

تطبيقات التعلم العميق لتعزيز كفاءة اتخاذ القرارات في الإدارة الخدمات الجامعية لولاية
مستغانم

Deep Learning Applications to Enhance Decision-Making Efficiency in the
University Services Administration of Mostaganem

ناير لعرج¹، بن زيدان الحاج²

Naer laredj¹, Ben Zidane Hadj²

¹ جامعة مستغانم، laredj6naer@gmail.com

² جامعة مستغانم، ben_zidane@live.fr

تاريخ الاستلام: 2026/02/28 تاريخ القبول: 2026/03/06 تاريخ النشر: 2026/03/21

ملخص: تهدف هذه الدراسة إلى توضيح دور استخدام تطبيقات التعلم العميق في تعزيز كفاءة اتخاذ القرارات في الإدارة الخدمات الجامعية بالإقامات، باستخدام المنهج الوصفي التحليلي بالاعتماد على مقابلة مع بعض المستخدمين في عينة من الاقامات الجامعية لولاية مستغانم، وتوصلت الدراسة إلى أن استخدام تطبيقات التعلم العميق من شأنه تعزيز الخدمات الجامعية، و تحسين جودتها وتوفير لطالب الجو الملائم والاستقرار في الاحياء الجامعية في ظل التوجه وزارة التعليم العالي نحو رقمنة قطاع، بتعزيز الجهات الرقابية وخلق التوازن بين دعم استخدام التطبيقات الإلكترونية، وتفعيل الحماية من المخاطر والقرصنة، من خلال تفعيل منظومة أمن سيبراني قوية تسمح بحماية التعاملات الإدارية الخدماتية الجامعية الرقمية

كلمات مفتاحية: تطبيقات التعلم العميق، الإدارة الخدمات الجامعية، معاملات رقمية، أمن سيبراني

Abstract: This study aims to clarify the role of deep learning applications in enhancing decision-making efficiency in university residence management, using a descriptive analytical approach based on interviews with some users in a sample of university residences in Mostaganem. The study concluded that the use of deep learning applications would enhance university services, improve their quality, and provide students with a suitable and stable environment in university residences, towards digitizing the sector, strengthening regulatory bodies, and striking a balance between supporting the use of electronic applications and activating protection against risks and piracy through the implementation of a strong cybersecurity system that protects digital university administrative and service transactions.

Keywords: Deep learning applications, university services management, digital transactions, Cybersecurity.

¹ المؤلف المرسل: ناير لعرج، الإيميل: laredj6naer@gmail.com
Naer laredj, e.mail : laredj6naer@gmail.com

1-المقدمة: لقد برزت تطبيقات التعلم العميق كأداة تحويلية في تعزيز كفاءة صنع القرار داخل إدارة الخدمات الجامعية، من خلال الاستفادة من كميات هائلة من البيانات، يمكن لخوارزميات التعلم العميق توفير رؤى تعمل على تبسيط العمليات وتحسين تخصيص الموارد وتحسين النتائج التعليمية، إن دمج التكنولوجيا في الخدمات الجامعية لا يدعم صنع القرار الصائبة فحسب، بل يعزز أيضا بيئة تعليمية أكثر تكيفا واستجابة، لا سيما في الخدمات الجامعية مثل الإقامة والاطعام والنقل، مما يسمح بمزيد من التنبؤ الدقيق والتخطيط الاستراتيجي والكفاءة التشغيلية. يمكن لخوارزميات التعلم العميق، مثل الشبكات العصبية، تحليل البيانات التاريخية للتنبؤ بالطلب على الإقامة، مما يسمح للجامعات بتحسين تخصيص الغرف وإدارة السعة بفعالية، التنبؤ بالطلب على الغذاء من خلال تحليل أنماط عادات تناول الطعام لدى الطلاب والعوامل الخارجية مثل الأحداث أو الطقس، وهذا يمكن الجامعات من تقليل النفقات وضمان إعداد خدمات الطعام بشكل كاف لتلبية الطلب، تحسين خدمات النقل من خلال تحليل أنماط الاستخدام والتنبؤ بأوقات الذروة، وهذا يسمح بجدولة وتخصيص الموارد بشكل أفضل، وتقليل أوقات الانتظار وتحسين الكفاءة العامة لخدمات النقل.

تعتبر مسألة تحسين كفاءة اتخاذ القرارات في إدارة الخدمات الجامعية، مثل المبيت، والإطعام، والنقل، من القضايا الحيوية التي تواجه قطاع التعليم العالي، في ظل النمو السريع لعدد الطلبة، يظهر التعلم العميق إمكانيات كبيرة في معالجة البيانات وتحليلها، مما يمكن الإدارات من اتخاذ قرارات مبنية على أدلة.

تتعلق الإشكالية أيضا بالعوائق التقنية والثقافية التي قد تحول دون تطبيق هذه التكنولوجيا، فضلا عن الحاجة إلى حماية البيانات وضمان الأمن السيبراني خلال تنفيذ هذه التطبيقات.

1.1. الإشكالية: في هذا السياق، تبرز الإشكالية في كيفية دمج تطبيقات التعلم العميق بشكل فعال في إدارة الخدمات الجامعية، وإمدادها بالتحليلات اللازمة التي تعزز من جودة الخدمات وتوفر بيئة ملائمة للطلاب. كيف يمكن استخدام هذه التطبيقات لتحسين التجربة الطلابية، وتحقيق الاستدامة في تقديم الخدمات بجودة عالية، وما هي التحديات والفرص المرتبطة بذلك؟

2.1. الأسئلة الفرعية: للإجابة على هذه الإشكالية تم تقسيمها للأسئلة الفرعية التالية:

1. ما هو تأثير تطبيقات التعلم العميق على كفاءة اتخاذ القرارات في إدارة الخدمات

الجامعية؟

2. كيف يمكن تحسين جودة خدمات المبيت، والإطعام، والنقل من خلال استخدام هذه

التطبيقات؟

3. ما التحديات التي قد تواجه إدارات الجامعات عند تطبيق التعلم العميق؟
4. كيف يمكن ضمان الأمن السيبراني في ظل استخدام تقنيات التعلم العميق؟
- 3.1. الفرضية: طرحنا الفرضية التالية من أجل فهم الموضوع بشكل أفضل:
"يمكن أن تساهم تطبيقات التعلم العميق بشكل فعال في تعزيز كفاءة اتخاذ القرارات في إدارة الخدمات الجامعية (مثل المبيت، والإطعام، والنقل) ، مما يؤدي إلى تحسين جودة الخدمات المقدمة للطلاب ورفع مستوى رضا لديهم".
- 4.1. أهمية الدراسة: تتجلى أهمية الدراسة في تقديم رؤى جديدة حول كيفية استخدام التعلم العميق لتعزيز جودة الخدمات المقدمة للطلبة، مما يساهم في رفع مستوى رضاهم الأكاديمي والاجتماعي، وهذا من خلال توفير تحليلات دقيقة وشاملة، ستساعد الدراسة في تحسين كفاءة اتخاذ القرارات في إدارة الخدمات الجامعية، مما قد يؤدي إلى قرارات أكثر فاعلية.
تساهم الدراسة كذلك في تعزيز الابتكار في استراتيجيات إدارة الخدمات الجامعية، مما يساعد المؤسسات التعليمية العالي على التكيف مع التغيرات المستمرة في احتياجات الطلاب والسوق، وتبسيط الضوء على التحديات والفرص التي تواجه تطبيقات التعلم العميق، توفر الدراسة الأدوات اللازمة لتجاوز هذه العقبات والاستفادة من الفرص المتاحة، توفير إطار للأبحاث المستقبلية.
- تؤكد الدراسة على أهمية تأمين البيانات وحمايتها، مما يساهم في تطوير استراتيجيات فعالة للأمن السيبراني في الجامعات.
- 5.1. منهج الدراسة: تتبع هذه الدراسة منهجا وصفيا وتحليليا، حيث يتم الاعتماد على تحليل البيانات والمعلومات المرتبطة بتطبيقات التعلم العميق في إدارة الخدمات الجامعية، باستخدام أدوات جمع البيانات مقابلات شخصية إجراء مقابلات مع بعض المستخدمين والمسؤولين عن الخدمات الجامعية للحصول على رؤى أعمق حول تأثير تطبيقات التعلم العميق واحتياجاتهم.
تم اختيار عينة من الاقامات الجامعية في ولاية مستغانم، تشمل مجموعة متنوعة من الطلاب والإداريين، لضمان تمثيل شامل لجميع الآراء والخبرات، تحليل نوعي لمحتوى المقابلات لفهم التوجهات والتحديات بشكل أعمق.
2. الإطار المفاهيمي حول التطبيقات التعلم العميق: متعدد الأوجه، ويشمل منهجيات وأطر ومجالات تطبيق متنوعة، هذا الإطار ضروري لفهم كيف يمكن تنفيذ التعلم العميق بشكل فعال وتحسينه عبر القطاعات المختلفة، لحل المشكلات المعقدة، مثل التنبؤ بالطلب وإدارة المخزون وتحسين الخدمات اللوجستية، يوفر استخدام التعلم العميق في الادارة ميزة تنافسية من خلال

تمكين التحليل الدقيق والسريع للبيانات، وهو أمر بالغ الأهمية لصنع القرار في البيئات الديناميكية.

يضم النظام البيئي للتعلم العميق العديد من الأطر والمكتبات التي تسهل تنفيذ الشبكات العصبية، هذه الأدوات ضرورية لتحسين الأداء وكفاءة الطاقة، لا سيما في التطبيقات كثيفة الحوسبة مثل رؤية الكمبيوتر ومعالجة الكلام والتعرف على الصور ومعالجة اللغة الطبيعية.


1.2. تعريف التعلم العميق: له عدة تعاريف من بينها

✓ حسب رافي كومار: هو فرع من فروع التعلم الآلي، ويعرف بأنه نوع من أنظمة التعلم التي تستخدم شبكات عصبية عميقة تتكون من طبقات متعددة لتحليل البيانات واستخراج الميزات بشكل ذاتي دون الحاجة لاستخدام ميزات يحددها الخبراء بشكل يدوي، يعتمد على معالجة كميات كبيرة من البيانات مع قدرات حسابية عالية ليتمكن من التعلم واكتساب أنماط معقدة وتحقيق أداء ممتاز في مهام مختلفة مثل التعرف على الصور، والكلام، والنصوص، وغيرها. (T (2018))

✓ يعرف كذلك تاباني، ح.، بوجول، ر: بأنه تقنية من تقنيات التعليم الآلي تعتمد على نماذج شبكات عصبية ذات طبقات متعددة تمكن الحواسيب من التعلم بشكل ذاتي من البيانات دون الحاجة لتحديد الميزات يدويا، مع قدرة فائقة على التعامل مع مهام معقدة وتحقيق نتائج تقرب أو تتفوق على أداء البشر في مجالات متنوعة مثل التعرف على الصور، الصوت، والنصوص. (Tabani (2020))

2.2. التمييز بين مفاهيم التعلم الآلي والتعلم العميق: تعلم الآلي والتعلم العميق هما فرعان من فروع الذكاء الاصطناعي، ويختلفان في مستوى التعقيد، والنمط، والاعتمادية على البيانات، وكذلك في كيفية معالجة المعلومات، المقارنة بينهما :

الشكل رقم (01): يبين الفرق ما بين التعلم الآلي والتعلم العميق



- 1.2.2. المستوى من التعقيد والتمثيل: التعلم الآلي يعتمد على نماذج وخوارزميات بسيطة نسبياً مثل أشجار القرار، والانحدار، والتي تتطلب عادة تحديد للميزات ذات الصلة بالمهمة.
- التعلم العميق يعتمد على شبكات عصبية عميقة ذات طبقات متعددة تُمكن النموذج من استخراج التمثيلات ذاتية التعلم من البيانات، دون الحاجة لتحديد ميزات يدوياً.
- 2.2.2. حاجة البيانات: التعلم الآلي يمكن أن يعمل بكفاءة مع كميات بيانات قليلة أو متوسطة، ولكنه يتطلب هندسة الميزات الجيدة، التعلم العميق يتطلب كميات كبيرة من البيانات للتدريب ويفضل وجود بيانات ضخمة لكي يحقق أداء عالي.
- 3.2.2. مستوى الأتمتة في التعلم: التعلم الآلي يعتمد بشكل كبير على خبرة الإنسان في اختيار وتعديل الميزات والخوارزميات، التعلم العميق يعتبر أكثر ذاتية، حيث يقوم النموذج باستخراج الميزات تلقائياً خلال عملية التدريب.
- 4.2.2. القدرة على التعامل مع البيانات غير المنظمة: التعلم الآلي غالباً ما يواجه صعوبة في التعامل مع البيانات غير المنظمة، ويحتاج إلى معالجة خاصة، التعلم العميق ممتاز في التعامل مع البيانات غير المنظمة مثل الصور، الصوت، والنصوص، لأنه قادر على تعلم التمثيلات المعقدة بنفسه.
- 5.2.2. الأداء والأداء في المهام المعقدة: التعلم الآلي فعال في مهام بسيطة ومتوسطة، ويعتمد بشكل أكبر على خوارزميات جيدة الاختيار، التعلم العميق يتفوق على غالبية نماذج التعلم الآلي خاصة في المهام التي تتطلب معالجة نوعية وكمية هائلة من البيانات، مثل التعرف على الصور والصوت.
- 6.2.2. التعقيد في النموذج والتنفيذ: التعلم الآلي أبسط نسبياً من حيث التطبيق والتنفيذ، ويمكن تنفيذه بسرعة مع قليل من الموارد، التعلم العميق يتطلب موارد حسابية عالية، ويكون أكثر تعقيداً في البناء والتدريب.
3. تطبيقات التعلم العميق: تشمل تطبيقات البرمجة اللغوية العصبية للتعلم العميق تحليل المشاعر واسترجاع المعلومات واكتشاف المعلومات الخاطئة، والتي تعتبر حيوية لفهم وإدارة مجموعات النصوص الكبيرة، يتم استخدامه أيضاً في إدارة علاقات العملاء لتحليل ملاحظات العملاء وتحسين تقديم الخدمة، التعرف على الصور، مع تطبيقات في التعرف على الوجه والمركبات المستقلة، حيث يعالج البيانات المرئية لاتخاذ قرارات في الوقت الفعلي.


1.1.3. التعامل مع مكتبة Keras للتصميم وتدريب نماذج الشبكات العصبية: يتضمن تصميم نماذج الشبكات العصبية وتدريبها باستخدام مكتبة Keras الاستفادة من التقنيات والأطر المختلفة لتحسين الأداء والكفاءة Keras ، وهي واجهة برمجة تطبيقات للشبكات العصبية عالية المستوى، مبنية على TensorFlow وتستخدم على نطاق واسع لبساطتها وسهولة استخدامها، يمكن أن يؤدي تكامل الأساليب المتقدمة مثل البحث في الهندسة العصبية (NAS) والأساليب القائمة على النواة والخوارزميات التطورية إلى تعزيز عملية التصميم والتدريب بشكل كبير، تهدف هذه الأساليب إلى تحسين دقة النموذج وتقليل التكاليف الحسابية ومعالجة التحديات مثل تجهيز الزائد وقيود الموارد.

1.1.3. بحث العمارة العصبية (NAS) : Auto-Keras هو نظام AutoML مفتوح المصدر يستخدم NAS لضبط الشبكات العصبية العميقة تلقائياً، وهي تستخدم التحسين البايزي لتوجيه مورفولوجيا الشبكة، مما يسمح بالاستكشاف الفعال لمساحة البحث ويقلل التكاليف الحسابية مقارنة بأساليب NAS التقليدية، سير العمل النموذجي لنظام Auto-Keras هو كما يلي. يبدأ المستخدم بحثاً عن أفضل بنية عصبية لمجموعة البيانات، تتلقى واجهة برمجة التطبيقات الاستدعاء، وتعالج مجموعة البيانات مسبقاً، وتمررها إلى الباحث لبدء البحث، سيقوم مُحسِّن بايزي في الباحث بتوليد بنية جديدة باستخدام وحدة المعالجة المركزية. يستدعي وحدة الرسم البياني لبناء البنية العصبية المولدة في شبكة عصبية حقيقية في ذاكرة الوصول العشوائي. يتم نسخ البنية العصبية الجديدة إلى وحدة معالجة الرسوميات لمدرّب النموذج للتدريب باستخدام مجموعة البيانات. يتم حفظ النموذج المدرب في تخزين النموذج. يتم إرجاع أداء النموذج إلى الباحث لتحديث العملية. (Jin (2019).

2.1.3. الأساليب القائمة على النواة: يمكن ترجمة الشبكات العصبية التلافيفية (CNNs) إلى نظيراتها القائمة على النواة، والمعروفة باسم شبكات النواة التلافيفية. تستخدم هذه النماذج طرقاً إحصائية لتعلم المعلومات من البيانات، وغالباً ما تعمل بشكل مشابه لشبكات CNN التقليدية

3.1.3. تقنيات التدريب: يعمل التدريب المتعامد ذو المعلومات الزائدة (OPT) على تحسين التعميم من خلال الحفاظ على الحد الأدنى من الطاقة فوق الكروية أثناء التدريب. تتضمن هذه الطريقة تعلم التحول المتعامد للخلايا العصبية، مما يعزز تنوع الخلايا العصبية ويحسن التعميم التجريبي، يقوم OPT بتعلّم تحويل متعامد لكل طبقة في الشبكة العصبية، مع الإبقاء على أوزان العصبونات المهيأة عشوائياً ثابتة دون تغيير

الشكل رقم (02): نظرة عامة على إطار التدريب المفرط التوسيع المتعامد..(OPT)



Liu, W., Lin, R. (2021). **Orthogonal Over-Parameterized Training**. Computer Vision and Pattern Recognition, 7251–7260. <https://doi.org/10.1109/CVPR46437.2021.00717>

يجمع النهج التطوري الموجه بالتدرج بين متانة الخوارزميات التطورية والأساليب القائمة على التدرج لتحسين أوزان الشبكة العصبية. يعالج هذا النهج مشكلات مثل الحساسية المثلى المحلية وحساسية المعلومات الفائقة، مع مراعاة تباين الشبكة لتقليل التعقيد.

2.3. تحليل النموذج والتحسين: يوفر Innvestigate واجهة مشتركة لتحليل الشبكات العصبية، ويقدم تطبيقات لطرق التحليل المختلفة. تساعد هذه الأداة في فهم وتفسير بنى الشبكات العصبية المعقدة، وهو أمر بالغ الأهمية لتحسين شفافية النموذج والجدارة بالثقة يتضمن توتر الشبكات العصبية تحويل مصفوفات الوزن الكثيفة إلى شكل Tensor Train ، مما يقلل بشكل كبير من عدد المعلمات مع الحفاظ على القوة التعبيرية للنموذج، هذه الطريقة مفيدة بشكل خاص لنشر النماذج على الأجهزة المنخفضة التكلفة

3.3. البنى البديلة: تستخدم الشبكات العصبية الدائرية ذات القطر العميق مصفوفات الوزن المنظمة لتحقيق دقة أفضل مع عدد أقل من المعلمات مقارنة بالنهج المنظمة الأخرى. هذه الشبكات فعالة بشكل خاص في بناء نماذج مدمجة ودقيقة لمجموعات البيانات الكبيرة تم تصميم الشبكات العصبية المدركة للضوء (PANs) للعمل مع قيود الأجهزة الضوئية، باستخدام استراتيجيات القياس الكمي لتكييف معاملات الشبكة العصبية مع مجال النقطة الثابتة. هذا النهج واعد لتقليل استهلاك الطاقة وتسريع الحسابات. (Araujo 2019)

4. تطبيق الشبكات المتقدمة مثل CNN و LSTM حسب متطلبات الحالة: تعتمد تطبيق الشبكات المتقدمة مثل الشبكات العصبية التلافيفية (CNN) وشبكات الذاكرة طويلة المدى (LSTM) بشكل كبير على المتطلبات المحددة للحالة. غالبًا ما يتم دمج هذه الشبكات للاستفادة من نقاط قوتها في التعامل مع البيانات المكانية والزمانية، على التوالي. إن شبكات CNN بارعة في

استخراج الميزات المكانية، بينما تتقن LSTMs التقاط التبعيات الزمنية. هذه المجموعة فعالة بشكل خاص في السيناريوهات التي تتطلب التحليل والتنبؤ والتصنيف في الوقت الفعلي عبر مختلف المجالات.

1.4. كشف العنف: تم تطوير نظام متكامل تماما باستخدام CNN و LSTM لتحليل الفيديو في الوقت الفعلي للكشف عن الأنشطة العنيفة، تم تصميم هذا النظام لإخطار السلطات فور اكتشاف العنف، وذلك باستخدام CNN لاستخراج الميزات المكانية و LSTM لتحليل التسلسل الزمني لضمان الكشف الدقيق في الوقت المناسب في بيئات مثل مراكز التسوق والملاعب الرياضية. (Sharma (2021))

2.4. خدمات ركوب الحافلات: تم تطبيق شبكات CNN-LSTM بنجاح للتنبؤ بالطلب على خدمات النقل، والتي يمكن تكييفها لخدمات النقل الجامعي، من خلال تحليل الأنماط في بيانات سفر الطلاب، يمكن لهذه الشبكات تحسين جدولة وتوجيه حافلات النقل الجامعية، مما يضمن الخدمة الفعالة خلال ساعات الذروة.

للتنبؤ بتدفق الركاب يمكن أيضا استخدام نموذج CNN-LSTM للتنبؤ بتدفق الركاب في أنظمة النقل الجامعي، مما يساعد على تخفيف الازدحام وتحسين موثوقية الخدمة، يتم تحقيق ذلك من خلال التقاط الخصائص المكانية والزمانية غير الخطية لبيانات الركاب. (Black (2022))

3.4. في خدمات المطاعم (CNN-LSTM): توقع الطلب يمكن استخدام شبكات CNN-LSTM للتنبؤ بالطلب اليومي في خدمات المطاعم الجامعية من خلال تحليل بيانات الاستهلاك التاريخية. يمكن أن يساعد هذا النهج في تقليل هدر الطعام وتحسين إعداد الوجبات من خلال التنبؤ الدقيق بعدد الوجبات المطلوبة كل يوم، معالجة البيانات يمكن لمكون CNN استخراج الميزات ذات الصلة من مجموعات البيانات المعقدة، مثل أنواع الوجبات وأنماط الاستهلاك، بينما يمكن لمكون LSTM نمذجة التبعيات الزمنية للتنبؤ بالطلب المستقبلي. (Tian (2023))

4.4. خدمات الإقامة: استخدام المساحة من خلال تحليل بيانات الإشغال، يمكن لـ CNN و LSTM تحسين تخصيص الغرف والمناطق المشتركة في المساكن الجامعية، وتحسين استخدام المساحات، إدارة الطاقة يمكن لهذه النماذج التنبؤ بأنماط استهلاك الطاقة في المراجع، مما يسمح بإدارة أكثر كفاءة للطاقة وتوفير التكاليف.

الأمن والسلامة يمكن استخدام CNN و LSTM في التعرف على النشاط البشري لمراقبة وضمان سلامة الطلاب داخل مباني الجامعة، يمكن أن يكون هذا مفيدا بشكل خاص في اكتشاف الأنشطة غير العادية أو حالات الطوارئ

التنقل الداخلي يمكن لهذه النماذج تحسين أنظمة الملاحة الداخلية من خلال توفير خدمات دقيقة تعتمد على الموقع، ومساعدة الطلاب والزوار على التنقل في الجامعات الكبيرة بكفاءة أكبر. (Gryzun 2023).

يجب أن يتم دمج هذه الأنظمة مع مراعاة دقيقة لمخاوف الخصوصية وأمن البيانات، لأنها تنطوي على جمع وتحليل بيانات الطلاب الحساسة.

5. التحديات التي تواجه إدارات الجامعات عند تطبيق التعلم العميق: من بين التحديات التي تواجه إدارات الجامعات عدة تحديات عند تطبيق تقنيات التعلم العميق، ومن أبرزها:

أ. التعقيد والحسابات الرياضية: يتطلب تطبيق نماذج التعلم العميق معرفة عميقة بالمفاهيم الرياضية والتقنية، مما قد يمثل عائقاً أمام الفرق الإدارية والأكاديمية غير المختصة بالتقنيات الحديثة، ويستلزم تدريباً وتطوير مهارات متخصصة.

ب. التجهيز الزائد (Overfitting): حيث تميل النماذج إلى تعلم بيانات التدريب بشكل مفرط، بما يشمل الضوضاء والقيم الشاذة، مما يقلل من قدرتها على التعميم على البيانات الجديدة، ويستدعي استخدام تقنيات التنظيم والتسرب، وهو تحدي يحتاج إلى إدارة دقيقة.

ج. تكلفة البنية التحتية والتكنولوجيا: يتطلب تعلم العميق موارد حوسبة عالية، مثل أنظمة الحوسبة السحابية أو مراكز بيانات متطورة، الأمر الذي يتطلب استثمارات مالية كبيرة من قبل الجامعات.

د. مخاطر الأخطاء والموثوقية: الاعتماد على نماذج غير مؤكدة أو غير موثوق بها يمكن أن يؤدي إلى قرارات غير دقيقة، وهو ما يثير قلقاً بشأن استدامة الاعتماد على التكنولوجيا في عمليات حاسمة مثل إدارة الموارد أو تقييم الطلاب.

هـ. الجوانب الأخلاقية والفلسفية: يثير استخدام الذكاء الاصطناعي أسئلة أخلاقية، كحماية البيانات الشخصية، والتحيز في النماذج، واتخاذ القرارات الآلية التي قد تؤثر على حياة الطلاب وأعضاء الهيئة التعليمية، ما يتطلب سياسات صارمة وإجراءات تنظيمية.

و. قلة التوعية والمعرفة الفنية: قد يكون هناك نقص في الوعي والخبرة الفنية بين الموظفين والإداريين، مما يبطئ عمليات التنفيذ ويزيد من الحاجة إلى التدريب المستمر.

ز. الامتثال للأنظمة والتشريعات: ضرورة الامتثال لقوانين حماية البيانات وحقوق المستخدمين، وهو أمر يتطلب إدارة دقيقة لضمان عدم التعرض لمشاكل قانونية أو أخلاقية.

6.دراسة حالة المديرية الخدمات الجامعية لولاية مستغانم:

أدت البيئة الديناميكية والأكثر تعقيداً إلى اعتماد تقنيات مبتكرة تضمن مزايا تنافسية. في هذا السياق، تظهر تقنيات الذكاء الاصطناعي والتعلم الآلي كأدوات تحويلية تحدث ثورة في الطريقة التي تصمم بها المؤسسات استراتيجياتها وتنفذها وتكيفها، مع فوائدها وأثارها. يوفر التفاعل بين التعلم الآلي وإستراتيجية الأعمال فهماً شاملاً لكيفية إحداث التكنولوجيا ثورة في صنع القرار والابتكار والكفاءة التشغيلية. تعتبر الذكاء الاصطناعي الثورة الصناعية الرابعة، التي تشمل عدة مجالات في المجتمع والشركات على أنه قدرة الآلات على أداء مهام مختلفة تتطلب عادةً قدرات بشرية، بالإضافة إلى التعلم من البيانات واتخاذ القرارات. يطرح الذكاء الاصطناعي تحديات تتطلب تكييف المناهج التعليمية، مع الاعتراف بأهمية الحوسبة في مختلف مراحل نظام التعليم وهذا ما انتهجته وزارة التعليم العالي والبحث العلمي باعتبار الاستراتيجية التكنولوجية، عنصراً و عاملاً أساسيين في وضع استراتيجية الأعمال والحفاظ على الميزة التنافسية وأداء الخدمة الحقيقية.

تركز المؤسسات الجامعية الجزائية والمؤسسات المرتبطة بها بشكل متزايد على دعم الطلاب الذين قد يواجهون تحديات أكاديمية، بهدف تحسين نتائجهم التعليمية من خلال تدخلات موجهة. وفي هذا الإطار، يصبح من الضروري الاستفادة من تقنيات التعلم العميق المتقدمة لتطوير أنظمة التوصيات. وقد تواءمت هذه الأنظمة لتحديد الطلاب المعرضين لخطر الأداء الضعيف من خلال تحليل الأنماط في بياناتهم الأكاديمية التاريخية، مما يسهل استراتيجيات الدعم الشخصية.

وقد نلخص أداء الطالب الجامعي في الشكل التالي الذي ينطوي تحت ضرورة الدعم التكنولوجي للخدمات المقدمة إليه:

الجدول رقم 01: عناصر النموذج المتقدم للتعلم العميق لتوقع الأداء الأكاديمي للطلاب في المؤسسات الجامعية

تكلفة عمليات النظام	تقنيات استخراج البيانات	أداء الطالب	المؤسسات الجامعية
معدل ترقية الطلاب والاحتفاظ بهم والانتقال/ معدل تسرب الطلاب			مؤسسات الخدمات الجامعية
			البيئة الطلابية
			الأستاذة والطلبة
فشل الطلاب والتعليم/ نتائج تعلم الطلاب /نسبة تحسين التعليم			المنهاج والبرنامج التكويني والتعليم المكيف والمخصص
كفاءة النظام التعليمي			التحليل الاستشراقي
دعائم اكتشاف المعرفة			أنظمة التعليم عن بعد والأنظمة الذكية

المصدر: من اعداد الباحثين

تطوير نموذج تطبيقات تعلم عميق لإدارة الإقامات الجامعية، يمكن للمديرية الاستفادة من تقنيات التعلم العميق لتحسين عمليات إدارة الإقامات، الطلبة، والمرافق المرتبطة بها. وفيما يلي شرح لكيفية بناء النموذج والمتغيرات التي يتم معالجتها:

1.6. هدف النموذج (المتغير الهدف): توقع أو تحسين إدارة الإقامات، مثل:

- تخصيص الإقامات للطلبة بناء على احتياجاتهم.
- تحسين جداول النقل للطلاب.
- إدارة وجبات الطعام بكفاءة.
- التنبؤ بحاجة الطلبة إلى خدمات معينة (مثل النقل أو الطعام) في أوقات معينة.

2.6. البيانات والمتغيرات المدخلة:

1.2.6. بيانات الطلبة:

- بيانات شخصية (الاسم، العمر، الجنس).
- السكن الحالي والمتوقع.
- سجل الطلبات السابقة للخدمات.
- جدول المحاضرات والكليات التي يدرس فيها.

2.2.6. بيانات الإقامات:

- مواقع الإقامات وعدد الغرف.
- حالة الإقامة (مشغولة/فارغة).

3.2.6. بيانات الأنشطة اليومية:

- مواعيد المحاضرات.

- جداول النقل (مواعيد النقل، الطرق والمواعيد).
- مواعيد الوجبات وعدد الموظفين أو الطلبة المشتركين.

4.2.6. بيانات النقل:

- جداول الحافلات أو وسائل النقل الأخرى.
- مواقع الطلبة المقررة والنقطة المجمع.

5.2.6. بيانات الطعام:

- نوع الوجبات وجودتها.
- الطلبات الجماعية أو الفردية.

3.6. نموذج تطبيقات التعلم العميق الممكن استخدامه:

- ✓ شبكات عصبونية عميقة (Deep Neural Networks) للتنبؤ بحاجات الطلبة وجدولة الموارد بشكل فعال.
- ✓ نماذج متتابعة (Sequential Models) مثل LSTM أو Transformer لتتبع سلوك الطلبة والتنبؤ بحاجاتهم المستقبلية من خدمات.
- ✓ نماذج تصنيف وتنبؤ (Classification/Regression) لتحديد الطلبات ذات الأولوية أو تقدير احتياجات النقل والطعام.

4.6. مراحل بناء النموذج:

- جمع البيانات وتنظيفها لضمان جودتها ودقتها.
- اختيار المتغيرات المهمة من البيانات المدخلة التي تؤثر على الهدف.
- تحديد المتغير الهدف (مثل: الحاجة إلى خدمة معينة، أو جدولة النقل، أو تخصيص غرفة).
- تصميم النموذج وتدريبه على البيانات التاريخية لاستخلاص الأنماط والتنبؤات.
- اختبار النموذج وتحديثه باستمرار لتحسين الأداء.

5.6. كيفية تطبيق النموذج في الواقع:

- تخصيص الإقامات تلقائياً استناداً إلى الطلبات والتوافر.
- جدولة النقل والوجبات بشكل ديناميكي وفقاً لحاجات الطلبة.
- التنبؤ بالطلبات المستقبلية لضمان جاهزية الموارد.

7. بناء النموذج بلغة بايتون: لبناء نموذج تعلم عميق باستخدام لغة بايثون لإدارة خدمات الإقامات الجامعية، يمكنك استخدام مكتبة مثل TensorFlow أو Keras لبناء وتدريب النموذج. سنوضح هنا مثال بسيط على كيفية بناء نموذج تنبؤي يعتمد على بيانات الطلبة واحتياجاتهم، مع

التركيز على تحديد الطلب الذي يحتاج إلى خدمة معينة (مثل النقل أو الطعام)، مثال: نموذج تنبؤي لتوقع احتياج الطالب لخدمة معينة
1.7. استيراد المكتبات الضرورية

```
import numpy as np
import pandas as pd

from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler, LabelEncoder
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense

2.7. تحضير البيانات افترض أن لديك بيانات في ملف (CSV)
data = pd.read_csv('student_services_data.csv')
عرض بعض البيانات print(data.head())
تحديد المتغيرات المدخلة والمتغير الهدف مثال: المتغيرات المدخلة تشمل العمر، الجنس، الموقع، وعدد المحاضرات، والمتغير الهدف هو نوع الخدمة المطلوبة (نقل، طعام، إقامة)
features = ['age', 'gender', 'location', 'num_classes']
target = 'service_need'
label_encoders = {} معالجة البيانات ترميز البيانات التصنيفية {}
for col in ['gender', 'location']:
    le = LabelEncoder()
    data[col] = le.fit_transform(data[col])
    label_encoders[col] = le
target_le = LabelEncoder() ترميز المتغير الهدف
data[target] = target_le.fit_transform(data[target])
X = data[features].values
y = data[target].values
تقسيم البيانات إلى تدريب واختبار
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
scaler = StandardScaler() قياس البيانات
```

```

X_train = scaler.fit_transform(X_train)
X_test = scaler.transform(X_test)

3.7. بناء النموذج باستخدام Keras
model = Sequential()
model.add(Dense(64, activation='relu', input_shape=(X_train.shape[1],)))
model.add(Dense(32, activation='relu'))
التصنيف متعدد الأصناف
model.add(Dense(len(target_le.classes_), activation='softmax'))

model.compile(optimizer='adam',
loss='sparse_categorical_crossentropy',
metrics=['accuracy'])

4.7. تدريب النموذج
history = model.fit(X_train, y_train, epochs=50, batch_size=16, validation_split=0.2)

5.7. تقييم النموذج
loss, accuracy = model.evaluate(X_test, y_test)
print(f'Accuracy: {accuracy*100:.2f}%')

6.7. استخدام النموذج للتنبؤ: مثال على طلب جديد للطالب
new_student = np.array([[20, label_encoders['gender'].transform(['Male'])[0],
label_encoders['location'].transform(['Campus A'])[0],
5])]
قياس البيانات وتحويلها
new_student_scaled = scaler.transform(new_student)
التنبؤ
prediction = model.predict(new_student_scaled)
service_index = np.argmax(prediction)
service_type = target_le.inverse_transform([service_index])
print(f'الخدمة المطلوبة: {service_type[0]}')

```

8. تحديات عصرنة الخدمات الجامعية وتماشيا مع التكنولوجيات الناشئة:
من خلال تطبيق الطريقة الصحيحة لاستخراج البيانات المنظمة وغير المنظمة، يمكن
لعلم البيانات أن يضيف قيمة، فالتقدم السريع في التعلم العميق أدى إلى تغييرات جوهرية في

عمليات علم البيانات نحو معالجة القضايا الصعبة واتخاذ قرارات تنظيمية وإدارية معاصرة تتوافق والضرورة الرقمية. مع توسع مبادرات التصنيع الذكي، يُنظر إلى التعلم العميق على أنه وسيلة محتملة لزيادة الكفاءة والاستدامة بشكل أكبر في تطبيق ذكاء الأعمال من خلال الإدارة التنظيمية. يتيح الاستفادة من التعلم الآلي في إدارة البيانات لمؤسسات الخدمات الجامعية الاستخدام الأفضل للبيانات التي تتعقها. لن يكون حجم إدارة البيانات الحديثة ممكناً بدون تطبيق التعلم الآلي، مما يجعل من الضروري أن تفهم المؤسسات التأزر بينهما.

أهم تحد، يكمن فهم إدارة البيانات بحد ذاتها أمر ضروري لمناقشة كيفية تحسين إدارة البيانات من خلال التعلم الآلي. تتضمن إدارة البيانات استقبال البيانات وتنظيمها وتخزينها وصيانتها. تستخدم كل مؤسسة إدارة البيانات إلى حد ما، فهل لهذه الإدارة الإمكانيات المعنوية والمادية الحقيقية للوصول إلى تلك المخرجات المنظرة من ما تحققه مدخلات التعلم العميق..ذ بقدر هذا السؤال هو إشكالية فمواكبة الظرف التكنولوجي والسعي للاستفادة من هذا المسار العملي يعتبر تحدياً من أجل تحقيق التسيير الاستراتيجي الفعال لهذه المؤسسات الخدمية. هذا الأمر يقودنا إلى جانب تقني، يتطلب ذلك بيانات كثيرة وعالية الجودة، بالإضافة إلى موارد حاسوبية كبيرة، سواء من حيث السعة التخزينية أو القدرة الحاسوبية. يجب أن يكون مبدأ الاقتصاد هو الأولوية قدر الإمكان: اعتماد نماذج أصغر حجماً لتقليل الأثر البيئي والحصول على نماذج أكثر متانة. وموضوع الاقتصاد هنا يبرز كمحور لتسيير هذا النوع من المؤسسة التي لها ثقل مالي كبير (الإنفاق العمومي).

من التحديات الأخرى، يبرز التدريب كعامل أساسي في تحقيق القيمة المضافة من عملية دمج الذكاء الاصطناعي في هذه الإدارة والقصد هنا التعلم العميق. فالنتائج تكشف عن وجود علاقات مهمة بين المهارات والتصورات والفعالية المتصورة للذكاء الاصطناعي الناتجة عن التدريب الملائم والموجه كعامل أساسي لتحسين إتقان الأدوات وقبولها. ورعد التدريب والتكوين، تظهر جودة التدريب والفعالية المتصورة للذكاء الاصطناعي لأن تطوير المهارات في مجال الذكاء الاصطناعي لا يقتصر على مسألة تقنية فحسب، بل إنه يؤثر أيضاً على ثقة المستخدمين وقدرتهم على التفكير النقدي. ولا انتهي التحديات عند هذه النقاط بل ترقى الى ما يفوق التفكير الآلي المتوافق مع الحقيقة الناشئة لمهام إدارة الخدمات الجامعية.

9. نتائج الدراسة:

نتائج استخدام تطبيقات التعلم العميق في إدارة خدمات الطلاب، مثل الإيواء والإطعام والنقل، تعتبر ملموسة ومحفزة لتحسين التجربة الطلابية وتحقيق الاستدامة بجودة عالية، ويمكن تلخيصها فيما يلي:

1. تحسين جودة الخدمة وسرعة الاستجابة تمكن تطبيقات التعلم العميق من تحليل البيانات بشكل دقيق وسريع، مما يسمح بالتنبؤ بالاحتياجات وتخصيص الموارد بشكل أكثر فاعلية، مثل تخصيص أماكن الإقامة أو جدولة أوقات النقل، مما يقلل من أوقات الانتظار ويزيد من رضا الطلاب.
2. تخصيص الخدمات وتحسين التجربة الطلابية تساعد نماذج التعلم العميق في فهم سلوك الطلاب وتفضيلاتهم، مما يمكن المؤسسات من تقديم خدمات موجهة وشخصية، مثل تقديم قوائم طعام تلبي الأذواق المتنوعة أو تقديم برامج نقل مرنة، بما يعزز مستوى الرضا والارتباط بين الطلاب والمنشأة.
3. تحقيق الكفاءة التشغيلية وتقليل التكاليف من خلال تعزيز عمليات إدارة الموارد بشكل ذكي، تساعد تطبيقات التعلم العميق على تقليل الفاقد في الموارد، وتحسين استغلال المساحات والنقل، الأمر الذي يساهم في تقليل التكاليف وتحقيق استدامة مالية أكبر.
4. تحسين التخطيط واتخاذ القرارات الاستراتيجية تتيح النماذج التنبؤية القائمة على التعلم العميق التوقع المستقبلي للطلبات والاحتياجات، مما يسهل عملية التخطيط طويل الأمد وتطوير استراتيجيات مستدامة تواكب النمو وتحد من الأثر البيئي، مثل تقليل استهلاك الطاقة والمياه.
5. تعزيز المساواة والعدالة في توزيع الخدمات تساعد أنظمة التعلم العميق في كشف التحيزات وتحقيق توزيع عادل ومتوازن للموارد والخدمات، مما يدعم بيئة أكثر شمولية وعدالة للطلاب من جميع الخلفيات.
6. تحقيق الاستدامة البيئية والاجتماعية من خلال تحسين إدارة النقل والمطاعم وموارد الإقامة، تقلل تقنيات التعلم العميق من الاستهلاك الزائد، وتدعم ممارسات صديقة للبيئة، وتقلل من الآثار الاجتماعية السلبية، مما يعزز سمعة المؤسسات الجامعية كبيئة مستدامة.

10. خاتمة:

تطبيق تقنيات التعلم العميق في مؤسسات الجامعية يمثل فرصة كبيرة لتعزيز العملية التعليمية والإدارية، إلا أنه يواجه تحديات متعددة تتطلب استثمارا في الموارد، وتطوير الكفاءات، ووضع سياسات أخلاقية وقانونية واضحة. لتحقيق نجاح هذه التقنية، يجب على الإدارات الجامعية تبني نهج استراتيجي متكامل يوازن بين الابتكار والاحتراز، مع الحرص على التوعية والتدريب المستمر لضمان استفادة فعالة ومسؤولية من إمكاناتها، مما يسهم في تعزيز مكانة الجامعات وتقديم خدمات أكاديمية وإدارية على أعلى مستوى من الجودة والكفاءة. وعلى الرغم من أهمية هذه الخدمات في تعزيز التجربة الجامعية، إلا أن تطويرها يتطلب دراسة مستمرة وتحليل دقيق لاحتياجات الطلبة وموارد المؤسسات، بهدف تحسين جودتها وتوفير بيئة جامعية متكاملة تراعي الجوانب الأكاديمية والإنسانية، بما يسهم في ترسيخ ثقافة الاستدامة والرفاهية داخل المؤسسات التعليمية.

11.المراجع:

1. Sharma, S., Sudharsan, B., Naraharisetti, S., Trehan, V., & Jayavel, K. (2021). A fully integrated violence detection system using CNN and LSTM. International Journal of Electrical and Computer Engineering, 11(4), 3374–3380.
2. Black, W. (2022). Multivariate Passenger Flow Forecast Based on ACLB Model. Lecture Notes in Electrical Engineering, 104–113.
3. Tian, M., Zhu, J., Xiong, H., & Xu, Y. (2023). Research on an Ultra-Short-Term Working Condition Prediction Method Based on a CNN-LSTM Network. Electronics, 12(6), 1391.
4. Gryzun, L. E., Shcherbakov, O., & Bida, B. (2023). Development of the information system for navigation in modern university campus. CTE Workshop Proceedings, 10, 380–398.