Articles in Press



Predicting Financial Distress Using Artificial Neural Network Models for Industrial Shareholding Companies Listed on the Amman Stock Exchange

Lubna Natheer Oqdeh, Abdullah Salah Hardan

PII: 1400.2025

DOI: https://doi.org/10.35192/jjoas-h.1400.2025

Reference: JJOAS-H 1400.2025

To appear in: Jordan Journal of Applied Science-Humanities Science Series

Received Date: 30 Jun 2025

Revised Date: 27 Jul 2025

Accepted Date: 03 Aug 2025

Please cite this article as: Oqdeh, L. N.& Hardan, A. S. (in press). Predicting Financial Distress Using Artificial Neural Network Models for Industrial Shareholding Companies Listed on the Amman Stock Exchange. Jordan Journal of Applied Science – Humanities Series. https://doi.org/10.35192/jjoas-h.1400.2025

This is a PDF of an article that has undergone enhancements after acceptance, such as the addition of a cover page and metadata, and formatting for readability. This version will undergo additional copyediting, typesetting and review before it is published in its final form. As such, this version is no longer the Accepted Manuscript, but it is not yet the definitive Version of Record; we are providing this early version to give early visibility of the article.

Please also note that, during the production process, errors may be discovered which could affect the content, and all legal disclaimers that apply to the journal pertain.

Articles in Press

Articles in Press

Predicting Financial Distress Using Artificial Neural Network Models for Industrial Shareholding Companies Listed on the Amman Stock Exchange

التنبؤ بالتعثر المالي باستخدام نماذج الشبكات العصبية الاصطناعية للشركات المساهمة الصناعية المدرجة في بورصة عمان

Lubna Natheer Oqdeh[1*], Abdullah Salah Hardan [1]

[1]The World Islamic Sciences and Education University (WISE)

lubna_oqdeh@yahoo.com*

Abstract

This study aimed to examine financial distress, a problem that affects many companies and threatens their continuity and survival. Over the past decades, researchers have developed several quantitative and statistical models to predict financial distress. More recently, developments in artificial intelligence have provided more accurate, flexible, and efficient prediction models. This study aimed to examine the ability of artificial neural network (ANN) models to predict financial distress. To achieve this objective, financial data were collected, and 25 financial ratios were calculated to reflect different aspects of financial performance. These ratios represented the independent variables, while the financial status of the company represented the dependent variable. The study population consisted of 48 industrial companies listed on the Amman Stock Exchange over ten years (2014–2023). The final sample included 25 industrial companies, providing a total of 250 observations. Several statistical analyses were conducted, including descriptive statistics, correlation analysis, and multicollinearity testing. Principal Component Analysis (PCA) was also used to reduce dimensionality. Two artificial neural network models were developed to predict financial distress: Multilayer Perceptron (MLP) and Long Short-Term Memory (LSTM). The performance of both models was evaluated using standard evaluation metrics. The findings demonstrated that both models were effective in predicting financial distress, with the LSTM model showing better performance. The MLP model achieved 94%, 100%, 93.3%, and 96.6% for accuracy, precision, recall, and F1 score, respectively. The LSTM model achieved higher results of 97.5%, 100%, 97.2%, and 98.6% for the same metrics, respectively. The study recommends conducting further research using other artificial intelligence models to predict financial distress in different sectors, improve understanding of this phenomenon, and provide comparable evidence across different contexts.

Keywords: Financial Distress, Artificial Neural Network, Multilayer Perceptron (MLP), Long Short-Term Memory (LSTM).

الملخص

هدفت هذه الدراسة إلى تحليل ظاهرة التعثر المالي التي تواجهها العديد من الشركات، وتهدد استمراريتها وبقائها. حيث قدم الباحثون في العقود الماضية العديد من النماذج الكمية والإحصائية للتنبؤ بالتعثر المالي. ومع ظهور الذكاء الاصطناعي مؤخرا حدثت تطورات وتحسينات سريعة، ووفرت نماذج أكثر دقة ومرونة وكفاءة في التنبؤ. هدفت هذه الدراسة لاختبار قدرة نماذج الشبكات العصبية الاصطناعية في التنبؤ بالتعثر المالي. ومن أجل

Articles in Press

تحقيق أهداف الدراسة، تم جمع البيانات المالية للشركات واحتساب ٢٥ نسبة مالية تعكس أبعادًا مختلفة من الأداء المالي. تعتبر هذه النسب المتغيرات المستقلة للدراسة، في حين تعتبر الحالة المالية للشركة المتغير التابع. تكون مجتمع الدراسة من ٤٨ شركة صناعية مدرجة في بورصة عمان خلال ١٠ سنوات في الفترة ٢٠١٤-٢٠٢٣. في حين بلغت عينة الدراسة ٢٥ شركة صناعية، مما وفر للدراسة إجمالي مشاهدات وصل إلى ٢٥٠ مشاهدة. تم تطبيق مجموعة من التحليلات الإحصائية، شملت الإحصاءات الوصفية، وتحليل الارتباط، واختبار التعددية الخطية. كما تم استخدام تحليل المكونات الرئيسية (PCA) بهدف تقليل الأبعاد. وقامت الدراسة بتطوير نوعين من الشبكات العصبية الاصطناعية من أجل التنبؤ بالتعثر المالي، وهما: الشبكات العصبية متعددة الطبقات (MLP)والشبكات العصبية طويلة-قصيرة الذاكرة(LSTM) . وتم تقييم أداء النموذجين باستخدام مقاييس معيارية. أظهرت النتائج فعالية النموذجين في التنبؤ بالتعثر المالي، مع تفوق ملحوظ لنموذج LSTM. فقد حقق نموذج MLP ٩٤٪، ١٠٠٪، ٩٣,٣%، و٩٦,٦٪ لمقاييس الدقة، الدقة الإيجابية، الاستدعاء، ومعامل F1 على التوالي، في حين تفوق نموذج LSTM في التنبؤ وحقق ٩٧,٥٪، ١٠٠٪، ٩٧,٢٪، و٩٨,٦% لنفس المقاييس. توصي الدراسة بإجراء المزيد من الأبحاث المستقبلية واستخدام نماذج أخرى من الذكاء الاصطناعي للتنبؤ بالتعثر المالي في قطاعات أخرى، لتعزيز فهم الظاهرة وتوفير أدلة قابلة للمقارنة.

الكلمات المفتاحية: التعثر المالي، الشبكات العصبية الاصطناعية، الشبكات العصبية متعددة الطبقات MLP، الشبكات العصبية طويلة-قصيرة الذاكرة LSTM.

المقدمة

الإطار النظري والدراسات السابقة

شهد العالم خلال العقود الأخيرة العديد من الأزمات والانتكاسات المالية التي أدت إلى انهيار عدد من كبرى الشركات والمؤسسات المالية العالمية، وكان من أبرزها إفلاس شركة إنرون عام ٢٠٠١، والذي ترافق مع انهيار شركة التدقيق "آرثر أندرسون" التي كانت تُعد من كبرى شركات التدقيق في العالم (Bratton, 2003؛ Collins, 2006). ولم تقتصر آثار هذه الانهيارات على الجوانب الاقتصادية المحلية، بل امتدت لتشمل الاقتصاد العالمي ككل في ظل العولمة والانفتاح الاقتصادي(Mulford & Comiskey, 2002) . أثارت هذه الأحداث الشكوك لدى مستخدمي القوائم المالية من مستثمرين ومقرضين وموردين وموظفين، حيث فقدوا الثقة بالمعلومات المحاسبية كمصدر لاتخاذ قراراتهم الاستثمارية، بعدما تبين أن هذه القوائم لم تكن قادرة على توفير إنذارات مبكرة قادرة على التنبؤ بتعثر الشركات (مرابط، ٢٠٢١). وفي هذا السياق، ظهرت نماذج التنبؤ بالتعثر المالي كحل استباقي يساعد الشركات والمستثمرين على فهم الواقع المالي وتفسير المؤشرات التي قد تؤدي إلى التعثر المالي. وقد أثبتت النماذج الكمية التقليدية، التي تعتمد على تحليل مجموعة من النسب والمؤشرات المالية، فعاليتها في هذا المجال، إلا أن نتائجها تفاوتت باختلاف حجم الشركات وبيئتها الاقتصادية، بالإضافة لمحدوديتها في التعامل مع العلاقات غير الخطية بين البيانات (Kou et al., 2021). ومع الثورة الرقمية والتحول التكنولوجي السريع في عالم الأعمال، وما رافقه من ظهور مفاهيم جديدة مثل المحاسبة السحابية، وأتمتة الأنظمة، والذكاء الاصطناعي، أصبحت هذه التقنيات جزءًا لا يتجزأ من بيئة الشركات الحديثة، ومن الضروري توظيفها في تحليل البيانات والتنبؤ بالأداء المالي (رشوان، ٢٠١٨). وقد أظهرت الدراسات الحديثة أن اعتماد تقنيات ونماذج الذكاء الاصطناعي في التنبؤ المالي قد ساهم بشكل ملموس في تحسين دقة التنبؤ واكتشاف التعثر في مراحله المبكرة، مما يتيح المجال لاتخاذ إجراءات وقائية وإعادة هيكلة استباقية(Smiti & Soui, 2020) .

وفيما يتعلق بالدراسات التي تمت على الشركات في السوق الأردني في مجال التنبؤ بالتعثر المالي، فقد ارتكزت غالبيتها على استخدام النماذج الكمية مثل دراسة (Al khatib & Al Bzour, 2011) والتي هدفت إلى تطبيق نموذجي ألتمان وكايدا على الشركات المساهمة في بورصة عمان خلال الفترة (١٩٩٠-٢٠٠٦). كما قامت دراسة (Al-Manaseer & Al-Oshaibat,2018) بتطبيق نموذج ألتمان وتحديد قدرته وصلاحيته في التنبؤ بالتعثر المالي لشركات التأمين المدرجة في بورصة عمان خلال الفترة ٢٠١١-٢٠١٦. أما دراسة (Al Omari et al., 2023) فقد ركزت على استخدام الشبكات العصبية الاصطناعية في تصنيف الأداء المالي والمعبر عنه بنسبة معدل دوران الأصول لشركات التأمين في الأردن خلال الفترة ٢٠٠٨-٢٠٢٠.

وبناء على ما تقدم، تكمن مشكلة هذه الدراسة في تحديد وتحليل قدرة عدد من أنظمة الذكاء الاصطناعي والمتمثلة بالشبكات العصبية الاصطناعية متعددة الطبقات (Multi-Layer Perceptron MLP)، والشبكات العصبية طويلة-قصيرة الذاكرة (Long-Short Term Memory)، في التنبؤ بالتعثر المالي للشركات المساهمة الصناعية المدرجة في بورصة عمان. وقد طبقت الدراسة على القطاع الصناعي الأردني لأهميته على مستوى

الاقتصاد الوطني من حيث الحجم والمساهمة في الناتج المحلي الإجمالي والقيمة السوقية وتنوع القطاعات الفرعية فيه؛ فقد بلغ مجموع الشركات المساهمة الصناعية المدرجة في بورصة عمان ٤٨ شركة حسب تقارير موقع هيئة الأوراق المالية بتاريخ أبريل ٢٠٢٥ (هيئة الأوراق المالية، ٢٠٢٥)، حيث بلغ حجم مساهمة هذا القطاع في الناتج المحلي الإجمالي ما نسبته ٤٤٪ (مساهمة مباشرة وغير مباشرة)، في حين بلغت القيمة السوقية للشركات الصناعية المدرجة ما يقارب ٥,٥ مليار دينار أردني أي ما يعادل ٣٢,٩٪ من إجمالي السوق، ويتفرع من قطاع الصناعة قطاعات فرعية متعددة تشمل الصناعات الاستخراجية والتعدينية والصناعات الكيماوية والصناعات الغذائية والصناعات الهندسية والإنشائية والصناعات الدوائية والصناعات الكهربائية وصناعة التبغ والسجائر وصناعة الورق والتغليف (بورصة عمان، ٢٠٢٥)

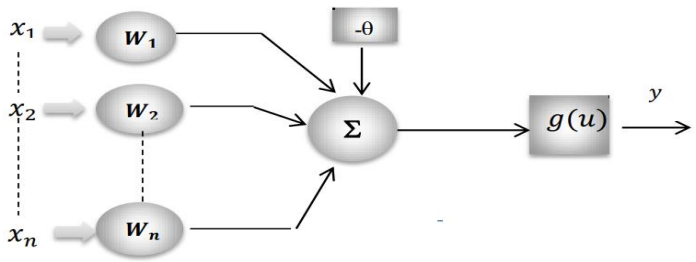
الإطار النظري

مفهوم الشبكات العصبية الاصطناعية:

تعتبر الشبكات العصبية الاصطناعية (Artificial Neural Networks) والتي يرمز لها عادة بالرمز (ANN) من أهم نماذج الذكاء الاصطناعي وأكثرها استخداما في عمليات التنبؤ بالبيانات المستقبلية، وتستمد فكرتها من محاكاة العقل البشري باستخدام الحاسوب، وهي مستوحاة من الشبكات العصبية البيولوجية البشرية التي تقوم على الفهم والتذكر والتعلم، وبالتالي القدرة على التصنيف والتنبؤ (Nguyen et al, 2023). وفي عملية التنبؤ تقوم الشبكات العصبية الاصطناعية على تقدير القيم المستقبلية بالاعتماد على العديد من البيانات السابقة التي تمت ملاحظتها (Paule-Vainez, 2020). يعود اكتشاف الشبكات العصبية الاصطناعية إلى عام ١٩٤٣ عن طريق العالم McCulloch and Pitts، حيث كان أول من قدم نموذج رياضي للخلايا العصبية المشابه للدماغ البشري (Ertel, 2017). وتعرف الشبكات العصبية الاصطناعية على أنها مجموعة من العقد المترابطة أو ما يعرف بالخلايا العصبية أو العصبون، بحيث تشكل معا نظاما لمعالجة البيانات يكون مشابها لطريقة عمل الشبكات العصبية الطبيعية البيولوجية للبشر (الجبيلي، ٢٠٢٣؛ Zizi et al., 2021).

مكونات الشبكة العصبية الاصطناعية

تتكون الشبكات العصبية الاصطناعية من ثلاث مكونات أساسية وهي: العقد العصبونية، الأوزان، والطبقات. تعد العقد العصبونية الخلايا العصبية الرقمية التي تترابط معا لتشكل شبكة عصبية اصطناعية، في حين كل عقدة لها سمة فريدة تعرف باسم الوزن، ويمكن مقارنة الوزن في الشبكات العصبية الاصطناعية بمعامل بيتا في نماذج الانحدار (Nguyen et al., 2024). وتتكون الشبكات العصبية من ثلاث طبقات رئيسية وهي: طبقة المدخلات والتي تتولى استقبال البيانات الخارجية وتغذيتها إلى الشبكة، حيث تُمرر إلى الطبقات التالية عبر الأوزان. طبقة المخرجات: والتي تكون مسؤولة عن تحديد قيمة المخرجات النهائية للشبكة العصبية الاصطناعية. طبقات خفية: تعمل على توصيل البيانات عبر طبقة الإدخال، ثم معالجتها في الطبقات الخفية من خلال حساب الأوزان المرجحة للمدخلات، وتطبيق دالة تنشيط لتحديد مخرجات كل عصبون. ويتم مقارنة هذه المخرجات بالقيم المستهدفة، وتكرر العملية في حال وجود فرق وتُعدّل الأوزان لتقليل الخطأ فيما يعرف بعملية تدريب الشبكة. يمكن للنموذج استخدام طبقة واحدة أو عدة طبقات خفية تبعًا لتعقيد المسألة المدروسة (الجبيلي، ٢٠٢٣؛ Lombardo et al., 2022). يظهر في الشكل (١) نموذج مبسط للخلية العصبية الاصطناعية ومكوناتها.



شكل (١): مكونات الخلية العصبية الاصطناعية

المصدر: (Aydin et al., 2022 ؛Wu et al., 2022)

Articles in Press

خصائص الشبكات العصبية الاصطناعية:

تتميز الشبكات العصبية الاصطناعية عن غيرها من نماذج الذكاء الاصطناعي في قدرتها العالية على التنبؤ خاصة في البيانات غير خطية واللامعلميه (غير معيارية)، حيث لديها القدرة على تمثيل وتحديد هذه العلاقات (Dogan et al, 2022). كما أنها لا تحتاج الى الكثير من الافتراضات حول البيانات حيث تعتبر مرنة بالتعامل معها، ولديها القدرة العالية على التعامل مع المشكلات الصعبة والمعقدة (Alamsyah & Kristanti, 2021؛ Shahwan & Fadel, 2020). وتمتاز بسهولة إجراءات تطبيقها عند بناء الشبكة وتدريبها واختبارها والقدرة على توفير نتائج موثوقة وذات دقة عالية (Aydin et al., 2022). ولعل أهم ما يميز الشبكات العصبية قدرتها على التعلم اعتمادا على البيانات المدخلة، وقدرتها على التكيف الذاتي بما يتماشى مع المعلومات الجديدة (صالح وآخرون، ٢٠٢٣). وفي هذا السياق ركز عدد من الباحثين على تطبيق نماذج الشبكات العصبية الاصطناعية إضافة إلى النماذج الإحصائية التقليدية مثل نموذج الانحدار اللوجستي، والتحليل التمييزي المتعدد في دراساتهم وللبيانات المالية والفترة الزمنية ذاتها، واختبار قدرتهم على التصنيف وتحديد الأفضل بينهم، ومن هذه الدراسات دراسة (Gregova et al, 2020؛ Shahwan & Fadel, 2020؛ Mishra et al., 2021؛ وهدان وآخرون، ٢٠٢٥)، حيث وجدت تفوق الشبكات العصبية على باقي النماذج في القدرة على التنبؤ بالتعثر المالي.

١,١,٤أنواع الشبكات العصبية الاصطناعية:

يوجد عدة أنواع من الشبكات العصبية الاصطناعية تبعا لطريقة بنائها من حيث ترتيب الخلايا العصبية وطريقه ترابطها وعدد الطبقات فيها (Roba & Moulay, 2024؛ الجبيلي، ٢٠٢٣)، وفيما يلي أنواع الشبكات العصبية التي تم استخدامها في الدراسة:

الشبكات العصبية متعددة الطبقات (Multilayer Perceptron)

يعتبر نموذج الشبكات العصبية متعدد الطبقات (Multilayer Perceptron - MLP) نوع خاص من الشبكات العصبية متعددة الطبقات ذات التغذية الأمامية، ترتبط كل خلية عصبية في طبقة معينة بجميع الخلايا في الطبقة التالية عبر شبكة كثيفة(Fully Connected) ، ويستخدم النموذج دوال تنشيط غير خطية مثل دالة "ReLU"أو "Sigmoid" لمعالجة العلاقات غير الخطية بين البيانات، كما يتم تدريب النموذج باستخدام خوارزمية الانتشار العكسي(Backpropagation) لتقليل الخطأ في التنبؤ. يتميز نموذج MLP بقدرته على تمثيل ومعالجة العلاقات المعقدة في البيانات وهذا يجعله مناسب في عملية التنبؤ بالتعثر المالي، كما يستخدم في تصنيف الصور، وتحليل النصوص(Goodfellow et al., 2016) . في حين لا يمتلك هذا النوع من الشبكات ذاكرة وليس له القدرة على تذكر معلومات سابقة، أي أنه يعالج البيانات الثابتة غير المتسلسلة.

الشبكات العصبية طويلة قصيرة الذاكرة (Long-Term Short-Term Neural Network-LSTM)

تعتبر LSTM نوعا خاصا من الشبكات العصبية المتكررة، والتي تم تطويرها لتحسين ومعالجة مشكلة اختفاء التدرجات، حيث تحتوي على خلايا ذاكرة متقدمة مع بنية من البوابات (بوابة الإدخال، بوابة النسيان، وبوابة الإخراج) التي تتحكم في تدفق المعلومات داخل الشبكة(Hochreiter & Schmidhuber, 1997) . تقوم هذه البوابات بالحفاظ على المعلومات المهمة لفترات زمنية طويلة والتخلص من المعلومات غير الضرورية، مما يجعلها فعالة في التعامل مع السلاسل الزمنية ومعالجة اللغات الطبيعية، والتعرف على الصوت (Greff et al., 2017). ويعتبر هذا النوع من الشبكات العصبية فعالا في عمليات التنبؤ بشكل عام، ومنها التنبؤ بالتعثر المالي والتي تعتمد على دراسة دقيقه للبيانات التاريخية واتجاهها والنمط الذي تتخذه عبر سنوات مالية طويلة مما يسهم في زيادة دقة التنبؤ (Ling & Cai, 2022).

التنبؤ بالتعثر المالي

عرف الباحثون التنبؤ بالتعثر المالي على أنه مجموعة من التقديرات والقياسات المتعلقة بالأحداث المستقبلية، والتي تم إعدادها بناء على أسس علمية وطرق رياضية وإحصائية، بالاعتماد على بيانات مالية تاريخية من أجل التنبؤ بمعلومات مستقبلية، لمواجهة الظواهر والأحداث والنتائج المالية المستقبلية (Altman, 1968؛ Kida,1980). ويقاس التنبؤ بالتعثر المالي باستخدام عدة نماذج وطرق منها النماذج الكمية والنماذج الإحصائية والرياضية ونماذج الذكاء الاصطناعي الحديثة، والتي تعتمد جميعها بشكل أساسي على المؤشرات والنسب المالية المستخرجة من القوائم المالية للشركات.

Articles in Press

مفهوم التعثر المالي

اختلف الباحثون في وضع مفهوم محدد لظاهرة التعثر المالي وفقا للعديد من المتغيرات والظروف المحيطة، فقد يشير التعثر المالي إلى حدوث أزمة حادة في السيولة تؤدي إلى عدم قدرة الشركة على الوفاء بالتزاماتها في مواعيدها المحددة، وقد يشير التعثر المالي إلى تكبد خسائر متتالية تسبب تصفية الشركة وتوقف نشاطها بشكل دائم، كما يعني عدم مقدرة الشركة على دفع توزيعات أرباح الأسهم (المغربي، ٢٠٢٢). يعد التعثر المالي أحد أهم المخاطر المالية التي تواجه الشركات خلال مسيرتها وعملها، حيث يشير إلى وجود وضع مقلق بسبب عدم قدرة الموارد المالية المتوفرة لدى الشركة على الوفاء بالالتزامات المختلفة، مما يعكس احتمالية عدم استمرارية نشاط الشركة (العامودي والحربي، ٢٠٢٤). وقد تعددت المفاهيم المشابهة لمصطلح التعثر المالي في الكثير من الأبحاث والدراسات حيث تم استخدام مصطلحات مرادفة المعنى له مثل: العسر والفشل والإفلاس في محاولة لوصف حالة الشركة المالية، وذلك بسبب اختلاف المعايير المالية والقانونية والاقتصادية من بلد لآخر إلا أن لكل منها مفهوم محدد ومختلف (Manh & Nguyen, 2024 ؛Abdelkader & Wahba, 2024).

مظاهر التعثر المالي

يعد التعثر المالي عملية تراكمية ناتجة عن سلسلة من الاضطرابات المالية والإدارية، وليست ظاهرة مفاجئة. صنّف الباحثون هذه المظاهر إلى مظاهر مالية مثل تذبذب النسب المالية، ارتفاع المديونية، تحقيق خسائر متراكمة، تراجع الربحية، انخفاض المبيعات وجودة الإنتاج، ضعف رأس المال العامل، تراجع السيولة، إضافة إلى تأجيل سداد الالتزامات وإعادة جدولتها (قريشي ،٢٠١٦). ومظاهر أخرى غير مالية مثل انخفاض الحصة السوقية، تسريح العمال، سوء الإدارة المالية، تضارب الآراء داخل الإدارة، وامتناع الموردين والممولين عن التعامل مع الشركة.

أسباب التعثر المالي

يحدث التعثر المالي نتيجة لتراكم مشكلات وأسباب داخلية وخارجية تؤثر على استقرار الشركات. ويعتبر تحديد هذه الأسباب مبكرًا عاملا مهما وأساسيا في تدارك خطر الإفلاس من خلال تبني سياسات علاجية فعالة وفي الوقت المناسب (الزبيدي، ٢٠٠٠). تعود هذه الأسباب إلى أسباب داخلية مثل ضعف كفاءة الإدارة وعدم قدرتها على تحقيق الأهداف الاستراتيجية، وسوء السياسات التسويقية والإنتاجية، وضعف تحصيل الذمم المدينة، والهدر في الموارد وضعف الرقابة، وانخفاض المبيعات نتيجة سوء التسويق، وارتفاع النفقات التشغيلية بشكل غير متوازن مع الإيرادات، كما يلعب الفساد الإداري، مثل الاختلاس والتلاعب بالبيانات دورا أساسيا في حدوث حالة التعثر المالي للشركات. أما الأسباب الخارجية فتشمل الظروف الاقتصادية والسياسية غير المستقرة، وتذبذب الأسواق، والتضخم العالمي، والكوارث الطبيعية، والأزمات الصحية والمالية (مثل كورونا ٢٠٠٨)، إضافة إلى تغيير التشريعات والقوانين، وارتفاع أسعار الصرف وتأثيرها على تكلفة الإنتاج (وهدان وآخرون، ٢٠٢٥؛ ElSayed et al., 2023؛ Vochozka et al., 2020).

معايير تحديد حالة التعثر المالي للشركات في الدراسة

يعتبر التعثر المالي للشركات المتغير التابع للدراسة وهو متغير ذو طبيعة نوعية، وقسمت الشركات في العينة إلى مجموعتين: مجموعة الشركات المتعثرة (٠)، ومجموعة الشركات غير المتعثرة (١). واستنادا للدراسات السابقة التي تناولت مفهوم التعثر المالي وتحديد الحالة المالية الفعلية للشركات وتصنيفها الى شركات متعثرة وأخرى غير متعثرة مثل (بالله وبن مسعود، ٢٠٢١؛ Aydin et al., 2022؛ زهواني، ٢٠٢٢؛ الجبيلي، ٢٠٢٣؛ Al Abbasi & Mohammad, 2024؛ وهدان وآخرون، ٢٠٢٥)، حيث اعتمدت هذه الدراسات في عملية التصنيف على معايير متعددة من أهمها: حدوث عملية إعادة هيكلة للشركة، خروج الشركة من السوق المالي، توقف نشاط الشركة بشكل نهائي وتصفية أعمالها، انخفاض أكثر من ثلثي رأس المال الخاص بالشركة، انخفاض ١٠٪ من مجموع أصولها، أو تحقيق خسارة لمدة عامين متتالين، حيث أن تحقق معيار واحد من هذه المعايير كان كافيا لتصنيف الشركة ضمن الشركات المتعثرة. في حين أن الدراسة الحالية كانت أكثر تحفظا واعتمدت في تصنيف الشركات على تحقيق معيارين على الأقل من ثلاث معايير أساسية وهي: تحقيق الشركة لخسارة لمدة عامين متتالين، انخفاض أكثر من ثلثي رأس المال الخاص بالشركة، وانخفاض ١٠٪ من مجموع أصولها، أي في حالة تحقيق الشركة معيارين من هذه المعايير يتم تصنيفها ضمن الشركات المتعثرة.

Articles in Press

طرق التنبؤ بالتعثر المالي

قام الباحثون بتطوير واستخدام العديد من طرق التقدير للتنبؤ بالتعثر المالي منها طرق رياضية ومنها إحصائية، وقاموا حديثا بتطوير طرق تعتمد على الذكاء الاصطناعي .ومن الطرق الرياضية الشائعة تلك التي اعتمد عليها الباحث Beaver عام ١٩٦٦، حيث استخدم مجموعة من المؤشرات والنسب المالية المحسوبة من البيانات المالية للشركات وعددها ٣٠ نسبة مقسمة على ست مجموعات عند التحليل والتنبؤ بالتعثر المالي، كما استخدم تحليل أحادي المتغيراتUnivariant analysis ، في حين تم انتقاد هذه الطريقة من حيث صعوبة التنبؤ بالتعثر المالي بناء على متغير واحد أو نسبة مالية واحدة من كل مجموعة(Dogan et al., 2022) . أما الطرق الإحصائية الأخرى فقد كانت تعتمد بشكل أساسي على اختبار التحليل التمييزي المتعدد، والانحدار اللوجستي، والانحدار المتعدد التي تم تطويرها من خلال الباحثين في هذا المجال. حيث يسمح التحليل التمييزي المتعدد للمتغيرات بالاختلاف عن المجموعات المعرّفة ويساعد في تحديد قواعد التصنيف، عن طريق تصميم دالة تمييزية من المتغيرات التمييزية المختلفة، وهذا التحليل يعتبر أساس النماذج الكمية التي طورها الباحثان ألتمان وسبرينجيت (الجبيلي، ٢٠٢٣؛ Khalil et al., 2022). حيث طور العلماء باستخدام الطرق الإحصائية نماذج كمية تعتمد على المتغيرات المستقلة التي وجدوا أنها الأكثر قدرة على التنبؤ وربطوها بأوزان وعلاقات رياضية كما في نموذج بيفر وألتمان وكايدا وسبرينجيت وتافلر وغيرها العديد من النماذج. اشتهرت هذه النماذج بين الباحثين الذين قاموا بتطبيقها في دراساتهم في العديد من البيئات الاقتصادية، الا أن هذه النماذج عانت من محددات في استخدامها نتيجة الفرضيات الإحصائية بضرورة تحقيق شروط مثل العلاقة الخطية بين المتغيرات، والتوزيع الطبيعي للبيانات، ووجود المتغيرات المستقلة القادرة على التنبؤ وشكل العلاقة بين المتغيرات المستقلة والتابعة، والتي من الصعب ضمان توفرها في المشاكل التي تواجه الباحثين في الحياة الواقعية(Dogan et al., 2022) . ومن هنا دعت الحاجة في ظل عصر المعلومات والتحول الرقمي وظهور مفهوم الذكاء الاصطناعي وتطبيقاته الواسعة، نحو تبني طرق أكثر مرونة ودقة في عملية التنبؤ بالتعثر المالي، حيث أثبتت العديد من الدراسات قدرة هذه النماذج العالية في التنبؤ وتفوقها على الطرق التقليدية والاحصائية الأخرى كما أنها أقل حساسية اتجاه الفرضيات الإحصائية التي تم ذكرها سابقا مما يجعلها أكثر مرونة وقابلية للتطبيق (Abdullah, 2021؛ Marso & El Merouani, 2020).

النسب المالية المستخدمة للتنبؤ بالتعثر المالي

يعتبر التحليل المالي باستخدام النسب المالية الأكثر أهمية واستخداما بين المحللين حيث يقوم على التعبير عن العلاقات بين بنود القوائم المالية عن طريق إيجاد علاقات حسابية بين أي بند وبند أخر للحصول على دلالات ذات معنى (الخلايلة، ٢٠١٣، ٤٣؛ الزبيدي، ٢٠٠٠، ٦٣). تختلف النسب المالية وطريقة احتسابها وفقا للغرض منها، فكل مجموعة من النسب تستطيع قياس جانب معين من الأداء المالي مثل نسب المديونية، والربحية، والسيولة، ونسب النشاط (معدل الدوران)، ونسب ومؤشرات الأسواق المالية (Manh & Nguyen, 2024؛ Judijanto & Riandari, 2024؛ Khawaja, 2023). يضم جدول (١) أهم النسب المالية المستخدمة في الدراسة والمجموعة التي تنتمي إليها كل نسبة مع طرق قياسها:

جدول (١): ملخص النسب المالية المستخدمة في الدراسة

رمز النسبة المالية	النسبة المالية	طريقة احتسابها
X١	الديون الى حقوق الملكية	مجموع الديون/ مجموع حقوق الملكية
X٢	مجموع الديون الى مجموع الأصول	مجموع الديون/ مجموع الأصول
X٣	حقوق الملكية الى الأصول الثابتة	حقوق الملكية/ الأصول الثابتة
X٤	معدل تغطية الفوائد	صافي الدخل قبل الفوائد والضرائب/ مصروف الفوائد
X٥	هامش الربح الإجمالي	الربح الإجمالي (المبيعات - تكلفة البضاعة المباعة) /صافي المبيعات
X٦	هامش الربح التشغيلي	الربح التشغيلي/ صافي المبيعات
X٧	نسبة صافي الربح	صافي الربح/ صافي المبيعات
X٨	معدل العائد على الأصول	صافي الربح / مجموع الأصول

Articles in Press

X٩	معدل العائد على حقوق الملكية	صافي الربح / مجموع حقوق الملكية
X١٠	نسبة التداول	الأصول المتداولة/ الالتزامات المتداولة
X١١	نسبة السيولة السريعة	(النقدية+ الذمم المدينة+ الاستثمارات قصيره الأجل) / الالتزامات المتداولة
X١٢	نسبة السيولة الفورية (الجاهزة)	النقدية + الاستثمارات قصيره الأجل / الالتزامات المتداولة
X١٣	نسبة رأس المال العامل إلى المبيعات	صافي رأس المال العامل / المبيعات
X١٤	معدل دوران الأصول	صافي المبيعات / مجموع الأصول
X١٥	معدل دوران الأصول الثابتة	صافي المبيعات / الأصول الثابتة
X١٦	معدل دوران الأصول المتداولة	صافي المبيعات/ الأصول المتداولة
X١٧	معدل دوران رأس المال العامل	صافي المبيعات / رأس المال العامل
X١٨	معدل دوران البضاعة (المخزون)	تكلفة البضاعة المباعة / المخزون
X١٩	معدل دوران الذمم المدينة	صافي المبيعات / الذمم المدينة
X٢٠	معدل دوران الذمم الدائنة	تكلفة البضاعة المباعة / (الذمم الدائنة + أوراق الدفع)
X٢١	العائد على السهم العادي	الربح بعد الضريبة المتاح لحملة الأسهم العادية /عدد الأسهم العادية
X٢٢	سعر السهم إلى عائده	القيمة السوقية للسهم/العائد على السهم
X٢٣	الأرباح الموزعة للسهم إلى عائده	الأرباح الموزعة نقدا للسهم / العائد على السهم
X٢٤	نسبة عائد التوزيع	حصة السهم من الأرباح الموزعة / سعر السهم السوق
X٢٥	نسبة القيمة السوقية للقيمة الدفترية	سعر السهم في السوق / القيمة الدفترية للسهم

الدراسات السابقة

تناولت العديد من الدراسات موضوع التنبؤ بالتعثر المالي في الشركات باستخدام العديد من الطرق الكمية والإحصائية، وباستخدام نماذج الذكاء الاصطناعي حديثا. فقد ركزت دراسة (Nguyen et al., 2024) على استخدام الشبكات العصبية الاصطناعية للتنبؤ بالتعثر المالي للشركات المدرجة في بورصة فيتنام، بالاعتماد على ١٣ مؤشرًا ماليًا تتعلق بالربحية، الملاءة، التشغيل، السوق، وهيكل رأس المال. وقد تم قياس التعثر المالي من خلال انخفاض الأرباح قبل الفوائد والضرائب عن نفقات الفائدة لمدة عامين متتاليين، باستخدام بيانات ٥٠٩ شركة (٦٦١٧ مشاهدة) خلال الفترة ٢٠٠٧–٢٠١٩. أظهرت نتائج الدراسة دقة تصنيف بلغت ٩٣,٩٪، مع تفوق قطاع الصناعة بنسبة ٩٤,٧٪، يليه قطاع الخدمات (٩٤,٢٪)، ثم قطاع التجارة (٩٠,٦٪). كما هدفت دراسة (Aydin et al., 2022) إلى تصنيف حالات الفشل المالي للشركات في بورصة إسطنبول من خلال نماذج الشبكات العصبية الاصطناعية وشجرة اتخاذ القرار واعتمدت الدراسة على ٢٥ نسبة مالية ومتغيرين غير ماليين كمتغيرات مستقلة، في حين مثلت الحالة المالية (متعثر/غير متعثر) المتغير التابع. شملت العينة ٢٤٠ شركة خلال الفترة ٢٠١٥–٢٠١٧. وحقق نموذج الشبكات العصبية دقة بلغت ٩٣,١٪ في قطاع الصناعة، ٩٤,٤٤٪ في التجارة، و٨٩,٤٧٪ في الخدمات، متفوقًا في بعض القطاعات على نموذج شجرة القرار الذي سجل دقة ٨٤,٠٣٪، ٨٧,٩٣٪، و٩٥,٢٤٪ على التوالي. وقدمت دراسة (Elhoseny et al., 2022) نموذجًا مبتكرًا للتنبؤ بالتعثر المالي باستخدام خوارزمية الحوت التكيفية (AWOA) مدمجة مع تقنية التعلم العميق، وشملت الدراسة أربع قواعد بيانات من شركات أسترالية (٦٩٠ شركة)، بولندية (١٠,٥٠٣ شركة)، تايوانية (٦,٨١٩ شركة)، إضافة إلى عينة عشوائية من (٥٠) شركة متعددة الجنسيات. أظهرت النتائج تفوق نموذج المقترح بتحقيق دقة تنبؤية بلغت ٩٥,٨٪ مقارنة بنماذج أخرى تراوحت دقتها بين ٧٨,٢٪ و٩٣,٨٪. وقامت دراسة (Wu et al., 2022) على بناء نموذجًا هجينًا للتنبؤ بالتعثر المالي يجمع بين نموذج Altman Z-Score التقليدي والشبكات العصبية الاصطناعية متعددة الطبقات(MLP) ، حيث استندت الدراسة إلى بيانات مالية مكونة من ١٧,٢٠٦ مشاهدة من شركات صينية خلال الفترة ٢٠١٦–٢٠٢٠، باستخدام خمس نسب مالية مشتقة من نموذج ألتمان كمتغيرات مستقلة، وقد أظهرت النتائج أن النموذج الهجين حقق أعلى دقة تصنيف بلغت ٩٩,٤٠٪، متفوقًا على نموذج ألتمان (٨٦,٥٤٪) والنموذج العصبي المنفرد (٩٨,٢٦٪)، مما يؤكد فعالية الدمج بين الأساليب التقليدية والذكية في تحسين دقة التنبؤ بالتعثر المالي. وهدفت دراسة(Abdullah, 2021) إلى تقييم فعالية عدد من نماذج التعلم الآلي في التنبؤ

بالتعثر المالي، شملت خمسة نماذج هي: الشبكات العصبية الاصطناعية، آلة دعم المتجهات، Naive Bayes، الجار الأقرب(KNN) ، ومصنف التجميع(Ensemble Classifier) . عملت الدراسة على تحليل بيانات ٢٤٤ شركة مدرجة في بورصة دكا خلال الفترة ٢٠١٥–٢٠١٩، معتمدة على خمس نسب مالية وستة متغيرات أخرى كمتغيرات مستقلة، حيث أكدت النتائج أن نموذج الشبكات العصبية قد حقق أعلى دقة خلال مرحلتي التدريب والاختبار (٩٤٪ و٨٢٪ على التوالي)، يليه نموذج الجار الأقرب (٨٢٪ و٨٥٪)، ثم نموذج التجميع (٨٩٪ و٨٦٪). كما طورت دراسة (Dube et al., 2021) نموذج باستخدام الشبكات العصبية الاصطناعية لتصنيف شركات الخدمات المالية والصناعية المدرجة في بورصة جوهانسبرغ خلال الفترة ٢٠٠٠–٢٠١٩. اعتمدت الدراسة على ٢٧ نسبة مالية و٧ متغيرات اقتصادية كلية. شملت العينة ٥٤ شركة خدمات مالية و٣٧ شركة صناعية. أظهر النموذج دقة تصنيف بلغت ٨١,٠٣٪ لقطاع الخدمات المالية و٩٦,٦٪ للصناعة، مع قدرته على التنبؤ بحالات التعثر قبل خمس سنوات من وقوعها. في حين سعت دراسة (Malakauskas & Lakstutiene, 2021) إلى تطبيق وتقييم فعالية ثلاثة نماذج في التنبؤ بالتعثر المالي: الانحدار اللوجستي، الشبكات العصبية الاصطناعية، وخوارزمية الغابة العشوائية. اعتمدت الدراسة على ٢٣ متغيرًا ماليًا يغطي سنتين متتاليتين (٢٠١٩–٢٠٢٠)، مع تضمين عوامل إضافية مثل العمر والتاريخ الائتماني في النموذج متعدد الفترات. شملت العينة ١٢,٠٠٠ شركة صغيرة ومتوسطة من ليتوانيا، إستونيا، ولاتفيا، وتم تصنيف الحالة المالية بناءً على التغير في درجة الائتمان بين سنتين، وأظهرت النتائج أن نموذج الغابة العشوائية حقق أعلى دقة تصنيف (٦٢,١١٪)، يليه الانحدار اللوجستي (٦١,٢٩٪)، ثم الشبكات العصبية (٥٥,٣٣٪). تم عرض تلخيص للدراسات السابقة في الجدول (١) ضمن الملحق.

وفي المقابل، وبناء على تحليل الدراسات السابقة تبين عدم وجود دراسة تجمع بين تطبيق النماذج الكمية التقليدية مثل نموذج ألتمان وكايدا وسبرينجيت، ونماذج الذكاء الاصطناعي للمقارنة بين نتائج المجموعتين بهدف تحديد النموذج الأمثل والأكثر دقة في التنبؤ بالتعثر المالي.

ما يميز هذه الدراسة عن الدراسات السابقة

تعتبر هذه الدراسة امتدادا للدراسات والأبحاث السابقة والتي قام بها الباحثون في هذا السياق، وقد استفادت منها بشكل مباشر وغير مباشر من خلال فهم مشكلة الدراسة وتحديد أبعادها، وشكلت الحجر الأساس في تكوين الإطار النظري للدراسة وفي فهم متغيراتها والعلاقة بينها وساعدت في تحديد المنهجية المتبعة فيها. في حين تختلف هذه الدراسة عن غيرها من الدراسات السابقة وتعتبر إضافة علمية مهمة من ناحية بيئة الدراسة حيث تعتبر هذه الدراسة الأولى من نوعها- بحدود علم الباحثين - التي تناولت موضوع التنبؤ بالتعثر المالي باستخدام نماذج الذكاء الاصطناعي في القطاع الصناعي للفترة المالية المختارة، لإعطاء دليل علمي من الأردن ومقارنتها بغيرها من الدراسات في البيئات المختلفة عربيا ودوليا. كما تتميز الدراسة من حيث المدة الزمنية التي تم اختيارها والتي تعتبر طويلة نسبيا مقارنة مع الأبحاث المماثلة لها في البيئات الأخرى، وذلك لتوفير أكبر قدر ممكن من المشاهدات والتي من شأنها زيادة الدقة في النتائج، حيث تغطي هذه الدراسة فترة ١٠ سنوات من ٢٠١٤-٢٠٢٣، في حين اقتصرت الدراسات السابقة على ٣ أو ٥ سنوات مثل (Abdullah, 2021؛ Horak et al, 2020).

مشكلة الدراسة وأسئلتها

تتعرض العديد من الشركات إلى خسائر مالية متكررة تؤدي إلى الإفلاس، نتيجة غياب أدوات إنذار مبكر قادرة على كشف موقفها المالي الحقيقي وتحذيرها في الوقت المناسب. وحديثا، برزت أهمية الأنظمة الذكية وتحديدا الشبكات العصبية الاصطناعية كأدوات تحليلية متقدمة قادرة على معالجة البيانات المالية واستخلاص الأنماط الكامنة وتوقع احتمالات التعثر بدقة أعلى من النماذج التقليدية (Elhoseny et al., 2022). تكمن مشكلة الدراسة في تحليل قدرة نماذج الذكاء الاصطناعي والمتمثلة بالشبكات العصبية الاصطناعية متعددة الطبقات (Multilayer Perceptron- MLP)، والشبكات العصبية طويلة قصيره الذاكرة (Long Short Term Memory-LSTM) في التنبؤ بالتعثر المالي للشركات المساهمة الصناعية المدرجة في بورصة عمان خلال الفترة ٢٠١٤–٢٠٢٣.

أسئلة الدراسة

وفي ضوء ما تقدم يمكن أن تتلخص مشكلة الدراسة بشكل دقيق من خلال الإجابة على الأسئلة التالية:

١. هل يمكن لنموذج الشبكات العصبية الاصطناعية متعددة الطبقات (MLP) التنبؤ بالتعثر المالي للشركات المساهمة الصناعية المدرجة في بورصة عمان خلال الفترة ٢٠١٤-٢٠٢٣؟

٢. هل يمكن لنموذج الشبكات العصبية الاصطناعية طويلة-قصيرة الذاكرة (LSTM) التنبؤ بالتعثر المالي للشركات المساهمة الصناعية المدرجة في بورصة عمان خلال الفترة ٢٠١٤-٢٠٢٣؟

أهمية الدراسة

تنبع أهمية الدراسة من أهمية وخصوصية المواضيع قيد البحث، حيث يعتبر التنبؤ بالتعثر المالي من المواضيع الهامة والتي تشغل اهتمام الأطراف المتعلقة بالمنشآت الاقتصادية كافة، لأن استقرار الشركات ونموها المستمر من شأنه أن يضمن لهم مصالحهم واستثماراتهم فيها. كما أن التنبؤ بالتعثر المالي يساعدهم في اتخاذ القرارات المالية بالشكل والوقت المناسبين.

١. **الأهمية العلمية:** يعتبر حقل الذكاء الاصطناعي وتطبيقاته في بيئة الأعمال من حقول العلم والمعرفة الحديثة وغير المشبعة، خاصة وأن مفهوم ونماذج الذكاء الاصطناعي آخذه بالتوسع والانتشار في العالم، كما لا تتوفر نتائج وأدلة علمية متفق عليها بين الباحثين، لذا تقدم الدراسة دليلا علميا مهما من واقع الاقتصاد الأردني قابلا للاستخدام والتطبيق في دراسات أخرى، ومن شأنه إثراء الأدب المعرفي في مجال الذكاء الاصطناعي وتطبيقاته، كما أن نتائج الدراسة قابلة للمقارنة مع غيرها من النتائج للأبحاث والدراسات العلمية في بيئات اقتصادية أخرى، ومن شأنها تزويد المكتبات العربية والأجنبية بنتائج علمية تسهم في مواصلة جهود الباحثين في هذا المجال العلمي الواسع.

٢. **الأهمية العملية:** تندرج هذه الدراسة ضمن الأبحاث التطبيقية، القابلة للتطبيق على أرض الواقع والاستفادة من نتائجها وتوصياتها للحد من حالات التعثر والإفلاس. تسهم هذه النتائج في تحديد قدرة نماذج الشبكات العصبية الاصطناعية في التنبؤ بالتعثر المالي مسبقا قبل وقوعه، مما يتيح الفرصة للشركات وإداراتها بتفادي هذا الخطر والعمل على تحسين الأداء وحل المشكلات مبكرا قبل تفاقمها والوصول لحالة التعثر المالي، الأمر الذي يساعد في خلق بيئة اقتصاديه مستقرة وآمنة للاستثمار، كما تحفظ حقوق ومصالح المستثمرين وأصحاب رؤوس الأموال والأطراف الأخرى.

حدود الدراسة

- **الحدود المكانية**: طبقت هذه الدراسة على جميع الشركات المساهمة الصناعية المدرجة في بورصة عمان خلال فترة الدراسة، والبالغ عددها ٤٨ شركة وفقا لمنشورات موقع مركز إيداع الأوراق المالية.
- **الحدود الزمانية:** مدة الدراسة ١٠ سنوات خلال الفترة ٢٠١٤-٢٠٢٣.
- **الحدود العلمية:** تتكون الدراسة من مجموعة من المتغيرات: المتغير التابع وهو التعثر المالي (الحالة المالية للشركة)، والمتغيرات المستقلة وهي النسب والمؤشرات المالية التي تعتبر مدخلات للشبكات العصبية الاصطناعية.

الطرق والإجراءات

منهجية الدراسة

تعد هذه الدراسة من الدراسات الوصفية التحليلية التي تهدف إلى وصف وتحليل متغيرات الدراسة، وفهم العلاقات القائمة بينها، وذلك في إطار السعي للإجابة على أسئلة الدراسة ومعالجة مشكلتها. وقد تم توظيف المنهج الوصفي الاستقرائي في عرض وشرح المفاهيم النظرية المتعلقة بظاهرة التعثر المالي والعوامل المرتبطة بها، من خلال استعراض الأدبيات والدراسات السابقة، كما تم اعتماد المنهج التحليلي التطبيقي لتحليل العلاقة بين المتغيرات المستقلة والمتغير التابع، وتحديد شكل وأثر هذه العلاقة.

مجتمع وعينة الدراسة

تكون مجتمع الدراسة من جميع الشركات المساهمة الصناعية المدرجة في بورصة عمان، والتي بلغ مجموعها ٤٨ شركة حسب تقارير موقع هيئة الأوراق المالية بتاريخ أبريل ٢٠٢٥ (هيئة الأوراق المالية، ٢٠٢٥). في حين تكونت العينة النهائية للدراسة من ٢٥ شركة فقط، حيث تم نقل ٢٠ شركة صناعية إلى سوق الأوراق غير المدرجة (OTC)، كما لم تتوفر معلومات مالية متتالية خلال فترة الدراسة لثلاث شركات.

Articles in Press

طرق جمع البيانات

اعتمدت الدراسة على المصادر الثانوية للبيانات المالية التاريخية، والتي تم الحصول عليها من التقارير المالية السنوية للشركات والمدرجة في قواعد البيانات المالية المعتمدة مثل مركز إيداع الأوراق المالية وبورصة عمان، وتشمل البيانات المالية الظاهرة في القوائم المالية كقائمة الدخل والميزانية. كما تم الرجوع إلى قواعد البيانات الرقمية والمكتبات الإلكترونية والمتصفح Google Schoolar للحصول على الدراسات والمقالات السابقة والمنشورة في المجلات والكتب العلمية والدوريات والرسائل العلمية التي تناولت موضوع الدراسة ومتغيراته المتعددة.

الأساليب الإحصائية

استخدمت الدراسة مجموعة من الأساليب والاختبارات الإحصائية لفحص واختبار العلاقات بين متغيرات الدراسة، مثل اختبارات الإحصاء الوصفي، ومعامل الارتباط، والتوزيع الطبيعي لمتغيرات الدراسة، واختبار التعددية الخطية وتحليل المكونات الرئيسية، بالإضافة لمقاييس دقة التنبؤ المعيارية للنماذج مثل Accuracy, Precision, Recall, F1- Score. واستخدمت الدراسة برنامج Python الخاص بالذكاء الاصطناعي لبناء نماذج الشبكات العصبية، وهي لغة برمجة عالية المستوى مفتوحة المصدر تستخدم في الدراسات المالية نظرا لقدراتها المتقدمة في تحليل البيانات المالية وتطبيق خوارزميات التعلم الآلي للتنبؤ بالمخاطر والتعثر المالي (Alaka et al., 2018).

تصميم البحث

تم جمع البيانات المالية من القوائم المالية ومن ثم احتساب النسب والمؤشرات المالية للشركات في عينة الدراسة خلال الفترة ٢٠١٤-٢٠٢٣، والتي تعتبر مدخلات الشبكة العصبية الاصطناعية ومتغيرات الدراسة المستقلة، كما تم تحديد الحالة المالية للشركات قيد الدراسة وتصنيفها الى مجموعة الشركات المتعثرة (٠) ومجموعة الشركات غير المتعثرة (١) بالاعتماد على المعايير التي تم ذكرها سابقا. كما تم تطبيق الإجراءات التالية على مجموعة النسب المالية والتي تمثل المتغيرات المستقلة للدراسة لغايات تحضيرها لتصبح جاهزة لعملية بناء النماذج وهي مرحلة المعالجة المسبقة للبيانات على النحو التالي:

مرحلة المعالجة المسبقة للبيانات (Preprocessing)

تعد مرحلة المعالجة المسبقة للبيانات ضرورية ومهمة لضمان جودة وتناسق البيانات قبل تطبيق نماذج الذكاء الاصطناعي. تم تنفيذ عدة خطوات منهجية لمعالجة البيانات والتعامل مع القيم المفقودة، وتحسين تمثيل الخصائص، وتجهيز البيانات للنموذج.

معالجة القيم المفقودة (Handling Missing Values)

احتوت مجموعة البيانات على قيم مفقودة في خمسة مؤشرات مالية رئيسية وهي X٤، X١٨، X٢٠، X٢٢، X٢٣، ويعود السبب في وجود هذه القيم المفقودة لعدة أسباب منها وجود قيم صفرية. وللتعامل معها تم استخدام أسلوب الإكمال التنبؤي وهي تقنية تستخدم لمعالجة القيم المفقودة في البيانات من خلال التنبؤ بها باستخدام نماذج تعلم الآلة، بدلا من تعويضها بطرق بسيطة مثل المتوسط أو الوسيط، وقد تم تدريب نموذج من نماذج الذكاء الاصطناعي وهو نموذج الغابات العشوائية (Random Forest) باستخدام البيانات المتوفرة للتنبؤ بالقيم المفقودة واستكمالها استنادًا إلى الأنماط المكتشفة في البيانات.

توحيد القياس، عدم توازن البيانات، وتقليل الأبعاد (Data Normalization, Imbalanced Data and Dimensionality Reduction)

- توحيد القياس: من أجل ضمان تجانس القياسات بين المتغيرات المالية المختلفة، تم تطبيق أسلوب توحيد القياس باستخدام أداة Standard Scaler، والتي تعمل على تحويل كل متغير إلى مقياس موحد من خلال إزالة المتوسط وقسمة القيم على الانحراف المعياري لكل متغير، وتعني بشكل أدق معالجة البيانات لتكون ضمن نطاق معين مثل ٠ إلى ١، يعتبر هذا الإجراء ضروريًا خاصةً عند استخدام نماذج مثل الشبكات العصبية، وذلك لتفادي تأثير التباين الكبير بين المتغيرات على نتائج النموذج، حيث يحسّن من كفاءة عملية التدريب، ويعتبر خطوة تمهيدية أساسية قبل تطبيق تقنيات مثل تحليل المكونات الرئيسية (PCA) أو تدريب نموذج الشبكات العصبية الاصطناعية.

Articles in Press

- عدم توازن البيانات (Data Imbalanced): لضمان مساهمة جميع الخصائص بشكل متساوي في عملية التدريب، تم استخدام تقنية Stratified Shuffle Split لضمان التوزيع المتوازن للفئات أثناء تقسيم البيانات بنسبة ٢٠/٨٠، حيث حافظ هذا الأسلوب على نسبة الشركات المتعثرة وغير المتعثرة في مجموعتي التدريب والاختبار، وهو أمر بالغ الأهمية في حالات التصنيف غير المتوازن.

بناء النماذج (Model Development)

بعد الانتهاء من مرحلة المعالجة المسبقة للبيانات تم بناء النماذج المختارة في الدراسة، ولغاية بناء الشبكات العصبية الاصطناعية تم تقسيم مجموعة البيانات إلى ٨٠٪ للتدريب، و٢٠٪ للاختبار. حيث تم بناء نوعين من الشبكات العصبية الاصطناعية وهي الشبكات العصبية الاصطناعية متعددة الطبقات (MLP)، والشبكة العصبية الاصطناعية ذات الذاكرة قصيرة- طويلة الأجل (LSTM) كما يلي.

الشبكة العصبية الاصطناعية متعددة الطبقات (MLP)

وهي عبارة عن نوع خاص من الشبكة العصبية ذات التغذية الأمامية (Feedforward neural network) والتي تكون فيها الطبقات متصلة مع بعضها (Fully connected layers) وتكون دالة التفعيل غير خطية. تم استخدام أداة Keras لبناء الشبكة، واشتمل النموذج على طبقتين خفيتين تحتويان على ٣٢ و١٦ خلية عصبية على التوالي، وكلاهما يستخدم دالة التنشيط (tanh)، بالإضافة إلى استخدام تقنيات Batch Normalization وDropout لمكافحة فرط التوافق وتحسين الاستقرار أثناء التدريب. أما طبقة الإخراج فقد استخدمت خلية واحدة بدالة تنشيط sigmoid لتصنيف الحالة المالية. تم تدريب النموذج باستخدام خوارزمية التحسين (Adam) ودالة خسارة(Binary Cross-Entropy) ، مع تطبيق آلية الإيقاف المبكر بعد ٢٠ حقبة (أو دورة تدريبية) لتفادي الإفراط في التدريب (Overfitting).

الشبكة العصبية الاصطناعية قصيرة- طويلة الذاكرة (LSTM)

تعاني الشبكات العصبية متعددة الطبقات من عدم توفر ذاكرة لديها أي لا يمكنها تذكر المعلومات، لذا تم بناء نوع أخر من الشبكات العصبية يسمى الشبكات العصبية طويلة قصيرة الذاكرة (Long Short-Term Memory - LSTM)، والتي تقوم على تحليل البيانات المتسلسلة والمعقدة كما أنها تحتفظ بالمعلومة لفترة أطول بكفاءة عالية، حيث تحتوي على بوابات مخصصة للتحكم بعملية تخزين المعلومات ونسيانها وإخراجها (Hochreiter & Schmidhuber, 1997). تم تحضير البيانات لاستخدامها في نموذجLSTM من خلال إنشاء نوافذ زمنية منزلقة (Sliding Window)، يضمن هذا الإجراء المحاذاة الزمنية الصحيحة لكل شركة، ويتيح التنبؤ بالتعثر المالي المستقبلي بناءً على الأداء المالي في السنوات السابقة، وقد تم اختيار حجم النافذة ليكون لمدة سنتين متتاليتين. تم بناء شبكة LSTM باستخدام أداة Keras، حيث تم تصميمها لالتقاط الأنماط الزمنية ضمن النوافذ المنزلقة. تكون النموذج من طبقة واحدة تحتوي على ٣٢ خلية عصبية، متبوعة بطبقةBatch Normalization وطبقة Dropout بنسبة ٠,٣، وانتهى النموذج بطبقة إخراج تحتوي على خلية واحدة بدالة تنشيط sigmoid لتصنيف الشركات إلى متعثرة وغير متعثرة. تم تدريب النموذج باستخدام خوارزمية Adam ودالة خسارة Binary Cross-Entropy، مع تطبيق آلية الإيقاف المبكر لمنع الإفراط في التدريب وتحقيق أفضل أداء تنبؤي ممكن.

تقييم النماذج (Model Evaluation)

بعد إتمام عملية التدريب تم اختبار النماذج باستخدام بيانات عينة الاختبار (٢٠٪ من عينة الدراسة)، وذلك لتقييم قدرتها على التعميم والتنبؤ بدقة على أرض الواقع بما يحقق أعلى دقة ممكنة في الفصل بين الشركات المتعثرة وغير المتعثرة. تم تقييم أداء النماذج باستخدام أربع مقاييس معيارية (Evaluation Metrics) شائعة في مجال التعلم الآلي، وهي: الدقة (Accuracy)، الدقة الإيجابية (Precision)، الاسترجاع (Recall)، ومقياس F1-score.

نتائج التحليل الإحصائي واختبار دقة النماذج

نتائج الإحصاء الوصفي لمتغيرات الدراسة

الوسط والوسيط: أظهرت نتائج التحليل الإحصائي الوصفي كما في جدول (٢) تباينًا ملحوظًا في خصائص البيانات المالية المستخدمة في النموذج. فقد بيّنت مؤشرات النزعة المركزية والتشتت وجود انحرافات واضحة بين المتوسطات والوسيطات للعديد من المتغيرات، مما يشير إلى وجود توزيع غير متماثل. على سبيل المثال، بلغ متوسط المتغير X١ نحو ٠,٦٤٧ في حين أن الوسيط كان أقل بكثير (٠,٣٨٨)، مما يدل على انحراف موجب ناتج

Articles in Press

عن وجود بعض القيم العالية. وقد تكررت هذه الظاهرة في متغيرات مثل X٤ وX١٩، حيث تجاوز الانحراف المعياري في الأخير (١٢٦,٦٣) المتوسط الحسابي (١٨,٥٤) بفارق كبير، مما يعكس مدى التشتت الحاد في البيانات المالية لبعض الشركات. كما أشارت نتائج الانحراف المعياري إلى وجود تباين كبير في بعض المتغيرات المالية، وهذا يعكس اختلافا واضحًا في أداء الشركات ضمن عينة الدراسة. حيث سجل المتغيرX١٩ أعلى انحراف معياري بلغ (١٢٦,٦٣)، مقابل متوسط قدره (١٨,٥٤)، ما يدل على وجود قيم متطرفة بشكل حاد وتباين مرتفع، والتي تعكس وجود شركات ذات أوضاع مالية استثنائية (الشركات المتعثرة) في عينة الدراسة. كذلك، أظهر المتغيرX٤ (والذي يتعلق بعدد مرات تغطية الفائدة) انحرافا معياريًا بقيمة (٧,١٣) والتي تزيد عن متوسطه (٠,٩١) بشكل كبير، مما يدل إلى وجود تشتت في البيانات حول المتوسط بصورة كبيرة. في المقابل، تميزت بعض المتغيرات مثل X٢ (نسبة الديون الى الأصول) و X٨(معدل العائد على الأصول) بانحراف معياري منخفض نسبيًا (٠,١٧٨ و٠,١٠٢ على التوالي)، مما يدل على تجانس أكبر في هذه المؤشرات في عينة الدراسة. أما نتائج اختبار التوزيع الطبيعي (Jarque-Bera) فقد أشارت إلى أن جميع المتغيرات محل الدراسة ترفض فرضية التوزيع الطبيعي عند مستوى معنوية ٠,٠٥ حيث بلغت قيمة (P-value = ٠,٠٠٠)، مما يدل على وجود انحرافات واضحة عن التوزيع الطبيعي للبيانات. تشير هذه النتائج صعوبة استخدام هذه المتغيرات في النماذج الإحصائية للتنبؤ بالتعثر المالي، خصوصًا تلك التي تفترض التوزيع الطبيعي، مثل الانحدار الخطي أو المتعدد. وبالتالي، من الضروري الاعتماد على نماذج وطرق تنبؤية لا تفترض التوزيع الطبيعي للبيانات من أجل دقة النتائج وموثوقية الاستنتاجات.

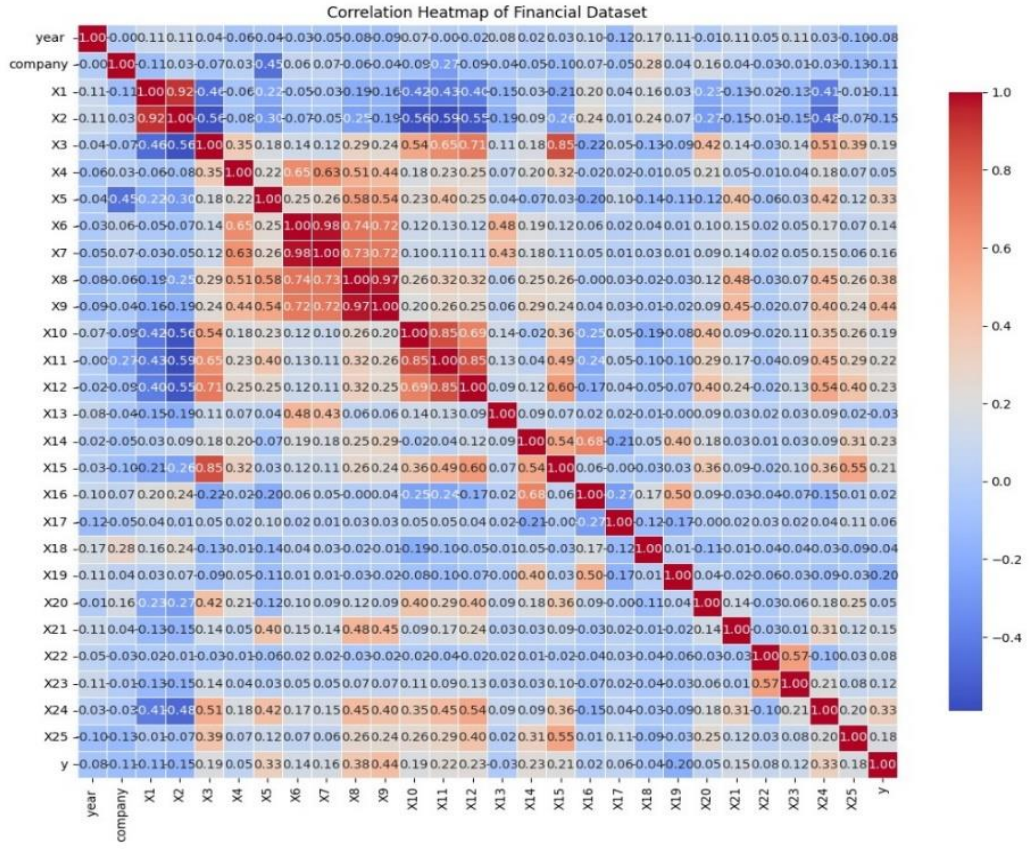
جدول (٢): نتائج التحليل الإحصائي

Variable	Mean	Median	Maximum	Minimum	Std. Dev.
X١	٠,٦٤٦٦٩٦	٠,٣٨٧٥٠٠	٣,٧٤٦٠٠٠	٠,٠٩٥٠٠٠	٠,٦٨٧٢٢٤
X٢	٠,٣٢٢٨٠٦	٠,٢٧٨٨٨٥	٠,٧٨٩٣١٠	٠,٠٨٦٤٤٠	٠,١٧٨٠٤٥
X٣	٢,٦٢٢٦٧٢	٢,٢٠٤٠٠٠	١٣,٣١٣٠٠	٠,٢٦٩٠٠٠	٢,٠٦٤٩٩١
X٤	٠,٩١٤٢٠٤	٠,٠٧٢٨٩٠	٦٤,٥٠٩٠١	-٥٨,٦٣٠٤٨	٧,١٢٦١٢٥
X٥	٠,٢١٩١٧٧	٠,١٧٦٢٣٥	٠,٧٢٠٢٤٠	-٠,٤٤٨٩١٠	٠,١٨٩٠٢٣
X٦	-٠,٠٦٢٦٣٢	٠,٠٦٥٩٠٥	٠,٦٦٧٥١٠	-١٣,٢٤٥١١	١,٢٥٥٨٠٨
X٧	-٠,٠٧٦١٢٧	٠,٠٤٧٥٨٠	٣,٦٢١٦١٠	-١٣,٢٧١٤٣	١,٢٧٥٣٥٠
X٨	٠,٠٣٥٩٧٦	٠,٠٣٤٣١٥	٠,٣٨٣٩٧٠	-٠,٨٥٧١٦٠	٠,١٠٢٠٢٨
X٩	٠,٠٤٥١٥٠	٠,٠٥٢٩٣٥	٠,٥١٠٠٦٠	-١,٣٠٠٦٩٠	٠,١٥١٥٩٠
X١٠	٢,٩٣٩٩١٦	٢,٣٢٤٠٠٠	٢٨,٤٩٨٠٠	٠,٣٥٩٠٠٠	٢,٧٨٥٤٧٦
X١١	١,٦٦١٨٤٠	١,١٢٧٥٠٠	١٥,٢٧٣٠٠	٠,٠٠٩٠٠٠	١,٦٥٤٢٠٣
X١٢	٠,٨٢٥٦١٦	٠,٤١٢٠٠٠	٥,٣٥١٠٠٠	٠,٠٠٢٠٠٠	١,١١٦٣٠١
X١٣	٠,١٨٣٣٦٨	٠,٤٧٣٥٠٠	٣,٨٥١٠٠٠	-٦٣,٤٢٥٠٠	٤,١٤٣١٦٣
X١٤	٠,٦٨١٦٣٢	٠,٥٩٨٥٠٠	٣,٢١٥٠٠٠	٠,٠٠٤٠٠٠	٠,٣٩٠٦٠٩
X١٥	٢,٦٨٥٥٠٨	١,٩٩٢٠٠٠	٢١,٢٣٥٠٠	٠,٠٠٦٠٠٠	٢,٨٧٤٦٤٩
X١٦	١,٥١٨٣٨٤	١,١٧٢٥٠٠	١٦,٥٦٨٠٠	٠,٠٢٧٠٠٠	١,٤٥٥٨٣٥
X١٧	٠,٩٢٨٦٤٠	١,٣٩٥٥٠٠	٨١,١٥٩٠٠	-٧٧,٦٨٢٠٠	١٢,٤٦٧٦٢
X١٨	٠,٠٧٢٧٣٣	٠,٠٣٢٢٤٥	١,٣٠٤٠٦٠	٠,٠٠٠٨١٠	٠,١٤٠٢٦٧
X١٩	١٨,٥٤٥٨٤	٤,٦٦٠٠٠٠	١٩٠٤,٠٢٣	٠,٣٣٩٠٠٠	١٢٦,٦٣٤٨
X٢٠	٠,٠٨٦٦٩٨	٠,٠٥٣٧٤٥	٠,٨٤٣٧٩٠	٠,٠٠٠١٢٠	٠,٠٩٦٠٤١
X٢١	٠,٢٢٤٠٣٦	٠,٠٨٣٥٠٠	٨,٦٧٢٠٠٠	-١,٠٧٧٠٠٠	٠,٨٤٣٤١٤
X٢٢	٠,٣٧٧٣٩١	٠,١٢٠١٧٠	٢٠,٥٠٠٤١	-١٣,١٦١٧٣	٢,٠٤٧١٣١
X٢٣	٠,٤٧٨٥١٦	٠,٣٥٤٩٨٥	٢٠,٦٣٨٠٠	-٠,٧٠٨٢٦٠	١,٣٤٩٥٠٤
X٢٤	٠,٠٣٠١١٦	٠,٠٢٨٧٢٠	٠,١٢١٦١٠	٠,٠٠٠٠٠٠	٠,٠٣٢٠٠١
X٢٥	١,٢٧٩٨٨٠	٠,٩٨٥٠٠٠	١٢,١٢٤٠٠	٠,٠٣٤٠٠٠	١,٣٩٥١٦٢

تحليل معامل الارتباط (Correlation Analysis)

تظهر مصفوفة الارتباط المرفقة في الشكل (٢) إلى وجود علاقات ارتباط قوية بين عدد من المتغيرات، حيث نجد ارتباط موجب وقوي بين المتغيرات X٦ (هامش الربح التشغيلي) وX٧(نسبة صافي الربح) بقيمة (٠,٩٨)، وكذلك بينX٨ (معدل العائد على الأصول) وX٩ (معدل العائد على حقوق الملكية) بقيمة (٠,٩٧)، وبين المتغير X١(الديون الى حقوق الملكية) والمتغير X٢(الديون إلى الأصول) بقيمة (٠,٩٢)، وأيضاً بين X١٠ (نسبة

التداول) وX١١(نسبة السيولة السريعة) بقيمة (٠,٨٥)، وكذلك الأمر بين X١٢ (نسبة السيولة الفورية) و X١١(نسبة السيولة السريعة) بقيمة (٠,٨٥). هذه القيم المرتفعة تشير إلى أن هذه المتغيرات تقيس نفس الظاهرة او البعد المالي وهي متغيرات مترابطة بدرجة كبيرة. كما أظهرت النتائج وجود علاقة ارتباط سالبة قوية بين المتغيرات X٢ (الديون الى الأصول) والمتغير X١١ (نسبة السيولة السريعة) بقيمة (-٠,٥٩)، وبين المتغيراتX٢(الديون الى الأصول) والمتغيرX٣ (حقوق الملكية إلى الأصول الثابتة) بقيمة (-٠,٥٦)، وبين المتغيرات X١٠ ,X٢ بقيمة (-٠,٥٦)، وبين المتغيرات X٣ ,X١ بقيمة (-٠,٤٦). مما يدل على أن ارتفاع أحد هذه المتغيرات يرتبط بانخفاض الآخر. في حين أظهرت النتائج أن بعض المتغيرات مثلX١٧ (معدل دوران رأس المال العامل) وX١٨ (معدل دوران المخزون) وX١٩ (معدل دوران الذمم المدينة) لديها معاملات ارتباط ضعيفة جدًا مع معظم المتغيرات الأخرى في مصفوفة الارتباط، فقد تراوحت قيم الارتباط بين هذه المتغيرات وبين غيرها بين -٠,١٢ و -٠,٢٧، وهي قيم منخفضة لا تشير إلى علاقة قوية. هذا الضعف في الارتباط يدل على قلة التداخل أو الترابط بين هذه المتغيرات والمتغيرات الأخرى في النموذج، مما يشير إلى أنها تحمل معلومات فريدة أو مستقلة في التنبؤ بالعامل التابع. كما تشير المصفوفة إلى أن المتغيرX٩ (معدل العائد على حقوق الملكية) لديه أعلى نسبة ارتباط مع المتغير التابع بنسبة ٤٤٪، يليه المتغير X٨ (معدل العائد على الأصول) بنسبة ارتباط بلغت ٣٨٪.



شكل (٢): مصفوفة الارتباط (Heatmap): مخرجات برنامج Python

تحليل التعددية الخطية للمتغيرات المستقلة (Multicollinearity)

بناء على طبيعة البيانات المالية لمتغيرات الدراسة والتي ظهرت من خلال نتائج التحليل الوصفي، تم تطبيق اختبار التعددية الخطية للكشف عن وجود علاقات خطية بين متغيرات الدراسة، وتحليل المكونات الرئيسية لتقليل أبعاد الدراسة حيث تستخدم هذه الاختبارات كتحليلات تمهيدية أو تشخيصية لدراسة العلاقات بين المتغيرات وفهم طبيعتها. من خلال الجدول (٣) أدناه، نجد أن المتغيراتX٨ ،X٢ ،X٦ ، X١٤، X٧، X٣ أظهرت مستويات مرتفعة جدا من التعددية الخطية، وهي أعلى بكثير من الحد المقبول إحصائيًا (VIF > ١٠)، مما يدل على وجود تداخل قوي بين هذه المتغيرات وغيرها في النموذج، وهذا من شأنه أن يضعف تفسير الأثر الحقيقي لكل منها على المتغير التابع. ما يستلزم المزيد من التحليل حول طبيعة علاقاتها بباقي المتغيرات، قد تعكس هذه المتغيرات معلومات مكررة أو مشتقة من متغيرات أخرى. أما المتغيرات ذات VIF بين ١٠ و٢٠ مثل X٩، X٥، X١، وX٢٤، فهي تُظهر مستويات معتدلة من التعددية الخطية، والتي تكون مقبولة إحصائيا في بعض

النماذج مع ضرورة الحذر من وجود تأثير متبادل بين هذه المتغيرات. وفي المقابل، سجلت بقية المتغيرات جميعها VIF أقل من ١٠، مما يشير إلى ضعف التداخل الخطي مع المتغيرات الأخرى، وبالتالي فإنها لا تعاني من التعددية الخطية. بناءً على ما تقدم، يجب إزالة أو دمج المتغيرات التي سجلت VIF مرتفع، أو تطبيق تحليل المكونات الرئيسية (PCA) لتقليل الأثر المشترك وتحسين جودة النموذج التنبؤي.

جدول (٣): نتائج اختبار التعددية الخطية (VIF)

المتغير	قيمة VIF	المتغير	قيمة VIF	المتغير	قيمةVIF
X١٩	١,٤٣٧٦	X١٠	١٠,٥٦٩٠	X١	١٤,٥٥٢٧
X٢٠	٢,٩٥١٥	X١١	٢٢,٥٣٨١	X٢	٣٣,٤٧٦٩
X٢١	٢,١٩٩٢	X١٢	١٠,١٢٣٣	X٣	٢٢,٢٢٣٥
X٢٢	١,٧١١١	X١٣	٣,٢٨٣٠	X٤	٣,٠٦١٩
X٢٣	١,٩٢٢٧	X١٤	٢٤,٥٤٥٣	X٥	٦,٨١١٧
X٢٤	٤,٢٥٢٨	X١٥	٢٠,٤٧٠٣	X٦	٣٢,٠٣٨٠
X٢٥	٣,٤٩٢١	X١٦	٦,٧٨٩٣	X٧	٢٣,١٤٥١
		X١٧	١,١٥٢٧	X٨	٤١,٦٤٧٥
		X١٨	١,٦٣٩٤	X٩	٢١,٩٠٤١

تحليل المكونات الرئيسية (Principal Component Analysis – PCA)

يستخدم تحليل PCA لمعالجة التعددية الخطية التي تنشأ بين متغيرات الدراسة ذات الارتباط القوي فيما بينها، والذي ظهر من خلال نتائج تحليلVIF ومصفوفة الارتباط، بهدف تقليل عدد المتغيرات وتحسين دقة التنبؤ وتبسيط النموذج. يظهر في الجدول رقم (٤) أدناه، أن أول ١٦ مكونا رئيسيا استطاعت تفسير أكثر من ٩٥٪ من التباين الكلي، وهي النسبة المقبولة في الدراسات التي تتضمن متغيرات مالية مترابطة للاحتفاظ بأكبر قدر ممكن من المعلومات، خاصة عند دمج PCA مع نماذج التعلم مثل الشبكات العصبية كما هو الحال في الدراسة الحالية (Abdi & Williams, 2010). وهذا يدل على أن الاعتماد على هذه المكونات يعتبر بديل عن المتغيرات الأصلية ويمكن أن يُسهم في بناء نموذج تنبؤي فعال باستخدام نماذج الذكاء الاصطناعي. وبناء على هذه النتيجة سيتم اعتماد هذه المكونات كمدخلات للشبكات العصبية بدل من المتغيرات الأصلية.

جدول (٤): نتائج تحليل المكونات الرئيسية (PCA)

				Cumulative	Cumulative					Cumulative	Cumulative
Number	Value	Difference	Proportion	Value	Proportion	Number	Value	Difference	Proportion	Value	Proportion
PC1	6.657302	3.275121	0.2663	6.657302	0.2663	PC14	0.506983	0.109566	0.0203	23.31674	0.9327
PC2	3.382181	0.865862	0.1353	10.03948	0.4016	PC15	0.397417	0.069468	0.0159	23.71415	0.9486

Articles in Press

PC3	2.516319	0.878001	0.1007	12.5558	0.5022	PC16	0.327949	0.020494	0.0131	24.0421	0.9617
PC4	1.638317	0.107142	0.0655	14.19412	0.5678	PC17	0.307456	0.113321	0.0123	24.34956	0.974
PC5	1.531176	0.041996	0.0612	15.72529	0.629	PC18	0.194135	0.01297	0.0078	24.54369	0.9817
PC6	1.48918	0.414032	0.0596	17.21447	0.6886	PC19	0.181165	0.078929	0.0072	24.72486	0.989
PC7	1.075147	0.187033	0.043	18.28962	0.7316	PC20	0.102235	0.045844	0.0041	24.82709	0.9931
PC8	0.888114	0.022843	0.0355	19.17774	0.7671	PC21	0.056391	0.010045	0.0023	24.88348	0.9953
PC9	0.865271	0.026501	0.0346	20.04301	0.8017	PC22	0.046346	0.014807	0.0019	24.92983	0.9972
PC10	0.838771	0.070714	0.0336	20.88178	0.8353	PC23	0.031539	0.007651	0.0013	24.96137	0.9985
PC11	0.768057	0.158536	0.0307	21.64983	0.866	PC24	0.023887	0.009142	0.001	24.98525	0.9994
PC12	0.609521	0.059123	0.0244	22.25936	0.8904	PC25	0.014745	---	0.0006	25	1
PC13	0.550397	0.043414	0.022	22.80975	0.9124						

اختبار كفاءة النماذج لتنبؤية

تم اختبار دقة نماذج الشبكات العصبية الاصطناعية باستخدام بيانات عينة الاختبار، وذلك لتقييم قدرتها على التعميم والتنبؤ بدقة. وقد تم اختبار مجموعة من عتبات التنبؤ تراوحت بين (٠,٧٠ إلى ٠,٩٩) من أجل تحديد أفضل حد فاصل للتصنيف، بما يحقق أعلى دقة ممكنة في الفصل بين الشركات المتعثرة وغير المتعثرة. تم تقييم أداء النماذج باستخدام أربع مقاييس معيارية وكانت النتائج كما يلي.

يظهر من خلال الجدول (٥)، أن كلا النموذجين يمتلكان قدرة عالية على التنبؤ بالحالة المالية للشركات، حيث بلغت قيمة الدقة الإيجابية (Precision) نسبة ١٠٠٪، وهذا يعني أن جميع الشركات المصنفة "متعثرة" من قبل النموذج كانت كذلك بالفعل. ومع ذلك، فإن نموذج LSTM تفوق على MLP في كل من الدقة العامة (Accuracy) والاستدعاء (Recall) ومقياسF١ ، مما يعكس قدرته الأفضل على كشف الأنماط الزمنية وتعقيدات البيانات المالية متعددة السنوات. كما تم إعداد مصفوفة الارتباك (التصنيف) الخاصة بالنموذجين والتي تقوم على تحديد عدد المشاهدات في كل فئة من الفئات التالية.

Articles in Press

جدول (٦): مصفوفة الارتباك للشبكة العصبية متعددة الطبقات MLP

	Predicted 0 (Distressed)	Predicted 1 (Not Distressed)
Actual 0 (Distressed)	(TN) 5	(FP) 0
Actual 1 (Not Distressed)	(FN) 3	(TP) 42

يتبين من خلال الجدول (٦) أن عدد الشركات التي تم تصنيفها عن طريق نموذج الشبكات MLPعلى أنها متعثرة وكانت فعليا متعثرة قد بلغ ٥ شركات، في حين بلغ عدد الشركات التي كانت فعلا متعثرة وصنفها النموذج على أنها غير متعثرة ٠ شركة، أي أن النموذج نجح بشكل كامل في تصنيف الشركات المتعثرة، مما أدى للوصول على دقة إيجابية Precision بلغت ١٠٠٪. أما بالنسبة للشركات غير المتعثرة فعليا والتي صنفها النموذج بشكل خاطئ على أنها متعثرة بلغ عددها ٣ شركات فقط بنسبة خطأ بلغت ٦,٦٧٪، وفي المقابل نجح النموذج في تصنيف ٤٢ شركة غير متعثرة فعليا وصنفها بنجاح على أنها غير متعثرة.

أما نموذج الشبكات LSTM فقد أظهرت نتائج مصفوفة الارتباك الظاهرة في جدول (٧)، أن عدد الشركات المتعثرة فعليا والتي صنفها النموذج بشكل صحيح على أنها متعثرة قد بلغ ٤ شركات، ولم يخطأ النموذج بتصنيف الشركات المتعثرة مما أدى للوصول على دقة إيجابية Precision بلغت ١٠٠٪. كما بلغ عدد الشركات غير المتعثرة والتي صنفها النموذج بشكل خاطئ على أنها متعثرة شركة واحدة فقط، في حين نجح النموذج بتصنيف ٣٥ شركة غير متعثرة بشكل صحيح.

جدول (٧): مصفوفة الارتباك للشبكة العصبية طويلة قصيرة الذاكرة LSTM

	Predicted 0 (Distressed)	Predicted 1 (Not Distressed)
Actual 0 (Distressed)	(TN)4	0 (FP)
Actually 1 (Not Distressed)	(FN)1	(TP)35

نتائج الدراسة ومناقشتها

توصلت هذه الدراسة إلى مجموعة من النتائج المهمة والمثيرة لاهتمام الباحثين وأصحاب القرار والمصالح في الشركات، حيث أثبتت الدراسة أن نماذج الشبكات العصبية الاصطناعية لديها القدرة على التنبؤ بالتعثر المالي بدقة عالية، حيث بلغت دقة التنبؤ لنموذج الشبكات العصبية MLP ٩٤٪، في حين تفوق نموذج الشبكات العصبية LSTM في دقة التنبؤ والتي بلغت ٩٧,٥٪. تتفق نتائج هذه الدراسة مع دراسة (Roba & Moulay, 2024) حيث بلغت دقة التنبؤ ٩٢,٩٪. كما توصلت دراسة (Nguyen et al., 2024) إلى فعالية نموذج بدقة بلغت ٩٣,٩٪. وأكدت دراسة (الجبيلي، ٢٠٢٣) ذلك بدقة في التصنيف بلغت ٩٥,٤٥. وفي دراسة (Aydin et al., 2022) توصلت الدراسة إلى تفوق نموذج الشبكات العصبية في التنبؤ بالتعثر المالي بدقة بلغت ٩٣,١٪، ٩٤,٤٤٪، و٨٩,٤٧٪ في قطاع الصناعة، التجارة، والخدمات على التوالي. أما دراسة (Ling & Cai, 2022) فقد طبقت نموذج الشبكات العصبية طويلة-قصيرة الذاكرة LSTM في التنبؤ بالتعثر المالي وحقق النموذج دقة إجمالية وصلت إلى ٩٤,٢٪. كما قدمت دراسة (Abdullah, 2021) دليلا أخر في هذا المجال حيث أظهرت النتائج دقة تصنيف وصلت ٩٤٪. وفي دراسة (Dube et al., 2021) حقق النموذج معدلات دقة تصنيف بلغت ٨١,٠٣٪ و٩٦,٦٪ لقطاعي الخدمات المالية والصناعة على التوالي في سوق جوهانسبرغ، كما وجدت دراسة (El-Bannany et al., 2020) تفوق الشبكات العصبية الاصطناعية على باقي نماذج تعلم الألة الأخرى المستخدمة في الدراسة، فقد بلغت دقة التنبؤ للشبكات العصبية العميقة ٩٣٪. وأيضا أكدت دراسة (Shahwan & Fadel, 2020) تفوق نموذج الشبكات العصبية الاصطناعية على باقي نماذج تعلم الألة حيث حققت دقة في التنبؤ بلغت ٩١,٣٪. وفي المقابل، تختلف نتائج هذه الدراسة مع نتائج عدد محدود من الدراسات من حيث النتائج، ففي دراسة (Zizi et al., 2021) توصلت النتائج إلى تفوق نموذج الانحدار اللوجستي على نموذج الشبكات العصبية في دقة التنبؤ بالتعثر المالي للشركات فقد بلغت دقة التنبؤ للشبكات العصبية ٨٣,٣٪ مقابل ٩٣,٣٪ لنموذج الانحدار اللوجستي. كما توصلت دراسة (Malakauskas & Lakstutiene, 2021) إلى النتيجة ذاتها حيث تفوق نموذج الغابة العشوائية بالتنبؤ بدقة تصنيف بلغت ٦٢,١١٪، تلتها نموذج الانحدار اللوجستي بدقة بلغت

Articles in Press

٦١,٢٩٪، وجاءت الشبكات العصبية الاصطناعية بالمرتبة الأخيرة بدقة تصنيف بلغت ٥٥,٣٣٪. وأثبتت دراسة (Smiti & Soui, 2020) نفس هذه النتائج حيث تفوق النموذج المقترح في الدراسة في التنبؤ بمتوسط دقة بلغت ٩٦,١٪، في حين بلغ متوسط دقة نموذج الجار الأقرب ٨٥,٩٪، وشجرة اتخاذ القرارات ٨٤٪، أما نموذج الة دعم المتجهات فقد حققت متوسط دقة ٨٢,٤٪، وأخيرا حقق نموذج الشبكات العصبية أدنى متوسط دقة بلغت ٦٨,٥٪.

التوصيات

بالاعتماد على النتائج التي توصلت إليها الدراسة ومقارنة النتائج المستخلصة مع الدراسات السابقة توصي الدراسة بضرورة الاعتماد على نماذج الذكاء الاصطناعي كنماذج فعالة للتنبؤ بالتعثر المالي، والتي من شأنها دعم اتخاذ القرار في البيئة المالية. والاعتماد على نماذج الشبكات العصبية وخاصة من نوع LSTM وذلك لفعاليتها ودقتها العالية في عملية التنبؤ بالتعثر المالي خاصة في الحالات التي تتطلب تحليل سلاسل زمنية لفعاليتها في التقاط الاتجاهات وتغيرات الأداء على المدى الطويل. كما توصي الدراسة استخدام نماذج أخرى من الذكاء الاصطناعي مثل شجرة اتخاذ القرار، الغابات العشوائية، ونموذج XGBoost وغيرها، ومقارنة نتائجها مع ما توصلت إليه الدراسة الحالية. ولتحديد النموذج الأكثر دقة في التنبؤ بحالة التعثر المالي يمكن إجراء دراسات مقارنة بين نماذج الذكاء الاصطناعي والنماذج التقليدية مثل نموذج ألتمان وكايدا وغيرها، كما يمكن بناء نماذج هجينة مكونة من أكثر من نموذج معا وذلك من اجل تحسين دقة التنبؤ بالتعثر المالي. كما توصي الدراسة الأخذ بعين الاعتبار المتغيرات النوعية إلى جانب المتغيرات الكمية مثل حجم الشركة، نوع القطاع، عمر الشركة وغيرها، وزيادة حجم العينة من خلال شمولية كافة قطاعات السوق كما يمكن توسيع الفترة الزمنية المختارة للدراسة.

الشكر والتقدير

نتوجه بخالص الشكر إلى المراجعين ورئيس التحرير على تعليقاتهم القيّمة على المسودة الأولية لهذه الورقة البحثية. كما نعرب عن تقديرنا لمشاركة الشركات المساهمة الصناعية المدرجة في بورصة عمان الذين ساهموا في هذه الدراسة، ونشكر بورصة عمان وجامعة العلوم الإسلامية العالمية على تسهيل عملية جمع البيانات. جميع الأخطاء أو أوجه القصور المتبقية هي مسؤوليتنا بالكامل.

الإقرارات الأخلاقية

تم إجراء هذه الدراسة وفقًا لمبادئ إعلان هلسنكي (١٩٦٤)، وحصلت على موافقة لجنة البحث والأخلاقيات في بورصة عمان وجامعة العلوم الإسلامية العالمية، الأردن. وقد تم الالتزام بالمبادئ الأخلاقية التالية أثناء تنفيذ البحث:

- مبدأ الموافقة الطوعية (تم الحصول على الموافقة المستنيرة من الجهات المعنية في بورصة عمان وجامعة العلوم الإسلامية العالمية).
- مبدأ تقليل المخاطر على المشاركين.
- مبدأ السرية.
- مبدأ إبلاغ المشاركين بمحتوى وأهداف البحث.
- مبدأ التوثيق الإلزامي لمراحل ونتائج البحث.
- مبدأ موثوقية الأدوات المنهجية المستخدمة في البحث.
- مبدأ صلاحية معالجة البيانات البحثية.

بيان توافر البيانات

تتوفر مجموعات البيانات التي تم جمعها وتحليلها خلال هذه الدراسة عند الطلب من الباحثين.

التمويل

لم يتم تلقي أي تمويل لإجراء هذا البحث.

Articles in Press

تضارب المصالح

يؤكد الباحثان عدم وجود أي تضارب في المصالح.

مساهمة الباحثين

- قام كل من لبنى عقدة وعبدالله الحردان بوضع تصور الدراسة وتصميمها، بالإضافة إلى جمع البيانات وتحليلها.
- تمَّ كتابة المسودة الأولى للمقال بواسطة لبنى عقدة وعبدالله الحردان.
- قام الباحثان بمراجعة النصوص وتحريرها، واعتمدا النسخة النهائية للنشر.

الموافقة على النشر

يوافق الباحثان على تقديم هذه الورقة البحثية للنشر، وهما بانتظار قرار هيئة التحرير بعد عملية التحكيم، ويوافقان على نشرها في حال قبولها. كما يؤكدان أن هذا العمل لم يُنشر سابقًا ولم يُقدَّم إلى أي مجلة أخرى للنظر في نشره.

المراجع

بالله، فلة وبن مسعود، محمد. (٢٠٢١). فعالية استخدام المنطق الضبابي للتنبؤ بالتعثر المالي لمؤسسات أشغال البناء في ولاية أدرار خلال الفترة (٢٠١٨–٢٠١٤). *Les Cahiers du MECAS* *١٧* (٢)، ٥٦٢-٥٧٢.

بورصة عمّان. (د.ت.). *الموقع الإلكتروني الرسمي*: https://www.ase.com.jo

الجبيلي، راميا. (٢٠٢٣). التنبؤ بتعثر القروض المصرفية باستخدام التحليل التمييزي وخوارزميات التنقيب في البيانات. *مجلة جامعة البعث – سلسلة العلوم الاقتصادية والسياحية، ٤٥* (٤).

الخلايلة، محمود. (٢٠١٣). *التحليل المالي باستخدام البيانات المحاسبية* (ط. ٩). دار وائل للطباعة والنشر والتوزيع.

رشوان، عبد الرحمن محمد سليمان. (٢٠١٨). دور تحليل البيانات الضخمة (Big Data) في ترشيد اتخاذ القرارات المالية والإدارية في الجامعات الفلسطينية: دراسة ميدانية. *مجلة الدراسات الاقتصادية والمالية، ١١* (١١).

الزبيدي، حمزة محمود. (٢٠٠٠). *التحليل المالي لأغراض تقييم الأداء والتنبؤ بالفشل* (ط. ١). مؤسسة الوراق للنشر والتوزيع.

زهواني، مروة. (٢٠٢٢). *تطبيقات نماذج الذكاء الاصطناعي للتنبؤ بمخاطر التعثر المالي في المؤسسة الاقتصادية: دراسة حالة* (أطروحة دكتوراه). جامعة غرداية

سابق، أمين. (٢٠٢٣). *التنبؤ بالتعثر المالي بالاعتماد على الشبكات العصبية الاصطناعية مقارنة مع النماذج الكمية: دراسة عينة من المؤسسات الاقتصادية الجزائرية* (أطروحة دكتوراه). جامعة تامنغست.[

صالح، هاني والمعداوي، جيهان وشهاب الدين، محمد. (٢٠٢٣). تحليل العوامل المؤثرة في الطلب بالسوق التأميني السعودي باستخدام تحليل الانحدار وتحليل الشبكات العصبية الاصطناعية. *مجلة البحوث التجارية، ٤٥* (٢)، ٦٩١-٧٢٥.

العامودي، مي عبد العزيز والحربي، مروج. (٢٠٢٤). استخدام نموذج التمان في التنبؤ بالتعثر المالي في قطاع البنوك السعودي: دراسة مقارنة قبل وبعد جائحة كورونا. *مجلة العلوم الاقتصادية والإدارية والقانونية، ٨*(٥)، ١-١٦.

قريشي، خير الدين. (٢٠١٦). تشخيص خطر الإفلاس باستخدام مميزات الإفصاح الحالي وفق النظام المحاسبي المالي. *مجلة رؤى اقتصادية، ٢* (٣).

مرابط، محمد. (٢٠٢١). فعالية نماذج التنقيط بالتعثر المالي في المصارف الإسلامية: دراسة تطبيقية لعينة من المصارف الإسلامية العربية. *مجلة الدراسات المالية والمحاسبة والإدارية بالجزائر، ٨*(١).

مركز إيداع الأوراق المالية. (د.ت.). *الموقع الإلكتروني الرسمي*: https://www.sdc.com.jo

المغربي، محمد الفاتح. (٢٠٢٢). *التحليل المالي* (ط. ١). الأكاديمية الحديثة للكتاب الجامعي.

Articles in Press

هيئة الأوراق المالية. (د.ت.) .*الموقع الإلكتروني الرسمي*: https://www.jsc.gov.jo

وهدان، محمد علي وعمران، رجب محمد وعلي، شيماء حمدي مصطفى. (٢٠٢٥). أثر استخدام المراجع الخارجي لأساليب التنقيب في البيانات على دقة التنبؤ بالتعثر المالي للشركات المقيدة بالبورصة المصرية: دراسة تطبيقية . *المجلة العلمية للبحوث التجارية، جامعة المنوفية*.

References

Abdelkader, N. A. M., & Wahba, H. H. (2024). A proposed multidimensional model for predicting financial distress: An empirical study on Egyptian listed firms. *Future Business Journal, 10*(1), 42.

Abdi, H., & Williams, L. J. (2010). Principal component analysis. *Wiley Interdisciplinary Reviews: Computational Statistics, 2*(4), 433–459.

Abdullah, M. (2021). The Implication of Machine Learning for Financial Solvency Prediction: An Empirical Analysis on Public Listed Companies of Bangladesh. *Journal of Asian Business and Economic Studies, 28*(4), 303-320.

Al Omari, R., Alkhawaldeh, R. S., & Jaber, J. J. (2023). Artificial neural network for classifying financial performance in Jordanian insurance sector. *Economies, 11*(4), 106.

Al-abbasi, R. G. H., & Mohammed, J. H. (2024). Using the Springate model to predict financial failure: An analytical study of a sample of private Iraqi commercial banks (2013–2022). *Tikrit Journal of Administrative and Economic Sciences, 20*(67).

Alaka, H. A., Oyedele, L. O., Owolabi, H. A., Bilal, M., Ajayi, A. O., & Akinade, O. O. (2018). Systematic review of bankruptcy prediction models: Towards a framework for tool selection. *Expert Systems with Applications, 94*, 164–184.

Alamsyah, A., Kristanti, N., & Kristanti, F. T. (2021, March). Early warning model for financial distress using artificial neural network. *IOP Conference Series: Materials Science and Engineering, 1098*(5), 052103. IOP Publishing.

Alkhatib, K., & Al Bzour, A. E. (2011). Predicting corporate bankruptcy of Jordanian listed companies: Using Altman and Kida models. *International Journal of Business and Management, 6*(3), 208–220.

Al-manaseer, S., & Al-Oshaibat, S. D. (2018). Validity of Altman Z-score model to predict financial failure: Evidence from Jordan. *International Journal of Economics and Finance, 10*(8).

Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance, 23*(4), 589–609.

Aydin, N., Sahin, N., Deveci, M., & Pamucar, D. (2022). Prediction of financial distress of companies with artificial neural networks and decision trees models. *Machine Learning with Applications, 10*.

Bratton, W. (2003). Enron, Sarbanes-Oxley, and accounting: Rules versus principles versus rents. *Villanova Law Review, 48*(4).

Collins, D. (2006). *Behaving badly: Ethical lessons from Enron*. Dog Ear Publishing.

Doğan, S., Koçak, D., & Atan, M. (2022). Financial distress prediction using support vector machines and logistic regression. In *Advances in econometrics, operational*

Articles in Press

research, data science and actuarial studies: Techniques and theories (pp. 429–452). Springer International Publishing.

Dube, F., Nzimande, N., & Muzindutsi, P. F. (2021). Application of artificial neural networks in predicting financial distress in the JSE financial services and manufacturing companies. *Journal of Sustainable Finance & Investment, 13*(1), 723–743.

El-Bannany, M., Sreedharan, M., & Khedr, A. M. (2020). A robust deep learning model for financial distress prediction. *International Journal of Advanced Computer Science and Applications*, *11*(2). 170-175.

Elhoseny, M., Metawa, N., & Sztano, G. (2022). Deep learning for financial distress prediction. *Annals of Operations Research, 312*(1).

Elsayed, N. H. Y., Aelasmer, S. Z., Ebrahime, R. S., Keedis, M. A., & Mansour, H. M. (2023). Using Kida Model in Predicting Financial Failure in Egyptian Firms. *Journal of Research in Finance and Accounting,8*(1), 696-711

Ertel, W. (2017). *Introduction to artificial intelligence*. Springer Nature.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems, 28*(10), 2222–2232.

Gregova, E., Valaskova, K., Adamko, P., Tumpach, M., & Jaros, J. (2020). Predicting financial distress of Slovak enterprises: Comparison of selected traditional and learning algorithms methods. *Sustainability, 12*(10), 3954.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation, 9*(8), 1735–1780.

Horak, J., Vrbka, J., & Suler, P. (2020). Support vector machine methods and artificial neural networks used for the development of bankruptcy prediction models and their comparison. *Journal of Risk and Financial Management, 13*(3), 60.

Judijanto, L., & Riandari, F. (2024). Fuzzy logic framework for financial distress prediction: Enhancing corporate decision-making under uncertainty. *International Journal of Basic and Applied Science, 13*(1), 1–13.

Khalil, A. A., Liu, Z., & Ali, A. A. (2022). Using an adaptive network-based fuzzy inference system model to predict the loss ratio of petroleum insurance in Egypt. *Risk Management and Insurance Review, 25*(1), 5–18.

Khawaja, M. J. (2023). Predicting financial failure using Altman's Z-score model: Evidence from commercial banks in Pakistan. *Annals of Social Sciences and Perspective, 4*(1), 91–102.

Kida, T. (1980). An investigation into auditors' continuity and related qualification judgments. *Journal of Accounting Research, 18*(2), 506–523.

Kou, G., Yang, P., Xiao, F., Chen, Y., & Alsaadi, F. E. (2021). Evaluation of feature selection methods for financial distress prediction in small and medium-sized enterprises. *Technological and Economic Development of Economy*, *27*(5), 1023–1047. https://doi.org/10.3846/tede.2021.14555.

Articles in Press

Ling, T., & Cai, Y. (2022). Financial crisis prediction based on long-term and short-term memory neural network. *Wireless Communications and Mobile Computing, 2022*(1), 5728470.

Lombardo, G., Pellegrino, M., Adosoglou, G., Cagnoni, S., Pardalos, P. M., & Poggi, A. (2022). Machine learning for bankruptcy prediction in the American stock market: Dataset and benchmarks. *Future Internet, 14*(8), 244.

Malakauskas, A., & Lakštutienė, A. (2021). Financial distress prediction for small and medium enterprises using machine learning techniques. *Engineering Economics, 32*(1), 4–14.

Manh, P. T., & Nguyen, H. V. (2024). Applying the Z-score model to predict corporate financial distress: An empirical research on the listed firms in Vietnam stock market. *Oblik i Finansi*, (1), 38–48.

Marso, H., & El Merouani, M. (2020). Predicting financial distress using hybrid feedforward neural network with cuckoo search algorithm. *Procedia Computer Science, 170*, 1134–1140.

Mishra, N., Ashok, S., & Tandon, D. (2021). Predicting financial distress in the Indian banking sector: A comparative study between the logistic regression, LDA and ANN models. *Global Business Review, 25*(6), 1540–1558.

Mulford, C. W., & Comiskey, E. E. (2002). *The financial number game*. John Wiley & Sons.

Nguyen, O. T., Nguyen, D. V., Anh, T. C. D., Nguyen, H. L., & Ta, A. T. (2024). Prediction of financial distress in Vietnam using multi-layer perceptron artificial neural network. In *11th International Conference on Emerging Challenges: Smart Business and Digital Economy 2023 (ICECH 2023)*. Atlantis Press.

Paule-Vianez, J., Gutiérrez-Fernández, M., & Coca-Pérez, J. L. (2020). Prediction of financial distress in the Spanish banking system: An application using artificial neural networks. *Applied Economic Analysis, 28*(82), 69–87.

Roba, M., & Moulay, O. K. (2024). Risk management in using artificial neural networks. *SocioEconomic Challenges, 8*(2), 302–313.

Shahwan, T., & Fadel, M. (2020). Machine learning models and financial distress prediction of small and medium sized firms: Evidence from Egypt. *Journal of Alexandria for Administrative Sciences*.

Smiti, S., & Soui, M. (2020). Bankruptcy prediction using deep learning approach based on borderline SMOTE. *Information Systems Frontiers, 22*(5), 1067–1083.

Vochozka, M., Vrbka, J., & Suler, P. (2020). Bankruptcy or success? The effective prediction of a company's financial development using LSTM. *Sustainability, 12*(18), 7529.

Wu, D., Ma, X., & Olson, D. L. (2022). Financial distress prediction using integrated Z-score and multilayer perceptron neural networks. *Decision Support Systems, 159*.

Zizi, Y., Jamali-Alaoui, A., El Goumi, B., Oudgou, M., & El Moudden, A. (2021). An optimal model of financial distress prediction: A comparative study between neural networks and logistic regression. *Risks, 9*(11), 200.

Articles in Press