

تعلم الآلة في التعليم دراسة منهجية

Machine learning in education: a systematic study

إعداد

سهام صالح حمد النافع

Seham S. Alnafea

كلية الدراسات العليا – جامعة الملك عبدالعزيز

أ.م/ علياء عبدالله الجندي

Dr. Alia Aljindi

كلية الدراسات العليا – جامعة الملك عبدالعزيز

Doi: 10.21608/ejev.2024.349430

استلام البحث: ٢٠٢٤ / ٣ / ٧

قبول النشر: ٢٠٢٤ / ٣ / ٢٣

النافع، سهام صالح حمد و الجندي، علياء عبدالله (٢٠٢٤). تعلم الآلة في التعليم دراسة منهجية. **المجلة العربية للتربية النوعية**، المؤسسة العربية للتربية والعلوم والآداب، مصر، (٣١)، ٣٢٩ - ٣٤٦.

<http://jasep.journals.ekb.eg>

تعلم الآلة في التعليم دراسة منهجية

المستخلص:

هدفت الدراسة الحالية إلى تقديم نظرة عامة منهجية على مجموعة من الدراسات حول تعلم الآلة في التقنيات التعليمية. تم تضمين تلخيصاً لأحدث الاكتشافات في مجال تعلم الآلة (ML)، مع التركيز على الآثار المترتبة على مجال التدريس والتعلم. تبدأ مراجعة الأدبيات هذه بتقديم الخلفية العلمية المتعلقة بتعلم الآلة كمجموعة فرعية من الذكاء الاصطناعي وبعض الأدوات المحددة المستخدمة في هذا المجال. بعد ذلك، تم تقديم بعض الدراسات التي تناولت تطبيق تعلم الآلة على عمليات وطرق التدريس. موضوع آخر تم تناوله في النظرة العامة على الأدبيات هو أنظمة التدريس الذكية التي تجمع بين ميزة التدريس مع أدوات الكمبيوتر المتقدمة. ثم تقدم الورقة الدراسات التي تطبق تعلم الآلة على عمليات تقييم العملية المعرفية. كما تم تناول الطرق التي تساعد هذه الأنظمة في التخطيط وتطوير المناهج. أخيراً، تمت مناقشة بعض المخاوف المتعلقة باستخدام تعلم الآلة بدلاً من التفاعل البشري. توضح مجموعة الأبحاث المدروسة الإمكانيات الهائلة لتعلم الآلة في التقنيات التعليمية.

Abstract:

The current study aimed to provide a systematic overview of a range of studies on machine learning in educational technologies. A summary of the latest discoveries in the field of machine learning (ML) is included, with an emphasis on implications for teaching and learning. This literature review begins by presenting the scientific background related to machine learning as a subset of artificial intelligence and some of the specific tools used in this field. Next, some studies discussing the application of machine learning to teaching processes and methods are presented. Another topic addressed in the literature overview is intelligent tutoring systems that combine the advantage of teaching with advanced computer tools. The paper then presents studies that apply machine learning to cognitive process assessments. The methods that help these systems in planning and developing curricula were also discussed. Finally, some concerns regarding using machine

learning instead of human interaction are discussed. The extensive body of research demonstrates the enormous potential of machine learning in educational technologies.

مقدمة:

إن الملاحظ لتابع الأحداث في العقد الأخير يجد وبما لا يقبل الشك وجود تطور قياسي وسريع لتقنيات المعلومات وتراكم البيانات الضخمة، الأمر الذي يتطلب استحداث طرق ومناهج جديدة لإدارتها، مثل الأنظمة القائمة على تعلم الآلة. يتطلب نمو البيانات المضطرب في مجال التعليم أيضاً وسائل آلية أكثر فاعلية لمعالجتها. تقدم الأدبيات الحالية نظرة عامة منهجية على مجموعة من الدراسات حول تعلم الآلة في التقنيات التعليمية. تم تضمين تلخيصاً لأحدث الاكتشافات في مجال تعلم الآلة (Machine Learning)، مع التركيز على الآثار المترتبة على مجال التدريس والتعلم. ينتمي تعلم الآلة إلى مجال الذكاء الاصطناعي Artificial Intelligence (AI) و هدفه هو تمكين أجهزة الكمبيوتر من التعلم من البيانات المتاحة والعمليات السابقة من أجل اتخاذ بعض الخيارات والقرارات ذات الصلة فيما يتعلق بتحسين النظام. الهدف من دراسة هذا المجال هو جعل التدريس أكثر ملاءمة للمعلمين الذين يمكنهم قضاء المزيد من الوقت في الأنشطة الإبداعية والتربوية في الفصل الدراسي. يساعد تطبيق تعلم الآلة أيضاً في جعل تجارب الطلاب أكثر فعالية وبالتالي تحقيق نتائج تعليمية أفضل.

تبدأ مراجعة الأدبيات هذه بتقديم الخلفية العلمية المتعلقة بتعلم الآلة كمجموعة فرعية من الذكاء الاصطناعي وبعض الأدوات المحددة المستخدمة في هذا المجال. بعد ذلك، تم تقديم بعض الدراسات التي تناولت تطبيق تعلم الآلة على عمليات وطرق التدريس. موضوع آخر تم تناوله في النظرة العامة على الأدبيات هو أنظمة التدريس الذكية التي تجمع بين ميزة التدريس مع أدوات الكمبيوتر المتقدمة. ثم تقدم الورقة الدراسات التي تطبق تعلم الآلة على عمليات تقييم العملية المعرفية. كما تم تناول الطرق التي تساعده هذه الأنظمة في التخطيط وتطوير المناهج. أخيراً، تمت مناقشة بعض المخاوف المتعلقة باستخدام تعلم الآلة بدلاً من التفاعل البشري.

الخلفية العلمية وأدوات تعلم الآلة:

لقد غيرت التقنيات المعلوماتية جميع مجالات حياتنا، حيث جلبت سرعة معالجة البيانات والفعالية والاتصال. لا يمكن اعتبار العملية التعليمية الحديثة، التي تهدف إلى إعداد الطلاب للمستقبل، حديثة وذات صلة دون استخدام هذه الأدوات أيضاً (Karsenti, 2019). من بين الاتجاهات الحديثة للبحث المعلوماتي، يعد الذكاء

الاصطناعي أحد المجالات الأكثر تقدماً، حيث يتم تطبيق مزايا السلوك البشري وأساليب التفكير على الآلات. يعرف تشاسينول وأخرون (Chassignol et al, 2018) الذكاء الاصطناعي بأنه "مجال علوم الكمبيوتر المخصص لحل المشكلات المعرفية المرتبطة بشكل شائع بالذكاء البشري، مثل التعلم و حل المشكلات والتعرف على الأنماط". هذا التعريف يفترض أن الذكاء الاصطناعي لا يستخدم المعلومات فحسب، بل يمكنه أيضاً التعلم منها. وتعلم الآلة هو جزء من الذكاء الاصطناعي يركز بشكل خاص على وسائل تعليم أجهزة الكمبيوتر للتعلم من البيانات تقليدياً دون الحاجة إلى برمجة مخصصة لهذا الغرض. تستخدم الأدوات التي يوفرها الذكاء الاصطناعي من أجل إظهار كيف يمكن الآلات معالجة وتفسير أنواع مختلفة من البيانات اللازمة للمجال التعليمي (Nafea, 2018) بعد تعلم الآلة جزءاً من تقييم الذكاء الاصطناعي التي تركز على التعلم الذاتي الذي تقوم به أنظمة الكمبيوتر.

في العصر الحالي نجد أنه لا غنى عن التقنية في التعليم، حيث أنها أثبتت فعاليتها على رفع نواتج التعلم للطلاب عبر المواد الدراسية. أضاف إلى ذلك، أنه يمكن أيضاً تطبيق حلول الذكاء الاصطناعي على بعض العمليات المساعدة للعملية التعليمية مثل الجدولة وتطوير المناهج، حيث تساعد في تطوير سيناريوهات وبيئات تعلم أكثر تقدماً (Ball et al., 2019). كما يشير إلى في (Lv & Li, 2015) أنه يمكن توظيف تعلم الآلة بفعالية في عمليات المتابعة وتخطيط العمليات وتنفيذ الأهداف. وفي نفس السياق تشير دراسة أوربينا وديلا كاليخا (Urbina & De la Calleja, 2017) ، أنه يمكن أن يساعد تعلم الآلة في حل مجموعة واسعة من مشاكل الكفاءة والمهام الأخرى التي ينص عليها التعليم الحديث. لذلك، هناك طرق عديدة لتطبيقات تعلم الآلة في التعليم.

لدراسة الوضع الراهن فيما يخص الأبحاث والدراسات المتعلقة بتعلم الآلة، من المهم أولاً مراجعة الأدوات التي يتم نشرها بشكل شائع لحل المشكلات المذكورة لطرق التدريس والتخطيط وتطوير المناهج وتقدير العملية المعرفية والتدريس الذكي. هناك بعض الأدوات وأساليب المحددة التي يقدمها تعلم الآلة لحل هذه المشكلات، والوسائل الأكثر استخداماً هي شجر اتخاذ القرار، والشبكات العصبية، والطرق القائمة على المثلثات، وشبكات بايز، والانحدار اللوجستي. وسنتناول كل منها كما وردت في الدراسات السابقة.

شجر اتخاذ القرار :Decision Trees

المنهجية الأولى التي يتم استخدامها بكثرة من خلال أنظمة تعلم الآلة بهدف تحسين التقنيات التعليمية هي شجرة اتخاذ القرار التي يتم تطبيقها على نطاق واسع عبر المهام في هذا المجال. تعد شجرة اتخاذ القرار أحد طرق التمثيل البياني

للخطوات التي يمكن اتخاذها بناءً على النتائج التي تم الحصول عليها خلال كل مرحلة (Urbina & De la Calleja, 2017). يوجد عادةً خياران للقرارات التي تتبع كل عقدة، بينما تحتوي كل شجرة قرار على عقدة الجذر الخاصة بها حيث تبدأ العملية. تشير دراسة بال وأخرون (Ball et al., 2019) إلى أن ميزة شجر اتخاذ القرار استخدام كل خطوة عقدة واحدة لاتخاذ الخيار التالي. أي أن كل عقدة هي نقطة حيث يتم تحديد الفرع التالي الذي سيتم أخذها وبالتالي يتم تنظيم عملية صنع القرار، مع السماح بمتابعة نتائج محددة.

تشير الدراسات إلى أنه يمكن تطبيق شجر اتخاذ القرار في عمليات مختلفة، فعلى سبيل المثال، فإنه يمكن اختيار المهمة بناءً على أداء الطالب (Urbina & De la Calleja, 2017). كما يمكن استخدام شجر اتخاذ القرار لتطوير مناهج شخصية في التعلم الإبداعي (Lin et al., 2013). يمكن أيضًا تطبيق شجر اتخاذ القرار لتطوير مناهج التعلم الشخصية في التدريس المستند إلى الكمبيوتر. ومن جانب آخر فإن دراسة كروكيت وأخرون (Crockett et al., 2017) تشير بأن هذه الأداة يمكن أن تساعد في التنبؤ بأنماط التعلم للطلاب وبالتالي تساعد الأنظمة على اختيار أنساب أساليب التعلم في التدريس الذكي. بعد شجر اتخاذ القرار من أكثر طرق تعلم الآلة استخدامًا في الأنظمة ويمكن تطبيقها عبر مجموعة متنوعة من المهام والعمليات.

الشبكات العصبية :Neural Networks

تشكل الشبكات العصبية فئة أخرى شائعة للغاية من تطبيقات أنظمة تعلم الآلة في العمليات التعليمية. تصنف أوربينا وديلا كاليخا (Urbina & De la Calleja, 2017) مبدأ الشبكات العصبية الاصطناعية على أنها أنظمة تشبه سلوك الخلايا العصبية المترابطة في الدماغ البشري. وأن عمليات تعلم الآلة تستند إلى هذا المبدأ، وتتصرف وحدات النظام بشكل مشابه للخلايا العصبية. تعمل وحدات الشبكة العصبية معًا: يمكن لعصب واحد إرسال محفز بحيث يتم تنشيط الخلايا العصبية الأخرى، وذلك على غرار المشابك العصبية المرسلة بين الخلايا العصبية في دماغ حي. يجسد كارسيتي (Karsenti, 2019) استخدام الشبكات العصبية من خلال عمليات التعرف على الصور التي تقوم بها أنظمة المعلومات. ضمن هذا النهج لتعلم الآلة، يتم تدريب النظام على تحليل البيانات والطبقات المتصلة بها دون ترميزها يدوياً، وبدلاً من ذلك يتم "تدريبها" بكميات كبيرة من البيانات. يمكن تطبيق هذا النهج على المهام التنبؤية في التعليم لبعض المهام مثل توقع أداء الطلاب. وفي هذا السياق يقترح باباميتسيو وإيكونوميديس (Papamitsiou & Economides, 2014) بعض الأمثلة على استخدام الشبكات العصبية في التعليم، مثل تحليل احتفاظ الطلبة

بالمعلومات أو تحليل درجاتهم. كما يؤكد على أن الشبكات العصبية تقوم باستخدام كميات كبيرة من البيانات المساعدة في تعلم النظام.

الأساليب القائمة على المثل :Instance-Based Methods

الأساليب القائمة على المثل هي طريقة أخرى يتم استخدامها في أنظمة تعلم الآلة لمساعدة العمليات التعليمية. مثل هذه الطريقة تعني أن النظام يستخدم مجموعة من المعلومات والحقائق والأمثلة التي تم تعلمها مسبقاً لعمل افتراضات حول موضوع ما (Urbina & De la Calleja, 2017). عند تطبيق هذه الطريقة، يختار النظام القائم على تعلم الآلة أقرب الأمثلة لوصف موضوع معين. يطبق إي آر (Er, 2012) أدوات تعلم الآلة المستندة إلى المثل للتنبؤ بأداء الطلاب، ولتحديد الطلاب المعرضين للخطر وتلبية احتياجاتهم في الوقت المناسب. تستخدم الأدوات القائمة على المثل مجموعة من الأمثلة والحقائق التي تم جمعها بواسطة نظام لعمل تنبؤات وافتراضات أخرى في العملية التعليمية.

التعلم وفق نظرية بايز :Bayesian Learning

نظام تعلم الآلة وفق نظرية بايز هو منهجية تبحث عن الفرضية التي يمكن أن تشرح بشكل صحيح طبيعة بيانات التدريب (Urbina & De la Calleja, 2017). وهو نظام يستخدم خوارزمية تستخدم نهج التعلم الاستقرائي وتعرف باسم المُصنّف البايزي الساذج أو مصنف نيف الساذج Naïve Bayes Classifier. عند تعين قيمة مستهدفة، تحمل هذه الخوارزمية البيانات من موقع الاحتمال الذي يناسب المهمة المحددة. يوضح إي آر (Er, 2012) أن خوارزمية بايز الساذجة تحسب توافر مجموعات مختلفة من البيانات وبهذه الطريقة، فإنها تفترض النتيجة. تُستخدم هذه الخوارزمية لبناء ما يسمى بشبكة بايز. تعد شبكة بايز طريقة للتعلم الآلي تتبع المعرفة من أجل تحديد احتمالية تعلم الدرس بشكل صحيح. وتوضح دراسة ما وآخرون (Ma et al, 2014) أن هذه الخوارزميات يمكن أن تستخدم نتائج اختبار الطلاب لتحديد ما إذا كانوا قد تعلموا حقاً المادة المخصصة. علاوة على ذلك، يمكن تطبيق الخوارزمية على مهام أكثر تعقيداً، مثل حل المشكلات في التدريس وذلك عندما يجب أن يعتمد تدفق التدريس على قرارات سابقة ذات صلة.

الانحدار اللوجستي :Logistic Regression

بعد الانحدار اللوجستي أيضاً أداة يمكن أن تساعد في عمليات تعلم الآلة وتحقيق النتائج في العملية التعليمية (Urbina & De la Calleja, 2017). تتناول دراسة بال آخرون (Ball et al., 2019) خوارزمية الانحدار اللوجستي باعتبارها تقوم بتحليل مدى تأثير كل عنصر على القرار العام. بعد ذلك، يحسب النظام المعامل الذي يصور مدى التأثير الذي أحدثه كل عنصر ويحدد حجم هذا المعامل مدى

ملاءمته للتعلم. يستخدم إي آر (Er, 2012) الانحدار اللوجستي في بحثه الذي يحدد الطلاب المعرضين للخطر ويستنتج بأن هذه الأداة تعطي نتائج مناسبة مقارنة بأدوات تعلم الآلة الأخرى المطبقة. وفي هذا السياق يوضح حسين وأخرون (Hussain et al., 2019) كيف يمكن للانحدار اللوجستي أن يخبرنا عن التنبؤ بصعوبات الطلاب في عملية التعلم. يمكن أيضًا تطبيق الانحدار في تعلم الآلة التعليمي والمساعدة في وضع الافتراضات ذات الصلة.

تعلم الآلة في التعليم:

أصبحت تقنيات المعلومات مطبقة على نطاق واسع عبر البيئات التعليمية لما يدركه المعلمون من الفوائد العديدة التي تقدمها. تتمتع أنظمة تعلم الآلة بإمكانيات كبيرة للتدرис حيث يمكن أن تساعد المعلمين على تحديد أكثر الطرق فعالية لتنمية احتياجات الطلاب (Nafea, 2018). وتوجد مجالات متعددة يمكن من خلالها أن تساعد أنظمة تعلم الآلة في التدرис وذلك بأن ترفع من كفاءة العملية التعليمية لجميع المشاركون. يتعلق هذا بكل من أداء المعلم وجهوده وكذلك النتائج التي يحققها الطلاب نتيجة لذلك.

الفئة الأولى من الاستخدامات التي يمكن أن تقدمها أنظمة تعلم الآلة للسياق التعليمي هي السماح للمدرسين بالحصول على مزيد من وقت الفراغ حيث يمكن تبسيط بعض المهام الشاقة إلى حد كبير من خلال الأنظمة القائمة على تعلم الآلة. أحد الأمثلة على هذا التبسيط هو ما أشارت إليه نافع (Nafea, 2018) من خلال عملية أخذ حضور الطالب الذي يمكن إدارته بسهولة بواسطة النظام، أو مساعدة المعلمين على تصنيف الطلاب بشكل أكثر مصداقية وموضوعية وفعالية من حيث الوقت. كما تؤكد دراسة كاريسينتي (Karsenti, 2019) أن الدرجات التلقائية يمكن أن توفر وقتاً إضافياً للمعلمين يمكنهم من استثماره في القيام ببعض الأنشطة الإبداعية. وفي المقابل، فإنه لا تزال هناك بعض المهام التي لا تستطيع الآلات تقييمها بشكل متماسك حتى الآن، على سبيل المثال، كتابة أطروحة أو تكملة جزء آخر من الأعمال المكتوبة، ولا تزال المشاركة البشرية لا غنى عنها في العديد من المجالات (Karsenti, 2019).

من خلال مناقشة مزايا أنظمة تعلم الآلة للتدرис، حدد كاريسينتي (Karsenti, 2019) العديد من النتائج الحاسمة للتدرис من منظور الفعالية. يمكن أن يساعد تعلم الآلة المعلمين على تعديل دوراتهم بناءً على أداء الطلاب. على سبيل المثال، يمكن لبعض المنصات، مثل منصة كورسيرا Coursera، الكشف عن المجالات التي كان أداء الطلاب فيها أسوأ وبالتالي يحتاجون إلى تحسين (Karsenti, Ball et al., 2019). وفي هذا السياق تكشف دراسة بال وأخرون (Ball et al., 2019) عن

كيفية تطبيق أنظمة تعلم الآلة على مناهج أكثر فعالية للمناهج الدراسية، حيث يمكن لهذه الأنظمة تحليل احتياجات الطلاب إحصائياً واستخلاص الأفكار من مجموعات البيانات الضخمة. يمكن أن يجعل أنظمة تعلم الآلة عملية التدريس أكثر فعالية.

من جانب آخر فقد حددت دراسة Nafea (2018) ميزة تتبع كل طالب على حدة وبشكل شخصي، حيث يمكن لتعلم الآلة أن يقدم أدوات داعمة ذات صلة. هذا التخصيص والشخصنة لعملية التعلم يصبح ممكناً بسبب القدرة العالية لتقنيات المعلومات على تقييم مجموعات أكبر من البيانات بشكل فعال وتقديم الأفكار التي لن يكتشفها المعلم بطريقة أخرى. وهذا ما يتم توضيحه في دراسة Karsenti (2019) عند تناول منصة ELSA القائمة على شخصنة التعلم والتي تعمل على مساعدة الطلبة على تصحيح نطقهم. وتتفق دراسة Asthana & Hazela (2020) في ذلك حيث تشير إلى أن إحدى أعظم مزايا تعلم الآلة في التعليم هي أنه يمكن أن يتحقق التدريس المخصص أو المشخص بدلاً من استخدام نهج نموذجي واحد يناسب الجميع. من خلال تحليل المتغيرات مثل أداء الطالب ونتائجها، يمكن للأدوات تعلم الآلة أن تساعد المعلمين في اتخاذ قرارات مستنيرة بشأن التخصيص وبالتالي تقديم نتائج أفضل لكل طالب. بمساعدة هذه الأنظمة، يمكن للمدرسين أيضاً تخصيص دروسهم وخططهم التعليمية بالكامل، وتعديلها وفقاً لاحتياجات الحالية للمتعلمين. يمكن أن يساعد تعلم الآلة في العملية التعليمية من خلال توفير الخلفية لاختيار الاستراتيجيات الشخصية والمخصصة للمعلمين.

بعد إنتاج ملاحظات مخصصة وذات صلة ميزة أخرى يمكن أن يقدمها التعلم الآلي لعملية التدريس. في حين أن تقديم الملاحظات هو ضرورة للتعلم الفعال، إلا أنها عملية تستغرق وقتاً طويلاً للمعلمين. يقدم التعلم الآلي بالفعل أدوات يمكنها تحليل نتائج الطلاب وإنشاء التعليقات المفيدة وذات الصلة (Asthana & Hazela, 2020). من خلال مناقشة نظام يوتيفين UTIFEN كمثال على أنظمة تعلم الآلة القائمة على التخصيص والشخصنة، فإن دراسة Karsenti (2019) توضح أن النظام الأساسي يمكن أن يوفر ملاحظات ووصيات مخصصة بناءً على أداء الطلاب. وفي نفس السياق تؤكد دراسة Asthana & Hazela (2020) على أن أنظمة التقييم القائمة على تعلم الآلة مفيدة لأنها خالية من الذاتية والتحيز البشري. يمكن أن يساعد تعلم الآلة في التدريس في أنشطة توفير الملاحظات الهامة.

أنظمة التدريس الذكية:

أحد تطبيقات تعلم الآلة في عملية التعلم الفعلية هو التدريس حيث يمكن للآلات أن تحل محل المشاركة البشرية. تسمى هذه التقنية أنظمة التدريس الذكي Intelligent Tutoring Systems (ITS) وهي مطبقة بالفعل على نطاق واسع في التعليم ومن المتوقع أن تنمو أكثر مع اكتساب التعلم عن بعد والتعلم عبر الإنترن트 أهمية. تشير دراسة كارسينيتي (Karsenti, 2019) إلى أن تطوير تقنيات الهاتف المحمول يساعد بشكل كبير في تطوير مناهج التدريس الذكية. تشير الدراسات بأنه لابد أن تكون أنظمة التدريس هذه قابلة للتكييف من أجل تقديم نتائج فعالة، حيث يفترض التدريس اتباع نهج شخصي يلبي احتياجات الطلاب الأكثراً صلة (Asthana & Hazela, 2020). كما أنه يجب من الأخذ بعين الاعتبار ضرورة أن يؤدي التدريس الرقمي إلى مجموعة متنوعة من الأنشطة، مثل الانخراط في الحوارات وإعطاء المهام وتصنيف المهام وتقديم الملاحظات. تشير دراسة ما وأخرون (Ma et al., 2018) إلى أن أنظمة التدريس الذكي ITS تختلف عن التعليمات الأساسية المعتمدة على الكمبيوتر (CBI)، حيث أن CBI لا تقم إلا بتغذية راجعة عند اكتمال المهمة. وفي المقابل، تستطيع أنظمة التدريس الذكي ITS التنقل في عملية التعلم خطوة بخطوة، مما يوفر تجربة مماثلة للتدريس البشري. ITS هي تقنية متقدمة يمكن مقارنتها بالدورس الخصوصية وتستخدم على نطاق واسع في التعلم عن بعد.

تقوم أنظمة التدريس الذكي ITS بميزة تخصيص عملية التعلم، والتعلم الآلي هو تقنية لا غنى عنها لهذه المهمة. تتكيف هذه الأنظمة مع الأداء المستمر للطالب وتقدم الخطوات والمهام التالية بناءً على البيانات التي تم جمعها مسبقاً. تشير دراسة أستانة وهازيلا (Asthana & Hazela, 2020) إلى أن ITS تقم ميزة تخصيص المواد التعليمية بما يتاسب مع احتياجات كل طالب، مع مراعاة مستوى التعلم، والمدة المفضلة للجلسات، ووتيرة الإدراك، والأداء في المهام. وفي نفس المجال توصي دراسة نافع (Nafea, 2018) باستخدام الدروس الخصوصية عبر الإنترن特 لاعتباره حلاً فعالاً لجعل محتوى الطلاب يلبي الاحتياجات الشخصية بشكل أفضل. يمكن لهذه الأنظمة الأساسية تسجيل نتائج الطلاب وبالتالي تقديم مناهج فردية للأداء.

تتطور أنظمة التدريس الذكي ITS بسرعة وتتنوع الطرائق المختلفة لاستخدام تعلم الآلة لتمكين هذه الأنظمة. تناقش دراسة تشاسينيولا وأخرون (Chassignola et al., 2018) العديد من الأمثلة لأنظمة ITS المستخدمة عبر المجالات التعليمية، مثل نظام الرياضيات النشطة أكتيف ماث ActiveMath و شيرلوك VIPER و كوميت COMET و نظام المدرس التلقائي SHERLOCK

أوتو تيوتر The AutoTutor . بينما يستخدم كل نظام منهجه الخاص لمعالجة البيانات التي تم جمعها، يتم تخصيص الأبحاث أيضاً للطرق الأساسية. تقارن دراسة ما وآخرون(Ma et al., 2018) بين ثلاثة مناهج أساسية لأنظمة التدريس الذكي ITS ، مثل التوقع وتخصيص المفاهيم الخاطئة Expectation and Misconception Tailoring (EMT) ، وتتبع النموذج ، والنموذج القائمة على القيود. النهج الأول وهو EMT هو نهج يهدف إلى مطابقة عبارات الطلاب مع المقاطع النصية التي يمكن أن تستخدمها الآلة لإشراك المتعلم في حوار. تستخدم هذه المطابقة طريقة التحليل الدلالي الكامن (Ma et al., 2018). تتبع النموذج هو النهج الثاني لأنظمة التدريس الذكي ITS وهو يستخدم مجموعة معينة من قواعد الإنتاج التي يتم تنشيطها عندما يتعين على النظام حل بعض المشكلات. تم تصميم هذه العملية بطريقة تشبه أساليب حل المشكلات التي يستخدمها المعلمون البشريون في بيئات مماثلة. وأخيراً فإن النموذج القائمة على القيد هي نظام يستخدم طريقة مختلفة تماماً، لأنها تعتمد على تحليل أخطاء الأداء. يركز نهج النموذج هذا على قيود كل مهمة ويوفر تغذية مرتبطة عند انتهاءك أحد القيود بطريقة ما. تحتوي أنظمة ITS على عدة أنواع يمكن تمييزها بالمنطق الذي تستخدمه.

إن طبيعة عملية التدريس الخصوصية تتطلب استخدام أنظمة تعلم آلة ذات المناهج الأكثر تقدماً والتي تستخدم الاستراتيجيات المختلفة لتحليل بيانات الإدخال. تشير دراسة كروكيت وآخرون(Crockett et al., 2017) إلى أن تطبيق شجر اتخاذ القرار هو أحد أقوى مناهج التعلم الآلي لدعم اتخاذ القرار في أنظمة التدريس الذكي ITS. هناك طريقة أخرى للتعلم الآلي تُستخدم على نطاق واسع في أنظمة التدريس الذكي ITS وهي شبكات بايز Bayesian networks والتي تؤكد دراسة ما وآخرون(Ma et al., 2014) على أهميتها وشيوع استخدامها كخوارزميات في أنظمة التدريس الذكي ITS.

هناك بعض الحلول الأخرى التي تستخدم في الأنظمة القائمة على تعلم الآلة ولكنها تقدم خدمات مختلفة إلى حد ما منها أنظمة التدريس الذكي ITS التي سبق مناقشتها. تعرض نافع (Nafea, 2018) في دراستها بعض الفوائد لتقنية المساعدة الافتراضية وتنذير أن هذه الأدوات توفر إمكانات التعلم الآلي المتقدم للطلاب. تصف الباحثة هذا الحل بأنه مساعدة يمكن أن يقدمها النظام للطالب الذي ينتقل في بعض المنصات التعليمية. يتم وصف هؤلاء المساعدين بأنهم قادرون على التواصل مع الطلاب وتقديم التوجيه والملاحظات. الهدف من هذه المساعدة هو تقليل الحاجز الذي قد تواجهه الطلاب أثناء المشاركة في بعض أدوات ومنصات التعلم الجديدة. وفي هذا السياق تتناول دراسة ليسطي وآخرون (Liseti et al., 2015) أنظمة التوصية وهي

أداة يتم تطبيقها على نطاق واسع في المجال عبر الإنترن特 من خلال موقع الويب، مثل منصة التسوق أمازون Amazon وفي كثير من مواقع التواصل الاجتماعي المحترفة. تستخدم هذه الأنظمة أدوات تحليلية متقدمة لتقديم التوصيات الأكثر صلة لمستخدميها، مثل المنتجات الجديدة أو الاتصالات المهنية. يمكن تطبيق نفس المبادئ في السياق التعليمي أيضاً، ويمكن أن يساعد تعلم الآلة هذه المنصات على تقديم توصيات مستنيرة للطلاب. كما ورد في دراسة إل فيولي (Lv & Li, 2015) حلاً مشابهاً للتدریس الذكي ولكنه الحل القائم على الواقع الافتراضي. يمكن أن تكون منصات الواقع الافتراضي بمثابة أداة تعليمية قوية باستخدام مزايا تعلم الآلة، ويمكن أن تساعدها الخوارزميات في ردود الفعل والإرشادات الفعالة. يمكن أيضاً أن يساعد المساعدون الظاهريون وأدوات التوصية في عملية التعلم.

يتم تطبيق أنظمة تعلم الآلة أيضاً في برمجيات التدریس المعرفي Cognitive Tutoring وهي برمجيات مصممة لمساعدة الطلاب في عملية التعلم. هذه البرمجيات تعتمد على نظام تكيفي Adaptive System يقوم بتحليل المعرفة ويساعد في توجيهه تقدم الطالب (Ma et al., 2014). وتشير دراسة دوبوا وأخرون (Dubois et al., 2010) إلى أن برمجيات التدریس المعرفي تستخدمنفس الأنماط التي يفترض أن يستخدمها الذكاء البشري عند تحليل البيانات والتوصيل إلى استنتاجات، ولذا فإن أنظمة التدریس المعرفي تعتبر أداة أخرى لتعلم الآلة التي يمكن الاستفادة منها لدعم العملية التعليمية.

تحديد صعوبات الطلاب:

تشير دراسة أورينا وديلا كاليخا (Urbina & De la Calleja, 2017) إلى إمكانية تطبيق تعلم الآلة لحل المشكلات الصعبة المتعددة الناشئة في السياق التعليمي. ترتبط إحدى أهم الصعوبات بالاختلافات الفردية للمتعلمين وببعض العقيمات المحددة التي قد تواجههم. يُقبل التعلم الآلي أيضاً كأداة لإنتاج تحليل لنتائج تعلم الطالب وتحديد المشكلات التي تواجههم. هناك دراسات تقدم رؤى حول هذا الموضوع وتشرح كيف يمكن القيام بهذا العمل التحليلي لتحديد مثل هذه القضايا وإيجاد سبل لمعالجتها.

في دراسة حسين وآخرون (Hussain et al, 2019) تم تحليل مجموعة من البيانات التي يدخلها الطلاب أثناء حل التمارين في التصميم الرقمي. كان هدف الباحثين هو تدريب خوارزميات محددة لأنظمة القائمة على تعلم الآلة حتى تتمكن تلك الأنظمة من التنبؤ بالتمارين التي قد يرتكب فيها الطالب خطأ. استنتجت الدراسة أن الخوارزميات مثل الشبكات العصبية الاصطناعية Artificial Neural Networks (ANNs) وآلات نقلات الدعم Support Vector Machines (ANNs)

(SVMs) تعتبر أكثر فاعلية على تحديد مثل هذه الأمور الإشكالية. تعتبر مثل هذه الحلول الرقمية ذات أهمية كبيرة اليوم حيث تزداد شعبية التعليم عبر الإنترنت وهناك حاجة إلى تقنيات متقدمة لدعم بيئة التعلم الرقمية. وبالتالي، فإن تحليل الأخطاء التي ستواجهه الطلاب هو اتجاه واعد للأبحاث المتعلقة بتعلم الآلة. توضح دراسة ما وأخرون (Ma et al., 2014) كيفية مساعدة المنذجة القائمة على القيود الأنظمة على التعلم من خلال أخطاء الأداء. إن نهج تعلم الآلة من خلال التحليل والتنبؤ بالأخطاء يعتبر جزءاً ضرورياً من هذا البحث في التعليم.

يوفر تعلم الآلة أدوات لا تعمل فقط على تقييم صعوبة التمرين ولكن أيضاً على التنبؤ بمعدلات التسرب والمخاطر. تستخدم الدراسة التي أجراها إي آر (Er, 2012) ثلاثة خوارزميات لتعلم الآلة لتحديد مستويات الطالب المعرضين للخطر وتكشف أن تعلم الآلة يمكن أن يساعد في التنبؤ بأداء الطلاب. تثبت الدراسة أن أنظمة الذكاء الاصطناعي قادرة على وضع افتراضات ذات صلة حول دراسات الطلاب.

تقييم الأداء:

يعتبر تقييم أداء الطلاب جزءاً مهماً من عملية التعلم بحيث يمكن للمعلمين تقديم الإرشادات اللازمة والتعليقات الملائمة إلى المتعلمين ومساعدتهم على التحسن، وإحدى أكثر طرق التقييم التربوي شيوعاً هي التحقق من مدى فعالية تذكر الطالب للمادة المقدمة وقدرتهم على استعادتها عند الحاجة (Nafea, 2018). تشير دراسة كوركماز وكوهيا (Korkmaz & Correia, 2019) إلى أن تقييم العملية المعرفية هو أحد أكثر المجالات المستهدفة والأكثر بحثاً في تطبيقات أنظمة تعلم الآلة في التعليم. على الرغم من أن الآلات ليست فعالة بعد بما يكفي للتحقق من الأعمال المكتوبة للطلاب بشكل صحيح، حيث تقدم فقط أدوات التدقيق اللغوي الأساسية، إلا أنها تعمل تدريجياً على تطوير إمكانات التقييم المعرفي (Karsenti, 2019). على الرغم من القيود الحالية، يمكن لتعلم الآلة تقديم أدوات متقدمة تدعم عمليات التقييم المعرفي.

الميزة الأساسية لتعلم الآلة على النهج البشري هي القدرة على تحليل كميات كبيرة من البيانات واستخلاص النتائج ذات الصلة في مهمة معينة. في التعليم، يعني هذا أن الأنظمة الذكية يمكنها معالجة نتائج تقييم الطلاب ومساعدة المعلمين في توجيه المتعلمين. تقدم أوريبينا وديلا كاليخا (Urbina & De la Calleja, 2017) مثالاً لدراسة عالجت مجموعة بيانات تضم ٥٠ طالباً، تم تحليل أداؤهم الأكاديمي عبر تخصصات الكمبيوتر بمساعدة أداة شجرة اتخاذ القرار. من خلال هذه الدراسة، اكتسب الباحثون مجموعة من قواعد "الشرط" التي يمكن تطبيقها بشكل فعال لإدارة الطلاب. يناقش كارسينتي (Karsenti, 2019) إمكانات التقييم المستمر الذي يمكن

أن تقدمه أدوات تعلم الآلة. إن التقييم المستمر الذي تم تمكينه بواسطة أساليب الذكاء الاصطناعي يعني أنه تتم مراقبة كل خطوة من خطوات الطالب ويمكن تقديم ملاحظات أكثر فعالية. يمكن أن يعود تطبيق الأنظمة القائمة على تعلم الآلة في تقييم الطالب بفوائد عديدة ومواطن متنوعة.

تطوير المناهج:

من بين التطبيقات المتنوعة لأدوات تعلم الآلة في عمليات التدريس والتعلم الفعال، فإنه يمكن تطبيقها لتصميم سياق تعليمي أكثر فعالية. جميع النتائج التي تمت مناقشتها سابقاً حول مزايا تعلم الآلة للعملية التعليمية تؤدي إلى تحسين المنهج العام. وأشارت نافع (Nafea, 2018) إلى أن إمكانيات الذكاء الاصطناعي في التعليم تساعدها المعلمين على تصميم الدروس بطريقة أكثر فعالية، وتمكنهم كذلك من تخصيص موادهم وفقاً لاحتياجات الطلاب. على سبيل المثال، يمكن تطبيق أدوات محددة لتحليل أي لحظة مندرس كانت صعبة على الطلاب وأيضاً للكشف عن أكثر التحديات التي واجهها الطلاب. يمكن أن يساعد تقييم أداء الطالب الذي تمت مناقشته أعلاه المعلمين على تحديد القضايا التي تحتاج إلى مراجعة أكثر شمولاً وتعديل المناهج الدراسية للتأكد من أن العملية فعالة. يمكن أن يساعد التعلم الآلي المعلمين في إجراء تغيير مناسب وفي الوقت المناسب في المناهج الدراسية.

يمكن أيضاً تطبيق أدوات الذكاء الاصطناعي لتصميم المناهج تلقائياً، مع مراعاة خصوصيات المتعلمين اعتماداً على أعمارهم واحتياجاتهم وخصائصهم الفردية. يرى بال وأخرون. (Ball et al., 2019) أن الطبيعة المتغيرة للتعليم الحديث، والتي تواجه ضغوط البيئة الديناميكية، تؤثر بشكل كبير على تطوير المناهج الدراسية التي يجب أن تكون ديناميكية أيضاً. ومع ذلك، فإن إعادة النظر في المناهج يدوياً قد تستغرق وقتاً طويلاً كما أنها ليست فعالة بما فيه الكفاية. و تقترح نفس الدراسة أن تعلم الآلة يمكن أن يوفر نهجاً تشغيلياً لتصميم وإعادة النظر في المناهج الدراسية في المدارس فهي تقدم طرفاً لتحليل هيئة الطلاب ولتحديد التغييرات التي قد تكون مرغوبة في المنهج الدراسي، بينما هناك مشكلة أخرى يتم تحليلها باستخدام تعلم الآلة وهي البيانات التعليمية. من خلال الجمع بين مجموعة البيانات، يمكن أن تساعد أدوات الذكاء الاصطناعي في تطوير أنساب المناهج التي يتم تخصيصها لتناسب إعدادات محددة.

مخاوف التفاعل البشري:

عندما يتعلق الأمر بحلول الذكاء الاصطناعي في التعليم، غالباً ما يكون هناك قلق ومخاوف مبررة من أن استبدال المعلمين البشريين بأنظمة ذكية يمكن أن يزيل ميزة التفاعل البشري وتبادل الخبرات. يحتوي التدريس الذكي على أدوات

وفيرة للتلبية احتياجات التعلم المتنوعة وتصميم خبرات تعلم مخصصة. تشير دراسة ما وأخرون (2014) بأن التعلم الإلكتروني يمكن أن يوفر تفاعلاً عاماً أكبر لعملية التعلم التي يتم الوصول إليها خاصة في ظل إمكانات التقدم التكنولوجي. على الرغم من الفرص القوية التي يوفرها التعلم الآلي، فإنه لا يزال هناك فلق مستمر من أن استبدال التفاعل البشري بتقنيات الكمبيوتر في التعلم يمكن أن يضر بالنتائج المعرفية للطلاب. وأن أنظمة ITS قد تفتقر إلى استراتيجية تدريس يقوم المعلم البشري بتطويرها بناءً على الخبرة الفردية وقاعدة المعرفة والنهج الإبداعي. تم انتقاد استخدام أنظمة ITS لأنها غير قادرة على استبدال المعلمين البشريين تماماً.

ترتبط بعض المخاوف الأخرى بالجوانب الاجتماعية والسلوكية للتعلم. أعرب تشاسينول وأخرون (Chassignol et al., 2018, 17) في دراستهم عن الفرق المتعلق بنقص تدريس المهارات الاجتماعية بمساعدة أنظمة النقل الذكية. وفقاً لدراسة كروكيت وأخرون (Crockett et al., 2017)، عيب الاستعاضة بالذكاء الاصطناعي بدلاً من التدريس البشري هو ضعف الأنظمة في تحليل السلوك. حتى الآن، لا يمكن أن يوفر التعلم الآلي الإمكانيات الكاملة لتحليل السلوكي الذي يمكن أن يقوم به المساعدون البشريون أثناء عمليات التدريس. ومع ذلك، يقترح الباحثون أن تطبيق طريقة شجرة القرار يمكن أن يساعد في تقييم عناصر سلوك الطالب وتتنظيم عملية التدريس وفقاً لذلك، في حين أن هناك أدوات أخرى أيضاً. هذا يعني أن تعلم الآلة يبحث بالفعل عن أدوات يمكنها التغلب على هذا التحدي وغيرها.

خاتمة:

أخيراً، تركز دراسات التعلم الآلي في التعليم على جوانب متنوعة من عمليات التدريس والتعلم والطرق التي يمكن أن تجعلها أكثر فاعلية وقابلة للتطبيق في الفصل الدراسي. قامت مراجعة الأدبيات بتحليل آخر التطورات في التعلم الآلي عند تطبيقها على السياق التعليمي. تم تلخيص بعض التقنيات أو الخوارزميات التي يمكن للتعلم الآلي نشرها لتعزيز الجوانب المتنوعة لعملية التعلم. بعض هذه الأدوات هي أشجار القرار، والشبكات العصبية، والطرق القائمة على المثلث، والتعلم وفق نظرية بايز أو ما يطلق عليه بالتعلم البايزي، والانحدار اللوجستي. إن وفرة الخوارزميات التي يمكن لتعلم الآلة استخدامها لإثراء العملية التعليمية يوضح الطبيعة المتقدمة لهذا المجال وإمكاناته الهائلة للتعلم.

تناولت الورقة أيضاً المجالات المتنوعة التي يمكن فيها تطبيق التعلم الآلي في العملية التعليمية، مثل جوانب التدريس وأنظمة التدريس الذكية وتقييم الأداء وتحديد صعوبات الطلاب وتطوير المناهج الدراسية. يمكن لأنظمة تعلم الآلة من تمكين التدريس في مجالات مختلفة، مما يوفر مزايا مثل تبسيط بعض العمليات

والأتمتة والتقييم الفعال والدرجات غير المنحازة وتوفير التغذية الراجعة. يعد إدخال أنظمة التدريس الذكية ميزة أخرى لتعلم الآلة الذي يوفر نهجاً مخصصاً للتعلم مع تقديم أدوات رقمية قوية. كما تمت مناقشة تعلم الآلة كطريقة لتحسين تقييم الأداء وتحديد صعوبات الطالب مع إمكانية تحسين هذه العمليات. يمكن أن تعمل أدوات الذكاء الاصطناعي هذه أيضاً في تصميم المناهج التي من شأنها أن تأخذ في الاعتبار بيانات الطلاب وأهداف التعلم. كما تمت مناقشة المخاوف المحتملة المرتبطة بالتركيز على أنظمة التدريس الذكية واستبدال التفاعل البشري. توضح مجموعة الأبحاث المدروسة الإمكانيات الهائلة لتعلم الآلة في التقنيات التعليمية.

المراجع:

- Asthana, P., & Hazela, B. (2019). Applications of Machine Learning in Improving Learning Environment. *Intelligent Systems Reference Library*, 417-433. https://doi.org/10.1007/978-981-13-8759-3_16
- Ball, R., Duhadway, L., Feuz, K., Jensen, J., Rague, B., & Weidman, D. (2019). Applying Machine Learning to Improve Curriculum Design. *Proceedings Of The 50Th ACM Technical Symposium On Computer Science Education*. <https://doi.org/10.1145/3287324.3287430>
- Chassignol, M., Khoroshavin, A., Klimova, A., & Bilyatdinova, A. (2018). Artificial Intelligence trends in education: a narrative overview. *Procedia Computer Science*, 136, 16-24. <https://doi.org/10.1016/j.procs.2018.08.233>
- Crockett, K., Latham, A., & Whitton, N. (2017). On predicting learning styles in conversational intelligent tutoring systems using fuzzy decision trees. *International Journal Of Human-Computer Studies*, 97, 98-115. <https://doi.org/10.1016/j.ijhcs.2016.08.005>
- Dubois, D., Nkambou, R., Quintal, J., & Savard, F. (2010). Decision-Making in Cognitive Tutoring Systems. *Studies In Computational Intelligence*, 145-179. https://doi.org/10.1007/978-3-642-14363-2_8
- Er, E., (2012). Identifying at-risk students using machine learning techniques: A case study with IS 100. *International Journal of Machine Learning and Computing*, 2(4), 476-480. <https://bit.ly/2Ji9Z4I>
- Hussain, M., Zhu, W., Zhang, W., Abidi, S., & Ali, S. (2018). Using machine learning to predict student difficulties from learning session data. *Artificial Intelligence Review*, 52(1), 381-407. <https://doi.org/10.1007/s10462-018-9620-8>

- Karsenti, T. (2019). Artificial intelligencein education:The urgent need to prepareteachers for tomorrow'sschools. *Formation Et Profession*, 27(1), 105. <https://doi.org/10.18162/fp.2019.a166>
- Korkmaz, C., & Correia, A. (2019). A review of research on machine learning in educational technology. *Educational Media International*, 56(3), 250-267. <https://doi.org/10.1080/09523987.2019.1669875>
- Lin, C., Yeh, Y., Hung, Y., & Chang, R. (2013). Data mining for providing a personalized learning path in creativity: An application of decision trees. *Computers & Education*, 68, 199-210. <https://doi.org/10.1016/j.compedu.2013.05.009>
- Lisetti, C., Amini, R., & Yasavur, U. (2015). Now All Together: Overview of Virtual Health Assistants Emulating Face-to-Face Health Interview Experience. *KI - Künstliche Intelligenz*, 29(2), 161-172. <https://doi.org/10.1007/s13218-015-0357-0>
- Lv, Z., & Li, X. (2016). Virtual Reality Assistant Technology for Learning Primary Geography. *Current Developments In Web Based Learning*, 31-40. https://doi.org/10.1007/978-3-319-32865-2_4
- Ma, W., Adesope, O., Nesbit, J., & Liu, Q. (2014). Intelligent tutoring systems and learning outcomes: A meta-analysis. *Journal Of Educational Psychology*, 106(4), 901-918. <https://doi.org/10.1037/a0037123>
- Nafea, I. (2018). Machine Learning in Educational Technology. *Machine Learning - Advanced Techniques And Emerging Applications*. <https://doi.org/10.5772/intechopen.72906>
- Papamitsiou, Z. & Economides, A. (2014). Learning Analytics and Educational Data Mining in Practice: A Systematic

Literature Review of Empirical Evidence. *Journal of Educational Technology & Society*, 17(4), 49-64.
<http://www.jstor.org/stable/jeductechsoci.17.4.49>

Urbina Nájera, A., & De la Calleja Mora, J. (2017). Brief Review of Educational Applications Using Data Mining and Machine Learning. *Revista Electrónica De Investigación Educativa*, 19(4), 84.
<https://doi.org/10.24320/redie.2017.19.4.1305>