

The Role of Artificial Intelligence Applications in the Future of Digital Private Banking: An Applied Study to Measure the Performance of Machine Learning Algorithms in Predicting Customers' Creditworthiness

Ghaith M. Mohammed¹, Nagham H. Neama², Ali A.H. Ibrahim³

² Department of Economics of Investment and Resources Management, College of Business Economics, Al- Nahrain University, Baghdad, Iraq

^{1,3} Department of Banking Management Economics, College of Business Economics, Al-Nahrain University, Baghdad, Iraq

ghaithmahdi.3@gmail.com , nagham_alnama@nahrainuniv.edu.iq Prof.ali@nahrainuniv.edu.iq

Article information:

Received: 18–11– 2025
Revised: 16–12– 2025
Accepted: 18–12– 2025
Published: 25–04– 2026

***Corresponding author:**

Ghaith M. Mohammed
ghaithmahdi.3@gmail.com



This work is licensed under a [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/).

Abstract:

The purpose of this paper is to examine how artificial intelligence technologies may improve big data analytics, forecast financial behavior, and boost risk management effectiveness in the banking industry. In order to assist the financial viability and competitiveness of digital banks.

The paper focuses on showing how these applications may enhance customer experience, personalize banking services, speed up credit decisions, and lower operational errors. The applied component depended on a virtual database with 5000 loan applications and 21 variables that represented the consumers' financial, behavioral, and demographic traits. (Gradient Boosting, Random Forest, Extra Trees, Gaussian Naive Bayes, Logistic Regression, SVC-RBF, and KNN-15) were the seven machine learning techniques used. Six metrics were used to assess their performance: (F1 Score, ROC-AUC, Brier Score, Accuracy, Precision, and Recall). With the highest ROC-AUC value of 73% and the best probabilistic prediction quality (Brier Score of 0.21), the Gradient Boosting algorithm fared better than the others, according to the data. Random Forest came next, with a recall rate of 73% and an overall accuracy of 67%. Gaussian Naive Bayes, on the other hand, had a comparatively lower accuracy but the greatest recall rate of 82%. These findings demonstrate that the most efficient method for assisting lending decisions and lowering default risks in digital banks is clustering algorithms.

Keywords: Artificial intelligence, Digital transformation, Machine learning algorithms

Conclusions:

The study's findings demonstrate that artificial intelligence applications are essential to the banking industry's digital transformation, especially when it comes to enhancing risk management and creditworthiness evaluation. The empirical results demonstrate that machine learning models increase lending decisions' consistency and accuracy, which improves operational performance and service quality. The lack of qualified human resources and the high expense of technology infrastructure are two major obstacles to the adoption of AI, according to the study. Additionally, the findings show that incorporating AI applications boosts digital banks' competitiveness and facilitates data-driven decision making. Therefore, attaining financial sustainability and promoting long-term performance in digital banking services are intimately related to the successful application of artificial intelligence.

دور تطبيقات الذكاء الاصطناعي في مستقبل المصارف الخاصة الرقمية: دراسة تطبيقية لقياس أداء خوارزميات التعلم الآلي في التنبؤ بالجدارة الائتمانية للزبائن

غيث مهدي محمد¹، نغم حسين نعمة²، علي عبد الحافظ ابراهيم³
² قسم اقتصاديات إدارة الأستثمار والاعمال، كلية اقتصاديات الاعمال، جامعة النهريين، بغداد، العراق
^{1,3} قسم اقتصاديات إدارة المصارف، كلية اقتصاديات الاعمال، جامعة النهريين، بغداد، العراق

ghaithmahdi.3@gmail.com , nagham_alnaama@nahrainuniv.edu.iq Prof.ali@nahrainuniv.edu.iq

المستخلص:

يهدف هذا البحث إلى دراسة كيفية إسهام تقنيات الذكاء الاصطناعي في تحسين تحليل البيانات الضخمة، والتنبؤ بالسلوك المالي للزبائن، وتعزيز كفاءة إدارة المخاطر في القطاع المصرفي. ويركز البحث على توضيح دور هذه التطبيقات في تحسين تجربة الزبائن، وتخصيص الخدمات المصرفية، وتسريع القرارات الائتمانية، وتقليل الأخطاء التشغيلية، بما يدعم الاستدامة المالية والقدرة التنافسية للمصارف الرقمية. اعتمد الجانب التطبيقي على قاعدة بيانات افتراضية شملت 5000 طلب قرض و 21 متغيراً تمثل الخصائص الديموغرافية والمالية والسلوكية للزبائن. وتم تطبيق سبع خوارزميات تعلم آلي هي (Gaussian ,Extra Trees ,Random Forest , Gradient Boosting) ، وجرى تقييم أدائها باستخدام ستة مقاييس هي (F1 ,Score ,Recall ,Precision ,Accuracy) ، حيث أظهرت النتائج تفوق خوارزمية Gradient Boosting من خلال تحقيق أعلى قيمة ROC-AUC بلغت 73% وأفضل جودة للتنبؤ الاحتمالي بمقياس Brier Score بلغ 0.21، تلتها خوارزمية Random Forest التي سجلت دقة عامة بلغت 67% ومعدل Recall بنسبة 73%. في المقابل، حققت خوارزمية Gaussian Naive Bayes أعلى معدل Recall بلغ 82% رغم انخفاض دقتها نسبياً. وتبين هذه النتائج أن الخوارزميات التجميعية تمثل الأسلوب الأكثر كفاءة في دعم قرارات الإقراض وتقليل مخاطر التعثر في المصارف الرقمية.

الكلمات المفتاحية: الذكاء الاصطناعي، التحول الرقمي، خوارزميات التعلم الآلي

معلومات البحث:

- تاريخ استلام البحث: 2025-11-18
- تاريخ ارسال التعديلات: 2025-12-16
- تاريخ قبول النشر: 2025-12-18
- تاريخ النشر: 2026-04-25

*المؤلف المراسل:

غيث مهدي محمد

ghaithmahdi.3@gmail.com



هذا العمل مرخص بموجب
المشاع الإبداعي نسب المصنف 4.0 دولي
(CC BY 4.0)

المقدمة:

لم يعد الذكاء الاصطناعي مفهوماً جديداً في الاقتصاد والتمويل والخدمات المصرفية، فقد استُخدم لسنوات لتحليل البيانات، وقياس اتجاهات السوق، وتخصيص المنتجات المصرفية. تكمن أهميته في قدرته على تفسير وتحليل البيانات المعقدة بدقة، مما يُحسن التنبؤات المصرفية، ويزيد من كفاءة إدارة المخاطر. وساهم الذكاء الاصطناعي في دخول المصارف إلى عصر رقمي جديد قائم على الأتمتة وتقليل التدخل اليدوي، مما حسن العمليات التشغيلية والخدمات الرقمية. كما مكّن من تقديم حلول ومقترحات مُخصصة تُلبّي احتياجات الزبائن، مما قلل من فعالية الممارسات التقليدية في ظل التحول الرقمي. واليوم، أصبح تبني تطبيقات الذكاء الاصطناعي ضرورة استراتيجية للمصارف للحفاظ على تنافسيتها، وتلبية متطلبات الزبائن الرقميين، ومواكبة تطورات مستقبل الخدمات المصرفية. قسم البحث إلى أربع محاور، تناول المحور الأول منهجية البحث، وتضمن المحور الثاني الجانب النظري، في حين خصص المحور الثالث للجانب التطبيقي، وأخيراً خصص المحور الرابع لاستعراض أهم النتائج والتوصيات.

المحور الأول: منهجية البحث وبعض الاسهامات العلمية السابقة

1.1 مشكلة البحث:

برزت مشكلات جوهرية تتعلق بقدرة المصارف الرقمية الخاصة على اتخاذ قرارات ائتمانية دقيقة وموثوقة، تُسهم في خفض مخاطر التخلف عن السداد وزيادة كفاءة الإقراض، وذلك نتيجةً للنمو السريع للتحول الرقمي واعتمادها لتقنيات الذكاء الاصطناعي. وتناثر جودة تقييمات الجدارة الائتمانية بشدة بسبب استمرار العديد من المصارف في استخدام أساليب قديمة أو نماذج إحصائية محدودة، تعجز عن التعامل بفعالية مع الكميات الهائلة من البيانات والمتغيرات المعقدة التي تُمثل بدقة السلوك المالي الفعلي للزبائن، ولكي يتم اعتماد خوارزميات التعلم الآلي فهناك مجموعة من الخوارزميات التي تتباين في نتائجها لتحديد دقة كفاءتها في اتخاذ قرارات الائتمان في ظل بيئة مصرفية رقمية، وتتمحور مشكلة البحث في التساؤل الآتي: إلى أي مدى تُسهم تطبيقات الذكاء الاصطناعي، ولا سيما خوارزميات التعلم الآلي، في مساعدة المصارف الرقمية الخاصة على التنبؤ بدقة أكبر بالجدارة الائتمانية للزبائن وتقليل مخاطر الإقراض؟ وما هي الخوارزميات الأفضل أداءً بناءً على مؤشرات التقييم المعتمدة؟

2.1 أهمية البحث:

تتبع أهمية البحث من الدور المهم الذي تلعبه تطبيقات الذكاء الاصطناعي لاسيما خوارزميات التعلم الآلي في تقدم المصارف وتطورها وتحسين تعاملاتها الرقمية، و لاسيما بعد التقدم الذي يشهده العصر الحالي والانتشار الواسع للتكنولوجيا المتقدمة، حيث تتمثل أهمية هذه التطبيقات في المصارف في تحسين الكفاءة التشغيلية، واتخاذ القرارات الائتمانية الدقيقة الخاصة بمنح القروض للزبائن. بالإضافة لتسريع عملية التحول الرقمي داخل المصارف، مع التركيز على الفرص المتاحة والتحديات التي قد تعيق تحقيق الاستفادة القصوى من هذه التكنولوجيا.

3.1 أهداف البحث:

يهدف البحث إلى بيان مدى إسهام تطبيقات الذكاء الاصطناعي لاسيما خوارزميات التعلم الآلي في تحسين العمليات المصرفية وتقديم توصيات عملية تساعد المصارف على وضع استراتيجيات فاعلة لدمجها في عملياتها الرقمية، بما يسهم في تعزيز التنافسية، وتحقيق النمو المستدام في بيئة مالية رقمية متغيرة، والمساعدة في الحصول على الخدمات المصرفية الرقمية والتي تتميز بتقنيات عالية الجودة والذكاء.

4.1 الفرضيات:

- يستند البحث إلى مجموعة من الفرضيات الآتية:
- تُظهر مؤشرات Accuracy و Precision و Recall و F1 Score و ROC-AUC و Brier Score وجود فروق ذات دلالة إحصائية في أداء خوارزميات التعلم الآلي المستخدمة في التنبؤ بالجدارة الائتمانية للزبائن.
- تحقق الخوارزميات التجميعية، و لاسيما Random Forest و Gradient Boosting مستويات أعلى من الدقة والجودة في التنبؤ الاحتمالي مقارنة بالخوارزميات الأخرى عند تقييم الجدارة الائتمانية.
- تؤثر خوارزميات التعلم الآلي تأثيراً ذا دلالة إحصائية في كفاءة قرارات الإقراض من خلال تقليل الأخطاء الائتمانية وتعزيز القدرة على التمييز بين الزبائن ذوي مستويات المخاطر المرتفعة والمنخفضة.
- ان استخدام خوارزميات التعلم الآلي تساعد في زيادة القدرة التنبؤية للمصارف الرقمية وخفض مخاطر التعثر مقارنة بالأساليب التقليدية المعتمدة في تقييم الجدارة الائتمانية.

5.1 مجتمع وعينة البحث:

تتكون عينة البحث من قاعة بيانات افتراضية تم توليدها برمجياً تحتوي على 5000 حالة طلب للقروض المصرفية، بطريقة تحاكي البيانات الحقيقية بحيث تتكون من 21 متغير مستقل موزعة كالاتي:

الجدول (1) متغيرات البحث

الوصف	المتغيرات
يمثل عمر الزبون (من 18 إلى 70 سنة)	العمر
الدخل السنوي للزبون 10,000 - 290,000	الدخل
عدد سنوات خدمة الزبون في العمل 0 - 32	سنوات الخدمة
النطاق (345 - 850) ويعتبر نطاق مشابه للدرجات الائتمانية الحقيقية	درجة الائتمان
من 0% إلى 8%	نسبة الدين إلى الدخل
بين 1,100 - 150,000	مبلغ القرض المطلوب
مثل 12، 24، 36 ... حتى 84 شهراً	مدة القرض بالأشهر
قيمة الضمانات، ورصيد حساب التوفير، ورصيد الحساب الجاري	القيم المالية الأخرى
يتمثل بعدد الافراد الذين ينفق عليهم الزبون	عدد المعالين
0 - 12	عدد مرات التأخر في السداد للقروض السابقة
	عدد القروض النشطة الحالية لدى الزبون
	رصيد الحساب الحالي
تحسين المنزل، التعليم، الزواج، السيارة، العلاج، إلخ	الغرض من القرض
الشمال، الجنوب، الشرق، الغرب، الوسط	منطقة سكن الزبون
أعزب، متزوج، مطلق، أرمل	الحالة الاجتماعية للزبون
حكومي، خاص، أعمال حرة، عاطل	جهة العمل
ثانوي، بكالوريوس، ماجستير، دكتوراه، أخرى	المستوى التعليمي
الموقع الإلكتروني، فرع، وسيط	قناة التقديم على القرض
(كلا = 0)، (نعم = 1)	وجود تاريخ تعثر سابق في القروض
هل تمت الموافقة على (كلا = 0)، (نعم = 1)	القرار الائتماني

المصدر: من اعداد الباحثين بالاعتماد على البيانات الافتراضية

بينما يمثل المتغير التابع بقرار قبول القرض او رفضه وبقيمتين اما 0 للرفض او 1 للقبول. كما خضعت البيانات لمعالجة مسبقة شملت التنظيف، الترميز، والتقييس، ثم جرى تقسيمها بنسبة 70% للتدريب و30% للاختبار.

6.1 أسلوب البحث:

تم اعتماد المنهج الوصفي والتحليلي، ويركز المنهج الوصفي على الربط بين الجانب النظري المتعلق بمفاهيم التحول الرقمي والذكاء الاصطناعي، بينما الجانب العملي يعتمد على تحليل البيانات الخاصة بطلبات القروض باستخدام نماذج التعلم الآلي.

7.1 الاسهامات العلمية السابقة:

1.7.1 الدراسة الأولى تمثلت في " دور الذكاء الاصطناعي في تحسين جودة الخدمات الرقمية، للباحث مرزوق واخرون، 2024"، بين الباحثين انه في ظل الوتيرة السريعة للتحول الرقمي والاعتماد المتزايد للمصارف على التكنولوجيا المعاصرة، تسعى هذه الدراسة إلى تحديد مدى قدرة تقنيات الذكاء الاصطناعي على تحسين جودة الخدمات الرقمية التي تقدمها المصارف التجارية المصرية. وتستند الدراسة إلى فكرة أن الذكاء الاصطناعي قد برز كعنصر أساسي في تحويل القطاع المصرفي من خلال تعزيز رضا الزبائن، وتهيئة عمليات صنع القرار، وزيادة الفعالية التشغيلية، والارتقاء بجودة الخدمات المقدمة عبر القنوات الرقمية. وقد استندت الدراسة إلى استبيان أرسل إلى عينة من 384 زبون من المصارف التجارية، يمثلون أربعة مصارف رئيسية تشكل الجزء الأكبر من السوق المصرفية في مصر. وأظهرت النتائج الميدانية وجود علاقة إيجابية قوية بين جودة الخدمات الرقمية المقدمة ودرجة تطبيق الذكاء الاصطناعي. كما أظهرت كيف يحسن تفعيل مكونات الذكاء الاصطناعي تجربة المستخدم عبر المنصات الإلكترونية، ويزيد من ثقة الزبون، ويسرع من تقديم الخدمات. وتوصلت الدراسة إلى أن قدرة المصارف على تبني التقنيات الذكية، والاستثمار في تطوير البنية التحتية التكنولوجية، وتشجيع الوعي الرقمي بين الموظفين والزبائن، أمر بالغ الأهمية لتحسين جودة الخدمات الرقمية. واقترح أنه لتشجيع التحول الرقمي وتحقيق الاستدامة التنافسية في القطاع المصرفي، ينبغي للإدارة العليا إعطاء الأولوية لتطبيقات الذكاء الاصطناعي، ومراقبة التطورات الدولية، وإنشاء استراتيجيات قابلة للتكيف.

2.7.1 الدراسة الثانية " The Impact of Artificial Intelligence Applications on Digital Banking in Turkish Banking Industry " Demirel, et al., 2024، " توضح هذه الدراسة كيف ساعدت تطبيقات الذكاء الاصطناعي على الخدمات المصرفية الرقمية في القطاع المصرفي التركي " توضح هذه الدراسة كيف ساعدت تطبيقات الذكاء الاصطناعي لاسيما تطبيقات المحادثة الآلية الذكية والاتصال المرئي، على مدار أكثر من 10 سنوات المصارف التجارية التركية على بناء خدمات مصرفية رقمية. بدأت الدراسة بملاحظة أن عدد الأشخاص الذين يستخدمون الخدمات الرقمية قد زاد بشكل كبير، وأن المصارف بحاجة إلى أدوات قد تحسن تجربة الزبائن، وتقلل النفقات والوقت، وتحسن الكفاءة التشغيلية. بعد التأكد من استقرار المتغيرات باستخدام اختبارات الجذور الاحادية، استخدمت الدراسة منهجية كمية تعتمد على تحليل السلاسل الزمنية باستخدام نماذج التكامل المشترك ARDL، وبالاعتماد على بيانات ربع سنوية تمتد من عام 2012 إلى عام 2022. حيث كان الهدف هو تحديد العلاقة بين درجة استخدام الخدمات المصرفية عبر الهاتف المحمول وانتشار هذه التطبيقات. للتأكد من أهمية كل تطبيق ووظيفته في تعزيز التحول الرقمي داخل المصارف، تم فحص آثار الدردشة الذكية والاتصال المرئي بشكل مستقل. وأظهرت النتائج أنه بالمقارنة مع تطبيقات الاتصال المرئي، كان لتطبيقات الدردشة الذكية تأثير أقوى وأكثر اتساقاً على زيادة عدد مستخدمي الخدمات المصرفية عبر الهاتف المحمول. في حين أن تطبيقات الاتصال المرئي كانت أقل تأثيراً وأقل استجابة، فقد وُجد أن استخدام الدردشة الذكية يرتبط ارتباطاً واضحاً بزيادة الاعتماد على الخدمات المصرفية الرقمية. ويفسر ذلك بعوامل تتعلق بثقة المستخدم، بالإضافة إلى المخاوف المتعلقة بالبيانات الحساسة والخصوصية. كما كشفت الدراسة أن تطبيقات الذكاء الاصطناعي لاسيما الخدمات المصرفية التفاعلية الذكية، تعد أدوات فعالة لتعزيز التحول الرقمي وزيادة رضا الزبائن على الخدمات المصرفية الإلكترونية. كما أظهرت النتائج ضرورة إنشاء آليات اتصال مرئي أكثر موثوقية، تلبى معايير الأمان وتزيد من ثقة المستخدم، بالإضافة إلى أهمية الاستثمار في هذه التطبيقات لما لها من دور في تحسين جودة الخدمة وتخفيف الضغط التشغيلي.

3.7.1 الدراسة الثالثة " Artificial Intelligence: A Revolution in the Banking Industry in India " Gupta, et. al: (2023)، " الذكاء الاصطناعي: ثورة في قطاع الخدمات المصرفية في الهند" تبدأ الدراسة بافتراض أن تحليلات البيانات الضخمة وخوارزميات التعلم الآلي أصبحت ضرورية الآن لضمان فعالية الأنظمة المالية الحديثة. ولا شك أن قدرة هذه الأدوات على فهم السلوك المالي للزبائن والتنبؤ بالمتطلبات المستقبلية قد أثرت على سرعة وجودة الخدمات. كما أظهرت الدراسة كيف أصبحت تقنيات الذكاء الاصطناعي الآن جزءاً أساسياً من البنية التحتية الرقمية للمصارف الهندية، بدلاً من استخدامها فقط في مهام بسيطة. وقد أدرج الذكاء الاصطناعي في خدمات مثل تحليل المشاعر، والمساعدين الافتراضيين، والدعم الفني على مدار الساعة، وتخصيص المنتجات، واستخدام خوارزميات الكشف عن الاحتيال في الوقت الفعلي، وتطبيقات "أعرف عميلك" المدعومة بالذكاء الاصطناعي، ووظيفة روبوتات الاستثمار في اتخاذ القرارات المالية دون تدخل بشري مباشر. مما يساعد المصارف على فهم زبائنهم بشكل أفضل وتقديم حلول مبنية على سلوكهم المالي الفعلي. وتم استخدام المنهج التحليلي والوصفي في هذه الدراسة والذي يجمع بين دراسة الأدبيات وأمثلة واقعية تظهر كيف تحولت المصارف الهندية من الأنظمة التقليدية إلى الأنظمة الآلية والقائمة على التعلم الآلي. واستنتجت الدراسة أن الذكاء الاصطناعي قد زاد بشكل ملحوظ من كفاءة الخدمات المصرفية من خلال مساعدة المصارف على تبسيط العمليات، وتقليل الأخطاء، وتحسين خدمة الزبائن. وتبين الدراسة كيف ساهم الذكاء الاصطناعي في مبادرات الشمول المالي من خلال نماذج بديلة لتصنيف الائتمان قائمة على البيانات، وتحسين الرقابة التنظيمية والامتثال من خلال منصات التكنولوجيا التنظيمية، مما سمح للمصارف بالوصول إلى فئات سكانية كانت تعاني من نقص الخدمات سابقاً. وتوصلت الدراسة إلى أنه على الرغم من أن تطبيقات الذكاء الاصطناعي تعد حافزاً استراتيجياً

للابتكار في القطاع المصرفي في الهند، إلا أنها تثير أيضاً مشاكل تتعلق بالأمن السيبراني، وأمن البيانات، والتحيز الخوارزمي، وضرورة إنشاء أطر تنظيمية مناسبة. يرى الباحث أن مستقبل القطاع المصرفي سيعتمد على مدى قدرة المصارف على تحقيق التوازن بين المزايا الهائلة للذكاء الاصطناعي ومتطلبات المساءلة والشفافية وحماية بيانات الزبائن. كما يرى الباحث أن النمو في تبني هذه التقنيات سيستمر طالما رافقه تطوير الحوكمة وزيادة إنتاجية موظفي المصارف الذين سيتعاملون مع الأنظمة الذكية.

4.7.1 مقارنة بين نتائج الدراسة الحالية ونتائج الدراسات السابقة:

تتفق نتائج هذه الدراسة مع نتائج دراسة مرزوق وآخرون، 2024 والذين أكدوا أن الذكاء الاصطناعي أصبح عنصرًا أساسيًا في تعزيز رضا الزبائن وتحسين جودة الخدمات المصرفية الرقمية. لكن هذه الدراسة تنتقل من منهج عام يركز على الخدمة إلى منهج تحليلي تطبيقي مرتبط بتقييم الجدارة الائتمانية، الذي يثبت هذه الفكرة. حيث تقدم الدراسة الحالية أدلة كمية مفيدة تُبين كيف تُسهم خوارزميات التعلم الآلي في تحسين دقة قرارات الإقراض وخفض مخاطر الائتمان، بينما استخدم مرزوق وآخرون منهج الاستبيان لقياس تأثير الذكاء الاصطناعي على تجربة الزبائن وجودة الخدمة. تدعم هذه الدراسة السابقة وتوسع نطاق تطبيقها من الإدراك السلوكي إلى اتخاذ قرارات ائتمانية قائمة على البيانات.

بينما أظهرت نتائج دراسة Demirel, et al., 2024، والتي تتوافق مع هذه الدراسة الحالية أن تطبيقات الذكاء الاصطناعي تُعد قوة دافعة رئيسية وراء التحول الرقمي للمصارف من خلال زيادة الكفاءة التشغيلية وخفض النفقات والوقت. ومع ذلك، يكمن الاختلاف الرئيسي في المنهج والهدف التطبيقي. حيث ركزت الدراسة الحالية على تقييم الأداء المقارن لخوارزميات التعلم الآلي في بيئة التصنيف الائتماني، بينما استخدمت دراسة Demirel نماذج السلاسل الزمنية لتحليل العلاقة طويلة الأجل بين استخدام التطبيقات الذكية وزيادة الاعتماد على الخدمات المصرفية الرقمية. ومن منظور مختلف، تؤكد النتائج العملية الحالية للدراسة الاستنتاجات التي توصل إليها Demirel، موضحة أن التحول الرقمي يتجاوز قنوات الخدمة ليصل إلى جوهر عملية صنع القرار المصرفي. واستنادًا إلى مؤشري ROC-AUC و Brier Score، أظهرت الخوارزميات التجميعية، مثل Gradient Boosting و Random Forest، قدرتها الفائقة على التمييز بين الزبائن ذوي الجدارة الائتمانية المختلفة.

أما دراسة Gupta et al., 2023 جاءت متوافقة مع الدراسة الحالية التي أكدت أن تحليلات البيانات الضخمة وخوارزميات التعلم الآلي أصبحت عنصرًا أساسيًا في البنية التحتية المصرفية المعاصرة، لا سيما في مجالات التصنيف الائتماني وإدارة المخاطر وكشف الاحتيال. وأظهرت نتائج الدراسة الحالية التطبيقية أن الخوارزميات التجميعية تفوقت على النماذج الإحصائية والخطية من حيث إنتاج تقديرات احتمالية أكثر دقة في خوارزمية (Brier Score) وتحقيق توازن أفضل بين الدقة والاستدعاء (F1 Score) يؤكد هذا صحة استنتاجات دراسة Gupta حول قصور النماذج التقليدية في إدارة البيانات المالية المعقدة وغير الخطية. كما تدعم الدراسة الحالية نتائج الباحثين بشأن أهمية النماذج القائمة على التعلم الآلي في خفض مخاطر التخلف عن السداد من خلال إصدار قرارات ائتمانية أكثر موضوعية ودقة.

ومن خلال ما تقدم فإن النموذج التطبيقي المستخدم في هذه الدراسة يوضح كميًا كيفية اختلاف كفاءة خوارزميات الذكاء الاصطناعي في دعم القرارات الائتمانية داخل المصارف الرقمية، ويمكن القول إن الدراسة الحالية عززت ما جاءت به الدراسات السابقة من حيث جانب المخاطر والكفاءة التشغيلية، وتبنتها على الجانب العملي وهذا ما انفردت به هذه الدراسة عن الدراسات السابقة. إضافة إلى ذلك، تُسهم في سد فجوة بحثية تتعلق بجودة خيارات الائتمان بناءً على التحليل الخوارزمي والتحول الرقمي على مستوى الخدمة والتطبيق.

المحور الثاني: الجانب النظري

1.2 أساسيات في تطبيقات الذكاء الاصطناعي

1.1.2 مفهوم الذكاء الاصطناعي وتعريفه

يعود مصطلح الذكاء الاصطناعي الي خمسينيات القرن الماضي وبالتحديد عام 1950، عندما عمل علماء الرياضيات (Alan Turing، Kurt Gödel، Alfred North Whitehead) على تطوير مفهوم "التفكير الميكانيكي" أو "التفكير الشكلي". وقد قادت دراسة المنطق بشكل مباشر إلى اختراع الكمبيوتر الرقمي القابل للبرمجة، فالذكاء الاصطناعي ليس مفهومًا جديدًا؛ فقد وُجد منذ عقود طويلة. ولم يعد الحديث عن الذكاء الاصطناعي مجرد خيال علمي، لاسيما مع تزايد التطبيقات والآلات التي تعتمد عليه، وظهور تأثيراته الملموسة على حياة البشرية. إذ يُعد الذكاء الاصطناعي عملية تحاكي الذكاء البشري باستخدام أنظمة الكمبيوتر، عبر تقليد سلوك البشر، نمط تفكيرهم، وآليات اتخاذ القرار، ان كلمة ذكاء اصطناعي لا تنطبق على كل شيء يتم فيه استخدام الخوارزميات والبرمجيات دون ان يكون هنالك تعلم

ذاتي، من خلال البيانات المعطاة والمعروضة. بالإضافة الى القدرة على جمع البيانات من أماكن مختلفة للوصول الى قرارات ونتائج صائبة تصب في مصلحة المستخدم (اكرام، امنية، 2023: 60). ويعرف الذكاء الاصطناعي بأنه علم متقدم للغاية مشتق من علوم الحاسوب يحاكي العقل البشري في أعلى مستويات ذكائه ويستخدم لأداء كافة المهام البشرية وحل كافة المشاكل التي يواجهها الإنسان باستخدام الأساليب التكنولوجية المتقدمة (نعمة وآخرون، 2025).

2.1.2 أهمية تطبيقات الذكاء الاصطناعي

تبرز أهمية تطبيقات الذكاء الاصطناعي بالآتي: (نادر، عبد العالي، 2023: 7).

- أ- ان لتطبيقات الذكاء الاصطناعي دور مهم في مختلف المجالات الحساسة، منها الطب، والتعليم، والمجالات العسكرية، والمصرفية.
- ب- بما ان تطبيقات الذكاء الاصطناعي تتمتع بالاستقلالية والدقة، فإنها تستخدم في جوانب صنع القرار من خلال قدرتها على تحليل كميات ضخمة من البيانات بسرعة وبدون تحيز.

المستخدمة في تطبيقات الذكاء الاصطناعي الذي يهتم بإنشاء خوارزميات يمكنها التعرف على انماط البيانات واستخدام تلك المعلومات للتنبؤ أو اتخاذ القرارات. وهذا يتطلب إنشاء نماذج رياضية تكون قادرة على التنبؤ بدقة بالبيانات الجديدة غير المعروفة مع التقاط البنية الأساسية للبيانات بدلاً من الاعتماد على افتراضات أو نماذج محددة مسبقاً، وتكون خوارزميات التعلم الآلي قادرة على التعلم بشكل مستقل والتكيف مع بنية البيانات (Rakholia, et. al., 2024: 131624).

2.2 اساسيات في التحول الرقمي

1.2.2 مفهوم التحول الرقمي وتعريفه

ان التحول الرقمي للمصارف يساعدها على تعزيز الكفاءة التشغيلية، وتقليل الأخطاء البشرية وتحسين جودة الخدمات المقدمة للزبائن، وهذا يعني ان التحول الرقمي هو استخدام التكنولوجيا لتحسين العمليات، وزيادة الكفاءة، وتقديم خدمات ومنتجات مبتكرة، لذلك يتعين على المصارف تبني التحول الرقمي من أجل التخلص من المهام العادية وتعزيز الوقت للتفكير المتعلق بالتطوير المؤسسي، ويمكن تعريف التحول الرقمي على انه تغييراً ثقافياً وتنظيمياً وتشغيلياً ناتجاً عن تبني التقنيات الرقمية، يهدف إلى تحسين الكفاءة والأداء المصرفي من خلال رقمنة العمليات والخدمات، مثل ابتكار المنتجات، إعداد الكشوفات المالية، تعزيز أنظمة الأمن، وتسهيل معاملات الزبائن (مرسي، موساوي، 2023).

ويعرف كذلك بأنه استخدام التقنيات الحديثة كالحواسيب والذكاء الاصطناعي لرقمنة أعمال المصرف وزيادة كفاءته وأمانه، مع تمكين الزبائن من إنجاز معاملاتهم مالياً عن بُعد، ويختلف عن مصارف الإنترنت بكونه يشمل رقمنة أنشطة المصرف كافة وليس خدمات الزبائن فقط (محمد، 2025، 53).

2.2.2 أهمية التحول الرقمي

تتمثل أهمية التحول الرقمي بالآتي: (شلفوح، 2024: 9).
أ- العمل على تحقيق رفاهية الزبائن، من خلال قيام المصارف باستخدام التكنولوجيا للقيام بتقديم خدمات رقمية لزيابائنها.
ب- يؤدي التحول الرقمي الى دفع المصارف نحو المنافسة من أجل المحافظة على ديمومتها في القطاع المصرفي.
ت- خفض استخدام النقود، وتحسين أمن المعاملات والشفافية لتمكين حلول مستقبلية مستدامة للمشاكل البنينة والاقتصادية.
ث- الأمن الرقمي، من خلال استخدام قنوات مالية أكثر تعقيداً، والمتمثلة بالأنظمة المصرفية الذكية وأنظمة التشفير وأنظمة الذكاء الاصطناعي وإدارة المخاطر والجرائم الإلكترونية.
ج- إتاحة الفرصة لاستثمارات أجنبية، حيث لا يتطلب ذلك تواجـد الزبون في الدولة لمدة طويلة.

3.2.2 تحديات التحول الرقمي

لا تزال العديد من البلدان تواجه مجموعة من العقبات في جهودها لتحقيق التحول الرقمي، والمتمثلة بنقص المهارات والقدرات، والوعي، بالإضافة الى التمويل المحدود والتعقيدات القانونية والتنشيرية، بالإضافة إلى صعوبة تثقيف الجميع حول الثقافة الرقمية وتعزيز ثقافة المعاملات المالية الإلكترونية، ومن التحديات نذكر منها ما يلي: (الظاهر، الموسوي، 2022: 1911).

ت- تساهم الآلات الذكية في تخفيف المخاطر والأعباء النفسية عن الإنسان، مما يتيح لها التركيز على مهام أكثر أهمية وإنسانية، كالمشاركة في جهود الإنقاذ أثناء الكوارث الطبيعية.

ث- تساهم تطبيقات الذكاء الاصطناعي في تبسيط العمليات، وتوفير الزمن والجهد اللازمين لإنجاز المهام، مما يؤدي إلى تحقيق أعلى مستوى من الإنتاجية.

ج- من خلال تعزيز تخصيص الموارد وتقليل الاعتماد على العمالة البشرية، تعمل تطبيقات الذكاء الاصطناعي على خفض التكاليف بشكل كبير، مما يعزز استدامة الأعمال.

3.1.2 دوافع استخدام تطبيقات الذكاء الاصطناعي

هنالك مجموعة من الدوافع التي تجعلنا نلجأ الى استخدام تطبيقات الذكاء الاصطناعي نذكر منها الآتي: (Eltimur, 2022: 588).

أ- سهولة في الاستخدام كونه يتم إنشاء قاعدة بيانات معرفية منظمة وفعالة، وتخزين البيانات بطريقة تسهل الوصول إلى المعلومات.

ب- الأمان، حيث يمكن للمصارف حماية موجوداتها المعرفية من احتمالية الضياع أو التسرب، من خلال تخزين المعلومات والمعرفة المتعلقة بالتطبيقات الخاصة بالذكاء الاصطناعي بشكل استراتيجي.

ت- تخلق تطبيقات الذكاء الاصطناعي آلية عمل مجردة من العاطفة، يمكنها القيام بالمهام بكفاءة عالية دون أن تتأثر بالتعب أو القلق، ولاسيما في الوظائف الصعبة.

ث- يتم وضع حلول سريعة للمشاكل المعقدة، من خلال اجراء عمليات تحليل لتلك المشاكل بدقة ومعالجتها بكفاءة.

4.1.2 مجالات استخدام تطبيقات الذكاء الاصطناعي

تعتبر تطبيقات الذكاء الاصطناعي من أبرز التطورات التكنولوجية في مختلف المجالات، لأنها تعزز كفاءة الإنتاج، وتسرع العمليات، وتقدم إجابات إبداعية للقضايا الصعبة. وتحاكي هذه التطبيقات القدرات البشرية مثل التحليل والمنطق واتخاذ القرار، لأنها تعتمد على تقنيات متطورة مثل التعلم الآلي ومعالجة البيانات الضخمة والشبكات العصبية ومعالجة اللغة الطبيعية وغيرها. يتم إنشاء كل من هذه التقنيات لتحقيق غرض معين، ويتم برمجتها وفقاً لإرشادات دقيقة. كما يساعد ذلك في جعل هذه التطبيقات تؤدي مهام ووظائف مختلفة وفقاً للأهداف التي تم إنشاؤها من أجلها لدعم المستخدمين في مجموعة متنوعة من المجالات، ومن هذه المجالات: مجال الطب والصحة، مجال الاعمال، الحياة اليومية، مجال صناعة القرار (Guchenkoy, 2020: 15).

حيث يعتبر التعلم الآلي أحد اهم التقنيات الأكثر شيوعاً في تطبيقات الذكاء الاصطناعي هو التعلم الآلي، فهو العلم الذي يسمح لأنظمة الحاسوب بالتعلم من البيانات وتحسين أدائها تدريجياً دون الحاجة إلى برمجتها بشكل صريح لكل إجراء أو وظيفة تقوم بها، فالحاسوب يحاول فهم الروابط أو الأنماط الموجودة في البيانات المقدمة إليه من أجل استخدام هذه المعلومات للقيام بمهمة معينة في المستقبل، مثل التصنيف أو التنبؤ أو اتخاذ القرار، وتعليم النظام كيفية التعامل مع المواقف المماثلة، ويمكن تعريف التعلم الآلي على انه أحد التقنيات

من البيانات في وقت قصير، لتوقع الأوضاع التنافسية والمالية بدقة.

تساعد هذه التقنيات المصارف على تحديد الفرص والمخاطر المرتبطة بالزبائن واتخاذ قرارات فورية بشأن منح الخدمات الرقمية. فعلى سبيل المثال، يمكن للمصارف استخدام الذكاء الاصطناعي في تطبيقاتها لدعم قرارات الإقراض والائتمان بطريقة آمنة وسريعة، دون أن يشعر الزبون بأي تعقيد، مما يتيح تقييم أهليته للحصول على القرض بدقة وموضوعية (Fernandez, 2019: 4).

2.3.2 تكلفة منخفضة للعمل

رغم ارتفاع التكلفة الأولية لتطبيقات الذكاء الاصطناعي، فإنها تسهم مستقبلاً في خفض التكاليف التشغيلية للمصارف، مما يمنحها ميزة تنافسية في القطاع المصرفي. لذلك لا بد من المصارف ان تستخدم هذه التطبيقات في واجهة التعامل مع الزبائن لتحديد الهوية وأداء مهام الموظفين اختصاراً للوقت، خصوصاً الجدد الذين يحتاجون إلى وقت للتأقلم مع إجراءات العمل.

بينما تتطلب التطبيقات الرقمية التقليدية فترة اختبار طويلة قبل تشغيلها، حيث يمكن لتطبيقات الذكاء الاصطناعي البدء بالعمل فور تفعيلها دون أخطاء أو تأخير، مع قدرتها على العمل المستمر طوال الأسبوع. كما تتيح هذه الأنظمة للمديرين تحليل الأداء، واكتشاف نقاط الضعف، وتقديم مقترحات تساعد في اتخاذ قرارات دقيقة لتعزز الإنتاجية والكفاءة التشغيلية (Svoboda, 2023: 9).

3.3.2 تعزيز مستوى كفاءة العمل المصرفي

تعد تطبيقات الذكاء الاصطناعي من أهم الأنظمة التي تعتمد عليها المصارف الرقمية لتحسين تجربة الزبائن ورفع الكفاءة التشغيلية، إذ تساهم في أتمتة العمليات، وتحليل البيانات، وتعزيز الأمان، مما يخلق تجربة مصرفية أسرع وأكثر دقة وأماناً. تقلل هذه التطبيقات من الأخطاء البشرية وتسرع الإجراءات التي كانت تستغرق وقتاً طويلاً.

بحيث أصبحت العمليات الروتينية مثل الموافقة على القروض أو الرد على استفسارات الزبائن أكثر سهولة وفاعلية، كما تمكن تطبيقات الذكاء الاصطناعي المصارف من تحليل البيانات الضخمة لتقديم خدمات مخصصة وعروض تتناسب مع احتياجات كل زبون بناءً على تاريخه المالي.

إضافة إلى ذلك، يساهم استخدام تقنيات التحقق البيومترية مثل بصمة الإصبع والتعرف على الوجه والصوت في حماية الحسابات ومنع الاحتيال عبر مراقبة المعاملات المشبوهة والإبلاغ عنها فوراً. لذلك تمثل تطبيقات الذكاء الاصطناعي تحولاً جذرياً في الخدمات المصرفية الرقمية، ومن المتوقع أن تجعل العمل المصرفي أكثر تطوراً وابتكاراً واستجابة لتطلعات

الزبائن في المستقبل. (Demirel, et al., 2024: 2)

4.3.2 تعزيز إنتاجية القوى العاملة والابتكار الاستراتيجي

يُعد تمكين الموظفين من أداء مهام أكثر قيمة أحد أبرز مجالات تأثير تطبيقات الذكاء الاصطناعي في العمليات المصرفية الرقمية. فهذه التطبيقات تتيح للمصارف استثمار رأسمالها البشري في تعزيز الإنتاجية والابتكار بدلاً من الانشغال بالأعمال الروتينية.

أ- افتقار بعض المصارف الى البنى التحتية المعتمدة على تكنولوجيا المعلومات والاتصالات.

ب- التكاليف المرتفعة لقاء امتلاك بضع أنظمة التحول الرقمي، والتي تعجز بعض المصارف عن شراؤها، او عدم تخصيص بنود كافية لها في الموازنات المالية.

ت- ضعف في الكفاءات الموظفة داخل المصارف، وعدم امتلاكها للخبرات الكافية في استخدام أنظمة التحول الرقمي والتعامل معها.

ث- المستوى الثقافي المتدني للزبائن المتعاملين مع المصارف المتبنية لأنظمة التحول الرقمي، وعدم ادراكهم لأهمية تلك الأنظمة في تسهيل عملياتهم المالية.

ج- ضعف خدمات الانترنت والاتصالات لدى بعض الزبائن في مناطق معينة.

4.2.2 استراتيجيات التحول الرقمي

هناك ثلاثة استراتيجيات أساسية للتحول الرقمي: (جبر، 2019: 23).

أ- استراتيجية التكيف مع التكنولوجيا: ان عملة التحول الرقمي تحتاج الى بنية تحتية تقنية قوية لجعلها أكثر قدرة على التكيف مع التكنولوجيا الجديدة، فضلاً عن تسريع التطوير وتقديم منتجات مصرفية جديدة. من خلال قيام المصارف باتخاذ قرارات لرقمة جميع عملياتها وتحديث موقعه الإلكتروني بطريقة تساعد الزبائن على الحصول على المنتجات والخدمات التي يحتاجون إليها في أي وقت.

ب- استراتيجية التوسع الإلكتروني: هنا تحاول المصارف أن تجعل استثماراتها الكبرى في التكنولوجيا تنتج ثمارها، عن طريق تبني استراتيجيات رقمية تنطوي على تغيير جذري في هيكلها التنظيمي وأساليب عملها الإداري وآليات تقييم الأداء بشكل رقمي.

ت- استراتيجية الانسجام مع المنافسة الجديدة: هنا تتكيف وتتسمج المصارف مع التغيير الحاصل في الطلب والعرض على الخدمات المصرفية من خلال خلق منتجات وخدمات رقمية جديدة تسمح لها بتسيخ وجودها في بيئة تنافسية جديدة.

3.2 التأثير المتوقع مستقبلاً لتطبيقات الذكاء الاصطناعي على

التحول الرقمي المصرفي

تُعد تطبيقات الذكاء الاصطناعي من أبرز التقنيات المتطورة التي تساعد القطاع المصرفي على تجاوز التحديات والمنافسة من خلال قدرتها على التنبؤ بالأحداث المستقبلية والاستعداد لها، مما يحدث تحولاً جوهرياً في طبيعة العمل المصرفي. وتمثل هذه التطبيقات عنصراً رئيسياً في تعزيز الأداء المصرفي، إذ تؤثر بشكل مباشر في تطوير المصارف الرقمية عبر عدة جوانب أساسية:

1.3.2 تعزيز الكفاءة والدقة في التوقعات المرتقبة

تُقدم الخدمات المصرفية الرقمية دون حاجة الزبون إلى زيارة المصرف، مما يؤدي ذلك إلى زيادة مستوى المخاطر. لذلك لا بد من المصارف ان تعتمد على تطبيقات الذكاء الاصطناعي لإنشاء بيئة عمل أكثر أماناً وقدرة على التنبؤ وتقليل المخاطر. يتم ذلك عبر خوارزميات متقدمة تعالج كميات ضخمة ومتنوعة

5. احتساب درجة الائتمان والقرار الائتماني باستخدام نموذج شبه لوجستي يمنح احتمالية أعلى للقبول عندما:
- ترتفع درجة الائتمان والدخل
 - تنخفض نسبة الدين الى الدخل
 - تقل عدد مرات التأخر في السداد
 - ينخفض مبلغ القرض المطلوب
 - انخفاض عدد القروض الحالية
 - ارتفاع قيمة الضمانات
 - عمر صغير للزبون
 - جهة العمل حكومي ثم خاص ثم اعمال حرة

وسيتم دراسة الجدارة الائتمانية للزبائن المتقدمين على الاقتراض باستخدام سبع خوارزميات تصنيف مختلفة (Extra Random Forest، Gradient Boosting، SVC، Logistic Regression، Gaussian NB، Trees، RBF، و KNN-15) وباعتماد ستة مؤشرات لتقييم أداء كل خوارزمية: الدقة (Accuracy)، الدقة النوعية (Precision)، الاستدعاء (Recall)، (F1 Score)، منحى خصائص التشغيل المستقبلية (ROC_AUC)، ومقياس براير (Brier Score) وذلك لاتخاذ قرار بالموافقة او الرفض في الإقراض وكما تظهر نتائج الخوارزميات في الجدول (2) ادناه:

الجدول (2) مقارنة كمية لأداء خوارزميات التعلم الآلي في التنبؤ بجدارة الزبائن الائتمانية باستخدام مؤشرات الأداء القياسية

Brier Score	ROC_AUC	F1	Recall	Precision	Accuracy	Model
21%	73%	69%	70%	68%	67%	Gradient Boosting
21%	72%	70%	73%	67%	67%	Random Forest
22%	70%	68%	72%	65%	65%	Extra Trees
23%	69%	70%	82%	62%	63%	Gaussian NB
23%	65%	66%	73%	61%	61%	Logistic Regression
24%	62%	67%	78%	59%	59%	SVC_RBF
26%	56%	59%	61%	56%	54%	KNN_15

المصدر: الجدول من إعداد الباحثين بالاعتماد على برنامج Python

- التنوع لكنها تعتمد على توليد أشجار قرار بشكل عشوائي، من أجل تحسين القرار وتقليل الافراط في التخصيص.
- ث- **خوارزمية (Gaussian NB)** تفترض هذه الخوارزمية ان القيم مستقلة وتتوزع توزيع طبيعي، وتستخدم عند الحاجة إلى تصنيف سريع وفعال حتى مع حجم بيانات كبير.
- ج- **خوارزمية الانحدار اللوجستي (Logistic Regression)** تعتبر من أكثر الخوارزميات قابلية للتفسير والتنبؤ بين جميع الخوارزميات الأخرى، كونها توفر احتمالات مستقرة وقابلة للمراجعة بسهولة، وتستخدم مع البيانات الخطية بسبب سرعتها وسهولة تفسيرها، وقدرتها على تحليل المخاطر المحتملة.
- ح- **خوارزمية آلة الدعم الناقل (SVC_RBF)** وهي إحدى خوارزميات التعلم الآلي، وتستخدم عندما تكون البيانات غير خطية ومعقدة، وذلك للكشف عن سلوك الزبائن المقبلين على القرض.

كما تساعد تطبيقات الذكاء الاصطناعي في اتخاذ القرارات المتكررة والبسيطة من خلال تحليل البيانات وجمع المعلومات الدقيقة، مما يرفع الكفاءة التشغيلية ويزيد تفاعل الموظفين مع بيئة العمل، وهو ما يعزز النمو التنظيمي للمصرف على المدى الطويل (Tian, 2024: 5).

المحور الثالث: قياس أداء خوارزميات التعلم الآلي في التنبؤ بالجدارة الائتمانية للزبائن

في هذا المحور من البحث تم اعتماد قاعدة بيانات مكونة من 5000 حالة طلب تحتوي على بيانات للزبائن المتقدمين للحصول على القروض حيث تتكون قاعدة البيانات من 21 متغير، وتم إنشاء مجموعة البيانات بطريقة محاكاة افتراضية تعتمد على توليد خصائص الزبائن بصورة تحاكي النمط الواقعي من خلال:

1. توليد بيانات ديموغرافية مثل العمر والحالة الاجتماعية والمنطقة وعدد المعالين.
2. توليد بيانات التعليم والعمل مثل المستوى التعليمي ونوع جهة العمل وسنوات الخدمة.
3. توليد البيانات المالية كالدخل، الأرصدة المالية، نسبة الدين إلى الدخل، عدد القروض الحالية، تاريخ التعثر.
4. توليد بيانات القرض نفسه مثل مبلغ القرض، الغرض، قيمة الضمانات، قناة التقديم.

الجدول (2) مقارنة كمية لأداء خوارزميات التعلم الآلي في التنبؤ بجدارة الزبائن الائتمانية باستخدام مؤشرات الأداء القياسية

1.3 خوارزميات التعلم الآلي
الآتي يبين التوضيح الخاص بكل خوارزمية مستخدمة ضمن الجدول (1):

- أ- **خوارزمية التعلم التدريجي (Gradient Boosting)**
تعتبر من أهم وأقوى خوارزميات التعلم الآلي، حيث تستخدم هذه الخوارزمية في التنبؤ والتحليل الائتماني كونها لا تعتمد على شجرة قرار واحدة وإنما تبني عدة أشجار، وكل شجرة قرار تقوم ببنائها تصحح الشجرة السابق في كل مرحلة تدريب تقوم بها.
- ب- **خوارزمية الغابات العشوائية (Random Forest)**
وتعتبر من أكثر تقنيات التعلم الآلي الشائعة والفعالة، وتستخدم لحل مشكلة التصنيف والتنبؤ، حيث تعتمد على مجموعة من أشجار القرار وكل شجرة تعطي قرار مستقل ثم يتم جمع الأشجار معاً للوصول إلى القرار النهائي الدقيق والمستقر.
- ت- **خوارزمية الغابات الإضافية العشوائية (Extra Trees)**
وتستخدم هذه الخوارزمية للتنبؤ والتصنيف، كونها تزيد من

القرار. مقارنةً مع النماذج التجميعية الأخرى، لذا تُحقق هذه الطريقة أداءً جيداً، لكنها أقل استقراراً.


بينما بلغت دقة خوارزمية (Gaussian Naive Bayes) 63%، حيث لا تدعم هذه الخوارزمية البيانات الائتمانية، التي تتميز بارتباطات قوية بين الخصائص المالية والسلوكية للزبائن، كونها قائمة على فرضية استقلال المتغيرات وتوزيعها الطبيعي بشكل كامل، وهو ما يُفسر هذا الأداء المتوسط لها. وهذا يحد من قدرتها على تصوير الأنماط الحقيقية بدقة. وبالمثل، بلغت دقة خوارزمية (Logistic Regression) 61% ويعود ذلك إلى أنه على الرغم من بساطتها وسهولة تفسيرها، إلا أن بنيتها الخطية تجعلها غير قادرة على تحديد التفاعلات غير الخطية المعقدة بين المتغيرات.

من جانب آخر، أظهرت خوارزمتا (KNN و SVC-RBF) أدنى مستويات من الدقة، بنسبة 59% و 54% على التوالي. ويُعزى هذا التدهور إلى تأثير خوارزمية KNN بعدد الجيران المستخدمين في التصنيف، فضلاً عن حساسيتها الشديدة لتوزيع البيانات واختيار المعاملات. عند التعامل مع مجموعة البيانات الضخمة والمعقدة، ويزيد هذا من ميلها للتعميم على حساب الدقة. لذا وفقاً لنتائج مقياس الدقة، تُعد الخوارزميات التجميعية الخيار الأمثل والأكثر موثوقية لدعم قرارات الإقراض بالقبول أو الرفض في المصارف الرقمية، لا سيما عند التعامل مع بيانات ائتمانية معقدة، أما الخوارزميات الأخرى، فهي أقل ملاءمة لهذا النوع من التحليلات.

2.2.3 الدقة النوعية (Precision)

وهي إحدى مؤشرات تقييم أداء خوارزميات التصنيف في التعلم الآلي، والتي تبين مدى موثوقية وصحة التنبؤات الإيجابية الصادرة مع تقليل الأخطاء الإيجابية المكلفة، وتقاس وفق الصيغة الرياضية الآتية:

$$Precision = \frac{TP}{TP + FP}$$



الشكل (2) الرسم البياني الخاص بمؤشر الدقة النوعية

(Precision)

المصدر: من اعداد الباحثين بالاعتماد على برنامج Python


خ- خوارزمية (KNN_15) ان أساس عمل هذه الخوارزمية هو مبدأ التشابه بين العينات، حيث تأخذ العينة تصنيفها على أساس أقرب 15 عينة لها ضمن بيانات التدريب، يتم استخدامها بسبب سهولتها، بالإضافة الى كونها لا تحتاج الى تدريب معقد، كما انها تعطي نتائج جيدة ودقيقة في حال كانت البيانات واضحة وموزعة بصورة منتظمة.

2.3 مؤشرات تقييم أداء الخوارزميات

1.2.3 الدقة (Accuracy)

تعتبر الدقة إحدى مؤشرات الأداء الأكثر استخداماً في تقييم خوارزميات التعلم الآلي، فهي تقيس مدى قدرة الخوارزمية على التنبؤ الصحيح بالنسبة الى إجمالي التنبؤات وكلما اقتربت النسبة الى 100% أصبح النموذج أكثر دقة في التنبؤ بشكل صحيح، حيث تعتبر مؤشر مهم لتقييم أداء خوارزميات التصنيف، ويتم حسابها وفق الصيغة الرياضية الآتية:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$



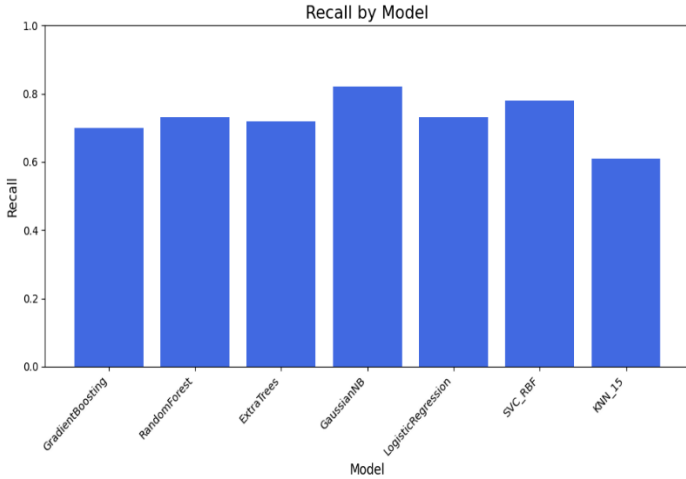
الشكل (1) الرسم البياني الخاص بمؤشر الدقة (Accuracy) المصدر: من اعداد الباحثين بالاعتماد على برنامج Python

يظهر الشكل (1) ان كل من خوارزمية (Gradient Boosting) و (Random Forest) حققت أعلى معدل دقة بلغ 67%، ويعود تميز هاتين الخوارزميتين إلى طبيعتهما التجميعية وقدرتهما على إدارة التفاعلات المعقدة والعلاقات غير الخطية بين المتغيرات الائتمانية. حيث تعتمد خوارزمية (Gradient Boosting) على التعلم التدريجي من خلال بناء نماذج متتابعة تُصلح عيوب النماذج السابقة. ويُقلل هذا من التحيز ويزيد من الدقة، مما يجعلها مناسبة لدراسة البيانات الائتمانية التي تتداخل فيها الخصائص المالية والسلوكية للزبائن.

أما خوارزمية (Extra Trees)، فقد احتلت المركز الثالث بدقة بلغت 65%. ويعود ذلك إلى تشابهها الهيكلي مع النماذج التجميعية واعتمادها على أشجار القرار. وعلى الرغم من الانخفاض الطفيف في الدقة، إلا ان زيادة عدم القدرة على التنبؤ في اختيار نقطة تقسيم البيانات يقلل من الارتباط بين أشجار

قدرة على اكتشاف الحالات الإيجابية، ويقاس وفق الصيغة الرياضية الآتية:

$$Recall = \frac{TP}{TP + FN}$$



الشكل (3) الرسم البياني الخاص بمؤشر الاستدعاء (Recall) المصدر: من اعداد الباحثين بالاعتماد على برنامج Python
يتضح لنا من الشكل (3) أن خوارزمية (Gaussian NB) حققت أعلى معدل استدعاء وبنسبة 82%، مما يشير إلى أنها الأكثر قدرة في التعرف على الزبائن المؤهلين فعلياً للحصول على القرض. وتقليل حالات الرفض الخاطئ. يُعزى الأداء الجيد للخوارزمية إلى بنيتها الاحتمالية واعتمادها على التوزيعات الاحتمالية، مما يجعلها أكثر حساسية في تحديد الحالات الإيجابية، حتى وإن كان ذلك على حساب زيادة بعض حالات القبول غير الدقيقة. ثم تلتها خوارزمية (SVC_RBF) بنسبة 78%، ويُفسر ذلك بقدرتها على نمذجة العلاقات غير الخطية داخل البيانات وهو أداء جيد يدل على أنها تمكنت النقاط أنماط سلوكية معقدة للزبائن المؤهلين، إلا إن ميل الخوارزمية إلى تصنيف عدد أكبر من الحالات على أنها إيجابية، بما في ذلك بعض الحالات عالية المخاطر، يحد من موثوقيتها في اتخاذ القرارات الانتمانية النهائية. كون ان هذا الأداء العالي في الاستدعاء لم يقابله تحسن مماثل في الدقة النوعية. أما كل من خوارزمية (Random Forest) و (Logistic Regression) فقد حققتا نفس النسبة عند 73%، مما يعكس توازناً جيداً بين القدرة على اكتشاف الزبائن المقبولين فعلياً والاستقرار في التنبؤات بسلوك الزبون الانتماني. ففي خوارزمية Random Forest، يعود هذا الأداء إلى آلية الدمج بين عدد كبير من أشجار القرار التي تنتج النقاط نسبة جيدة من الحالات الإيجابية دون الميل المفرط إلى التعميم، أما Logistic Regression فقد حافظت على مستواها بسبب قدرتها على تحديد الاتجاه العام للعلاقة بين المتغيرات والقرار الانتماني. بينما سجلت (Extra Trees) نسبة 72%، وهي قريبة من النسب السابقة وتدل على كفاءة في التعامل مع بيانات القروض. وجاءت خوارزمية (Gradient Boosting) بنسبة 70% وهي نسبة أقل نسبياً مقارنة ببعض الخوارزميات الأخرى، رغم تفوقها في دقة التنبؤ، مما يعني أنها أكثر تحفظاً في تصنيف الزبائن بأنهم مؤهلين في

يبين الشكل (2) ان كل من خوارزمية التعلم التدريجي (Gradient Boosting) وخوارزمية الغابات العشوائية (Random Forest) حققنا أعلى دقة نوعية بنسبة 68% و67% على التوالي، أي انه من بين جميع الحالات التي تم تصنيفها من قبل النموذج على انها مقبولة للحصول على قرض، تبين ان 68% و67% على التوالي كانتا صحيحتان، ويمكن تفسير هذا الارتفاع بأن النماذج التجميعية تبني قرارها من مجموعة أشجار قرار، ثم تدمج المخرجات بطريقة تقلل من القرارات المتطرفة وتحسن موثوقية الحكم الإيجابي، حيث ان هذا الأداء المرتفع يعتبر مناسباً للمصارف التي تسعى الى تقليل مخاطر الإقراض الناتجة عن الموافقة الخاطئة لمنح القرض. بينما تظهر خوارزمية الغابات الإضافية العشوائية (Extra Trees) ما نسبته 65% والتي تعتبر مقبولة الى حد ما لكنها اقل استقراراً في الوقوف على الحالات الصحيحة المقبولة، وتفسير هذا الأداء كونها تعتمد على بنية تجميعية مشابهة لخوارزمية Random Forest، إلا أن اعتمادها على اختيار نقاط تقسيم البيانات بصورة عشوائية يقلل من دقة بعض الأشجار. أما خوارزمية (Gaussian NB) فقد حققت نسبة 62% وتبين هذه النسبة ضعف الخوارزمية البسيط نسبياً في التنبؤ بقدرة الزبائن المؤهلين للحصول على القرض، كونها تعتمد على افتراض ان البيانات مستقلة، وهذا الافتراض لا يتناسب مع طبيعة بيانات الجدارة الانتمانية التي تتسم بترابط الخصائص المالية والسلوكية للزبائن، ما يؤدي إلى ارتفاع احتمال تصنيف بعض الحالات عالية المخاطر ضمن فئة القبول. ثم جاءت خوارزمية الانحدار اللوجستي (Logistic Regression) بنسبة متقاربة للخوارزمية السابقة 61% وهذه النسبة توضح القدرة المحدودة في التعامل مع العلاقات غير الخطية بين بيانات الزبون ونتيجة قبول المنح. وانخفض مؤشر الدقة النوعية في خوارزمية (SVC_RBF) حيث بلغت النسبة 59% كونها لم تستطع تحقيق تميز واضح في الأداء. واخيراً سجلت خوارزمية (KNN_15) أدنى انخفاض 56% حيث يعكس هذا صعوبة استخدام هذه الخوارزمية في مثل هكذا بيانات، بسبب عدم وضوح توزيع البيانات بطريقة تتناسب مع هذه الخوارزمية، كونها تتأثر بعدد الجيران المستخدمين في البيانات.

في ظل التحليل السابق، تؤكد نتائج مقياس الدقة النوعية أن الخوارزميات التجميعية، ولا سيما خوارزمية (Gradient Boosting) و (Random Forest)، تمثل الخيار الأكثر أماناً وموثوقية عند تطوير أنظمة دعم القرارات الانتمانية في المصارف الرقمية. ومن ناحية أخرى، تُشكل خوارزمية (Extra Trees) خياراً متوسطاً يتميز بأداء جيد ولكنه أقل استقراراً نسبياً، بينما تظل الخوارزميات الأخرى أقل ملاءمة في الحالات التي تتطلب تقليل مخاطر الموافقة الخاطئة على القروض.

3.2.3 الاستدعاء او الاسترجاع (Recall)

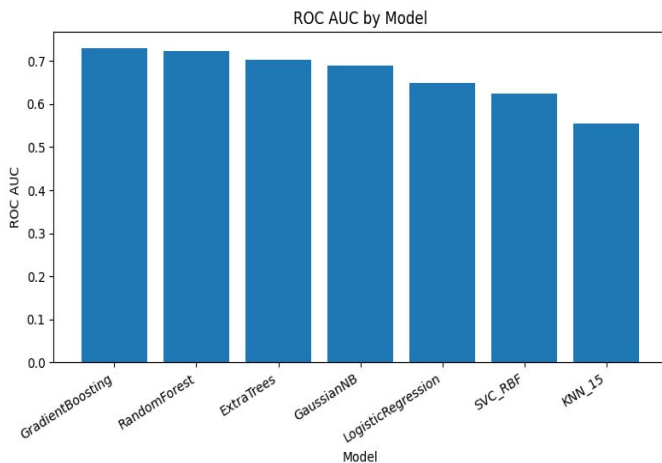
وهو مؤشر احصائي يستخدم في تقييم أداء خوارزميات التصنيف الخاصة بالتعلم الآلي، حيث يفيد في قياس قدرة الخوارزمية على تحديد جميع الحالات الإيجابية في البيانات، وكلما اقتربت النتيجة من 100% يدل هذا على ان الخوارزمية

بتحقيقها نسبة 69%، وهو أداء مرتفع نسبياً يعكس قدرتها على تحقيق دقة عالية واستقرار في التنبؤ، إلا أن طبيعتها التحفظية في التصنيف أدت إلى انخفاض قليل في الاستدعاء مقارنة ببعض الخوارزميات الأخرى، الامر الذي يجعلها خوارزمية مرغوبة في تحليل مخاطر الائتمان، ثم تأتي خوارزمية (Extra Trees) في المرتبة التالية بنسبة 68%، وهي قريبة في الأداء من الخوارزميات السابقة، مما يدل على أنها تحقق توازناً جيداً لكنها أقل كفاءة نسبياً في معالجة العلاقات المعقدة بين المتغيرات. ثم جاءت خوارزمية (SVC_RBF) بسبة 67% مما يعكس أداءً متوسطاً، يشير إلى ميل الخوارزمية لتوسيع نطاق التصنيف الإيجابي. بينما حققت خوارزمية (Logistic Regression) نسبة 66%، مما يشير إلى محدوديتها في تمثيل الأنماط غير الخطية بين المتغيرات الائتمانية. واخيراً ظهرت خوارزمية (KNN_15) بأدنى مستوى لها وبنسبة بلغت 59%، مما يوضح ضعفها في تحقيق التوازن بين الدقة النوعية والاستدعاء بسبب تأثرها الكبير بتوزيع البيانات وعدد العينات القريبة المختارة.

من التحليل السابق نجد أن الخوارزميات التجميعية مثل (Gradient Boosting و Random Forest) تحقق أفضل أداء من حيث التوازن بين الدقة النوعية والاستدعاء، ما يجعلها تمثل الخيار الأكثر ملاءمة لتقييم الجدارة الائتمانية في بيئات مصرفية رقمية تتسم بعدم توازن البيانات، حيث تعطي قرارات أكثر موثوقية في التنبؤ بقبول أو رفض طلبات الزبائن في الحصول على القروض.

5.2.3 مقياس (ROC_AUC)

ويسمى بالمساحة تحت منحنى الخصائص التشغيلية للمستقبل، ويستخدم هذا المقياس لتقييم أداء الخوارزمية من خلال تحليل قدرة الخوارزمية على التفريق بين الفئات الإيجابية والسلبية، أي قدرتها على التفريق بين الزبائن الذين ينبغي قبولهم أو رفضهم لمنح القرض.



الشكل (5) الرسم البياني الخاص بمقياس (ROC_AUC) المصدر: من اعداد الباحثين بالاعتماد على برنامج Python


يبين الشكل (5) قدرة كل خوارزمية على التمييز بين الزبائن الذين ينبغي قبول طلباتهم والزبائن الذين ينبغي رفضهم.

الحصول على القرض، وبالتالي قد يرفض بعض الزبائن المستحقين فعلياً، كونها تركز على تقليل الأخطاء الكلية وتحسين الدقة العامة وجودة التنبؤ الاحتمالي. اما خوارزمية (KNN_15) فقد أظهرت أضعف أداء بنسبة 61%، مما يدل على محدودية قدرتها في التعرف على جميع الزبائن المؤهلين نتيجة لتوزيع البيانات بصورة عشوائية وعدد العينات القريبة المستخدمة في التصنيف. من التحليل السابق نجد أن الخوارزميات ذات الاستدعاء العالي مثل (SVC_RBF و Gaussian NB) تعد أكثر كفاءة في الكشف عن جميع الزبائن الجديرين بالثقة وتقليل حالات الرفض الخاطي، وهو أمر بالغ الأهمية في التحليل الائتماني لتجنب خسارة زبائن مؤهلين وهو ما قصدنا به سابقاً بتقليل الأخطاء الإيجابية المكلفة. ولضمان اتخاذ القرار الائتماني الأفضل لا بد من الموازنة الدقيقة بين الدقة النوعية والاستدعاء وهذا ما سنجده في مؤشر (F1 Score).

4.2.3 درجة (F1 Score) F1

وهو من اهم مؤشرات تقييم أداء خوارزميات التصنيف في التعلم الآلي، ويسمى بمعدل التوازن التوافقي بين الدقة النوعية والاستدعاء، ويستخدم هذا المؤشر عندما تكون البيانات غير متوازنة، يعني ذلك ان عدد العينات الإيجابية تكون أكبر او اقل بكثير من العينات السلبية الامر الذي يدفع الى احداث توازن في العينات ما بين الدقة النوعية والاستدعاء، وتكون الصيغة الرياضية لها كالاتي:

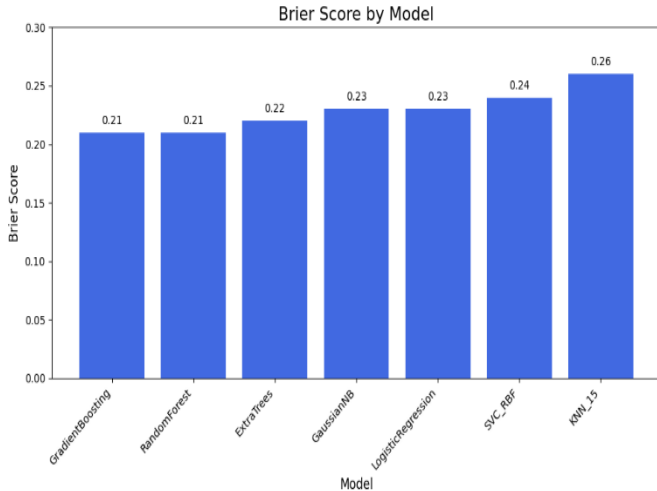
$$F1 = \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \times 2$$



الشكل (4) الرسم البياني الخاص بمؤشر (F1 Score) المصدر: من اعداد الباحثين بالاعتماد على برنامج Python

نجد في الشكل (4) ان كل من خوارزمية Random Forest و Gaussian NB) حققنا نسبة 70% وهي اعلى نسبة، ويدل ذلك على قدرتهما العالية في الموازنة بين تحديد الزبائن المقبولين وغير المؤهلين عند تقييم الجدارة الائتمانية، ويعود هذا الأداء المتوازن إلى طبيعتها التجميعية التي تعتمد على دمج مخرجات عدد كبير من أشجار القرار، مما يقلل من تأثير الأخطاء الفردية ويحقق استقراراً أعلى في قرارات التصنيف. اما خوارزمية (Gradient Boosting) أظهرت أداء جيد

وهو أحد مقاييس الاحصاء والتعلم الآلي، حيث يستخدم في تقييم دقة التنبؤ في الاحتمالات، ففي تحليل الأداء يعتبر مقياساً أساسياً ومهماً، حيث يقترب المقياس من التنبؤ المثالي عندما تكون القيمة قريبة للصفر، وكلما ابتعدت عن الصفر دل ذلك على الخطأ في التنبؤ. اذن فهو يوفر مقياساً أكثر عمقاً لتقييم جودة التنبؤات مقارنة بالمقاييس التقليدية مثل الدقة أو الاستدعاء، لأنه يأخذ في الاعتبار مدى اقتراب التنبؤ الاحتمالي من الحقيقة الفعلية ولا يعتمد فقط على صحة القرار النهائي.



الشكل (6) الرسم البياني الخاص بمقياس (Brier Score) المصدر: من اعداد الباحثين بالاعتماد على برنامج Python
يوضح الشكل (6) مستويات مقياس (Brier Score) لمجموعة من الخوارزميات المستخدمة لتقييم أهلية المقترضين للحصول على القروض. يقيس هذا المقياس دقة التنبؤات الاحتمالية من خلال مدى تقارب القيم المتوقعة مع النتائج الفعلية. وتشير القيم المنخفضة إلى تنبؤات أكثر دقة، وبالتالي فإن انخفاض قيمة (Brier Score) يدل على أن الخوارزمية تقدم تقديرات احتمالية أكثر دقة لقبول أو رفض القرض.

حيث نجد النتائج تشير إلى أن خوارزمية (Random Forest و Gradient Boosting) حققنا أفضل أداء، إذ بلغت نسبة المقياس لكل منهما 0.21، مما يعكس دقة واستقراراً مرتفعين في التنبؤ بقرارات القبول. ويُعزى هذا الأداء المتميز إلى آلية التعلم التجميعي التي تعتمدانها، والتي تقوم بدمج مخرجات عدة أشجار قرار لتقليل التباين وتحسين دقة التنبؤ. ثم تلتها خوارزمية (Extra Trees) بقيمة 0.22، مما يشير أيضاً إلى أداء قوي، رغم الزيادة الطفيفة في الخطأ الناتجة عن ارتفاع مستوى العشوائية في بناء الأشجار. أما خوارزمية (Gaussian NB و Logistic Regression) فقد سجلتا قيمة 0.23، مما يدل على أن الدقة التنبؤية لهما أقل نسبياً. ويعود ذلك إلى اعتماد Gaussian Naive Bayes على افتراضات استقلالية المتغيرات، واعتماد Logistic Regression على نموذج خطي، لا تلتقط بشكل كافٍ الارتباط غير الخطي في بيانات الائتمان. وجاءت بعدهما خوارزمية (SVC_RBF) بقيمة 0.24، مما يشير إلى ضعف في تقدير الاحتمالات، لاسيما عند التعامل مع بيانات تتضمن تداخلاً كبيراً بين الفئات. وفي المقابل، سجلت خوارزمية (KNN_15) أعلى قيمة بلغت 0.26، وهو

كلما ارتفعت قيمة (ROC_AUC) اقتربت الخوارزمية أكثر من القدرة المثالية في التحديد بين الفئتين الإيجابية والسلبية في قرار الإقراض. ويظهر أن خوارزمية (Gradient Boosting) حققت أعلى قيمة بلغت 73% وتلتها خوارزمية (Forest Random) ونسبة 72%، مما يعكس قدرة عالية لهاتين الخوارزميتين على التمييز بين الزبائن ذوي الجدارة الائتمانية المرتفعة والزبائن من ذوي المخاطر العالية. وتحديد من يجب منحه او عدم منحه القرض، ولاتخاذ قرار ائتماني مبني على تقدير المخاطرة هو ما يجعل هذه الخوارزمية مناسبة له، كونها تتعامل مع بيانات غير خطية. اما خوارزمية (Extra Trees) فقد سجلت مستوى 70%، وهو مستوى مقبولاً ويشير إلى القدرة الجيدة على التفريق بين الفئتين الإيجابية والسلبية. وقد أظهرت خوارزمية (Gaussian NB) قيمة 69%، مما يشير إلى قدرتها على إنتاج قرار ائتماني معقول يميز بين القبول والرفض، رغم بساطتها وافتراضها استقلالية المتغيرات. ويعكس هذا الأداء أن الخوارزمية قادرة على التقاط الاتجاه العام للمخاطرة الائتمانية، إلا أن محدودية افتراضاتها تقلل من قدرتها على الفصل الدقيق بين الحالات المتداخلة وبالتالي تعد أقل كفاءة من النماذج التجميعية. بينما انخفضت القيمة في خوارزمية (Logistic Regression) إلى 65%، وهذا يدل على أن هذه الخوارزمية الخطية تمتلك قدرة محدودة على التقاط التعقيد الحقيقي في البيانات الائتمانية، وبالتالي تواجه صعوبة في التمييز بين الزبائن ذوي الجدارة الائتمانية العالية والمنخفضة عندما تكون العلاقة بين المتغيرات غير خطية. اما خوارزمية (SVC_RBF) فقد انخفضت لتصل إلى 62%، مما يعني أن قدرة النموذج على التمييز بقيت متوسطة وأقل استقراراً، نتيجة تداخل البيانات. وأخيراً سجلت خوارزمية (KNN_15) أدنى نسبة بلغت 56%، مما يشير إلى ضعف قدرتها على بناء قرار ائتماني تعتمد عليه في التمييز بين الزبائن من حيث القدرة الائتمانية.

من التحليل السابق نجد أن الخوارزميات التجميعية ولاسيما Gradient Boosting و Random Forest، هي الأكثر كفاءة وموثوقية في دعم قرارات الإقراض داخل المصارف الرقمية، لقدرتها العالية على التمييز بين الزبائن الجيدين ائتمانياً وذوي المخاطر المرتفعة، حيث ان مقياس ROC_AUC المرتفع يعتبر أفضل خيار وأكثر موثوقية في قرار منح القرض او الرفض لتقليل المخاطر.


6.2.3 مقياس (Brier Score)

النوع حساس للغاية من أخطاء الإقراض. بينما يعرض الجزء السفلي الأيسر False Negative من المصفوفة 231 حالة رفضها النموذج على الرغم من أنها كانت مؤهلة للموافقة. على الرغم من أن هذا النوع من الخطأ لا يعرض المصرف لمخاطر مالية فورية، إلا أنه قد يؤدي إلى ضياع فرص التمويل وتقليل القدرة التنافسية للمصرف من خلال رفض الزبائن ذوي إمكانات السداد القوية. من ناحية أخرى، يُظهر الجزء السفلي الأيمن True Positive من المصفوفة أن النموذج صنف 564 زبوناً مؤهلاً بشكل صحيح، مما يُشير إلى كفاءته في تحديد خصائص الزبون ذي الامكانية على الوفاء بالتزاماته الائتمانية.

تتبع قدرة نموذج التعلم التدريجي على تحقيق توازن عادل بين الكشف الدقيق عن الزبائن غير المؤهلين والحفاظ على درجة عالية من الدقة في التعرف على الزبائن المؤهلين في توزيع الأرقام داخل المصفوفة. ومع ذلك، فإن وجود عدد كبير من الإيجابيات الخاطئة يُشير إلى ضرورة تحسين حساسية النموذج للعوامل المتعلقة بالمخاطر. وبشكل عام، تُوضح المصفوفة كيف يُمكن للأدوات القائمة على التعلم الآلي دعم قرارات الائتمان بنجاح داخل المصارف من خلال تحديد الأنماط الخفية في بيانات الزبائن وتقديم تقديرات أكثر موثوقية للسلوك المالي المتوقع. كما تُظهر كيف يُمكن للنموذج التعامل مع بيانات مُعددة ومتراصة.

2.3.3 خوارزمية الغابات العشوائية (Random Forest)

تُقدم مصفوفة الارتباك في نموذج الغابة العشوائية صورة واضحة للأداء التنبؤي. من خلال فحص توزيع القيم داخل المصفوفة، حيث يُمكننا من خلال المصفوفة فهم قدرة النموذج على التمييز بين الزبائن ذوي الجدارة الائتمانية العالية الذين يستحقون الموافقة على القروض، والذين توضح بياناتهم أن هناك احتمالية عالية للتخلف عن السداد.



الشكل (8) الرسم البياني لمصفوفة الارتباك (خوارزمية الغابات العشوائية)

المصدر: من اعداد الباحثين بالاعتماد على برنامج Python

يظهر في الشكل (8) الجزء العلوي الأيسر True Negative من المصفوفة أن النموذج صنف بشكل صحيح 422 طلباً كانوا ضمن فئة الرفض، ويعكس هذا قدرة جيدة على اكتشاف الأنماط المرتبطة بمخاطر الائتمان العالية، وهو أمر

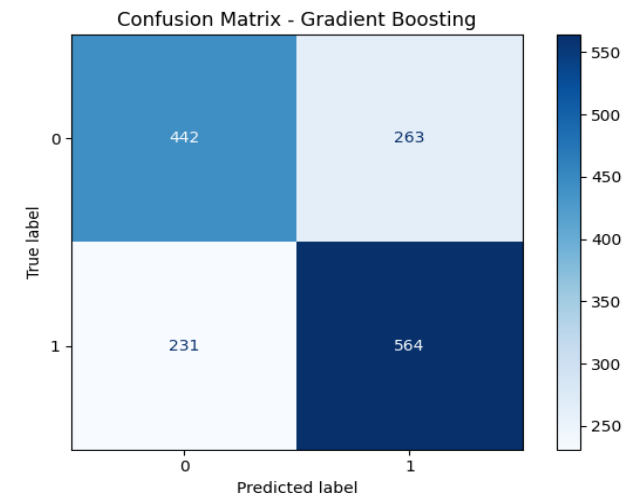
ما يعكس أدنى مستوى من الدقة التنبؤية. ويُعزى ذلك إلى اعتمادها الكبير على العينات الأقرب، مما يجعلها شديدة الحساسية لتوزيع البيانات ويؤدي إلى زيادة في أخطاء التقدير. يؤكد هذا التحليل أن الخوارزميات التجميعية مثل (Random Forest و Gradient Boosting) هي الأكثر كفاءة في التنبؤ بالقرارات الائتمانية داخل المصارف الرقمية، نظراً لقدرتها على تقليل الخطأ الاحتمالي وتحسين دقة التقديرات وهو ما يعزز من جودة إدارة المخاطر الائتمانية ويحد من حالات التعثر مستقبلاً. وفي المقابل، تواجه النماذج الإحصائية والخطية صعوبة في التعامل مع البيانات المالية المعقدة التي تتسم بأنماط سلوك غير خطية لدى الزبائن.

3.3 مصفوفة الارتباك Confusion Matrix

تم اعتماد مصفوفة الارتباك لأفضل ثلاث خوارزميات في الأداء:

1.3.3 خوارزمية التعلم التدريجي (Gradient Boosting)

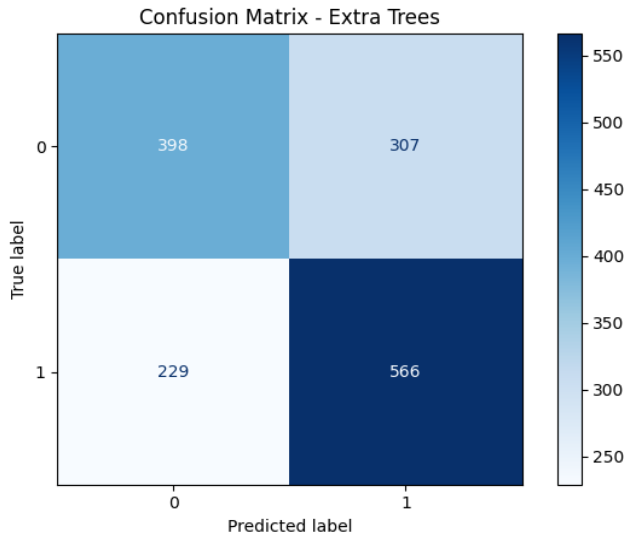
تُظهر مصفوفة الارتباك الخاصة بنموذج Gradient Boosting قدرة النموذج على التمييز بين الزبائن المقبولين والمرفوضين للحصول على القروض. والواضح من القيم المعروضة في الشكل (7) أن النموذج كان قادراً على تصنيف عدد كبير من الحالات بدقة، سواء تلك التي يجب رفضها أو تلك التي يجب الموافقة عليها، مما يدل على فهمه للارتباطات الحاسمة بين المتغيرات المؤثرة على قرار الائتمان.



الشكل (7) الرسم البياني لمصفوفة الارتباك (خوارزمية التعلم التدريجي)

المصدر: من اعداد الباحثين بالاعتماد على برنامج Python

حيث يظهر في الجزء العلوي الأيسر True Negative من المصفوفة قدرة النموذج على تحديد الحالات التي لا تتوافق مع متطلبات الموافقة على القروض واكتشاف المؤشرات المرتبطة بمخاطر الائتمان العالية، حيث يعرض 442 زبون تم تحديدهم بدقة على أنهم غير مناسبين للموافقة. من ناحية أخرى، ويظهر في الجزء العلوي الأيمن False Positive 263 حالة كان ينبغي أن تكون ضمن فئة الرفض ولكن تم تصنيفها عن طريق الخطأ على أنها موافقات من قبل النموذج. ويؤدي هذا إلى الموافقة على طلبات من زبائن لا يتمتعون بجدارة ائتمانية كافية، مما قد يعرض المصرف لمشاكل مالية مستقبلية. ويعتبر هذا



الشكل (9) الرسم البياني لمصفوفة الارتباك (خوارزمية الغابات الإضافية العشوائية)

المصدر: من اعداد الباحثين بالاعتماد على برنامج Python

يعرض الشكل (9) في الجزء العلوي الأيسر للمصفوفة True Negative 398 حالة طلب صُنفت بدقة على أنها رفض، ويُظهر هذا قدرة النموذج على تحديد الزبائن غير المؤهلين للتمويل، وتحديد المؤشرات المرتبطة بمخاطر الائتمانية عالية. من ناحية أخرى، بينما يُظهر الجزء العلوي الأيمن False Positive 307 من الحالات قبلها النموذج رغم وجودها ضمن مجموعة الرفض. في سياق الإقراض، يُعد هذا النوع من الأخطاء الأكثر مخاطرة، إذ ينطوي على منح قروض للزبائن غير القادرين على سدادها، مما يُعرض المصرف لمخاطر الخسائر المستقبلية. بينما نجد في الجزء السفلي الأيسر False Negative 229 حالة رفضها النموذج رغم وجودها ضمن فئة القبول. على الرغم من عدم وجود خسائر مالية فورية نتيجة لهذا النوع من الأخطاء، إلا أن الزبائن الجديرين بالائتمان الذين تمكنوا من السداد تفوتهم فرص التمويل، مما يُؤثر سلباً على نمو قاعدة الزبائن ومستوى العلاقات المصرفية. ويُعرض أسفل اليمين True Positive 566 حالة حددها النموذج بشكل صحيح على أنها إيجابية حقيقية. ويُثبت هذا قدرة النموذج على تحديد الاتجاهات الإيجابية في البيانات التي تشير إلى الزبائن القادرين على الوفاء بالتزاماتهم المالية. تُظهر هذه النتائج جميعها إلى أن نموذج Extra Trees يتمتع بإمكانات تنبؤية جيدة، لاسيما عندما يتعلق الأمر باكتشاف الزبائن ذوي الجدارة الائتمانية، ويتضح هذا من العدد الكبير لحالات الإيجابيات الصحيحة. ونظراً لأن منح الائتمان لزبون غير مؤهل يُعد من أكثر الأخطاء تكلفة التي يمكن أن يرتكبها المصرف، فإن مستوى الإيجابيات الخاطئة المرتفع نسبياً يشير إلى أن النموذج لا يزال بحاجة إلى تحسين من حيث حساسيته لمتغيرات مخاطر الائتمان. ومن خلال التحليل الدقيق للمتغيرات، تتحقق المصفوفة بشكل أساسي من قدرة نموذج Extra Trees على التعامل مع مجموعة واسعة من البيانات المعقدة وتقديم مساعدة مفيدة لاتخاذ القرارات الائتمانية. حيث يمكن تحسين أدائه بشكل أكبر من خلال تغيير المعاملات أو إضافة المزيد من المتغيرات التي

مهم للمصارف لأن التصنيف الدقيق للزبائن ذوي المخاطر العالية يمنعهم من منح قروض غير مضمونة. أما في الزاوية العلوية اليمنى تُعرض حالة False Positive وهي متكونة من 283 طلب صنفه النموذج على أنه مقبول على الرغم من أنه كان في الواقع ضمن فئة الرفض، وينعكس على هذا النوع من عدم الدقة مخاطر عالية، إذ يظهر أن النموذج يمنح قروضاً للزبائن لا يتمتعون بجدارة ائتمانية كافية، مما يزيد من احتمالية تكبد المصرف خسائر في حال تخلفهم عن السداد. وفي أسفل اليسار False Negative يظهر 220 حالة طلب مرفوضة من قبل النموذج لكنها كانت ضمن المجموعة المؤهلة. وعلى الرغم من أن المصرف لا يخسر أموالاً بشكل مباشر نتيجة لهذا النوع من الأخطاء، إلا أنه يفقد فرص التمويل للزبائن الذين لديهم قدرة قوية على السداد، مما قد يؤثر على نمو قاعدة زبائن المصرف وقدرته على المنافسة. بينما يظهر 575 حالة طلب تم تقييمها بشكل صحيح على أنها مؤهلة للموافقة، في أسفل اليمين True Positive. ويوضح هذا مدى قدرة النموذج على تحديد الخصائص المالية والسلوكية للزبون الجيد الذي يمكنه السداد. حيث اتضح من المصفوفة القدرة الفعالة لنموذج "الغابة العشوائية" على فحص الارتباطات المعقدة بين المتغيرات وتحديد الزبائن الذين لا يمثلون مخاطر كبيرة على المصرف.

يتضح من المصفوفة ان هناك أداء متوازن لنموذج الغابة العشوائية من خلال توزيع قيم المصفوفة الخاصة بطلبات القروض ضمن فئة القبول، ويتضح هذا من خلال ملاحظة زيادة عدد الحالات المصنفة بشكل صحيح مقارنةً بالحالات المرفوضة بشكل خاطئ. وقد صنف النموذج عدداً كبيراً من الحالات بشكل صحيح ضمن فئتي القبول والرفض. ورغم وجود العديد من حالات القبول الخاطئة، إلا أن معدل الخطأ يعتبر معقولاً بالنظر إلى حجم البيانات. ويوضح هذا كيف يمكن للنموذج المساعدة في اختيار الائتمان من خلال تقييم خصائص الزبائن والتنبؤ بجدارتهم الائتمانية. بالإضافة إلى ذلك، يُثبت النموذج قدرته على إدارة البيانات الضخمة ذات المتغيرات المتعددة، ويزيد من إمكانية إجراء تحسينات إضافية من خلال توسيع متغيرات التدريب.

3.3.3 خوارزمية الغابات الإضافية العشوائية (Extra Trees)

توضح مصفوفة الارتباك الخاصة بنموذج الغابات الإضافية العشوائية الواضحة في الشكل (9) القدرة على إدارة بيانات القروض وتقييم الجدارة الائتمانية. وتنعكس طريقة تحويل النموذج لأنماط البيانات إلى قرارات قبول أو رفض في توزيع القيم داخل المصفوفة. وتقدم المصفوفة صورة أوضح لكفاءة النموذج في دعم قرارات الائتمان داخل المصارف، مما يُظهر قدرة النموذج على التمييز بين الزبائن الذين يتمتعون بقدرة حقيقية على السداد، وأولئك الذين تشير خصائصهم المالية والسلوكية إلى احتمالية أعلى للتخلف عن السداد.

- نماذج التعلم الآلي ومعالجة كميات كبيرة من البيانات بكفاءة وموثوقية.
4. التركيز على برامج التدريب والتأهيل الرقمي لتحسين قدرة موظفي المصارف على استخدام تطبيقات الذكاء الاصطناعي وتقييم نتائجها لاتخاذ القرارات.
 5. ضرورة دمج أدوات الذكاء الاصطناعي، مثل التحليلات التنبؤية وأنظمة التوصية، مع الخدمات المالية الرقمية لتعزيز كفاءة القرارات الخاصة بالتقييم الائتماني ورفع مستوى الخدمة.
 6. دمج تقنيات التحول الرقمي القائمة على الذكاء الاصطناعي ضمن أهداف المصارف طويلة الأجل، بدلاً من اعتبارها بدائل مؤقتة أو حلولاً سريعة.
 7. زيادة استخدام الخوارزميات التنبؤية في تحليل بيانات الائتمان بهدف خفض معدلات التخلف عن السداد وتعزيز إدارة مخاطر الائتمان.
 8. ترسيخ ثقافة الابتكار الرقمي وإعداد الإطار المؤسسي للانتقال التدريجي إلى الخدمات المصرفية الذكية من خلال تنفيذ جهود تنظيمية وتوعوية داخل المصارف.

توافر البيانات:

تم تضمين البيانات المستخدمة لدعم نتائج هذه الدراسة في المقالة.

تضارب المصالح:

يعلن المؤلفون أنه ليس لديهم تضارب في المصالح.

مصادر التمويل:

لم يتم تلقي أي دعم مالي.

شكر وتقدير:

لا أحد أو ذكر أي شخص آخر.

References:

1. Marzouq, Abdulaziz Ali, Ismail, Ammar Fathi Musa, Abduljayed, Mahmoud Majid Mahmoud. (2024). Dawr al-dhaka al-istina‘i fi tahsin jawdat al-khadamat al-raqamiyya. Raya International Journal of Business Sciences, 3(10).
2. Gupta, V., Awasthi, S., & Jadhav, S. (2023). Artificial intelligence: A revolution in the banking industry in India. International Journal for Multidisciplinary Research (IJFMR), 5(4).
3. Akram, Taybi, Amniya, Moulay. (2023). Athar al-dhaka al-istina‘i ‘ala jawdat al-khadamat al-masrifiiyya: Dirasat halat al-bunuk al-tijariyya bi wilayati al-Bayadh wa

تعزز قدرته على التمييز بين الزبائن ذوي المخاطر العالية وغيرهم.

المحور الرابع: الاستنتاجات والتوصيات

أولاً: الاستنتاجات:

1. أظهرت نتائج البحث التطبيقي أن تطبيق تقنيات الذكاء الاصطناعي في المصارف الرقمية باتت ضرورة استراتيجية لضمان نمو القطاع المصرفي على المدى الطويل وتعزيز القدرة التنافسية في بيئة عالية المخاطر ومعقدة البيانات، وليس مجرد خيار تقني ثانوي.
2. أظهرت النتائج تفوق الخوارزميات التجميعية، لا سيما Gradient Boosting و Random Forest، في تحديد الجدارة الائتمانية. وقد تفوقت هذه الخوارزميات على الخوارزميات الأخرى من حيث الدقة والاستقرار وجودة التنبؤ، مما يجعلها أكثر ملاءمة لدعم قرارات منح القروض.
3. أظهرت مقاييس الأداء القدرة الفائقة لخوارزميات التعلم الآلي على التمييز بين الزبائن ذوي مستويات المخاطر المختلفة. وهذا بدوره يقلل بشكل مباشر من احتمالية التخلف عن السداد ويحد من أخطاء الائتمان المكلفة.
4. من خلال النتائج تم التوصل إلى أن استخدام التحليلات التنبؤية القائمة على الذكاء الاصطناعي تُسهم في تسريع إجراءات منح الائتمان وتحسين جودة القرارات المصرفية مع تقليل الأخطاء البشرية والتدخلات.
5. أوضح التطبيق العملي كيف يعزز الذكاء الاصطناعي كفاءة إدارة المخاطر من خلال تقييم سلوك الزبائن والبيانات التاريخية والتنبؤ المبكر بحالات التخلف عن السداد.
6. خلصت الدراسة إلى أن دمج تقنيات الذكاء الاصطناعي مع التحول الرقمي يُحسن تجربة الزبائن ويعزز ثقتهم في الخدمات المصرفية الرقمية.
7. أظهرت النتائج أن نقص الكفاءات البشرية المتخصصة وارتفاع تكلفة البنية التحتية التقنية هما أكبر عائقين أمام دمج هذه التقنيات في المصارف.
8. إن وجود ثقافة تنظيمية داعمة وقيادة مصرفية قادرة على إدارة التغيير بكفاءة واستخدام التقنيات الحديثة أمران ضروريان لنجاح التحول الرقمي المدعوم بالذكاء الاصطناعي.

ثانياً: التوصيات:

1. لضمان الاستخدام الآمن والفعال ضمن عملية التحول الرقمي، يُوصي الباحث الإدارة العليا للمصارف والهيئات التنظيمية بوضع إطار استراتيجي واضح لتطبيق تطبيقات الذكاء الاصطناعي.
2. ينبغي اعتماد الخوارزميات التجميعية، ولا سيما Boosting و Random Forest، كنماذج أساسية في الأنظمة المصرفية المدعومة بالذكاء الاصطناعي والخاصة بتقييم الجدارة الائتمانية، نظراً لكفاءتها الكبيرة في التنبؤ الدقيق وتخفيف المخاطر.
3. ضرورة الاستثمار في بناء وتطوير البنية التحتية الرقمية المدعومة بالذكاء الاصطناعي للمصارف لتسهيل تشغيل

- al-raqami wa atharuha fi 'amaliyyat idarat al-ma'rifa fi al-mu'assasat al-khadamiyya: Dirasat halat Masraf al-Jumhuriya. *Journal of Human and Society Studies*, (24).
12. Mohammed, Sodfa Al-Tahir, Al-Mousawi, Muthanna Abdul Kazem. (2022). Dawr al-tahawwul al-raqami fi ta'zir jawdat al-khadamat al-masrifiyya fi al-qita' al-masrifi: Dirasat halat bi-al-masarif al-misriyya wa al-'iraqiyya. *Al-Ghari Journal of Economic and Administrative Sciences*, Special issue of the proceedings of the International Scientific Conference of the Faculty of Administration and Economics.
 13. Jabr, Wurood Qasim. (2019). Teknuluja al-tahawwul al-raqami wa ta'thiruha fi tahsin al-ada' al-istiratiji lil-masrif. Higher Diploma thesis, College of Administration and Economics, University of Karbala, Banking Management.
 14. Fernandez, A. (2019). Artificial intelligence in financial services. *Analytical Articles, Economic Bulletin*, (2).
 15. Svoboda, A. (2023). The impact of artificial intelligence on the banking industry. *Journal of Banking and Finance Management*, 4(1).
 16. Partanen, J., Jajae, S. M., & Cavén, O. (2017). Business intelligence within the customer relationship management sphere. In *Real-time strategy and business intelligence*. Palgrave Macmillan.
 17. Demirel, S., & Topcu, M. (2024). The impact of artificial intelligence applications on digital banking in the Turkish banking industry. *International Journal of Information Technology and Decision Making* <https://doi.org/10.1155/2024/9921363>
 18. Tian, X. (2024). The role of artificial intelligence in the digital transformation of commercial banks: Enhancing efficiency, customer experience, and risk management. *SHS Web of Conferences*, 208, Article 03005. <https://doi.org/10.1051/shsconf/202420803005>
 4. Ni'ma, Nagham Hussein, Shahda, Nour Salama, Fuad, Iman Mustafa. (2025). Istikhdam tatbiqat al-dhaka al-istina'i fi tahqiq ahdaf al-tanmiyya al-mustadama: Al-furas wa al-tahaddiyat. *International Journal of Historical and Social Studies*, (41).
 5. Nader, Boudraa, Abdelali, Boudraa. (2023). Tatbiqat al-dhaka al-istina'i wa ta'thiruha 'ala tajribat al-'umala' wa al-khadamat al-bankiyya. Master's thesis, Faculty of Economic Sciences and Management Sciences, University of Martyr Sheikh Larbi Tebessi, Monetary and Banking Economics.
 6. Eltimur, D. Y. (2022). Artificial intelligence applications in the context of the protection of human rights. *Journal of Akdeniz University Faculty of Law*, 12(2).
 7. Mohammed, Basina Mamdouh. (2025). Al-amn al-saybrani wa al-dhaka al-istina'i wa dawruhuma fi himayat nuzum al-ma'lumat. 1st ed. Jordan: Al-Warraaq for Publishing and Distribution.
 8. As'ad, Abeer. (2020). Al-dhaka al-istina'i wa tatbiqatuhu fi hayatina al-yawmiyya. 1st ed. Amman, Jordan: Dar wa Maktabat Al-Kindi for Publishing and Distribution.
 9. Rakholia, R., Suárez-Cetrulo, A. L., Singh, M., & Carbajo, R. S. (2024). Advancing manufacturing through artificial intelligence: Current landscape, perspectives, best practices, challenges, and future direction. Ireland's Centre for Artificial Intelligence (CeADAR), School of Computer Science, University College Dublin.
 10. Morsi, Khawla, Mousawi, Hajar. (2023). Tatbiq al-tahawwul al-raqami ka-aliyya li-tahsin ada' al-bunuk: Dirasat halat bank muta'addid al-jinsiyyat. *Al-Manhal Economic Journal*, 6(1).
 11. Shalfouh, Abdulrahman Al-Harari Mohammed. (2024). Tahaddiyat al-tahawwul