بهدف التخفيف من التوزيع غير المتجانس لمجموعة البيانات التعليمية، بالإضافة إلى تقديم إنذار مبكر للمتعلمين المعرضين للرسوب، على أن الإطار تمتع بمعدل حساسية أعلى وإيجابية أقل للأخطاء، فضلًا عن انخفاض معدل سوء التصنيف (Du *et al.*, 2020a). وعلى صعيد المقارنة بين خوارزميات التعلم الآلي المختلفة وقدرتها على التعامل مع البيانات التعليمية غير المتجانسة فقد حققت خوارزمية الغابة العشوائية درجة دقة بلغت 76.83%، متفوقة بذلك على خوارزميات الشبكات العصبية الاصطناعية، وأشجار القرار، والانحدار اللوجستي (Ghorbani and Ghousi, 2020).

وفيما يتعلق في التنبؤ بأداء المتعلمين الأكاديمي بالاعتماد على البيانات المجدولة والنصية فقد حقق إطار العمل RfBERT أداء أفضل على البيانات التجريبية من حيث الدقة؛ مما أسهم في تحسين أداء النموذج ككل بنسبة 4.37٪ (Qu *et al.*, 2022). كما أن الاعتماد على الشبكة التوليدية (GAN) بهدف التنقيب في البيانات غير المسجلة أو المفقودة، من خلال محاكاة سلوك المتعلم جنبًا إلى جنب مع آلية انتباه عالية المستوى لقياس أهمية البرنامج الدراسي حقق نسبة دقة بلغت 94.83% (Zeng *et al.*, 2020). بينما حقق نموذج الشبكة العصبية الاصطناعية (CNN) الهادف إلى التنبؤ بالتسرب الدراسي نتائج دقة في سيناريوهات مختلفة بلغت 0.8642 (Wen *et al.*, 2020).

10. مناقشة النتائج

في ضوء النتائج السابقة للمراجعة المنهجية تم استنتاج عدد من النقاط، التي تتعلق باتجاهات وأدوات التنقيب عن البيانات التعليمية، ففيما يتعلق بالاتجاهات البحثية الحديثة في مجال التنقيب عن البيانات التعليمية، فمن الملاحظ أن اتجاه التنبؤ يعد من أكثر الاتجاهات البحثية شيوعًا و تنوعًا من حيث المجالات التي عَمَدَ إلى تغطيتها، فمن ناحية ركز على أداء المتعلمين الأكاديمي و من ناحية أخرى ركز على معالجة القضايا المتعلقة بالرسوب و التسرب الدراسي فضلًا عن التنبؤ بالعوامل المؤثرة على جودة المخرجات الأكاديمية للمتعلمين كالتكاليف و الرسائل العلمية، بالإضافة إلى التركيز على جعل العميلة التعليمية أكثر فعالية، من خلال التنقيب عن أمثلة وحالات في سياقات واقعية وطرحها في قالب أسئلة للمتعلمين، و تكييف التعليم و تحليل البيانات الديناميكية في الوقت الحقيقي ، و كذلك تحديد الموضوعات الدراسية المناسبة أو الصعبة للمتعلمين، علاوة على تحليل مشاعر المتعلمين، من خلال تحليل النصوص text mining كأسلوب لمعرفة انطباعات المتعلمين ومستوى رضاهم عن العملية التعليمية، وقد يرجع السبب في شيوع تلك الاتجاهات على وجه التحديد إلى نضوج الأطر العملية و الخوارزميات المستخدمة مما أسهم في زيادة إقبال الباحثين على هذا الاتجاه و التركيز على تنويع قضاياه و مجالاته البحثية، و تجدر الإشارة إلى أن تلك الأطر العملية مكنت الباحثين من الوصول إلى نتائج منطقية و قابلة للتطبيق في سياقات تعليمية حقيقية، وقد برزت قوة تلك الأطر العملية المستخدمة في اتجاه التنبؤ بشكل لافت، من خلال إدخال تطبيقات الشبكات العصبية الاصطناعية و المتمثلة ب (CNN ,ANN, DNN) على وجه التحديد جنبًا إلى جنب مع العديد من الخوارزميات أدى ذلك الدمج إلى تحقيق نتائج دقيقة و قابلة للتطبيق. فعلى سبيل المثال حقق إطار العمل الذي جمع الشبكة العصبية الاصطناعية (DNN) مع خوارزميات شجرة القرار وRandom Forest وgradient boosting والانحدار اللوجستي ومصنف ناقل الدعم وK-nearest neighbor نسبة دقة بلغت 89% (Nabil *et al.*, 2021).

وفي سياق متصل، بالاتجاهات البحثية الحديثة في التنقيب عن البيانات التعليمية، فمن الواضح ندرة الأبحاث التي قدمت حلولًا للتنبؤ بالمسار الأكاديمي الأنسب للمتعلم بناءً على أدائه وسلوكه وميوله الأكاديمي (Xiao *et al.*, 2021). وعند إمعان النظر أكثر في هذا السياق على وجه التحديد فإن العديد من المعوقات التي تواجه الأنظمة التعليمية كالتسرب والتأخر الدراسي للمتعلمين سيتم تلافيها والعمل على الحد منها بمجرد إيجاد تلك الحلول ومحاولة تحسينها والعمل على تطبيقها في سياقات حقيقية في المجال التعليمي. وفيما يتعلق بالممارسات التقنية الذكية في مجال التنقيب عن البيانات التعليمية، فمن الواضح شيوع عدد من تلك الممارسات؛ فدمج الشبكة العصبية الاصطناعية DNN في أطر العمل أدي إلى حل أكثر المشكلات تعقيدًا والمتمثلة في عدم تجانس أو عدم توازن البيانات التعليمية (Du *et al.*, 2020b). وعلى صعيد آخر متعلق بخوارزميات التعلم الآلي فمن اللافت للانتباه تفوق خوارزمية Random forest على الخوارزميات الأخرى من حيث نتائج ومستويات الدقة فضلًا عن قدرتها على التعامل مع البيانات التعليمية غير المتجانسة (Ghorbani and Ghousi, 2020). ومن الجدير بالذكر، أن إدخال ممارسات تقنية من شأنها أن تتحقق بشكل عشوائي من صحة نتائج الأطر والنماذج العملية أسهم في اتخاذ القرارات المناسبة لتحسين الأداء وزيادة مستويات الدقة والاستدعاء لتلك الأطر والنماذج (Ghorbani and Ghousi, 2020). علاوة على ذلك، فإن الشبكة التوليدية (GAN) تمتعت بأداء لافت في قدرتها على التنقيب في البيانات التعليمية في ظل فقدانها أو عدم تسجيلها، وذلك من خلال محاكاة سلوك المتعلم مع نتائج دقة بلغت حوالي 94% (Zeng *et al.*, 2020).

11. الخلاصة

أثبت علم التنقيب عن البيانات فاعليته كأحد أهم الحلول الرامية للتعامل مع البيانات الضخمة وتحليلها بكفاءة وذلك بهدف تحويلها من بيانات غير مترابطة إلى كيان معلوماتي متكامل، يمكن الاعتماد عليه في اتخاذ القرارات ورسم السياسات والخطط الإستراتيجية. وفي سياق التعليم فقد كان لعلم التنقيب عن البيانات دورٌ بارزٌ في حل العديد من المشكلات التي تواجه الأنظمة التعليمية كالتنبؤ بالتسرب الدراسي للمتعلمين، فضلًا عن التنبؤ

المبكر بالأداء الأكاديمي واقتراح المسار التخصصي الأكثر مناسبة للمتعلم. علاوة على ذلك، فقد قدمت أدوات التنقيب عن البيانات التعليمية خدمات نوعية لدعم عملية التدريس وتكييف التعليم بالاستناد على أساليب وتقنيات علمية. وعلى صعيد الممارسات التقنية الذكية لعلم التنقيب عن البيانات التعليمية فقد أثبتت دورها الفعال في العديد من المجالات وذلك من خلال أطرها العملية المستندة على الخوارزميات وعلم البيانات وتطبيقات الذكاء الاصطناعي، بالإضافة إلى طرق التحقق العشوائي من صحة ودقة النماذج. وتجدر الإشارة إلى أن هذا البحث قدم مراجعة منهجية منظمة للدراسات العلمية الحديثة التي تناولت قضايا التنقيب عن البيانات التعليمية، وذلك بهدف التعرف على أهم الاتجاهات البحثية الحديثة وتقييم أفضل الممارسات التقنية الذكية في مجال التنقيب عن البيانات التعليمية.

12. **التوصيات**:

في ضوء النتائج الخاصة في المراجعة المنهجية، يُمكن طرح عدد من التوصيات:

- الحراك البحثي المتعلق بالتنقيب عن البيانات التعليمية يتسم بالندرة في قواعد البيانات العربية، مقارنة بقواعد البيانات العالمية؛ لذا نوصي بضرورة البحث في هذا المجال.
- تُعد الأبحاث التي قدمت حلولًا متعلقة في التنبؤ بالمسارات الأكاديمية الأنسب للمتعلمين قليلة؛ لذا نوصي بإجراء مزيد من الأبحاث في هذا المجال على وجه التحديد.
- نوصي الباحثين والمهتمين في مجال التنقيب عن البيانات التعليمية بإدخال تطبيقات الشبكات العصبية الاصطناعية، بهدف زيادة مستويات الدقة والموثوقية.
- نوصي الباحثين والمهتمين في مجال التنقيب عن البيانات التعليمية على حل المشكلات المتعلقة بعدم تجانس البيانات التعليمية، من خلال الاعتماد على الشبكة العصبية الاصطناعية (DNN).
- نوصي الباحثين والمهتمين في مجال التنقيب عن البيانات التعليمية باستخدام الشبكة التوليدية (GAN) في ظل فقدان أو عدم تسجيل البيانات التعليمية.
- نوصي بضرورة نشر الوعي بأهمية التنقيب عن البيانات التعليمية، من خلال إقامة المؤتمرات والدورات والورش التدريبية.
- نوصى الأقسام والكليات التربوية بإدراج مقررات عن تطبيقات الذكاء الاصطناعي في التعليم.
- نوصي بضرورة قيام الجامعات بطرح تخصصات نوعية متعلقة بالتنقيب عن البيانات والبيانات الضخمة، بهدف إكساب المتعلمين المهارات العلمية والعملية اللازمة للاستفادة من هذا المجال على الوجه الأمثل.
- نوصى الأكاديميين وطلبة الدراسات العليا بالاتجاه نحو إنتاج ابحاث ومشاريع للدراسات العليا في التخصصات التربوية مبنية على أطر عملية ونمذجة لتقنيات الذكاء الاصطناعي.

نبذة عن المؤلفات

أمينه سعد الدوسري

قسم المناهج وطرق التدريس، كلية التربية، جامعة الملك فيصل، الأحساء، المملكة العربية السعودية، 00966542747419، aldossary@kfu.edu.sa

الدوسري، حصلت على درجة الماجستير في تخصص علوم الحاسب الآلي المتقدمة تخصص دقيق الحوسبة السحابية، جامعة ليستر، المملكة المتحدة، سعودية، محاضرة، حصلت على جائزة التفوق العلمي من الملحقية الثقافية السعودية في لندن لعامين متتالين 2018 م و2019م، حصلت على جائزة الطالب المثالي من معهد جامعة ليستر في ديسمبر من عام 2017م، من أعمالها (طورت أداة لتحليل بيانات خوادم شركة Twitter, برنامج لإدارة قواعد البيانات السحابية، إطار عمل للتحقق من وصول البيانات في حالات تأخر أو فقدان الاتصال الشبكي). رقم الأوركيد (ORCID): 0000-0002-6706-4370

لينا أحمد الفراني

قسم تقنيات التعليم، كلية الدراسات العليا التربوية، جامعة الملك عبد العزيز، جدة، المملكة العربية السعودية، 00966544299500، lalfrani@kau.edu.sa

د. الفراني خريجة بكالوريوس علوم الحاسبات من جامعة الملك عبدالعزيز، أنهت دراسة الماجستير والدكتوراة في تخصص تقنية المعلومات والاتصالات في التعليم من جامعة ليدز في بريطانيا، أستاذ مشارك في قسم تقنيات التعليم في جامعة الملك عبدالعزيز، لديها اهتمامات بحثية في مجالات تكنولوجيا التعليم والتعليم الإلكتروني والتعليم عن بعد والذكاء الاصطناعي والتربية الخاصة، نشرت العديد من الأبحاث في مجلات عربية وأجنبية، لها أوراق علمية منشورة في مؤتمرات أجنبية، ومحكمة معتمدة في مجلة Social Sciences & Humanities Open, Elsevier. رقم الأوركيد (ORCID): 0000-0002-7199-0377

المراجع

العلوان، جعفر أحمد. (2020). الاتجاهات الإدارية المعاصرة في تنمية الموارد البشرية مراجعة منهجية للأدبيات ذات العلاقة. *مجلة العلوم الإنسانية والاجتماعية: جامعة الإمام محمد بن سعود الإسلامية*، **بدون رقم مجلد**(46)، 67–119.

لال، زكريا يحيى، الجندي، علياء عبد الله. (2005). *الاتصال الإلكتروني وتكنولوجيا التعليم*. الطبعة الثالثة. الرياض، السعودية: مكتبة العبيكان.

وثيقة التحول الرقمي. (2020). *رؤية المملكة 2030*. متوفر بموقع: https://vro.moenergy.gov.sa/Arabic/DocLib/NTP_ar.pdf (تاريخ الاسترجاع : 23/ 11 /2022)

Al Ulwan, J.A. (2020). Aliatijahat al'iidariat almueasirat fi tanmiat almawarid albashariat murajaeatan manhajiatan lil'adabiaat dhat alealaqa 'Contemporary administrative trends in the development of human resources a systematic review of the relevant literature'. *Journal of Humanities and Social Sciences,* **n/a**(46), 119–67. [in Arabic]

Lal, Z.Y. and Aljindi, A.A. (2005). *Alittesal Alelictroni w Tiknolojya Altaleem* 'Electronic Communication and Education Technology'. Riyadh, Saudi Arabia: Obeikan Bookstore. [in Arabic]

Wathīqah Altaḥawwul Alrqmy. (2020). *Roayat Almmlkt 2030'*Kingdom Vision 2030'. Available at: https://vro.moenergy.gov.sa/Arabic/DocLib/NTP_ar.pdf (accessed on 23/ 11 /2022) [in Arabic]

Abdelkader, H., Gad, A., Abohany, A. and Sorour, S. (2022). An efficient data mining technique for assessing satisfaction level with online learning for higher education Students during the COVID-19. *IEEE Access*, **10**(n/a), 6286–303.

Araujo, L., Lopez-Ostenero, F., Martinez-Romo, J. and Plaza, L. (2020). Deep-learning approach to educational text mining and application to the analysis of topics difficulty. *IEEE Access*, **8**(n/a), 218002–14.

Buenano-Fernandez, D., Gonzalez, M., Gil, D. and Lujan-Mora, S. (2020). Text mining of open-ended questions in self-assessment of university teachers: An LDA topic modeling approach. *IEEE Access*, **8**(n/a), 35318–30.

Chen, H., Nguyen, B., Yan, Y. and Dow, C. (2020). Analysis of learning behavior in an automated programming assessment environment: A code quality perspective. *IEEE Access*, **8**(n/a), 167341–54.

Czibula, G., Ciubotariu, G., Maier, M. and Lisei, H. (2022). IntelliDaM: A machine learning-based framework for enhancing the performance of decision-making processes. A case study for educational data mining. *IEEE Access*, **8**(n/a), 80651–66.

Du, X., Yang, J. and Hung, J. (2020a). An integrated framework based on latent variational autoencoder for providing early warning of at-risk students. *IEEE Access*, **8**(n/a), 10110–22.

Du, X., Yang, J., Hung, J. L. and Shelton, B. (2020). Educational data mining: A systematic review of research and emerging trends. *Information Discovery and Delivery*, **48**(4), 225–36.

Feng, G., Fan, M. and Ao, C. (2022). Exploration and visualization of learning behavior patterns from the perspective of educational process mining. *IEEE Access*, **10**(n/a), 65271–83.

Ghorbani, R. and Ghousi, R. (2020). Comparing different resampling methods in predicting students 'performance using machine learning techniques. *IEEE Access*, **8**(n/a), 67899–911.

Gronberg, N., Knutas, A., Hynninen, T. and Hujala, M. (2021). Palaute: An online text mining tool for analyzing written student course feedback. *IEEE Access*, **9**(n/a), 134518–29.

Iqbal, N., Jamil, F., Ahmad, S. and Kim, D. (2020). Toward effective planning and management using predictive analytics based on rental book data of

academic libraries. *IEEE Access*, **8**(n/a), 81978–96.

Kumar, R. and Sharma, A. (2017). Data mining in education: a review. *International Journal of Mechanical Engineering and Information Technology*, **5**(1), 1843–5.

Li, Z., Li, Y. and Xie, Z. (2020). Exploring the significant predictors to the quality of master's dissertations. *IEEE Access*, **8**(n/a), 21152–8.

Mengash, H. (2020). Using data mining techniques to predict student performance to support decision making in university admission systems. *IEEE Access*, **8**(n/a), 55462–70.

Nabil, A., Seyam, M. and Abou-Elfetouh, A. (2021). Prediction of students ' academic performance based on courses 'grades using deep neural networks. *IEEE Access*, **9**(n/a), 140731–46.

Prabowo, H., Hidayat, A., Cenggoro, T., Rahutomo, R., Purwandari, K. and Pardamean, B. (2021). Aggregating time series and tabular data in deep learning model for university students 'GPA prediction. *IEEE Access*, **9**(n/a), 87370–7.

Prada, M., Dominguez, M., Vicario, J., Alves, P., Barbu, M. and Podpora, M. (2020). Educational data mining for tutoring support in higher education: A web-based tool case study in engineering degrees. *IEEE Access*, **8**(n/a), 212818–36.

Priyambada, S., Er, M., Yahya, B. and Usagawa, T. (2021). Profile-based cluster evolution analysis: Identification of migration patterns for understanding student learning behavior. *IEEE Access*, **9**(n/a), 101718–2.

Qi, C. and Liu, S. (2021). Evaluating on-line courses via reviews mining . *IEEE Access,* 9(n/a), 35451–39.

Qu, Y., Li, F., Li, L., Dou, X. and Wang, H. (2022). Can we predict student performance based on tabular and textual data?. *IEEE Access*, **10**(n/a), 86008–19.

Rahman, M., Watanobe, Y., Matsumoto, T., Kiran, R. and Nakamura, K. (2022). Educational data mining to support programming learning using problem-solving data. *IEEE Access*, **10**(n/a), 26186–202.

Shao, Z., Sun, H., Wang, X. and Sun, Z. (2020). An optimized mining algorithm for analyzing students 'learning degree based on dynamic data. *IEEE Access*, **8**(n/a), 113543–56.

Siddaway, A. (2014). What is a systematic literature review and how do I do one. *University of Stirling*, **1**(1), 1–13.

Siemens, G. and 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*, ACM, Vancouver, British Columbia, Canada, 04/2012.

Wen, Y., Tian, Y., Wen, B., Zhou, Q., Cai, G. and Liu, S. (2020). Consideration of the local correlation of learning behaviors to predict dropouts from MOOCs. *Tsinghua Science and Technology*, **25**(3), 336–47.

Xiao, X., Sun, R., Yao, Z., Zhang, C. and Chen, X. (2021). A Novel framework with weighted heterogeneous educational network embedding for personalized freshmen recommendation under the impact of COVID-19 storm. *IEEE Access*, **9**(n/a), 67129–42.

Zeng, Y., Ouyang, Y., Gao, R., Qiu, Y., Yu, Y. and Wang, C. (2020). HHA: An attentive prediction model for academic abnormality. *IEEE Access*, **8**(n/a), 124755–66.

Zhai, G., Yang, Y., Wang, H. and Du, S. (2020). Multi-attention fusion modeling for sentiment analysis of educational big data. *Big Data Mining and Analytics,* **4**(3), 311–9.